

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İSTATİSTİK ANABİLİM DALI

**VAN GÖLÜ SU SEVİYESİ DEĞİŞİMİNİN YAPAY SİNİR AĞLARIYLA
TAHMİNİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Furkan SİDAL
DANIŞMAN: Doç. Dr. Yener ALTUN

VAN-2023

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İSTATİSTİK ANABİLİM DALI

**VAN GÖLÜ SU SEVİYESİ DEĞİŞİMİNİN YAPAY SİNİR AĞLARIYLA
TAHMİNİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: FURKAN SİDAL

VAN-2023

KABUL VE ONAY SAYFASI

İstatistik Anabilim Dalı'nda Doç. Dr. Yener ALTUN danışmanlığında, Furkan SİDAL tarafından sunulan “Van Gölü Su Seviyesi Değişiminin Yapay Sinir Ağlarıyla Tahmini” isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince/...../..... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan:.....

İmza:

.

Üye:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun/...../..... tarih ve sayılı kararı ile onaylanmıştır.

İmza

Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Furkan SİDAL



ÖZET

VAN GÖLÜ SU SEVİYESİ DEĞİŞİMİNİN YAPAY SİNİR AĞIYLA TAHMİNİ

SİDAL, Furkan
Yüksek Lisans Tezi, İstatistik Anabilim Dalı
Tez Danışmanı: Doç. Dr. Yener ALTUN
Ocak 2023, 69 sayfa

Van Gölü su seviyesinde geçmişten bu yana süregelen düşüşler ve artışlar gözlenmektedir. Göl su seviyesindeki bu değişim sebeplerinin bulunabilmesi için birçok çalışma yapılmıştır. Yapılan bu çalışmalarda fiziksel nedenlerinin tespitinin yanı sıra istatistiksel yaklaşımlarla da göl seviyesi incelenmektedir.

Bu tez istatistiksel bir çalışma olup, meteorolojik etmenlerin göl su seviyesi üzerine etkileri tespit edilerek bir tahmin modeli kurulmaya çalışılmıştır. Bu modelde teknolojinin hızla gelişmesine paralel insan beynini oluşturan sinir sistemini taklit eden yapay sinir ağları kullanılarak meteorolojik parametreler (yağış, sıcaklık, buharlaşma, rüzgâr hız, nispi nem ve aktüel basınç) ile Van Gölü su seviyesi tahmin edilmiştir. Çalışmanın bir diğer uzantısı da bağımsız değişkenler olarak yağış, sıcaklık, buharlaşma, rüzgâr hız, nispi nem ve aktüel basınç, bağımlı değişken olarak ise Van Gölü su seviyesindeki değişimlerin kullanıldığı çoklu doğrusal regresyon analizi ile model denklemi oluşturulmuş olup iki model karşılaştırılmıştır.

Bu çalışmada, her iki modelin karşılaştırılması ile elde edilen sonuçlara göre Van Gölü su seviyesi tahmini için, yapay sinir ağları ile tahminin çoklu regresyon analizi yöntemine kıyasla daha gerçekçi sonuçlar ortaya koyabileceği ve YSA tahmin çalışmalarının göl su seviyesinde yalnız zamansal değil alansal da yapılabileceği gözlemlenmiştir.

Anahtar kelimeler: Çoklu doğrusal regresyon analizi, Göl su seviyesi tahmini, Modelleme, Van gölü su seviyesi tahmini, Yapay sinir ağları.



ABSTRACT

PREDICTION OF LAKE VAN WATER LEVEL CHANGE WITH ARTIFICIAL NEURAL NETWORK

SİDAL, Furkan

M.Sc. Thesis, Department of Statistics

Supervisor: Assoc. Prof. Dr. Yener ALTUN

January 2023, 69 pages

Continuous decreases and increases have been observed in the water level of Lake Van since the past. Many studies have been carried out to find the reasons for this change in the lake water level. In these studies, the lake level is examined with statistical approaches as well as the determination of its physical causes.

This thesis is a statistical study and a prediction model has been tried to be established by determining the effects of meteorological factors on the lake water level. In this model, meteorological parameters (precipitation, temperature, evaporation, wind speed, relative humidity and current pressure) and the water level of Lake Van were estimated by using artificial neural networks that imitate the nervous system that forms the human brain in parallel with the rapid development of technology. Another extension of the study is that the model equation was created with multiple linear regression analysis using precipitation, temperature, evaporation, wind speed, relative humidity and actual pressure as independent variables, and changes in the water level of Lake Van as dependent variables, and the two models were compared.

According to the results obtained by comparing both models expressed in this study, it has been observed that the estimation with artificial neural networks can produce more realistic results compared to the multiple regression analysis method for the estimation of the water level of Van Lake, and that ANN estimation studies can be done not only temporally but also spatially at the lake water level.

Keywords: Artificial neural networks, Lake water level forecast, Modeling, Forecast of Lake Van water level, Multiple linear regression analysis.



ÖN SÖZ

Çalışma sürecinde her türlü yol gösterici olan, olumlu tavrıyla beni cesaretlendiren, bilgi birikimiyle çalışmama farklı açıdan bakmamı sağlayan beraber çalışmaktan ve her zaman öğrencisi olmaktan gurur duyduğum değerli danışman hocam Doç. Dr. Yener ALTUN' a sonsuz teşekkür ederim.

Ayrıca bu çalışmayı yaparken çalışmamda bana destek olan tüm bilgi ve birikimlerini benimle paylaşan bütün arkadaşlarıma teşekkür ederim.

Son olarak tüm hayatım boyunca benim yanımda olan, aldığım kararları her zaman destekleyen sadece bu çalışma sürecinde değil tüm hayatım boyunca beni cesaretlendiren ve moral veren aileme sonsuz şükranlarımı sunar ve teşekkür ederim.

2022

Furkan SİDAL



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	iii
ÖN SÖZ.....	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ	xi
ŞEKİLLER LİSTESİ.....	xiii
SİMGELER VE KISALTMALAR	xv
1. GİRİŞ.....	1
1.1. Yapay Sinir Ağları (YSA)	2
1.1.1. YSA'nın tanımı.....	2
1.1.2. YSA'nın tarihçesi	3
1.1.3. YSA'nın kullanım alanları.....	5
1.1.4. YSA'nın güçlü ve zayıf yönleri	5
1.1.5. YSA elemanları	8
1.1.5.1. Girdiler	8
1.1.5.2. Ağırlıklar	9
1.1.5.3. Toplanmış ağırlıklar (birleştirme) fonksiyonu	9
1.1.5.4. Aktivasyon fonksiyonu ve çeşitleri	10
1.1.5.5. Çıktılar.....	12
1.1.6. YSA'larda öğrenme	12
1.1.6.1. YSA'larda öğrenme stratejileri.....	12
1.1.6.2. YSA'larda öğrenme kuralları	13
1.1.7. YSA'ların sınıflandırılması	14
1.1.7.1. İleri beslemeli (feed – forward) ağlar	14
1.1.7.2. Geri beslemeli (feed back into) ağlar.....	15
1.1.8. YSA mimarileri	16
1.1.8.1. Tek katmanlı YSA'lar.....	17
1.1.8.2. Çok katmanlı YSA'lar	17
1.1.8.3. Geri beslemeli YSA'lar	18

1.1.8.4. Kafes yapılı YSA'lar	19
1.1.9. YSA çalışma adımları.....	19
1.1.9.1. Verilerin ağa sunulması ve ağ yapısının belirlenmesi	19
1.1.9.2. Gizli Nöron Sayısının Belirlenmesi.....	20
1.1.9.3. Birleştirme aktivasyon fonksiyonlarının seçilmesi.....	21
1.1.9.4. Durdurma kriterlerinin belirlenmesi	21
1.1.9.5. Modeller için performans (hata) ölçüleri	21
1.1.9.6. Hata azaltma yöntemleri	22
1.2. Regresyon Analizi (RA)	23
1.2.1. Regresyon Analizi tanımı	23
1.2.2. Regresyon analizi türleri.....	23
1.2.2.1. Doğrusal regresyon analizi.....	24
1.2.2.2. Basit doğrusal regresyon analizi	24
1.2.2.2.1. Basit doğrusal regresyonda parametrelerin tahmini....	25
1.2.2.2.2. Basit doğrusal regresyonda belirlilik katsayısı	26
1.2.2.3. Çoklu doğrusal regresyon analizi	27
1.2.2.3.1. Çoklu doğrusal regresyonda parametrelerin tahmini ..	28
1.2.2.3.2. Çoklu doğrusal regresyonda belirlilik kat sayısı.....	30
2. KAYNAK BİLDİRİŞLERİ	31
3. MATERYAL VE YÖNTEM.....	37
3.1. Materyal.....	37
3.1.1. Çalışma alanı	37
3.1.2. Veri seti.....	38
3.1.3. Uygulamada kullanılan yazılım	39
3.1.3.1. Matlab (matrix laboratuvarı)	39
3.2. Yöntem	41
3.2.1. Verilerin hazırlanması	41
3.2.2. YSA yöntemi ile model oluşturulması	42
3.2.2.1. Verilerin matlab ortamına aktarılması	43
3.2.2.2. Ağın oluşturulması ve parametrelerin belirlenmesi.....	43

	Sayfa
3.2.2.3. Ađın eđitilmesi.....	46
3.2.2.4. YSA performansının deđerlendirilmesi	46
3.2.3. ÇRA yöntemi ile model oluşturulması	47
4. BULGULAR	51
4.1. YSA Modeli.....	51
4.1.1. YSA yapısının özellikleri	51
4.1.2. YSA eđitim sonuçları	54
4.1.3. YSA tahmin sonuçları.....	56
4.2. ÇRA Modeli	58
4.3. YSA ve ÇRA Modellerinin Karşılaştırılması.....	61
5. SONUÇ.....	63
KAYNAKLAR.....	65
ÖZ GEÇMİŞ.....	69

ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Biyolojik ve yapay nöron karşılaştırması.....	3
Çizelge 1.2. Bazı toplama fonksiyonları	10
Çizelge 3.1. Çalışmada kullanılan parametreler.....	38
Çizelge 3.2. Matlab Ortamı Veri dağılımı.....	43
Çizelge 3.3. Excel Ortamı Veri dağılımı	47
Çizelge 4.1. İlerleme verileri	55
Çizelge 4.2. Test verileri.....	57
Çizelge 4.3. Gerçek ve tahmin edilen su seviyesi değerleri	57
Çizelge 4.4. Regresyon analizine ait analiz sonuçları	58
Çizelge 4.5. Regresyon analizi Anova testi sonuçları	59
Çizelge 4.6. Regresyon analizi ağırlık katsayıları	59
Çizelge 4.7. Regresyon analizi tahmin sonuçları	60
Çizelge 4.8. YSA ve ÇRA performans sonuçları	62
Çizelge 4.9. YSA ve ÇRA karşılaştırma	62



ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 1.1. Biyolojik nöronun matematiksel gösterimi.	8
Şekil 1.2. İleri beslemeli YSA yapısı.	15
Şekil 1.3. Geri beslemeli YSA ağ yapısı.	16
Şekil 1.4. Tek Katmanlı YSA.	17
Şekil 1.5. Çok Katmanlı YSA.	18
Şekil 1.6. Geri Beslemeli YSA.	19
Şekil 3.1. Van Gölü haritası.	37
Şekil 3.2. Matlab arayüzü.	40
Şekil 3.3. nftool arayüzü.	41
Şekil 3.4. Değişkenlerinin Matlab'a Tanıtılması.	43
Şekil 3.5. Değişkenlerin Sınıflandırılması.	44
Şekil 3.6. Ağa ait parametrelerin belirlenmesi.	45
Şekil 3.7. Excel eklentisi.	48
Şekil 3.8. Regresyon analizi.	49
Şekil 4.1. Bölünen eğitim verileri.	51
Şekil 4.2. YSA yapısının özellikleri.	52
Şekil 4.3. YSA'nın yapısı.	53
Şekil 4.4. Eğitim parametreleri.	54
Şekil 4.5. YSA eğitim sonrası performans grafiği.	55
Şekil 4.6. YSA eğitim regresyon sonuçları.	56
Şekil 4.7. Gerçek ve tahmin edilen su seviyelerinin karşılaştırılması.	58
Şekil 4.8. Gerçek ve tahmin edilen su seviyelerinin karşılaştırılması.	61



SİMGELER VE KISALTMALAR

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

Simgeler

Açıklama

AB	Aktüel Basınç
B	Buharlaştırma
D	Yağış
NN	Nispi Nem
RH	Rüzgar Hızı
T	Sıcaklık
R^2	Belirlilik Katsayısı
x_i	Girdi (Bağımsız) Değişken
y_i	Çıkış (Bağımlı) Değişken
s	Net Girdi Değeri
F	Aktivasyon Fonksiyonu
$P_{(parametre)}$	Parametreler
$P_{(ort.parametre)}$	Parametrelerin Ortalaması

Kısaltmalar

Açıklama

BİST	Borsa İstanbul
ÇRA	Çoklu Regresyon Analizi
DSİ	Devlet Su İşleri
EKK	En Küçük Kareler Yöntemi
MATLAB	Matrix Laboratory
MAPE	Ortalama Mutlak Yüzde Hatası
RA	Regresyon Analizi
MAPE	Ortalama Mutlak Yüzde Hatası



1. GİRİŞ

Van Gölü su seviyesinde geçmişten bu yana devam eden düşüşler ve artışlar gözlenmektedir. Van Gölü su seviyesindeki bu düşüş ve artışların sebeplerinin bulunabilmesi için birçok çalışma yapılmıştır. Yapılan bu çalışmalarda fiziksel nedenlerinin tespitinin yanı sıra istatistiksel yaklaşımlarla da göl seviyesi incelenmektedir.

Yapay sinir ağlarının (YSA) günümüzde birbirinden farklı birçok alanda yaygın ve etkin kullanımına rastlamak mümkündür. Su seviyesi tahmini de bu alanlardan bir tanesidir. Literatürde özellikle yer altı su seviyesi tahminlerinde birçok model kurularak yapılmış çalışmalar bulunmaktadır.

İnsanlar gibi bilgiyi analiz etmek ve işlemek için tasarlanan YSA'lar, birden fazla nöronu (hücreyi) belirli bir kural ile birleştirmek ve bir görevi gerçekleştirmek için istatistiksel, matematiksel, yapısal ve felsefi problemlere çözüm üreten sistemlerdir. YSA, yakın zamanda ortaya çıkmış ve birçok gerçek dünya problemini çözmek için farklı disiplinlerce çokça kabul görmüştür (Keskenler ve Keskenler, 2017).

Bu çalışmada meteorolojik etmenlerin Van Gölü su seviyesi üzerine etkileri tespit edilerek bir tahmin modeli kurulmaya çalışılmıştır. Bu modelde teknolojinin hızla gelişmesi ile insan beynine ait biyolojik sinir ağını taklit eden YSA'lar kullanılarak yağış (D), sıcaklık (T), buharlaşma (B), rüzgar hızı (RH), nispi nem (NN) ve aktüel basınç (AB) gibi meteorolojik parametreler ile Van Gölü su seviyesinin tahmin edilmesi amaçlanmıştır.

DSİ 17. Bölge Müdürlüğü'nden 2004-2022 yılları arasında aylık ortalama Van Gölü su seviyesi verileri ve Meteoroloji Genel Müdürlüğü'nden Van bölgesinde yer alan çeşitli istasyonlardan 2004-2022 yılları arasında alınan aylık ortalama meteorolojik parametre verileri (yağış, sıcaklık, buharlaşma, rüzgar hızı, nispi nem ve aktüel basınç) kullanılarak bir model oluşturup bu meteorolojik verilerin göl seviye (GS) değişimine etkisi YSA ile tahmin edilmiştir. Modelin eğitimi tamamlandıktan sonra 2022 yılına ait veriler kullanılarak test edilmiştir. Çıkan sonuçlar çoklu doğrusal regresyon analizi (ÇRA) yöntemi ile istatistiksel olarak karşılaştırılmıştır.

Çalışmanın genel bilgiler bölümünde YSA'nın gelişimi, geleneksel sistemlerden farkları, nöronların çalışma şekilleri, bileşenleri ve ağı eğitimi incelenmiş, üstünlükleri, uygulama alanları ve YSA'ların sınıflandırılma biçimleri anlatılmış, ağ topolojilerinden kullanım türlerine göre bahsedilmiştir. Ek olarak bu bölüm içerisinde regresyon analizinin (RA) önemi ve ÇRA hakkında bilgiler verilmiştir.

Çalışmanın ikinci bölümünde literatür taraması yapılarak konuya uygun çalışmaların sonuçları verilmiştir.

Üçüncü bölümde materyal ve yöntemler hakkında bilgiler verilmiştir. Bu bölümde çalışma alanı, veri setleri ve kullanılan yazılımlar tanıtılarak uygulanan yöntemler açıklanmış ve çalışmada kullanılan modelleme teknikleri incelenmiştir.

Dördüncü bölümde meteorolojik etmenlerin Van Gölü su seviyesi üzerine etkileri için elde edilen veri setleri ile YSA ve ÇRA modelleri kurularak bu modeller sonucunda hesaplanan tahmin performansları karşılaştırılmıştır.

Son olarak beşinci bölümde kurulan iki modelin analiz sonuçları yorumlanarak karşılaştırılmış ve önerilerde bulunulmuştur.

1.1. Yapay Sinir Ağları (YSA)

1.1.1. YSA'nın tanımı

YSA'lar insan beyninin öğrenme yolunu taklit ederek bilgisayarların olayları öğrenmelerini sağlayan ve bu öğrendiği bilgiler ile yeni veriler üreten sistemlerdir. İnsan beynin çalışma şeklini taklit ederek, biyolojik ve düşünce özelliklerinin matematiksel modellemesine dayanır. YSA'lar canlı organizmaların biyolojik sinir yapısını taklit ederek oluşturulmuş bir modeldir (Nabiyev, 2021).

İnsan beyninin hesaplamaları dijital makinalardan çok farklı bir şekilde gerçekleştirdiğinin kabul edilmesiyle YSA üzerindeki çalışmalar kuruluşundan bu yana motive olmuştur (Haykin, 2005).

YSA, insan beynine özgün olan öğrenme tekniğinden esinlenerek geliştirilmiş bir teknolojidir. YSA insanlara ait biyolojik sinir sistemini yapısının çalışma şeklini taklit

eder. Yani bu sisteme ait biyolojik sinir hücrelerinin aralarında birbirleri ile kurduğu sinaptik (synaptic) bağın dijital olarak modellenmesidir (Elmas, 2012).

İnsanlarda öğrenme işlemi, nöronlar arasındaki sinaptik bağlantılar yardımıyla gerçekleşmektedir. Nöronlar, giriş sinyallerini çok sayıdaki dendritler aracılığıyla alırlar. Dendritler tarafından algılanan bir girdi eylemi tetikleyici veya engelleyici olabilir. Nöron gövdesine girişler toplanarak yerleştirilir. Bu girdi belirli bir eşiği aştığında, hücre aksonu aracılığıyla diğer hücrelere bir etki iletir. Bu basit açıklama yapay nöronlar için model oluşturur (Ersoy ve Karal, 2012).

Çizelge 1.1. Biyolojik ve yapay nöron karşılaştırması

Biyolojik Nöron Yapısı	Yapay Nöron Yapısı
Nöron (Neuron)	Girdi Değeri
Dendrit (Dendrite)	Toplama Fonksiyonu
Hücre Gövdesi (Cell Body)	Aktivasyon Fonksiyonu
Akson (Akson)	Çıkış Değeri
Sinaps (Synapse)	Ağırlıklar

1.1.2. YSA'nın tarihçesi

YSA'nın tarihi, insanların sinirbilimine olan ilgisi ve bilgileri bilgisayar bilimine uygulaması ile başlamıştır (Öztemel, 2016).

İnsan beyni, çalışma prensibi ve özellikleri üzerine uzun yıllardır araştırmalar yapılmaktadır. Bu araştırmaların ilk bilimsel adımı 19. yüzyılın sonlarında psikolog William James tarafından atıldı. İlk YSA modeli 1943 yılında sinir hekimi Warren McCulloch ve matematikçi Walter Pitts tarafından geliştirilmiştir (Keskenler ve Keskenler, 2017). McCulloch ve Pitts nöronun matematiksel modelini oluşturan MP adında bir model ortaya çıkarmışlardır. Ardından nöronlar kullanılarak mantıksal modellerin formülize edildiği görülmüştür. Yeni öğrenme stratejileri geliştirilerek birden fazla nöron kullanılmaya başlanmıştır (Dase ve Pawar, 2010). Donald Hebb, 1949'da yazdığı "Organization of Behavior" adlı kitabında "Hebbian öğrenme"nin temel teorisini tartışmıştır. Hebb çalışmasında hücreler ile oluşan YSA'nın öğrenme ile ilişkili olduğunu ortaya koymuştur. 1954 yılında Rosenblatt, algısal ayrımcılık ve genelleştirmeye dayalı temel fiziksel parametreler tarafından belirli bir organizasyon formu için öğrenmenin

öngörülebilir olduğunu söyledi. Bu, daha sonraki çalışmalar için büyük önem taşıyan algılayıcı modeli ortaya koymuştur (Rosenblatt, 1958).

1960 yılında Widrow ve Huff, bu basit nöron modelini geliştirerek öğrenebilen ve delta kuralı olarak bilinen ağırlıkların değiştirildiği öğrenme kuralını tanıtan ilk Adaline (Adaptif Doğrusal nöron) modeli üzerinde çalışmış ve gerçek çıktı ile istenen çıktı arasındaki farka eşit bir hata terimi kullanmıştır (Widrow ve Huff, 1960).

Bu zamana kadar geliştirilmiş olan YSA modelleri doğrusal olmayan sorunları çözme yeteneğine sahip değildi. Minsky ve Papert YSA'nın XOR probleminin çözümündeki başarısızlığı ile doğrusal olmayan problemleri çözme yeteneğine sahip olmadığını yazdıkları algılayıcılar (perceptron) kitabında iddia etmişlerdir. Ortaya atılan bu iddia sonucunda birçok kişi hayal kırıklığına uğramış ve YSA çalışmalarına ara verilmiştir (Öztemel, 2016).

YSA'ların çalışmaları 1980'li yıllarda yeniden ivme kazanmaya başlamıştır. 1982 yılında Kohonen tarafından “Self-learning Nitelik Haritaları” adlı çalışma yayınlandı. 1982’de Hopfield tarafından beyinleri modellemenin aksine, kullanışlı araçlar yaratmak amacıyla bir çalışma yayımlandı. Bu ağların nasıl çalışabileceğini ve neler yapabileceğini matematiksel analizler yardımıyla göstermiştir. Hopfield, gezgin satıcı problemini çözmesi ile YSA'ların geliştirilebileceğini ve klasik bilgisayar yazılımları tarafından çözülmesi zor olan sorunlara çözüm üretilebileceğini göstermiştir.

Rumelhart'ın paralel programlama çalışmalarını içeren ve 2 cilt halinde yayınlanan çalışması (McClelland & Rumelhart, 1986; Rumelhart & McClelland, 1986,1988), YSA'lar için devrim niteliğinde bir buluş olan çok katmanlı algılayıcıların ortaya çıkmasında önemli bir adım olmuştur. Bu adım ile ileri beslemeli (feed-forward) ağlarda bir öğrenme modeli olan hatanın geriye yayılım algoritmasının ilk adımları atılmıştır (Keskenler ve Keskenler, 2017). Çok katmanlı algılayıcılar (ÇKA) tarafından XOR problemi dahil birçok problemin çözülmesi YSA üzerindeki olumsuz baskıları ortadan kaldırmış ve tekrar çalışmaların hız kazanmasını sağlamıştır.

Devam eden yıllarda ÇKA'lara alternatif modeller ortaya çıkmaya başlamıştır. Günümüzde devam eden çalışmalar ile YSA'lar teorik bir yapı olmaktan ziyade günlük hayatta birçok alanda kullanılan problemlerin çözümünde önemli bir kavram olmuştur.

1.1.3. YSA'nın kullanım alanları

YSA'lar genellikle günümüzde makine öğrenimi algoritmalarının uygulandığı tahmin etme, verileri sınıflandırma, veriler arasında ilişki kurma, verileri yorumlama ve filtreleme işlemlerinde kullanılmaktadır (Ağyar, 2015).

YSA'nın genel olarak uygulandığı alanlar altı grup içerisinde aşağıdaki gibi özetlenebilir.

Arıza Analizi ve Tespiti: Sistemlerin, cihazların veya elemanların düzenli çalışmasını öğrenen bir YSA ile bu sistemlerdeki olası arızalar tespit edilebilir. YSA; arıza analizinde kullanılan uçak veya bileşenleri, entegre devreler, elektrikli makineler vb. arızalarında kullanılmaktadır (Nabiyev, 2021).

Tıp Alanında: YSA hastalık tahmini, hastalık sürecinin izlenmesi, hastalıklı hücreleri tespit ederek erken teşhis, tanı ve tedavi alanlarında kullanılmaktadır. (Demirhan ve ark., 2010).

Savunma Sanayi: Silah otomasyonu ve hedef takibi, nesne veya görüntü algılama ve ayırma, yeni sensör tasarımı ve gürültü azaltma gibi alanlarda kullanılmaktadır.

Haberleşme: Görüntülerin ve verilerin sıkıştırılması, otomatik bilgi dağıtım hizmeti, gerçek zamanlı ses çevirisi uygulamalarında kullanılmaktadır.

Üretim: Üretimde kullanılan sistemlerin optimizasyonu, ürünlerin analizi, tasarımı, kalite analizi, kontrolü, planlaması vb. alanlarda kullanılmaktadır.

Otomasyon ve Kontrol: Yaygın olarak uçak oto pilot sisteminin otomasyonu, ulaşım araçlarının otomatik yol bulma/talimatları, robot sistem kontrolü, doğrusal olmayan sistemlerin modellenmesi ve kontrolü gibi alanlarda uygulanmıştır.

1.1.4. YSA'nın güçlü ve zayıf yönleri

YSA ile oluşturulan modeller biyolojik sinir ağından esinlenerek oluşturulmaktadırlar. Bundan dolayı YSA tarafından oluşturulan bir modelin biyolojik sinir ağlarının özelliklerine sahip olduğu söylenebilir. Bu özellikler aşağıdaki gibidir (Baş, 2006).

Doğrusal Olmama: YSA'nın sahip olduğu hücreler doğrusal değildir. Dolayısıyla bu doğrusal olmayan yapıların bir araya gelmesi sonucu oluşan YSA'lar da doğrusal değildir ve bu özellik tüm ağ yapısına yayılmıştır. Bu özelliği ile YSA'lar doğrusal olmayan ve çözülmesi zor olan karmaşık problemlerin çözümünde kullanılan en önemli araç haline gelmiştir.

Öğrenme: YSA, bilgisayar öğrenimine odaklanır, kendilerine gösterilen yeni durumlara uyum sağlar ve bu uyum ile sürekli olarak yeni etkinlikler öğrenebilir. Öğrenilen olaylar arası benzerliklerden yararlanır. Geçmiş deneyimlerden bilgi edinebilir ve eğitimlerinden hemen sonra yeni bir veri setine yanıt verebilirler. Bir örneğin sonucuna göre diğer örnekler hakkında açıklamalar yapabilir. Sahip olduğu bu özelliği ile geleneksel yöntemler tarafından çözülmesi karmaşık olan problemlere çözüm üretebilmektedirler.

Genelleme: YSA'lar iyi örüntü tanımlayıcıları ve güçlü sınıflandırıcılardır. Çünkü tanımlanmamış, hatalı (gürültülü) veya kendi kendine öğrenme nedeniyle kayıp veriler üzerinde genelleme yapabilirler (Yüksek, 2006).

Uygulanabilirlik: İlgilendiği problemin çözülmesi amacıyla eğitilen bir YSA, problemin dinamikliğine uygun olarak tekrar eğitilebilmekte, değişimler sürekli devam ediyorsa anlık olarak da eğitime devam ederek problemdeki değişikliklere göre ağırlıklarını ayarlayabilmektedirler. YSA'lar bu özelliği sayesinde uyarlamalı örnek tanıma, sinyal işleme, sistem teşhisi ve kontrolü gibi alanlarda etkin bir şekilde kullanılabilmektedir (Saraç, 2004).

Eksik Bilgi ile Çalışabilme: YSA'lar eksik veri olmasına rağmen bu bilgiler ile çalışabilir ve buna rağmen yeni örneklerde sonuç üretebilirler. Veriler arasında eksik bilgilerin olması YSA'nın çalışma performansını olumsuz etkileyeceği anlamına gelmez. Bunun en bariz nedeni kurulan modeldeki eksik bilginin öneminden kaynaklanmaktadır ve ağ eğitildikçe eksik veriyi kendisi öğrenir (Öztemel, 2016).

Hata Toleransı: Geleneksel bilgisayar sistemleri sistem hatalarına karşı son derece hassastır. Sistemdeki en ufak bir hata, sonuca ulaşmada başarısızlığa neden olabilir. Ancak YSA'nın bir veya birden fazla nöronunun hasar görmesi sistemi geleneksel teknolojilerdeki kadar etkilemez ve ağ sorunsuz bir şekilde çalışmaya devam eder. Çünkü hasar gören hücrenin ağırlık değeri ağırlık performansından düşer. YSA'lar

çeşitli şekillerde çok sayıda hücrenin biri birine bağlanması ile oluşturulur. Bu nedenle YSA'ların yapısı paralel olarak dağıtılır ve ağın bilgisi tüm hücrelere dağıtılır (Yüksek, 2006).

Sınırsız Sayıda Değişken ve Parametre Kullanma: YSA'lar geleneksel istatistiksel analizlerin aksine sınırsız sayıda değişken ve parametreler ile çalışabilmektedir. Bundan dolayı yüksek bir tahmin doğruluğu ile çözümler üretebilmektedir (Yurtoğlu, 2005).

YSA'nın sahip olduğu güçlü yönlerinin yanı sıra zayıf yönleri de bulunmaktadır. Bu zayıf yönler aşağıda verilmektedir.

Ağ Yapısının Belirlenmesi: YSA'nın kurulum süreci, oldukça zor bir süreçtir. Kurulacak ağın yapısı, metodolojisi ve parametrelerinin belirlenmesi genellikle denemeler yapılarak belirlenmektedir. Parametreler deneme yanılma yolu ile sürekli değiştirilerek birçok sonuç elde edilir ve en uygun parametre modeli seçilir. Bundan dolayı bu işlemler oldukça zor, zaman alan ve zahmetlidir. Çünkü ortaya çıkan modelin performansı ve çözümünün optimum olup olmadığını kestirmek zordur. Model doğru olsa bile YSA'lar en iyi olan çözümün garantisini vermez, yalnızca bu çözümler kabul edilebilir düzeyde olur.


Ağ Yapısının Davranışlarının Açıklanması: Bir çözümün neden ve nasıl üretildiği hakkında bilgi bulunması mümkün değildir. Yani ÇRA modellerinde olduğu gibi, bağımsız değişkenler ile bağımlı değişken arasındaki bağlantıyı veren bir denklem elde edilmez. Bağlantılar arası ağırlıklar değişkenlik gösterdiğinden giriş parametrelerinin etkisinin düzeyi hakkında bilgi sahibi olmak mümkün değildir.

Örnek Sayısının Fazla Olmasına İhtiyaç Duyması: YSA'ların eğitilebilmesi ve test edilebilmesi için yeteri kadar veriye ihtiyaç duyulmaktadır. Bunun için kesin bir kriter olmamasına rağmen az sayıda değişkenin ve verinin kullanılması ile iyi sonuçlar elde edilemeyebilir.

Sadece Nümerik Bilgilerle Çalışabilme: Ağ tarafından kullanılan bilgilerin tümü nümerik olmak zorundadır. Tüm değerler nümerik olarak ifade edilerek ağa gösterilmelidir (Öztemel, 2016).

1.1.5. YSA elemanları

YSA'ların temel elemanları, biyolojik nöronların çalışma şeklinden esinlenen yapay nöronlardan oluşmaktadır. Bu nöronların aralarında oluşturdukları bağ, katmanlar halinde gruplandırılarak YSA'ları oluşturmaktadır. Şekil 1.1'de bir beyine ait hücre yapısının matematiksel olarak nasıl modellendiğinin grafik gösterimi yer almaktadır (Haykin, 2005).



Şekil 1.1. Biyolojik nöronun matematiksel gösterimi.

1.1.5.1. Girdiler

Dış dünyadan gelen bilgiler (x_i) toplanarak girdi katmanına gelir. Yani ağırlık öğrenmesini istenen bilgiler girdi katmanında toplanır. Örneğin Van Gölü su seviyesine etki eden D , T , B , RH , NN ve AB gibi bilgiler bu katmanda girdi olarak toplanır ve bu girdileri sayısı kadar nöron bulunur.

1.1.5.2. Ağırlıklar

Ağırlık değerleri (w_i) hücreye gelen girdilerin önemini ve etkisini gösterir. Bu etki pozitif veya negatif olabilir (Caner ve Akarslan, 2009).

Bu katmanda her bir girdi değeri kendine ait ağırlıkları ile yani net girdi değeri olarak hücreye bağlanır. Transfer fonksiyonuna gönderilmek için hazırlanan bu net girdi değerleri farklı metotlar ile hesaplanır.

Ağa sunulan girdilerin ağırlıkları sabit değildir. YSA kendine yeni örnekler gösterildikçe kendisi için en uygun sonucu verene kadar ağırlık değerlerini değiştirir ve en uygun ağırlık değerini sağlar. Eğitimin başında ağırlıklar rastgele verilir. Eğer işlem sonunda çıkış değeri kabul edilebilir hata düzeyine ulaşmışsa ağırlık eğitimi tamamlanmıştır. Aksi taktirde işlemler tekrar başa döndürülür ve ağırlıklar yeniden ayarlanır. Gerçek değerler ile modelin sonucunda tahminin edilen çıktı değerleri arasındaki hatanın minimuma indirgenmesi çok önemlidir (Sönmez Çakır, 2020).

1.1.5.3. Toplanmış ağırlıklar (birleştirme) fonksiyonu

Birleştirme (Toplama) Fonksiyonu yardımıyla girdiler ile ağırlıkların çarpılması sonucu ağa gelen gizli katmanlarda yer alan hücrelere ait Net Girdi (s) değeri bulunur. Bu değerlerin hesaplanmasında birkaç yöntem kullanılabilir.

$$s = \sum_{i=1}^n x_i * w_i \quad (1.1)$$

Eş. 1.1’de x_i girdilere ait değerleri, w_i ise bu girdilerin ağırlıklarını göstermektedir. İlk girdiden son girdiye kadar her biri kendilerine verilmiş rastgele ağırlık değerleri ile çarpılır ve bu sonuçlar toplanarak s değerinin sonucu bulunmaktadır.

Verilerin kullanım amaçları ve türleri için farklı birleştirme fonksiyonları da kullanılabilir. Kullanılacak en uygun birleştirme fonksiyonu deneme yanılma yolu ile bulunur. Bazı toplama fonksiyonları Çizelge 1.2’de gösterilmiştir.

Çizelge 1.2. Bazı toplama fonksiyonları

Eşitlik	Açıklama
$s = \sum_{i=1}^n x_i * w_i$	Toplam
$s = \prod_{i=0}^n x_i * w_i$	Çarpım
$s = \text{Max}(x_i * w_i)$	Maksimum
$s = \text{Min}(x_i * w_i)$	Minimum
$s = \sum_{i=1}^n \text{Sgn}(x_i * w_i)$	Çoğunluk
$s = s(\text{eski}) + \sum_{i=1}^n x_i * w_i$	Kümülatif Toplam

1.1.5.4. Aktivasyon fonksiyonu ve çeşitleri

Birleştirme fonksiyonun hesaplanmasından sonra ortaya çıkan s değerden sonra aktivasyon fonksiyonuna geçilir. Birleştirme fonksiyonun sonuçları aktivasyon fonksiyonu vasıtası ile çıktıya dönüştürülür. Aktivasyon fonksiyonu hücreye giren net girdi değerini hesaplayarak hücrenin bu girdi değerine karşılık ürettiği çıktı değerini belirler. Eğer aktivasyon fonksiyonsuz bir yapay sinir ağı düşünülürse bu ağ, basit bir doğrusal regresyona benzeyecektir. Problem türüne ve ağ yapısına bağlı olarak değişik aktivasyon fonksiyonları kullanılabilir.

Sigmoid (Logsig) Fonksiyonu: Bu fonksiyonda doğrusal ve doğrusal olmayan fonksiyonlar için dengelenmiş çıktılar ile modelleme geliştirebilir (Öztemel, 2016). Literatürde en çok kullanılan aktivasyon fonksiyonlarından biridir (Demuth ve Beale, 2004). Ağırlıklı ortalama değerini 0-1 arasında bir değere dönüştürür.

$$F = \frac{1}{1 + e^{-s}} \quad (1.2)$$

Eş. 1.2’de sigmoid fonksiyonu için ağın değeri hesaplanır (Sönmez Çakır, 2020). Örneğin Eş. 1.3’te 0.4344 Net değerinin Sigmoid aktivasyon fonksiyonu ile işlediğimizde ağın vereceği değer hesaplanmıştır.

$$F = \frac{1}{1+e^{-s}} = \frac{1}{1+e^{-0,4344}} = 0,6069 \quad (1.3)$$

Hiperbolik Tanjant (Tansig) Fonksiyonu: Sigmoid'e benzer şekilde doğrusal ve doğrusal olmayan fonksiyonlar için hesaplamalar yapılabilir. Hiperbolik Tanjant fonksiyonu da Sigmoid fonksiyonu gibi girdi değerlerini gerçek sayılardan oluşturur, ancak çıktı değerlerini Sigmoid'den farklı bir şekilde -1 ile 1 arasında üretir. Bu sayede sıfır merkezli bir fonksiyon olarak kullanılabilir. Sigmoid'e alternatif olarak tercih edilebilen bir fonksiyondur (Eriş, 2018).

Lineer Aktivasyon Fonksiyonu: Doğrusal problemleri Eş.1.4'teki gibi çözmek için aktivasyon fonksiyonu olarak seçilebilir. Birleştirme fonksiyonundan sonra hesaplanan s girdi değeri, belli bir katsayı (A) ile çarpılıp çıktı olarak hesaplanır.

$$F = A * s \quad (1.4)$$

Adım (Step) Aktivasyon Fonksiyonu: Eş. 1.5'te gösterilen hesaplama sonucuna göre belirtilen koşullarda s değerinin bir değerin üstünde veya altında olmasına göre hesaplanır. Çıktı 1 veya 0 değerini alır.

$$F = \begin{cases} 1 & \text{if } s > \text{Eşik Değer} \\ 0 & \text{if } s \leq \text{Eşik Değer} \end{cases} \quad (1.5)$$

Eşik Değer Fonksiyonu: s girdi değeri 0'dan küçük veya eşit, 1'den büyük, 0 ile 1 arasında olduğunda kendini veren çıktılar üreten bir fonksiyondur. Eş. 1.6'da eşik değer fonksiyonun hesaplanması verilmiştir.

$$F = \begin{cases} 0 & \text{if } s \leq 0 \\ s & \text{if } 0 < s < 1 \\ 1 & \text{if } s \geq 1 \end{cases} \quad (1.6)$$

Sinüs Aktivasyon Fonksiyonu: Öğrenilmesi gerektiği düşünülen bir olayın sinüs fonksiyonuna uygun bir dağılım gösterdiği durumlarda kullanılır. Eş. 1.7’de sinüs fonksiyonunun hesaplaması verilmiştir.

$$F = \sin(s) \quad (1.7)$$

1.1.5.5. Çıktılar

Aktivasyon fonksiyonun hesaplanmasının ardından çıkan sonuç hücrenin çıktı değeri olmaktadır. Bu değer başka bir hücreye girdi olabilir veya direkt bilgi olarak kullanılabilir.

Bir hücre tarafından yalnızca bir çıkış değeri elde edilir. Süreci tamamlamak için diğer süreç öğelerine giden bilgi her zaman aynıdır. Süreç tamamlandığında YSA görevini tamamlamış ve üretmesi gereken bilgiyi üretmiştir (Sönemez Çakır, 2020).

1.1.6. YSA’larda öğrenme

YSA’larda öğrenme, farklı öğrenme stratejileri ve kuralları ile gerçekleştirilmektedir.

1.1.6.1. YSA’larda öğrenme stratejileri

Öğrenme stratejileri, “öğretmenli, destekleyici, öğretmensiz ve karma öğrenme” olarak dört alanda incelenmiştir (Öztemel, 2016).

Denetimli (Öğretmenli) Öğrenme: Bu stratejide bir öğretmen YSA’nın öğrenebilmesi için yardımcı olur. Ağa sunulan girdiler ile elde edilmesi beklenen çıktılar hakkında bilgi sahibi olur. Girdi ve çıktılar arasında var olan ilişki belirlenebilir. Ağın eğitilmesi için verilen girdiler için ağın elde etmesi gereken çıktılar sayısal olarak bellidir (Ataseven, 2013).

Denetimsiz (Öğretmensiz) Öğrenme: Bu öğrenme yönteminde, denetimli öğrenmenin aksine ağın öğrenmesine yardımcı olan bir öğretmen yoktur. Ağın öğretim

esnasında sadece girdi değerleri verilir. Verilen girdiler arasındaki ilişkileri ağı kendi kendisine öğrenmesi beklenir. Bu, daha çok sınıflandırma problemlerinin çözümünde tercih edilir. Ancak ağı öğrenmesi tamamlandıktan sonra çıktıların yorumlanması kullanıcı tarafından yapılması gerekmektedir (Öztemel, 2016).

Destekleyici Öğrenme: Bu öğrenme yöntemi genel olarak denetimli öğrenme yönetimine benzer, ancak hedef çıktılarından farklı olarak çıktıların ne kadar doğru olduğunu gösteren bir kriter verilir. Danışmalı öğrenmede, ağı davranışının uygun olup olmadığını belirten bir öz yetenek bilgisi gerekmektedir. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir (Sarı, 2016).

1.1.6.2. YSA’larda öğrenme kuralları

Hata Düzeltme Öğrenimi (Error-Correction Learning): Bu öğrenim türü ağ çıktısını gerçek çıktı ile karşılaştırarak hatayı eğitime yönlendiren denetimli öğrenme yöntemi olarak kullanılır.

Hebb Kuralı: Bu kural 1949 yılında Donald Hebb tarafından geliştirilmiştir. Biyolojik öğrenme mantığına dayalı ilk öğrenme kuralıdır. Hebb Kuralına göre bir yapay nöron başka bir hücreden bilgi alıyorsa ve her iki hücre de aktifse (sayısal olarak aynı işarete sahipse), her iki hücre arasındaki bağlantının güçlendirilmesi gerekir (Anderson ve McNeill, 1992). Bir hücre aktifse, bağlı olduğu hücreyi aktif hale getirmeye çalışır ve pasif ise onu pasif hale getirmeye çalışır (Öztemel, 2016).

Delta Kuralı: Bu, Hebb Kuralı’nın geliştirilmiş halidir (Elmas, 2012). Bu kurala göre, beklenen çıktı ile gerçek çıktı arasındaki farkları azaltmak için bağlantıların ağırlıkları sürekli olarak değiştirilmelidir. Bu kuralda, üretilen çıktı ile beklenen çıktı arasındaki farkların karelerinin ortalaması En Küçük Kareler Yöntemi (Least Mean SquareLMS) ile en aza indirilmeye çalışılır.

Hopfield Öğrenme Kuralı: Ağırlıkların güçlendirilmesini veya zayıflatılmasını öğrenme ile gerçekleştirilmektedir. Burada öğrenme katsayısı 0-1 arasında değer almaktadır ve kullanıcı tarafından belirlenmiş, pozitif değerler alan sabit bir sayıdan meydana gelmektedir (Öztemel, 2016).

Kohonen Öğrenme Kuralı: Denetimsiz öğrenme kurallarından biri olan Kohonen Öğrenme Kuralı, 1990 yılında Teuvo Kohonen tarafından geliştirilmiştir. Ödül ve ceza kavramına dayanan bu kuralda, ağırlıkların en uygun değeri alması için eğitim sırasında nöronlar çekişmektedir. En uygun çıktıyı üreten nöron rekabet sürecini tamamlar ve diğer nöronların ağırlıklarını değiştirebilmeleri için çekişmeden çekilir (Kohonen, 1990).


1.1.7. YSA'ların sınıflandırılması

YSA mimarileri, nöronlar arasındaki bağlantıların yönlerine veya ağdaki sinyallerin akış yönlerine dayanır; İleri beslemeli ve geri beslemeli olarak ikiye ayrılır (Ataseven, 2007).

Bir YSA içindeki gizli katmanların sayısı, YSA'nın kaç katmana sahip olduğu sorusunun cevabıdır. Tek katmanlı modeller basit ve lineer problemlerin çözümünde kullanılırken çok katmanlı modeller ise daha karmaşık ve lineer olmayan problemlerin çözümünde kullanılır (Kartalopoulos, 1996). Bir YSA'nın en az bir girişi, bir çıkışı ve bir gizli katmanı olmalıdır (Benli, 2002).

1.1.7.1. İleri beslemeli (feed – forward) ağlar

İleri beslemeli ağlar YSA'ların basit ve ilkel yapısını olarak bilinmektedir. Bilgi sadece ileriye doğru gizli ve çıkış katmanına ilerlemektedir. Sistem belleksizdir. Bu YSA yapısına statik ağlarda denilmektedir (Nguyen, 2007).




Şekil 1.2. İleri beslemeli YSA yapısı.

Şekil 1.2.'de üç (3) girişli (x_1, x_2, x_3), iki (2) çıkışlı (y_1, y_2) ve gizli katmanda beş (5) tane nöronu olan çok katmanlı ileri beslemeli bir ağ yapısıdır (He ve ark., 2000).

1.1.7.2. Geri beslemeli (feed back into) ağlar

Geri beslemeli sinir ağı, çıktı ve ara katmanlardaki çıktılardan girdi birimlerine veya önceki ara katmanlara geri bildirimin yapıldığı bir ağ yapısıdır. Bu çeşit sinir ağları, dinamik hafızalara sahiptir. Bu yapıdaki nöronların çıktısı sadece o anki giriş değerlerine değil önceki giriş değerlerine de bağlıdır. Bu nedenle, bu ağ yapısı özellikle tahmin

uygulamaları için kullanılmaktadır. Ayrıca bu ağlar, çeşitli zaman serilerini tahmin etmede başarılı olmuştur (Mackay ve David, 1992).



Şekil 1.3. Geri beslemeli YSA ağ yapısı.


Şekil 1.3'te geri bildirim ağı modelinde işlemci elemanları, karşılaştıkları her hatadan öğrendikleri bilgilerle bir sonraki adımda bu hataları dikkate alarak çıktı katmanına doğru ilerlemeleri gösterilmiştir (Sarı, 2016).

1.1.8. YSA mimarileri

YSA'lar Tek Katmanlı, Çok Katmanlı, Geri Beslemeli ve Kafes Yapılı olmak üzere dört grupta incelenebilir.

1.1.8.1. Tek katmanlı YSA'lar


Tek katmanlı ağların yapısını sadece girdi ve çıktıdan oluşturur. Tek katmanlı ağlarda çıkış fonksiyonu doğrusal olduğu için bu fonksiyon 1 veya -1 değerlerini alır. Bu çıktı değeri 1 ise birinci sınıfa, -1 ise ikinci sınıfa kabul edilmektedir (Öztemel, 2016).



Şekil 1.4. Tek katmanlı YSA (Öztemel, 2006).

1.1.8.2. Çok katmanlı YSA'lar

Çok katmanlı sinir ağlarının çalışma şekli, tek katmanlı ağlarla aynıdır. Çok katmanlı sinir ağlarında, giriş ve çıkış katmanları arasında gizli katmanlar bulunur. Sorunun yapısına uygun olarak gizli katmanların sayısı ve bu katmanlardaki hücre sayısı belirlenmektedir (Güngör, 2007).




Şekil 1.5. Çok katmanlı YSA (Karaatlı ve ark., 2012).

Şekil 1.4'te tek katmanlı bir ağ yapısı, Şekil 1.5'te ise giriş, gizli ve çıkış katmanından oluşan çok katmanlı algılayıcı ağı görülmektedir.

1.1.8.3. Geri beslemeli YSA'lar

Geri beslemeli YSA'larda, çıktı ve ara katman değerleri, girdi birimlerine veya önceki ara katmana geri beslenir. Böylece girdiler hem ileri hem de geri iletilir (Kaya ve ark., 2005).

Geri beslemeli YSA'larda, aktivasyon ve hata değeri süresiz olarak veya sabit noktaya ulaşana kadar yayılabilir. Aynı katmandaki elemanlar birbirine bağlı olduğu için, gizli katmandaki bir eleman hem iç hem de dış elemanlardan gelen verileri girdi olarak kabul eder. Bu nedenle, geri bildirim bağlantıları fazladan girdiye yol açacaktır. Bu değerler ağı kendisi tarafından hesaplanır (Bayır, 2006).



Şekil 1.6. Geri beslemeli YSA (Kaya ve ark., 2005).

1.1.8.4. Kafes yapılı YSA'lar

Kafes yapılı YSA'larda kafes yapısı bir veya daha fazla sinir hücresi dizisinden oluşmaktadır. Kafesin boyutu, kafes grafiğın bulunduğu uzaydaki boyut sayısı olarak ifade edilmektedir (Güngör, 2007).

1.1.9. YSA çalışma adımları

Bir YSA'yı eğitmek ve sonuç üretmesini sağlamak için bazı adımların gerçekleştirilmesi gerekmektedir.

1.1.9.1. Verilerin ağa sunulması ve ağ yapısının belirlenmesi

YSA'lar örneklerden öğrenen ve bu öğrendiklerini daha önce görmediği örneklere uygulayan bir yapıdır. Ağa yeni girdiler sunulduğunda önce bunlarla da eğitimin

tamamlanması gerekecektir. Verilerin ağa sunulmasında genel kabul görmüş bir kural yoktur. Verinin ağa nasıl sunulacağı eğitim algoritmasına bağlıdır. Bazı algoritmalarda veriler bütün halinde ağa tanıtılır, bazı algoritmalar için ise veri tanıtımı değişken setleri halinde yapılır. Veri sayısı hakkında genel bir kural yoktur ancak ağa uygun sayıda verinin sunulması öğrenmenin iyi bir şekilde gerçekleşmesi için gereklidir.

Verilerin ağa sunulma aşamasında bölümlendirme işlemi yapılır. Hangi değişkenlerin bağımsız hangisinin bağımlı değişken olduğunun, verilerin ne kadarı eğitim ne kadarı test için kullanılacağı ağa tanıtılır. Çalışmalarda değişken seti; Train (Eğitim), Testing (Test), Validation (Doğrulama) olmak üzere üç bölüme ayrılmaktadır. Bu bölümlendirme işlemi literatürde genelde %80 eğitim, %10 test, %10 doğrulama veya %70 eğitim, %15 test, %15 doğrulama olarak yapılmaktadır (Zhang ve ark., 1998).

1.1.9.2. Gizli Nöron Sayısının Belirlenmesi

YSA ile eğitime başlarken belirlenmesi gereken değerlerden biri de modelin katmanlarında kaç tane gizli nöron olacağıdır. Bu sayı belirlenirken kesin bir kural yoktur. Genellikle belirli sayılardan başlayarak ve giderek artan şekilde uygun nöron sayısı belirlenir. Gereğinden az tahmin edilmesi ağın kötü sonuçlar vermesine, gereğinden fazla nöronun ise ağın sadece kendisine gösterilen verileri ezberlemesine ve iyi sonuçlar üretmesine neden olmaktadır (Yıldız, 2009).

Giriş nöronlarının sayısını n ve çıkış nöronlarının sayısını m şeklinde ifade ederek literatür tarafından desteklenen birkaç gizli nöron sayısı belirleme yöntemi vardır (Sönemez Çakır, 2020).

$$n = m \quad (1.8)$$

$$n = 2m \quad (1.9)$$

$$\sqrt{nxm} \quad (1.10)$$

Eş. 1.8 Tang ve Fishwick, Eş. 1.9 Wong ve Eş. 1.10 ise Masters tarafından önerilen gizli nöron belirleme denklemleridir (Sönemez Çakır, 2020).

1.1.9.3. Birleştirme aktivasyon fonksiyonlarının seçilmesi

Daha önceki konularda bir ağ için bahsedilen bazı birleştirme ve aktivasyon fonksiyonları arasından araştırmacının hangisini seçeceği kişisel bilgi ve deneyimlerine bağlıdır. Hız ve bellek durumuna göre daha avantajlı fonksiyonlar tercih edilmelidir.

1.1.9.4. Durdurma kriterlerinin belirlenmesi

Bir ağın eğitiminin ne zaman biteceği en önemli konulardan biridir. Ağa ulaşamayacağı bir durdurma kriteri verilir ise ağ bu değere ulaşabilmek için sürekli yineleme yapmaya devam edecektir. Başka bir durumda ağ çok az yineleme sonucunda öğrenmeyi tamamlayamayabilir. Bundan dolayı ağ tasarlanırken ağın çok erken veya çok geç durmasını sebep olacak kriterler seçilmemelidir.

1.1.9.5. Modeller için performans (hata) ölçüleri

YSA'nın hatasını kabul edilebilir sınırlara indirmek, ağın ürettiği bilgilerin doğruluğu açısından oldukça önemlidir. Ancak bazen ağırlıklar değişse bile ağın hata değeri azalmayabilir. Bunun başlıca sebepleri; örnek seçiminde hatalar, ağın genel yapısındaki yanlışlıklar, yapının iyi anlaşılmaması, ağın yanlış fonksiyonlarla kurulması vb. olabilir. Aynı zamanda gerçek değerler ile ağdan elde edilen tahmin değerleri arasındaki hata değerinin minimum olması gerekmektedir (Sönmez Çakır, 2020).

Gerçek değer ile modelden elde edilen değerler arasındaki fark hata olarak tanımlanır. Hangi model için bu hata değeri küçük ise o model tercih edilmelidir. Modellerde hatanın belirlenmesinde kullanılacak doğruluk ölçütleri Eş. 1.11-1.16'daki gibidir (Al-Hamdi ve Soliman, 2004; Sönmez Çakır, 2020).

Y_t = Gerçek değer

F_t = Modelden elde edilen çıktı değeri

- Mean Absolute Deviation-MAD (Mutlak Ortalama Sapma)

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t| \quad (1.11)$$

- Sum of Squared Error- SSE (Hata Kareler Toplamı)

$$SSE = \sum_{t=1}^n (Y_t - F_t)^2 \quad (1.12)$$

- Mean Square Error- MSE (Ortalama Hata Kareleri)

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2 \quad (1.13)$$

- Root Mean Square Error – RMSE (Ortalama Hata Kareleri Karekökü)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2} \quad (1.14)$$

Bu ölçülerin dışında geliştirilmiş başka ölçüler de vardır. Bunlar aşağıdaki gibi hesaplanmıştır (Al-Hamdi ve Soliman, 2004).

- Percent Error – PE (Yüzde Hata)

$$PE = \frac{Y_t - F_t}{Y_t} \times 100 \quad (1.15)$$

- Mean Absolute Percent Error – MAPE (Ortalama Mutlak Yüzde Hata)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \times 100 \quad (1.16)$$

Lewis (1982) yılında kaleme aldığı eserinde MAPE değerinin diğer ölçümlere göre daha etkin sonuçlar verdiğini ve belirli değerler arasındaki MAPE değerlerinin değişimi açıklamakta yeterli olduğunu söylemiştir. Lewis'in düşüncesine göre MAPE değeri %10'dan daha az ise model yüksek doğruluğa sahip (çok iyi tahmin edici), değer %10 ile %20 aralığında ise orta derecede doğruluğa sahip (iyi tahmin edici), %20 ile %50 aralığında ise düşük derecede doğruluğa sahip fakat kabul edilebilirdir. %50'nin üzerindeyse tahmin değeri yok (kötü tahmin edici) olarak sıralanabilir.

1.1.9.6. Hata azaltma yöntemleri

Hesaplanan hatayı etkileyen en önemli ve düzeltilebilir faktör ağa verilen ağırlıklardır. Ağırlıkları farklılaştırmak hatayı azaltabilir. Ancak ulaşılabilecek en küçük hata miktarına ulaşıldığında ağ eğitilir. Ağırlıkların tekrar değiştirilmesi, ağın tahmininde

veya işleyişinde farklılıklar yaratabilir, ancak bu farklılıklar istatistiksel olarak anlamlı olmayabilir (Elmas, 2016). Hatayı azaltmak için ağırlıkları değiştirmek tek çözüm değildir. Ancak YSA'nın katmanındaki veya katmanlarındaki yapay nöron sayısındaki değişimleri takip etmek gerekmektedir. Başlangıçta herhangi bir sayı verilebilen bu hücreler, sonraki iterasyonlarda azaltılabilir veya artırılabilir. İyi tanımlanmış hücre sayısına ve veriye uygun fonksiyonlara sahip iyi tanımlanmış bir sinir ağı daha doğru bilgi verecektir (Rojas, 2013).

1.2. Regresyon Analizi (RA)

1.2.1. Regresyon Analizi tanımı

Regresyon, en az iki değişken arasında bulunan ilişkinin denklem ile ifade edilmesidir (Çil, 2008). Benzer şekilde RA'da değişkenlerin bağımlı ve bağımsız kabul edildiği durumda aralarındaki ilişki bir denklem ile ifade edilmektedir (Köksal, 1980).

Regresyon terimi ilk olarak Francis GALTON tarafından kullanılmıştır (Galton, 1886). Regresyon, değişkenler arasındaki ilişkiyi incelerken akla gelen ilk tekniktir. İstatistiksel açıdan, iki değişken arasındaki ilişki, bu değişkenlerin karşılıklı olarak değişen değerleri arasında var olan bir bağıllık olarak anlamlandırılır. Bir "x" değişkenin değeri değiştiğinde, bu değişkene bağlı olan "y" değişkenin değeri de değişiyorsa, bu değişkenlerin arasında bir ilişkinin var olduğu söylenebilir (Başara, 1996).

1.2.2. Regresyon analizi türleri

Literatürde birçok regresyon analizi türü bulunmaktadır. Bu bölümde çalışmada kullanılan türlerden bahsedilmiştir.

1.2.2.1. Doğrusal regresyon analizi

Doğrusal (linear) regresyon, sayısal bir bağımlı (y) değişkeni ve bir veya daha fazla bağımsız (x) değişkeni arasındaki ilişkiyi modellemeye yönelik yaklaşımdır (Kılıç, 2013).

RA'da, verilerin tümü (ana kitle) yerine bu verilerden seçilen örneklerle analiz yapılır. Ana kitle verilerinin sayısı çok fazla olduğundan istatistiksel analizler, zaman ve araştırma maliyetleri dikkate alınarak tüm ana kitle verileri yerine bu ana kitleden rastgele seçilen belirli sayıdaki verilerle yapılır. Örnek verilerle elde edilen sonuçlar, ana kitledeki ilişkiyi tahmin etmek için kullanılır (Yüzük, 2019).

RA'nın çözümünde değişkenler arasındaki ilişki kurulurken bazı varsayımlar veya kurallar ileri sürülür. Bu varsayımlar ve kurallar dahilinde bir çözüm yapılır ve sonucu kontrol edilir (Akgül, 2016). Bu varsayımları aşağıdaki gibi sıralanabilir (Berry, 1993):

- 1- Tüm bağımsız değişkenler nicel veya nitel olarak ölçülmeli ve bağımlı değişken y nicel ve sürekli olmalıdır. x ve y değişkenleri doğru bir şekilde ölçülmelidir.
- 2- Tüm bağımsız değişkenlerin varyansı sıfırdan farklı olmalıdır.
- 3- Bağımsız değişkenler arasında doğrusal bir ilişki olmamalıdır.
- 4- Hata terimleri ortalaması sıfırdır ($E(\varepsilon_i) = 0$).
- 5- Hata terimi ile bağımsız değişkenler arasında korelasyon olmamalıdır.
- 6- Hata terimlerinin varyansı sabit olmalıdır ($V(\varepsilon_i) = \sigma^2$).
- 7- Hata terimleri arasında otokorelasyon olmamalıdır ($Cov(\varepsilon_i, \varepsilon_j) = 0$).
- 8- Hata terimleri (ε_i) normal dağılmalıdır.

1.2.2.2. Basit doğrusal regresyon analizi

Bu model, tek bir açıklayıcı (bağımsız) değişken x ile açıklanan (bağımlı) değişken y arasında lineer bir ilişki olduğunda, x değişkeni yardımıyla y değişkenini tahmin etmek için kullanılmaktadır.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1.17)$$

Eş. 1.17’de gösterilen eşitliği ile doğrusal bir model kurulabilir. Bu modelde β_0 lineer fonksiyonun sabit terimidir ve $X = 0$ iken regresyon doğrusu üzerinde dikey eksen ile kesiştiği noktayı temsil eder. β_1 ise bu fonksiyonun eğimini açıklamaktadır ve aynı zamanda RA’da bağımsız değişken x ’ teki bir birimlik değişimin bağımlı değişkende ne kadarlık bir değişim oluşturduğunu gösteren regresyon katsayısıdır. Hata terimi ε ile ifade edilmektedir (James ve ark., 2021).

1.2.2.2.1. Basit doğrusal regresyonda parametrelerin tahmini

Modeldeki hata terimi; gerçek y değerleri ile tahmini y değerleri arasındaki farkı en aza indirmek ve gerçekte olması gereken katsayılara en yakın sonuçları bulmak için “En Küçük Kareler (EKK) Yöntemi” kullanılmaktadır (Yüzük, 2019).

EKK yöntemi, hata karelerini en aza indirmeye dayanır. Bu karelere ait hata toplamı dışbükey bir fonksiyondur. Hatayı en aza indirmek için kareler toplamının türevi alınır. Bu yöntemin kullanılmasıyla β_0 ve β_1 katsayıları tahmin edilmektedir (James ve ark., 2021). Bu yaklaşımla bulunacak denklem, en az hata ve en gerçekçi değeri verecek bir eğri denklem olacaktır. EKK yönteminin başarılı bir şekilde uygulanabilmesi için verilen noktalardaki ölçüm hatalarının normal dağılım göstermesi gerekmektedir (Koutsoyiannis, 1989).

Bu yöntemde, regresyon denklemindeki α ve β katsayıları $\sum \varepsilon_i^2$ (hata kareler toplamı) en küçük olacak şekilde tahmin edilmelidir. Bunun için öncelikle lineer regresyon denkleminde ε_i değeri hesaplanır.

$$\varepsilon_i = y_i - \alpha - \beta x_i \quad (1.18)$$

$$\sum \varepsilon_i^2 = \sum (y_i - \alpha - \beta x_i)^2 \quad (1.19)$$

Eş.1.18’de ε_i değerinin nasıl hesaplandığı belirtilmiştir. ε_i değeri hesaplandıktan sonra Eş. 1.19’da gösterilen eşitlik ile $\sum \varepsilon_i^2$ değeri elde edilir. Burada α ve β ’nın kısmı türevleri ayrı ayrı alınarak sıfıra eşitlenip çözümlerse, parametresinin katsayısı b Eş. 1.20’de belirtildiği gibi bulunur (Hines ve ark., 1990).

$$b = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \quad (1.20)$$

Aynı şekilde $a = \bar{Y} - b\bar{X}$ bulunur. Daha sonra bulunan bu değerler $y = a + bx$ eşitliğinde yerine yazılarak doğrusal regresyon denklemi oluşturulmuş olur.

EKK yöntemine göre uydurulan regresyon doğrusunun özelliklerini aşağıdaki gibi sıralayabiliriz (Neter et al, 1989).

1. Hatalarının toplamı sıfır.
2. Hataların kareleri toplamı minimumdur.
3. Bağımlı değişkenlerin (Y_i) toplamı uydurulan regresyon modeline göre tahmin edilen değerlerin (Y_i) toplamına eşittir.
4. i. değerdeki hatanın ağırlığı i. değerdeki bağımsız değişkene göre alındığında hataların toplamı veya hata değerleri ile bağımsız değerlerin çarpımları toplamı sıfırdır.
5. Hata değerleri ile uydurulan modele göre tahmin edilen değerlerin çarpımlarının toplamı sıfırdır.
6. Regresyon doğrusu ($\bar{X}, \bar{Y}$) noktasından geçer.

1.2.2.2.2. Basit doğrusal regresyonda belirlilik katsayısı

Belirlilik Katsayısı (R^2), bağımlı değişkendeki değişimin bağımsız değişkenler ile ne oranda açıklandığını gösteren katsayıyı ifade etmektedir. Basit regresyonda tek bir bağımsız değişken kullanıldığı için bağımlı değişkendeki değişimler yalnızca bu değişken kullanılarak açıklanmaktadır.

$$R^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (1.21)$$

Eş.1.21’de R^2 değerinin hesaplanması gösterilmiştir. Bu hesaplamanın sonucunda $0 \leq R^2 \leq 1$ aralığında bir değer alır. R^2 ’nin değeri 1’e ne kadar çok yakın olursa bağımlı değişkendeki değişmelerin bağımsız değişken tarafından o kadar iyi açıklandığı ortaya koyulmaktadır (Yüzük, 2019).

1.2.2.3. Çoklu doğrusal regresyon analizi

Bağımlı ve bağımsız değişken arasındaki ilişki basit regresyon analizi ile analiz edilmektedir. Bazı analizlerde, birçok bağımsız değişken bir bağımlı değişkeni etkileyebilir. Çok sayıda bağımsız değişkenin bir bağımlı değişkeni etkilediği durumlarda çoklu regresyon modeli kurulmalıdır (Okutkan, 2014).

Çoklu doğrusal regresyonun iki genel amacı bulunmaktadır. Bunlardan biri, bağımlı değişkeni etkilediği belirlenen değişkenler aracılığıyla bağımlı değişkenin değerinin tahmin edilmesidir, bir diğeri; bağımlı değişkeni etkilediği düşünülen bağımsız değişkenlerden hangisinin veya hangisinin bağımlı değişkeni daha fazla etkilediğini belirlemek ve aralarındaki ilişkiyi tanımlamaktır (Alpar, 2003).

Birden çok bağımsız değişkenli bir model kullanırken;

$$Y = b_0 + b_1 X_{i1} + b_2 X_{i2} + + b_n X_{in} + e_i \quad (1.22)$$

$$Y = b_0 + \sum_{k=1}^p b_k X_{ik} + e_i \quad (1.23)$$

Bağımlı değişkenin tahmini Eş. 1.22 ve Eş. 1.23’deki gibi hesaplanır. Burada b_0 , $b_1, ..., b_n$ regresyon katsayılarıdır (Öztürkcan, 2009).

1.2.2.3.1. Çoklu doğrusal regresyonda parametrelerin tahmini

Bu modelin parametreleri, basit doğrusal regresyon modelinin parametreleriyle aynı yöntemlerle tahmin edilebilir.

$$Y_i = \beta_1 + \beta_2 X_{i2} + \beta_3 X_{i3} + \dots + \beta_k X_{ik} + \varepsilon \quad (1.24)$$

Eş. 1.24'te ana kitle ÇRA modeli gösterilmektedir.

Y_i ile $E(Y_i)$ arasındaki farkların karelerinin toplamı EKK yöntemi kullanılarak minimize edilir. Yapılan bu minimize işlemleri sonucunda,

$$\begin{aligned} \sum_{i=1}^n Y_i &= n\beta_1 + \beta_2 \sum_{i=1}^n X_{i2} + \dots + \beta_k \sum_{i=1}^n X_{ik} \\ \sum_{i=1}^n X_{i2} Y_i &= \beta_1 \sum_{i=1}^n X_{i2} + \beta_2 \sum_{i=1}^n X_{i2}^2 + \dots + \beta_k \sum_{i=1}^n X_{i2} X_{ik} \\ &\vdots \\ \sum_{i=1}^n X_{ik} Y_i &= \beta_1 \sum_{i=1}^n X_{ik} + \beta_2 \sum_{i=1}^n X_{ik} X_{i2} + \dots + \beta_k \sum_{i=1}^n X_{ik}^2 \end{aligned} \quad (1.25)$$

Eş. 1.25'te gösterilmiş olan denklemler elde edilir. Elde edilen bu denklemler çoklu doğrusal regresyonun normal denklemleridir. Bu denklemler yardımı ile

$$\beta_1 = \bar{Y} - \beta_2 \bar{X}_2 - \beta_3 \bar{X}_3 - \dots - \beta_k \bar{X}_k \quad (1.26)$$

Eş. 1.26'da gösterildiği gibi tahmin edilmektedir.

ÇRA modelinde, matris yaklaşımı kullanılarak analiz basitleştirilir. Böylece, tahminlerin varsayımları, katsayı tahminleri, özellikleri ve varyansları ile regresyon denkleminin ilişkin diğer analizler daha kolay anlaşılır ve kanıtlanır (Çerçi, 2010).

Matris yönteminde ise $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + u_i (i=1,2,3,\dots,n)$ gibi çok açıklayıcı değişkene sahip bir model, aşağıdaki Eş. 1.27 modelini göstermektedir.

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 X_{11} + \beta_2 X_{21} +\beta_k X_{k1} + u_1 \\ Y_2 &= \beta_0 + \beta_1 X_{12} + \beta_2 X_{22} +\beta_k X_{k2} + u_2 \\ \\ Y_n &= \beta_0 + \beta_1 X_{1n} + \beta_2 X_{2n} +\beta_k X_{kn} + u_n \end{aligned} \tag{1.27}$$

Bu modelin matrislerle ifadesi ise Eş. 1.28’de veya $Y = X\beta + u$ şeklinde gösterilmektedir.

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{k1} \\ 1 & X_{12} & X_{22} & \dots & X_{k2} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & X_{1n} & X_{2n} & \dots & X_{kn} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} u_0 \\ u_1 \\ \vdots \\ \vdots \\ u_k \end{bmatrix} \quad (1.28)$$

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ \cdot \\ Y_n \end{bmatrix} \quad (1.29)$$

$$X \begin{bmatrix} 1 & X_{11} & X_{21} & \cdots & X_{k1} \\ 1 & X_{12} & X_{22} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ 1 & X_{1n} & X_{2n} & \cdots & X_{kn} \end{bmatrix} \quad (1.30)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_3 \end{bmatrix} \quad (1.31)$$

$$u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_3 \end{bmatrix} \quad (1.32)$$

Eş. 1.29 $n \times 1$ boyutlu bağımlı değişken gözlemleri vektörü, Eş. 1.30 $n \times k$ boyutlu açıklayıcı değişken verileri matrisi, Eş. 1.31 $k \times 1$ boyutlu katsayılar vektörü ve Eş. 1.32 $n \times 1$ boyutlu hata terimleri vektörüdür (Kızılırmak, 2022).

1.2.2.3.2. Çoklu doğrusal regresyonda belirlilik kat sayısı

ÇRA’da birden fazla bağımsız değişken olduğu için R^2 bağımlı değişkendeki değişimlerin bağımsız değişkenler tarafından açıklanma oranını verecektir. ÇRA’da basit regresyonda olduğu gibi bu değer hesaplanmaktadır ancak işlem kolaylığı için matrisler kullanılması tercih edilmelidir.

Aynı bağımlı değişkendeki değişimler farklı regresyon modelleriyle açıklanabilir. Bu modellerin matematiksel yapıları, gözlem sayıları ve değişken sayıları farklı olabilir. Bundan dolayı ÇRA modellerinde R^2 kullanımı uygun olmamaktadır. ÇRA modellerinde modele yeni değişken eklendikçe R^2 değeri daima artar. Bu nedenle, aynı bağımlı değişken farklı sayıda bağımsız değişken içeren regresyon modellerini karşılaştırmak için düzeltilmiş belirlilik katsayısı ($\overline{R^2}$) kullanılır (Yüzük, 2019).

$$\overline{R^2} = 1 - \frac{n-1}{n-k} \cdot (1 - R^2) \quad (1.33)$$

$\overline{R^2}$, Eş. 1.33’de gösterildiği gibi hesaplanır.

2. KAYNAK BİLDİRİŞLERİ

Literatür incelendiğinde YSA ve RA yöntemleri kullanılarak birçok alanda çeşitli çalışmalar yapılmıştır. Günümüze kadar farklı disiplin ve alanlarda kullanılmıştır. Bu bölümde YSA ve RA konularında yapılan bazı çalışmalar bulunmaktadır.

Babayiğit ve ark. (2015), meteorolojik verileri ve geçmiş yeraltı suyu seviyelerini kullanarak yeraltı suyu seviyelerini tahmin etmek için matematiksel modellerin geliştirilmesine yeni bir GP yaklaşımı, çok genli genetik programlamayı (ÇGGP) uygulamışlardır. Bu modelin oluşturulmasında 2007-2010 dönemini kapsayan Karacaviran gözlem kuyusunun dört yıllık günlük verileri ve Develi meteoroloji istasyonunun günlük meteorolojik verileri kullanılmıştır. Bu modellerin doğruluğu değerlendirilerek ÇRA ile karşılaştırılmıştır. ÇGGP modellerine ait sonuçların dört farklı kritere göre ÇRA'dan daha iyi olduğu belirlenmiştir.

Damla (2020), Yalova Gökçe Barajı'nın su seviyesini etkileyen 2000-2019 yılları arasındaki Selimandıra çayının debisi, buharlaşma ve yağış değerleri, baraj suyu debileri, sızıntı suyu miktarı, barajın seviyesi verilerini kullanarak YSA ile 2019 yılında baraj rezervuarındaki su seviyesini tahmin etmiştir. Oluşturulan modellerde, aylık veri setleri çok katmanlı YSA fonksiyonu olan Levenberg-Marquardt algoritması ile değerlendirilmiştir. Tahmin verilerinin %94,14 determinasyon oranı ile gerçek su seviyesine yakın tespit edilmiştir. Sonuç olarak, 2019 yılında tahmin edilen ortalama baraj su seviyesi 73,77m iken, barajdaki fiili ortalama su seviyesi 72,13m olmuştur. Bu sonuçlar ile YSA modelinin Yalova Gökçe Barajı su seviyesi tahmininde başarılı sonuçlar verdiği söylenebilir.

İspir (2017), Hatay Amik Ovası Kumlu bölgesinde DSİ Genel Müdürlüğüne ait gözlem kuyusundan ölçülen 2000-2015 yılları arasındaki aylık yeraltı suyu seviyesi ölçüm değerlerini ve aylık bazda yapılan toplam yağış ve ortalama sıcaklık ölçüm değerlerini kullanarak yeraltı suyu seviyesi tahmini yapmıştır. Çalışmada ÇRA Otoregresif Model (AR) ve YSA modelleri oluşturulmuş ve yeraltı suyu seviye tahmini performans değerlendirmesi yapılmıştır. YSA modelinin bölgenin yeraltı suyu

seviyesinin tahmininde ÇRA ve AR modellerine göre daha iyi sonuçlar verdiği gözlemlenmiştir.

2004 yılından 2010 yılına kadar YSA, regresyon ve zaman serisi analiz teknikleri ile Türkiye'nin elektrik enerjisi tüketimi tahmin edilmeye çalışılmış ve en uygun yöntemin araştırılması amaçlanmıştır. Uygulamada MINITAB ve Matlab Neural Network Toolbox yazılımı kullanılarak 3 teknik için ayrı ayrı yürütülen çalışmalar sonucunda, tahmin aracı olarak YSA'nın en uygun çözümü verdiği görülmüştür (Hamzaçelebi ve Kutay, 2004).

Vurşan (2017), tempcore sistemi ile üretilen nervürlü yapı çeliğinin mekanik fizik özelliklerinin ÇRA ve YSA ile tahminlerini yapmıştır. Kimyasal bileşimi oluşturan elementlerden; karbon, mangan ve silisine ek olarak haddelme sürecinde mukavemete etki eden su debisi, ebat vb. diğer parametreler, “bağımsız değişken” olarak belirlenmiştir. Her iki yöntem ile bağımlı değişken olan “Akma Mukavemeti” ve “Çekme Mukavemeti” değerleri tahmin edilmiştir. Her iki yöntem de incelendiğinde tahmin oranı yüksek olan YSA yönteminin daha iyi sonuçlar verdiği test edilen örneklerle gösterilmiştir.

YSA ve regresyon modellerini kullanarak PM10 miktarını tahmin edip iki yöntemin sonuçlarını karşılaştırılmıştır. Öncelikle 2012-2018 yılları arasında ölçülen PM10 miktarı bağımlı değişken olarak tanımlanmış ve bunu etkileyebilecek 5 bağımsız değişken belirlenmiştir. Regresyon ve YSA modelleri kullanılarak 2018 yılı için PM10 miktarı tahmin edilmiştir. Her iki yöntemin performans sonuçlarını değerlendirmek için ortalama mutlak yüzde hata (MAPE), ortalama karesel hata (MSE), ortalama mutlak hata (MAD), kök ortalama karesel hata (RMSE) değerleri hesaplanmıştır. Bunu hesaplamaların sonucunda YSA ile oluşturulan modelin diğerlerine göre daha iyi uyum sağlamıştır. YSA yöntemi ile 2019 yılı PM10 değeri tahmini yapılmıştır (Akbulut ve Özcan, 2020).

Okutkan (2014), YSA ve ÇRA modelleri geliştirerek bazı finansal oranlar, makroekonomik ve mikro göstergeleri gibi parametreler ile BİST'te yer alan hisse senetlerinin performansını değerlendirmiştir. Çalışmasında hisse senedi fiyatlarını tahmin etmek için 10 adet bağımsız değişken kullanmıştır. Risk iştahı yüksek olan ve parasını kısa vadeli para kazanmak yerine orta ve uzun vadede borsaya yatırmak isteyen

yatırımcılar için YSA ve ÇRA yöntemleri kullanarak yatırım kararlarının nasıl alınacağı belirtmeye çalışmıştır.

Can (2012), YSA yönteminin hidroloji alanında uygulanabileceğini göstermek için, su yapılarının fonksiyonel, güvenli ve ekonomik tasarımı için gerekli olan akış değerlerinin belirli bir süre içerisinde elde edilmesinde kullanılmıştır. Bu amaçla geliştirilen YSA farklı alternatif durumlar için eğitilmiştir. Girdi ve çıktı veri setleri oluşturmak için ÇRA'dan yararlanılmıştır. YSA sonuçları, akademik, devlet ve uzmanlaşmış eğitim kurumları tarafından halen kullanılan ÇRA modelleri ile karşılaştırılmıştır. Sonuçlar, YSA'nın bu alanda rahatlıkla kullanılabileceğini ve hata oranlarının teknik toleranslar içerisinde olduğunu göstermiştir.

Uğur (2007), YSA kullanarak inşaat maliyetlerini tahmin etmek için betonarme taşıyıcı sistem ile benzer özelliklere sahip çok katlı toplu binaların yapım maliyetleri hesaplanmış ve mevcut verilerden yola çıkılarak oluşturulan geri beslemeli ve denetimli öğrenme fonksiyonlu çok katmanlı yapılı YSA'ya veri olarak girilmiştir. Ağ tarafından hesaplanan maliyet tahminleri, regresyon analizi ile yapılan maliyet hesaplamaları ile karşılaştırılarak uygulanan YSA yönteminin performansı değerlendirilmiştir. Elde edilen sonuçlara göre YSA'dan elde edilen veriler, regresyon analizi sonuçlarına göre daha gerçekçi ve kullanılabilir sonuçlar üretmiştir.

Kökçam ve ark. (2018), Meriç Nehri'nin İpsala, Plovdiv, Svilengrad ve Kirişhane akış izleme istasyonlarının akış hızlarını tahmin etmek için bir YSA modeli oluşturmuşlardır. Model tarafından elde edilen tahminler, çeşitli performans yöntemleri yardımıyla gerçek değerlerle karşılaştırıldığında, YSA'nın bu konunun tahmininde başarılı sonuçlar verdiği görülmüştür.

Baytak ve ark. (2013), İzmir'de sokak ölçeğinde CO, CH₄, NMVOC, NO_x, O₃, PM₁₀ ve SO₂ gibi hava kirletici değişikliklerini tahmin etmek için meteorolojik değişkenler ve araç sayısı verileri kullanılarak YSA modelleri oluşturulmuştur. Sigmoid fonksiyonu kullanılarak tahmin edilen yoğunlaşmalar arasındaki en yüksek R (Korelasyon Kat Sayısı) 0.89 ve NMSE (En Küçük Hata) ise 0.22 sonuçlarını veren tek katmanlı bir model ile elde edilmiştir. Bu sonuçlar YSA modellerinin veri toplanan diğer caddelerde de çalışarak İzmir hava kalitesi yönetiminde bir araç olarak kullanılabileceğini göstermektedir.

Wen ve ark. (2018), Sumu Barun Jaran Gölü seviyesindeki değişimleri çevresel faktörleri göz önünde bulundurarak YSA teknikleri ile tahmin etmişlerdir.

Sınıflandırma teknikleri ve veri madenciliği yaklaşımı kullanılarak Chini Gölü su seviyesi tahmini için çeşitli algoritmaların karşılaştırmasını yapmak üzere bir çalışma yapmışlardır. Göl su seviyesi tahmini için Karar Ağacı, YSA ve Destek Vektör Makinesi yöntemleri kullanılmıştır (Hin ve Othman, 2020).

Konya Ovası'na ait su kaynağını oluşturan Beyşehir Gölü'nün su seviyesi dönüşümlerini YSA yöntemini kullanarak tahmin etmeye çalışmıştır. DSİ tarafından 1962-1990 yılları arasında yapılan giriş ve kayıp akıntı, yağış, buharlaşma, gölden çekilen su miktarı ve göle ait su seviyesi ölçümleri kullanılarak YSA yöntemi yardımıyla seviye değerleri elde edilmiş ve elde edilen değerler geleneksel yöntemlerden elde edilen sonuçlarla karşılaştırılmıştır (Yarar ve Onüçyıldız, 2009).

Çalım (2018), baraj rezervuarı seviye değişimi tahminleri için YSA yöntemi kullanmıştır. Elde edilen YSA sonuçları ÇRA ve otoregresif model sonuçları ile karşılaştırılmıştır. Sonuçlara göre; YSA model çözüm sonuçları, kullanılan diğer yöntemlere göre baraj rezervuar seviye değişiminin tahmininde daha iyi performans göstermiştir.

Biswas ve ark. (2009), YSA ile Surma Nehri'nin su seviyesini tahmin etmişlerdir. Sonuçlara dayanarak, YSA kullanılmasıyla gerçek zamanlı nehir suyu seviyelerinin tahmin edilmesinin mümkün olduğu sonucuna varılmıştır.

Castillo ve ark. (2018), nehir sistemindeki su seviyesini modellemek ve tahmin etmek için YSA tabanlı bir model önermişlerdir. Bu çalışmada kullanılan veriler Magdalena Nehri'nin Aguadas, Barbosa ve Palenquito istasyonlarından alınmış olup, örnekler 01/01/1997 ve 31/12/2015 tarihleri arasında toplanmıştır. YSA kullanılarak geliştirilen bu model iyi sonuçlar ortaya koymuştur.

Yeraltı su seviyesini tahmin etmek için İleri Beslemeli YSA tekniklerinden oluşan bir model oluşturulmuştur. Bu YSA modeli, iki gizli katman ve sigmoid aktivasyon fonksiyonu ile geri yayımlı algoritma kullanılarak eğitilmiştir. Çalışmanın sonuçları, sınırlı veri durumunda bile, YSA'nın bir sert kaya bölgesindeki yeraltı suyu seviyesini oldukça iyi bir doğrulukla tahmin etmek için kullanılabileceğini açıkça göstermiştir (Mayilvaganan ve Naidu, 2011).

Piasecki ve ark. (2015), YSA teknikleri ile Drwęckie Gölü su seviyesi dalgalanmalarını modellemişlerdir. Modelleme amacıyla Olsztyn'deki meteoroloji istasyonundan alınan 1980-2012 yılları arasındaki meteorolojik veriler kullanılmıştır. Çalışmalarının sonucunda, göl su seviyesi değişimlerinin YSA ile tahmin edilmesinin doğru sonuçlar verdiği ifade edilmiştir.

Kızılaslan ve ark. (2014), İznik Gölü'nün günlük su seviyesini tahmin etmek için YSA teknikleri kullanmışlardır. Girdi olarak kullanılan veriler Meteoroloji Genel Müdürlüğü'ne ait 217 nolu istasyondan çıktı olarak kullanılan su seviyesi verileri ise Elektrik İşleri Elektrik İşleri Etüt İdaresi Genel Müdürlüğü (EİE)'den alınmıştır. Sadece meteorolojik veriler kullanılarak doğru tahminler yapılmayacağı gözlenmiştir.

Van Gölü'nün zamansal değişim su seviyelerini modellemek için YSA kullanılmıştır. Oluşturulan modelin eğitiminde geri yayılım algoritması kullanılmıştır. Bu çalışmada göl seviyesindeki dinamik değişimler değerlendirilmiştir. Sonuç olarak çalışma, YSA'nın yağış ve ardışık su seviyeleri arasındaki karmaşık ilişkiyi başarılı bir şekilde modelleyebileceğini göstermiştir (Altunkaynak ve Şen, 2007).



3. MATERYAL VE YÖNTEM

3.1. Materyal

Bu çalışmada, yağış, sıcaklık, buharlaşma, rüzgar hızı, nispi nem ve aktüel basınç gibi meteorolojik verilerin Van Gölü su seviyesi üzerine etkileri tespit edilerek tahmin modelleri kurulmuştur. Bu bölümde çalışma alanı, veri seti ve kullanılan yazılımlardan bahsedilmiştir.

3.1.1. Çalışma alanı

Kapalı havzanın en alçak bölümünde yer alan Van Gölü, %2.6 tuzluluk oranıyla bir soda gölüdür. Van Gölü 3.626 km² yüzey alanı, 607 km³ hacmi, 12.470 km² drenaj alanı, 9,7 pH değeri ve maksimum 451 metre derinliği ile Türkiye'nin en büyük su kütlesidir. Van Gölü, Van ve Bitlis il sınırları içerisinde yer almaktadır. Şekil 3.1'de Van Gölü'ne ait sınırlar belirtilmiştir.



Şekil 3.1. Van Gölü haritası.

Van Gölü kapalı bir havza olduğundan, göl seviyesi genellikle iklim ve mevsimlere göre değişir. Gölün su seviyesindeki gözle görülür değişiklikler, farklı zamanlarda meydana gelen iniş ve çıkışlardır. Bu tür değişikliklerin büyük ölçüde yağış, sıcaklık ve buharlaşma kontrolü altında geliştiği söylenebilir (Yıldız, 2009).

3.1.2. Veri seti

Çalışmada kullanılan veriler Van ili sınırları içerisinde yer alan Meteoroloji 14. Bölge Müdürlüğü ve DSİ 17. Bölge Müdürlüğü'ne ait çeşitli ölçüm istasyonlarından temin edilmiştir.

Çizelge 3.1. Çalışmada kullanılan parametreler

<i>Parametre</i>	<i>Birimi</i>	<i>Kullanım Türü</i>	<i>Temin Edilen Kurum</i>
Yağış	mm=kg÷m ²	Bağımsız Değişken	Meteoroloji Genel Müdürlüğü
Sıcaklık	°C	Bağımsız Değişken	Meteoroloji Genel Müdürlüğü
Buharlaşma	mm	Bağımsız Değişken	Meteoroloji Genel Müdürlüğü
Rüzgar Hızı	m/sn	Bağımsız Değişken	Meteoroloji Genel Müdürlüğü
Nispi Nem	%	Bağımsız Değişken	Meteoroloji Genel Müdürlüğü
Aktüel Basınç	hPa	Bağımsız Değişken	Meteoroloji Genel Müdürlüğü
Van Gölü Su Seviyesi	m	Bağımlı Değişken	DSİ Genel Müdürlüğü

Çizelge 3.1'de kullanılacak yağış, sıcaklık, buharlaşma, rüzgar hızı, nispi nem, aktüel basınç ve Van Gölü su seviyesi parametreleri, bu parametrelerin mm (milimetre), °C (santigrat), m/sn (metre bölü saniye), % (yüzde), hPa (hektopaskal), m (metre) ölçü birimleri, modelde hangi amaçla kullanıldığı ve nereden temin edildiği belirtilmiştir. Bu parametreler 2004-2022 yılları arasında temin edilen kurumlara ait istasyonlar ile ölçülmüş olup aylık verileri kapsamaktadır.

3.1.3. Uygulamada kullanılan yazılım


Tez kapsamında kolaylığı ve erişilebilirliği nedeniyle YSA ile gerçekleştirilen model için Matlab yazılımı, ÇRA ile geliştirilen model içinse Excel yazılımı tercih edilmiştir. İlerleyen bölümde Matlab yazılımı ile ilgili genel bilgi verilmiştir.

3.1.3.1. Matlab (matrix laboratuvarı)

Matlab, 1985 yılında Cleve Moler'in o zamanlar mühendislikte yaygın olarak kullanılan FORTRAN'a alternatif olarak geliştirdiği Matrix Laboratuvarı adlı bir yazılımdır. Matlab, kullanımı kolay, etkileşimli bir ortamda algoritmalar geliştirmek, sayısal işlemler gerçekleştirmek, verileri analiz etmek ve görselleştirmek için tasarlanmış üst düzey bir hesaplama dilidir (MathWorks, 2022).

Matlab'ın diğer uygulama geliştirme platformlarına göre avantajı, zengin matematiksel işleme yeteneklerine sahip olmasıdır. Diğer programlama dillerinde kod satırları yazılarak gerçekleştirilen işlemler Matlab'ın hazır matematiksel algoritmaları ile tek bir işlemde yapılabilmektedir. Tüm programlama dilleri gibi Matlab'ın da kendi programlama dili vardır. Matlab ile geliştirilen programlar Matlab programı ile çalışır. Ayrıca bu programlar istenirse .exe uzantılı uygulama programlarına veya .dll uzantılı program kitaplıklarına dönüştürülebilir. Ayrıca Matlab ile yazılan programlar istenirse C/C++ dillerine de çevrilebilmektedir. Matlab'ın grafiksel kullanıcı ara yüzleri oluşturmaya yönelik GUI aracı da bunu kolaylaştırır.


Bu çalışmada, YSA modelinin oluşturulması için Matlab R2021b versiyonu kullanılmıştır. Programın her yıl yenilenen versiyonları mevcuttur. Güncellenen versiyonlar arasında programın çalışma şeklinde olmasa da programın ara yüzünde ve bazı fonksiyonların kullanımda farklar vardır.



Şekil 3.2. Matlab arayüzü.

Matlab ortamı komut, geçerli dizin, çalışma alanı ve komut geçmişi olmak üzere dört pencereden oluşur. Bu pencerelerin genel görünümü Şekil 3.2’de gösterilmektedir. Geçerli dizin, çalışma yapılan dosyaların kaydedileceği ve bu dosyalara doğrudan erişim sağlanabildiği klasördür. Komut penceresi, komutların yazıldığı ve yanıtlarının görüntülendiği penceredir. Çalışma alanı penceresi, kullanılmakta olan değişkenleri listeleyen penceredir. Komut geçmişi penceresi, girilen önceki komutları listeleyen penceredir (Hamzaçebi, 2021).

Matlab platformunda YSA kurulumu, uygulaması ve simülasyonunu sağlayan Neural Fitting Application (NFTOOL) arayüzü bulunmaktadır. Bu arayüz yardımı ile birçok farklı YSA yapısını modelleyebilmek mümkündür. Verilerin seçilmesine, ağın oluşturulmasına, eğitilmesine ve performansının değerlendirilmesine yardımcı olur. Şekil 3.3’de nftool arayüzü gösterilmektedir.



Şekil 3.3. nftool arayüzü.

3.2. Yöntem

Bu tez çalışması kapsamında daha önceki bölümlerde ayrıntılı olarak YSA ve RA yöntemleri, tez çalışmasının önemi ile literatür çalışması, çalışma alanı, kullanılan veriler ve yazılımlar hakkında bilgiler verilmiştir. Bu bölümde hem YSA hem de RA modellerinin geliştirme süreçleriyle alakalı bilgiler verilmiştir.

3.2.1. Verilerin hazırlanması

Modellerin oluşturulması, eğitilmesi, belirlenen hedef değerleri ile elde edilen çıktı değerlerinin karşılaştırılması ve sonuçların değerlendirilmesi süreci öncelikle geçmiş kayıtlardan oluşan girdi ve çıktı değerlerine ait veri setleri toplanarak

başlanmıştır. Veriler, Van ili sınırları içerisinde yer alan Meteoroloji 14. Bölge Müdürlüğü ve DSİ 17. Bölge Müdürlüğü'ne ait çeşitli ölçüm istasyonlarından ölçülen 2004-2022 yıllarını kapsayan aylık verilerden oluşmuştur.

$$P_{(ort,parametre)} = \frac{1}{n} \sum_{i=1}^n P_{(parametre)} \quad (3.1)$$

Birden fazla istasyon tarafından ölçülen bu değerler Eş. 3.1'de gösterildiği gibi hesaplanarak tek değer haline dönüştürülmüştür. Burada $P_{(parametre)}$ ilgili parametrenin aylık olarak ölçülen değerlerini, n bu parametrenin ölçüm yapılmış toplam istasyon sayısını, $P_{(ort,parametre)}$ ise bu parametrenin aylık ortalama değerini ifade etmektedir. Bu işlem tamamlandıktan sonra 2004-2022 yıllarını kapsayan toplam 225 adet veri elde edilmiştir. 2004-2021 yılları arasında yer alan toplam 216 adet veri, modelleri oluşturmak için 2022 yılına ait 9 adet veri, kurulan modelleri test etmek için kullanılmak üzere iki gruba ayrılmıştır.

Son olarak veriler, modeller oluşturulmadan önce ayarlanmış minimum maksimum yöntemi ile Eş. 3.2'deki gibi modellerin verimliliğini artırmak için 0.1 ila 0.9 aralığında normalize edilerek veri setinin boyutsuz bir form alması sağlanmıştır.

$$X_i = 0.8 \frac{(X - X_{\min})}{(X_{\max} - X_{\min})} + 0.1 \quad (3.2)$$

Burada X_i normalize edilecek değer, X ölçülen değer, $X_{\min}$, X için en küçük değer, $X_{\max}$, X için en büyük değeri ifade etmektedir.

3.2.2. YSA yöntemi ile model oluşturulması

Veriler üzerindeki gerekli işlemler yapıldıktan sonra YSA mimarisini oluşturmak için aşağıdaki adımlar takip edilmiştir.


3.2.2.1. Verilerin matlab ortamına aktarılması

İlk olarak tahmin yapmak için toplanan, düzenlenen ve normalize işlemi yapılan veriler Matlab ortamına aktarılmıştır.

Çizelge 3.2. Matlab ortamı veri dağılımı

<i>Türü</i>	<i>Adet</i>
Eğitim	216
Test	9
Toplam	225

Daha sonra Çizelge 3.2’de belirtildiği gibi bağımlı ve bağımsız değişkenlerin her biri için toplanan 2004-2022 yılları arasındaki 225 adet veriden, 2004-2021 yılları arasındaki 216 adet veri ağın eğitimi için kullanılırken 2022 yılındaki 9 adet veri test için seçilmiştir. Son olarak veriler Şekil 3.4’de yazılan komutlar ile transpoze edilerek program çalıştırılmıştır.




Şekil 3.4. Değişkenlerinin matlaba tanıtılması.

3.2.2.2. Ağın oluşturulması ve parametrelerin belirlenmesi

YSA modelini oluşturmak için öncelikle ağın yapısı oluşturulmalıdır. Bu yapı, model ile ilgili hücre sayısı, eğitim ve aktivasyon fonksiyonu gibi bilgileri barındıran bir

yapıdır. Ağın yapısını oluşturmak için nntool komutu kullanılarak Şekil 3.5’de çalışmanın yapılacağı uygulama açılmıştır.



Şekil 3.5. Değişkenlerin sınıflandırılması.

Değişkenleri sınıflandırıldıktan sonra Şekil 3.6’de ağın yapısında kullanılacak algoritma, aktivasyon fonksiyonu, performans fonksiyonu, katman sayısı, gizli hücre sayısı ve nöron sayısı alanları yer almaktadır. Modelin oluşturulmasında ileri beslemeli ağ tipi kullanılmıştır. Tahmin yapılırken ağırlıkların belirlenmesinde aktivasyon fonksiyonu olarak “tansig” ve “logsig” fonksiyonlar denenmiştir. Matlab’da eğitim

fonksiyonu olarak da “trainbfg”, “trainbr”, “traincgf”, “traingdm”, “traingdx”, “trainlm”, “trainoss” ve “trainrp” gibi fonksiyonlar bulunmaktadır. Bu fonksiyonlar denenmiş, denemeler sonucunda ağın en iyi öğrendiği fonksiyon belirlenmiştir.

The screenshot shows the 'Create Network or Data' dialog box with the following settings:

- Name:** YSAModel
- Network Properties:**
 - Network Type:** Feed-forward backprop
 - Input data:** EgitimGirdiVerisi
 - Target data:** EgitimCiktiVerisi
 - Training function:** TRAINLM
 - Adaption learning function:** LEARNGDM
 - Performance function:** MSE
 - Number of layers:** 2
- Properties for: Layer 1**
 - Number of neurons:** 10
 - Transfer Function:** TANSIG
- Buttons:** View, Restore Defaults, Help, Create, Close

Şekil 3.6. Ağa ait parametrelerin belirlenmesi.

Öğrenme katsayısını belirlemek için belirli bir yöntem olmadığından dolayı eğitim sırasında bu çalışmada öğrenme katsayısı belirlenirken 0.5-0.9 arasında değerler için denemeler yapılmıştır. Uygulamada bulunan veri miktarı dikkate alınarak iterasyon sayısı 10.000 olarak belirlenmiştir. Bu durumda belirtilen tekrar sayısına ulaşıldıktan sonra

ağ öğrenmeyi durdurur. Bundan sonra ağın daha fazlasını öğrenemeyeceği ve daha iyi bir sonuç bulamayacağı anlaşılmaktadır.

3.2.2.3. Ağın eğitilmesi

Bu adımda oluşturulmuş olan ağ eğitim girdi verileri ve eğitim çıktı verileri kullanılarak eğitilmiştir. Ara katmanlardaki hücre sayıları ve öğrenme katsayıları yapılan denemelerle belirlenmiştir. Daha önce normalize edilen test giriş değerleri bu adımda denormalize edilerek elde edilen tahmin değerleri yorumlanmıştır.

3.2.2.4. YSA performansının değerlendirilmesi

Bu aşamada gerçek su seviyesi değerleri ile YSA ile oluşturulmuş modelin bulduğu tahmini değerler karşılaştırılarak ağın performansı ölçülmüştür.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \times 100 \quad (3.3)$$

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t| \quad (3.4)$$

Ortaya çıkan hatayı tespit etmek için bir performans kriteri olarak Eş. 3.3'deki Ortalama Mutlak Yüzde Hatası (MAPE) ve Eş. 3.4'teki Mutlak Ortalama Sapma (MAD) formülleri kullanılmıştır. Burada Y gerçek değeri, F , Y için tahmin edilen değeri, n ise toplam tahmin sayısını ifade etmektedir. MAPE, farklı birim değerlere sahip modellerin karşılaştırılmasında kullanılmaktadır. Örneğin gerçek değerleri kullanılan bir model ile bu modelde tahmin edilen değerleri karşılaştırmak için kullanılan istatistiktir. MAD, tüm değerlerin aritmetik ortalamadan mutlak farklarının ortalaması olarak hesaplanmaktadır.

3.2.3. CRA yöntemi ile model oluşturulması


Bu aşamada YSA mimarisi oluştururken kullanılmış olan aynı veriler CRA tekniği kullanılarak da tahmin edilmiştir. Gerçekleşen tahmin sonuçlarına ait performans değerlendirilerek YSA mimarisinin ortaya koyduğu performans ile karşılaştırılmıştır.

ÇRA yöntemi ile kurulan model Excel yazılımı kullanılarak oluşturulmuştur. İlk olarak toplanan, düzenlenen ve normalize işlemi yapılan veriler Excel ortamına aktarılmıştır.

Çizelge 3.3. Excel ortamı veri dağılımı

<i>Türü</i>	<i>Adet</i>
Eğitim	216
Test	9
Toplam	225

Daha sonra YSA modelinde de olduğu gibi Çizelge 3.3'te belirtilen bağımlı ve bağımsız değişkenlerin her biri için toplanan 2004-2022 yılları arasındaki 216 adet veriden, 2004-2021 yılları arasındaki 216 adet veri modelin kurulması için kullanılırken 2022 yılındaki 9 adet veri ise modeli test etmek için seçilmiştir.



Şekil 3.7. Excel eklentisi.

Verilerle alakalı işlemler tamamlandıktan sonra Excel’de Şekil 3.7’de gösterilen Veri Çözümleme aracı etkinleştirilmiştir. Bu araç, çeşitli istatistiksel çözümlemeler geliştirmeye yaramaktadır. Her çözümlemenin verileri ve parametreleri sağlandıktan sonra araç, uygun istatistiksel makro işlevlerini kullanarak sonuçları bir çıkış tablosunda görüntüler. Bazı araçlar, çıkış tablolarına ek olarak, grafikler de oluşturmaktadır.

Regresyon

Giriş

Y Giriş Aralığı:

X Giriş Aralığı:

☐ Etiketler ☐ Sabit Sıfır

☐ Güvenirlilik Düzeyi %

Çıkış seçenekleri

☐ Çıkış Aralığı:

☒ Yeni Sayfa:

☐ Yeni Çalışma Kitabı

Farklar

☐ Farklar ☐ Fark Çizimi

☐ Standart Farklar ☐ Hat Uyumu Çizimi

Normal Olasılık

☐ Normal Olasılık Çizimi

Tamam

İptal

Yardım

Şekil 3.8. Regresyon analizi.

Modele ait bağımsız ve bağımlı değişkenlerin giriş aralığı, verilere ait etiketler, güvenirlilik düzeyi, çıkış seçenekleri, sonuçlar ve sonuçlara ait grafiksel bilgiler Şekil 3.8’de gösterilen araç yardımı ile seçilerek model oluşturulmuştur.

Son olarak oluşturulan modelin performansı gerçek su seviyesi değerleri ile tahmin edilen değerler Eş. 3.3’deki Ortalama Mutlak Yüzde Hatası (MAPE) ve Eş. 3.4’teki Mutlak Ortalama Sapma (MAD) formülleri kullanılarak hesaplanmıştır.




4. BULGULAR

4.1. YSA Modeli

4.1.1. YSA yapısının özellikleri

Elde edilen toplam 225 adet veriden, 216 adet veri ağı eğitmek için kullanılmıştır. Geriye kalan 9 adet veri ise test için kullanılmıştır. Çalışmada kurulan modellerde 6 adet giriş değişkeni bulunurken 1 tane de çıkış değişkeni mevcuttur.



Validation and Test Data
Set aside some samples for validation and testing.


Select Percentages

Randomly divide up the 216 samples:

Training:	70%	152 samples
Validation:	15% ▾	32 samples
Testing:	15% ▾	32 samples

Şekil 4.1. Bölünen eğitim verileri.


Matlab ortamında geliştirilen bir YSA modelinin oluşturulup eğitilmesi için eğitimverilerin eğitim, test ve onaylama şeklinde sınıflandırılması gerekmektedir. Bu sınıflandırma işlemi genel olarak random yapılmaktadır. Şekil 4.1’de YSA modelini eğitmek için ayrılmış olan toplam 216 adet veri %70 öğrenme, %15 test, %15 onaylama olarak ayrılmıştır.



Şekil 4.2. YSA yapısının özellikleri.


Şekil 4.2’de ağ yapısının özellikleri gösterilmektedir. Veriler arası doğrusal olmayan bir ilişki olduğu için en çok kullanılan ileri beslemeli geri yayımlı çok katmanlı

bir ağ tercih edilmiştir. Tahmin yapılırken ağırlıkların belirlenmesinde aktivasyon fonksiyonu olarak deneme yanılma yolu ile en başarılı sonucu veren “TANSIG” fonksiyonu seçilmiştir. Matlab’ da yer alan eğitim fonksiyonları denenmiş, denemeler sonucunda ağın en iyi öğrendiği fonksiyon, “TRAINLM (Levenberg-Marquardt)” olarak gözlemlenmiş ve bu fonksiyon seçilmiştir. Ağın performansının değerlendirilmesi için “MSE (Ortalama Karesel Hata)” fonksiyonu seçilmiştir.



Şekil 4.3. YSA’nın yapısı.

Şekil 4.3’te ağ yapısının görünümü gösterilmektedir. 6 adet giriş verisi ve 1 adet çıkış verisi kullanılmıştır. Katman ve gizli hücre sayıları sırasıyla 2 ve 12 adet olarak belirlenmiştir. Bunlar deneme yanılma yolu ile en başarılı sonucu veren değerler olarak belirlenmiştir.




Şekil 4.4. Eğitim parametreleri.

Şekil 4.4'te ağırlık eğitiminde kullanılan parametreler gösterilmiştir. Bu parametreler maksimum performans için ulaşılması gereken hedef değerlerdir. Denem yanılma yolu ile en başarılı sonucu veren bu parametrelere ait değerler Şekil 4.4'te olduğu gibi belirlenmiştir.

4.1.2. YSA eğitim sonuçları

Eğitim tamamlandıktan sonra her iterasyondaki eğitim, doğrulama ve test verilerinin nasıl değiştiğini gösteren performans grafiği Şekil 4.5'de gösterilmiştir. Bu sonuca göre tamamlanan bu model 4.674 iterasyonda en iyi sonuca ulaşmıştır.




Şekil 4.5. YSA eğitim sonrası performans grafiği.

YSA modeli, 6x216 giriş matrisi ve 1x216 çıkış matrisi ile eğitildikten sonra, ağ ilerleme verileri Çizelge 4.1’ de gösterilmiştir. Performans değeri 0’a yakın olan 0.0131 hata değeri ile çalışmıştır. Bu değerin 0’a yakın olması ağın başarı yüzdesinin fazla olduğu anlamına gelmektedir. Ağın en iyi sonuca ulaşması ve eğitimini tamamlaması 11 saniye sürmüştür. En iyi tahmin sonucunu ise 4674. İterasyonda vermiştir.

Çizelge 4.1. İlerleme verileri

<i>İlerleme</i>	<i>Sonuç</i>
İterasyon	4674
Zaman	11 sn
Performans	0,0131

Şekil 4.6'da modele girilen çıktı değerleri ile modelin tahmini arasındaki ilişki görülmektedir. Bu kapsamda eğitim, doğrulama, test ve bunların ortak Regresyon (R) değerleri 0.88 olarak görülmektedir. Bu değerler 1'e oldukça yakın değerler olduğu için öğrenme işlemi başarıyla gerçekleştirilmiştir.



Şekil 4.6. YSA eğitim regresyon sonuçları.

4.1.3. YSA tahmin sonuçları

YSA ile yapılan göl su seviyesi tahmini %99 doğrulukla gerçekleşmiştir. Tahmin sonucunda MAPE değeri 0'a çok yakın, 0.34 olarak bulunmuştur yani %0.34' lük bir hata payı meydana gelmiştir. MAD değeri ise 0.05 olarak bulunmuştur. Tahminlerde MAPE ve MAD değerinin 0'a yakın olması ağın daha gerçekçi sonuçlar vereceği anlamına gelmektedir.


Çizelge 4.2. Test verileri

AB (hPa)	B (mm)	NN (%)	RH (m÷sn)	S (°C)	D (mm=kg÷m²)
819.62	8.90	78.44	1.83	-6.51	61.68
821.83	14.60	79.65	1.57	-3.02	22.87
818.33	38.15	77.17	2.43	-1.65	61.29
821.54	24.80	58.82	2.39	8.39	24.80
821.22	115.30	66.83	2.37	10.50	47.77
820.56	189.30	45.02	2.33	18.51	12.17
819.34	255.20	35.76	2.30	22.11	1.34
820.90	298.70	30.34	2.21	23.26	0.26
822.86	230.20	35.15	2.11	18.46	0.64

Çizelge 4.3. Gerçek ve tahmin edilen su seviyesi değerleri

Gerçek Su Seviyesi (m)	Tahmin Edilen Su Seviyesi (m)	 GSS- TS (m)
1648.49	1648.41	0.0713
1648.49	1648.42	0.0721
1648.52	1648.46	0.0650
1648.58	1648.57	0.0120
1648.67	1648.59	0.0733
1648.66	1648.53	0.1341
1648.59	1648.56	0.0276
1648.59	1648.56	0.0297
1648.33	1648.36	0.0284

Çizelge 4.2’de daha önce modele hiç tanıtılmamış gerçek veriler gösterilmiştir. Bu veriler oluşturulan modeli test etmek için girdi verileri olarak kullanılmıştır. Çizelge 4.3’de bu verilere ait çıktı değeri olarak gerçek ve YSA modeli tarafından tahmin edilen su seviyeleri, bu seviyelere ait sapmalar gösterilmiştir. YSA modeli tarafından tahmin edilen verilerin gerçek verilere çok yakın değerler olduğu gözlemlenmiştir. Örneğin herhangi bir dönemde ölçülmüş olan gerçek su seviyesi 1648.59 iken o döneme ait meteorolojik parametreler kullanılarak bu değer YSA modeli sonucunda 1648.56 olarak tahmin edilmiştir. Bu değer ile gerçek su seviyesi değeri arasındaki fark ise 0.0297 olarak belirlenmiştir.



Şekil 4.7. Gerçek ve tahmin edilen su seviyelerinin karşılaştırılması.

Gerçek ve YSA modeli tarafından tahmin edilen su seviyesine ait değerler Şekil 4.7’de grafiksel olarak karşılaştırılmıştır. Bu grafikte gerçek su seviyesi ve YSA ile tahmin edilen su seviyesi değerleri arasındaki farkı gösterilmektedir. YSA’nın tahmin etmiş olduğu sonuçlar gerçek su seviyesine oldukça yakın değerlerdir.

4.2. ÇRA Modeli

YSA modeli eğitiminde kullanılan 216 adet veri ÇRA teknikleri ile analiz edilmiştir. Yağış, sıcaklık, buharlaşma, rüzgar hızı, nispi nem ve aktüel basınç parametreleri bağımsız göl su seviyesi parametresi ise bağımlı değişken olarak seçilmiştir.

Çizelge 4.4. Regresyon analizine ait analiz sonuçları

<i>Regresyon İstatistikleri</i>	
R	0.50
R ²	0.25
Açıklayıcı R ²	0.23
Standart Sapma	0.21
Gözlem Sayısı	216

Regresyon analizi ile oluşturulan modelin özeti Çizelge 4.4'te gösterilmiştir. R değeri 0.50 olarak görülmektedir. Bu değerin 1'e yakınlığı veriler arasındaki ilişkinin gücünü belirlemektedir. Açıklayıcı R^2 değeri 0.23 olarak hesaplanmıştır Yani bağımsız değişkenler, bağımlı değişkendeki değişimin %23'unu açıklayabilmektedir. Bu oldukça düşük bir değer olduğu için modelin verilere uygunluğu yetersiz olarak tespit edilmiştir.

Çizelge 4.5. Regresyon analizi Anova testi sonuçları

	<i>P-değeri</i>
Kesişim	0.0000000000003331314
Aktüel Basınç(hPa)	0.000000002914535553
Buharlaşma (mm)	0.246535646475162000
Nispi Nem (%)	0.002697488662792100
Rüzgar Hızı(m÷sn)	0.000166834974606470
Sıcaklık (oC)	0.565908899270477000
Yağış (mm=kg÷m ²)	0.028965916779807900

Çizelge 4.5'te P değerine ait bilgiler yer almaktadır. P-değeri, 0.05'ten küçük olan aktüel basınç, nispi nem, rüzgar hızı ve yağış değişkenleri su seviyesini anlamlı olarak etkilemektedir. P-değeri, 0.005'ten büyük olan buharlaşma ve sıcaklık değişkenlerinin ise su seviyesi üzerinde etkisinin anlamsız olduğu anlaşılmaktadır.

Çizelge 4.6. Regresyon analizi ağırlık katsayıları

	<i>Katsayılar</i>
Sabit Katsayısı (Q)	1.185
AB	-0.631
B	-0.205
NN	-0.575
RH	-0.438
S	0.104
Y	0.321


Regresyon analizi sonucunda oluşan değişken katsayıları Çizelge 4.6'da gösterilmiştir. Hesaplanan bu katsayılar ilgili parametrelerin su seviyesini ne kadar etkilediğini göstermektedir.

$$Y = Q + (-0.631 * AB) + (-0.205 * B) + (-0.575 * NN) + (-0.438 * RH) + (0.104 * S) + (0.321 * Y) \quad (4.1)$$

Çizelge 4.7. Regresyon analizi tahmin sonuçları

<i>Gerçek Su Seviyesi (m)</i>	<i>ÇRA ile Tahmin Edilen Su Seviyesi (m)</i>	<i> GSS- TS (m)</i>
1648.49	1648.07	0.4168
1648.49	1647.98	0.5093
1648.52	1648.00	0.5157
1648.58	1647.95	0.6343
1648.67	1647.95	0.7183
1648.66	1647.99	0.6721
1648.59	1648.03	0.5577
1648.59	1648.01	0.5712
1648.33	1647.97	0.3603

ÇRA denklemi Eş. 4.1'deki gibi oluşturulmuştur. Bu eşitlikte bağımsız değişkenlerin bağımlı değişken üzerindeki etkileri tespit edilmiştir. Örneğin sıcaklık değişkeninin bir birimlik değişimi su seviyesini 0.104 değerinde değiştirecektir. Buradaki katsayılar kullanılarak ilgili parametre değerleri eşitlikte yerlerine yazıldığında su seviyesi değeri hesaplanmaktadır. Çizelge 4.2'de yer alan test adet verileri kullanılarak bu denklem ile su seviyesi tahmin edilmiştir. Çizelge 4.7'de bu verilere ait çıktı değeri olarak gerçek ve ÇRA modeli tarafından tahmin edilen su seviyeleri, bu seviyelere ait sapmalar gösterilmiştir. Örneğin herhangi bir dönemde ölçülmüş olan gerçek su seviyesi 1648.49 iken o döneme ait meteorolojik parametreler kullanılarak bu değer ÇRA modeli sonucunda 1648.07 olarak tahmin edilmiştir. Bu değer ile gerçek su seviyesi değeri arasındaki fark ise 0.4168 olarak belirlenmiştir.



Şekil 4.8. Gerçek ve tahmin edilen su seviyelerinin karşılaştırılması.

Gerçek ve ÇRA modeli tarafından tahmin edilen su seviyesine ait değerler Şekil 4.8’de grafiksel olarak karşılaştırılmıştır. Bu grafikte gerçek su seviyesi ve ÇRA ile tahmin edilen su seviyesi değerleri arasındaki farkı gösterilmektedir.

4.3. YSA ve ÇRA Modellerinin Karşılaştırılması

Çalışma kapsamında 216 adet aynı veri seti kullanılarak YSA ve ÇRA ile iki farklı model geliştirilmiştir. Çizelge 4.8’ de iki modele ait performans sonuçları gösterilmektedir. Modellerin geliştirilmesi tamamlandığında YSA ve ÇRA için R değeri sonuçları sırasıyla 0.88 ve 0.50, MAPE değeri sonuçları 0.34 ve 3.34, MAD değeri sonuçları ise 0.57 ve 0.10 olarak bulunmuştur. Bu sonuçlara göre YSA ile geliştirilen modelin hata payı % 0.34, ÇRA’nın hata payı % 3.34 olarak hesaplanmıştır. YSA ile geliştirilmiş olan modelin mutlak ortalama sapması 0.05, ÇRA’nın ise 0.10 olarak bulunmuştur. MAD sonuçlarına göre YSA’nın ÇRA modeline göre gerçek su seviyesine daha yakın değerler tahmin ettiği tespit edilmiştir. Değişkenler arasındaki ilişki düzeyinin ölçülmesi için her iki modelin R sonuçları karşılaştırılmıştır. Karşılaştırma sonuçlarına göre YSA ile oluşturulan modelin değişkenler arasındaki ilişkisi ÇRA ile geliştirilen modele göre oldukça fazla olduğu tespit edilmiştir. Bu değer her zaman 1’e yakın değerler olması istenilmektedir.

Çizelge 4.8. YSA ve ÇRA performans sonuçları

<i>Performans</i>	<i>YSA</i>	<i>ÇRA</i>
R	0.88	0.50
MAPE (%)	0.34	3.34
MAD	0.05	0.10

Geliştirilen modeller, 9 adet aynı veri seti ile su seviyesini tahmin ederek test edilmiştir. Test sonuçları ile ortaya çıkan su seviyesi tahmin değerleri, gerçek su seviyesi değerleri ile karşılaştırılmıştır.

Çizelge 4.9. YSA ve ÇRA karşılaştırma

<i>Gerçek Su Seviyesi</i>	<i>YSA Su Seviyesi</i>	<i>ÇRA Su Seviyesi</i>	<i> GS-YSA </i>	<i> GS-ÇRA </i>
1648.49	1648.41	1648.07	0.0713	0.4168
1648.49	1648.42	1647.98	0.0721	0.5093
1648.52	1648.46	1648.00	0.0650	0.5157
1648.58	1648.57	1647.95	0.0120	0.6343
1648.67	1648.59	1647.95	0.0733	0.7183
1648.66	1648.53	1647.99	0.1341	0.6721
1648.59	1648.56	1648.03	0.0276	0.5577
1648.59	1648.56	1648.01	0.0297	0.5712
1648.33	1648.36	1647.97	0.0284	0.3603

Gerçek su seviyesi değerleri, her iki modelden elde edilen tahmin sonuçları, gerçek değerler ile tahmin sonuçlarının arasındaki mutlak değer farkları Çizelge 4.9’da gösterilmektedir. Örneğin herhangi bir dönemde ölçülmüş olan gerçek su seviyesi 1648.49 iken o döneme ait meteorolojik parametreler kullanılarak bu değer YSA modeli sonucunda 1648.41, ÇRA modeli sonucunda ise 1648.07 olarak tahmin edilmiştir. YSA modelinin tahmin etmiş olduğu değer ile gerçek su seviyesi değeri arasındaki mutlak fark 0.0713, ÇRA modelinin tahmin etmiş olduğu değer ile gerçek su seviyesi değeri arasındaki fark ise 0.4168 olarak belirlenmiştir. Bu iki fark karşılaştırıldığında YSA ile geliştirilmiş olan model ÇRA ile geliştirilen modele göre gerçek veriye daha yakın değerler ortaya koyduğu tespit edilmiştir.

5. SONUÇ

Bu çalışmada, YSA ve ÇRA yöntemleri ile kurulan modellerin doğrusal olarak tahmin etme performansları karşılaştırılmıştır. İstatistiksel bir çalışma olan bu tezde meteorolojik etmenlerin Van Göl su seviyesi üzerine etkileri YSA ve ÇRA yöntemleri ile tespit edilmiştir. Bu modellerin performansları karşılaştırılarak en iyi performansı sağlayan model belirlenmiştir. Çalışmada kullanılan yağış, buharlaşma, aktüel basınç, rüzgar hızı, sıcaklık, nispi nem ve göl su seviyesi verileri Van ili sınırları içerisinde yer alan Meteoroloji 14. Bölge Müdürlüğü ve DSİ 17. Bölge Müdürlüğü'ne ait çeşitli ölçüm istasyonlarından temin edilmiştir.

Elde edilen veri setine göre YSA'nın uygun ağ yapısını oluşturmak için çeşitli literatür taramaları yapılmış ve edinilen bilgiler doğrultusunda birçok denemeler yapılmıştır. Sonuç olarak en uygun ağ mimarisi bulunmuştur. Bu ağ mimarisi oluşturulurken geri yayımlı çok katmanlı bir ağ tercih edilmiştir. TANSİG fonksiyonu, ağırlıkların belirlenmesinde kullanılan aktivasyon fonksiyonu olarak seçilmiştir. Matlab' da yer alan eğitim fonksiyonları arasından "TRAINLM (Levenberg-Marquardt)" fonksiyonu seçilmiştir. Ağı eğitimi için 216 veri seti kullanılırken, ağı test edilmesi için 9 veri seti kullanılmıştır. YSA ile yapılan tahmin sonucunda MAPE değeri 0'a çok yakın 0.34 bulunmuş yani %0.34 hata payı oluşmuştur. Bu değer %10'nun altında olduğu için oluşturulan tahmin modeli yüksek doğruluk değerine sahiptir. Ayrıca başka bir değerlendirme yöntemi olan MAD değeri ise 0.05 olarak bulunmuştur. Bu model ile yapılan hesaplamalar sonucunda belirlilik katsayısı (R) %88,94, R^2 ise %79,10 olarak belirlenmiştir. Yani R^2 değeri, çıkış değişkenindeki toplam değişimin %79,10'nun çıkış değişkenleri tarafından açıklandığını göstermiştir.

Ayrıca ÇRA yöntemi ile de su seviyesi tahmini yapılarak, geliştirilen modelin sonucunda MAPE değeri 3.34 olarak bulunmuştur yani %3. hata payı oluşmuştur. Bu değer %10'nun altında olduğu için oluşturulan tahmin modeli yüksek doğruluk değerine sahiptir. Ayrıca başka bir değerlendirme yöntemi olan MAD değeri ise 0.10 olarak bulunmuştur. Bu model ile yapılan hesaplamalar değerlendirildiğinde ise R %49,83 ve R^2 %24,83 olarak belirlenmiştir.

MAPE (Mean Absolute Percent Error), tahmin modeli gerçek değerleri kullanırken başka bir tahmin modeli doğal logaritma değerlerini kullandığından performans ölçüm istatistiği olarak değerlendirilmiştir. Buna göre her iki modelin hesaplama ve test sonuçları incelendiğinde YSA ile geliştirilmiş olan modelin ÇRA ile geliştirilen modele göre daha iyi bir tahmin başarısı elde ettiği gözlemlenmiştir. Bunun nedeni YSA'ların kendilerini eğitebilmeleri ve eksik, bozuk gibi verilerle tahmin yapabilmeleridir.

YSA'lar ve RA arasında çeşitli birçok fark bulunmaktadır. Bunlar, RA'nın matematiksel bir modele uygun olması ve varsayımlarla modellenenebilmesi gibi farklılıklar şeklindedir. Ancak YSA'larda varsayımlar yoktur, birçok olayı kendilerini eğiterek sonuçlandırabilir ve daha önce görülmemiş örnekler hakkında bilgi üretebilirler. YSA'lar eğitimleri sırasında kendilerine verilen örneklerden genellemeler yapmakta ve bu genellemelerle yeni örnekler hakkında bilgi üretebilmektedir.

Çalışmada kullanılan parametrelerin dışında göle giren akım değerleri ve gölden çıkan akım değerleri de göl su seviyesini tahmin etmek için etkili olmaktadır. Bu parametrelere ait verilerin elde edilmesi ve Van Gölü su seviyesi tahminlerinin daha güvenilir olması açısından oldukça önemlidir. Bu nedenle bu çalışmayı daha ileriye taşımak için su seviyesini etkileyen diğer sayısal veriler kullanılarak uzman bir YSA ile su seviyesi tahminleri yapılabilir. YSA tahmin çalışmalarının göl su seviyesinde yalnız zamansal değil alansal da yapılabilceği gözlemlenmiştir.

Bu çalışmanın amacı doğrultusunda YSA ve ÇRA modelleri karşılaştırılmış olup YSA'nın meteorolojik parametreler ile Van Gölü su seviyesi modellemesine başarıyla uygulanabileceği ve geleneksel RA'ya göre çok daha iyi sonuçlar vereceği gösterilmiştir. Ancak bu sonuçlara rağmen yöntemin başarısı yeterli verinin bulunmasına ve meteorolojik parametreler dışında su seviyesini etkileyen farklı parametrelerin varlığına bağlıdır. Bundan dolayı veri toplama ve toplanan veriyi işleme sistematik bir şekilde sağlanmalıdır. Örnek olarak bu çalışmada kullanılan meteorolojik verilerin yanı sıra su seviyesine etki eden farklı veriler de kullanılabilirdi. Ancak veri elde etmedeki zorluklar bunu mümkün kılmamıştır. Buna rağmen elde edilen verilerle başarılı bir uygulama gerçekleştirilmiştir.

KAYNAKLAR

- Ağyar, Z., 2015. Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. **Mühendis ve Makina**, 56 (662): 22-23.
- Akbulut, İ., Özcan, B., 2020. Hava Kirliliği Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. **Kocaeli Üniversitesi Fen Bilimleri Dergisi**, 3 (1): 12-22.
- Akgül, Y., 2016. **Doğrusal Regresyon, Bulanık Doğrusal Regresyon ve Bulanık Hedef Programlama Yöntemleri ile Türk Sigorta Sektöründe Mali Yeterlilik Tahmin Analizi** (doktora tezi, basılmamış). CÜ, Sosyal Bilimler Enstitüsü, Sivas.
- Al-Hamdi, H. M., Soliman, S. A., 2004. Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model. **Electric Power Systems Research**, 68 (1): 47-59.
- Altunkaynak, A., Şen, Z., 2007. Fuzzy logic model of lake water level fluctuations in Lake Van, Turkey. **Theoretical and Applied Climatology**, 90 (3): 227-233.
- Anderson, D., McNeill, G., 1992. **Artificial Neural Networks Technology**. Rome Laboratory, Yay. No: A011, ABD. 177.
- Ataseven, B., 2013. Yapay Sinir Ağları ile Öngörü Modellemesi. **Öneri Dergisi**, 10 (39): 101-115.
- Babayiğit, E., Babayiğit, B., Çobaner, M., 2016. Meteorolojik Veriler Kullanılarak Yeraltı Su Seviyesinin Genetik Programlama ile Tahmini. **Niğde Üniversitesi Mühendislik Bilimleri Dergisi**, 5 (2): 177-187.
- Baş, N., 2006. **Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama** (yüksek lisans tezi, basılmamış). MSÜ, Fen Bilimleri Enstitüsü, İstanbul.
- Bayır, F., 2006. **Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama** (yüksek lisans tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Fatih, İstanbul.
- Baytak, D., Sofuoğlu, S. C., Alkan, O., Elbir, T., 2013. Karayolu Trafikinden Kaynaklanan Kirlenici Seviyelerinin Yapay Sinir Ağları ile Tahmin Edilmesi. **Hava Kirliliği Araştırmaları Dergisi**, 1 (1): 28-35.
- Berry, W., 1993. **Understanding Regression Assumptions**. 1.Basım. SAGE Publications, Inc, Amerika Birleşik Devletleri. 97.
- Biswas, R. K., Jayawardena, A. W., Takeuchi, K., 2019. Prediction of Water Levels in the Surma River of Bangladesh by Artificial Neural Network. **22nd Annual Conference (2009), Japan Society of Hydrology and Water Resources**. 29 Haziran-1 Temmuz 2009, Kanazawa. 17.
- Can, M., 2012. **Yapay Sinir Ağları ile Akım Tahmini: Mahmudiye Göleti Örneği** (yüksek lisans tezi, basılmamış). İKÜ, Fen Bilimler Enstitüsü, İstanbul.
- Caner, M., Akarslan, E., 2009. Mermer Kesme İşleminde Spesifik Enerji Faktörünün ANFIS ve YSA Yöntemleri ile Tahmini. **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, 15(2): 221-226.
- Castillo, J. M. M., Cspedes, J. M. S., Cuchango, H. E. E., 2018. Water Level Prediction Using Artificial Neural Network Model. **International Journal of Applied Engineering Research**, 13(19): 14378-14381.
- Çalım, M. M., 2008. **Yapay Sinir Ağları Yöntemi ile Baraj Hazne Kotu Tahmini** (yüksek lisans tezi, basılmamış). MKÜ, Fen Bilimler Enstitüsü, Hatay.
- Çayıroğlu, İ., 2015. Görüntü İşleme 11.Hafta-Yapay Sinir Ağları. http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme

- [Ders Notlari-11.Hafta.pdf](#). Karabük Üniversitesi Mühendislik Fakültesi, Kars. Erişim tarihi: 04.03.2022.
- Damla, Y., 2020. *Yalova Gökçe Barajının Su Seviyesinin Yapay Sinir Ağları ile Tahmin Edilmesi* (yüksek lisans tezi, basılmamış). KÜ, Fen Bilimleri Enstitüsü, Kırklareli.
- Dase R. K., Pawar D. D., 2010. Application of Artificial Neural Network for stock market predictions: A review of literature. *International Journal of Machine Intelligence*, 2 (2): 14-17.
- Demirhan, A., Kılıç, Y. A., İnan, G., 2010. Tıpta Yapay Zeka Uygulamaları. *Yoğun Bakım Dergisi*, 9 (1): 31-41.
- Demuth, H., Beale, M., 2004. *Neural Network Toolbox User's Guide*. Fourth edition. The MathWorks, Natick. 846.
- Elmas, Ç., 2012. *Yapay Zeka Uygulamaları, Yapay Sinir Ağları – Bulanık Mantık–Genetik Algoritma*. Fifth edition. Seçkin Yayıncılık, Yay. No: 54, Ankara. 480.
- Eriş, M., 2018. *Derin Öğrenme Yöntemleri Kullanarak Adli Bilişim İncelemelerinde Delil Çıkarımının Gerçekleştirilmesi* (yüksek lisans tezi, basılmamış). FÜ, Fen Bilimleri Enstitüsü, Elazığ.
- Ersoy E., Karal Ö., 2012. Yapay Sinir Ağları ve İnsan Beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi II*, 1 (2): 188-205.
- Güngör, E., 2007. *Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi* (yüksek lisans tezi, basılmamış). KÜ, Sosyal Bilimler Enstitüsü, Kocaeli.
- Hamzaçebi, C., 2021. *Matlab Uygulamalı Yapay Sinir Ağları*. Second edition. Seçkin Akademik ve Mesleki Yayınları, Türkiye. 256.
- Hamzaçebi, C., Kutay, F., 2004. Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19 (3): 227-233.
- Haykin, S., 2005. *Neural Networks: A Comprehensive Foundation*, Ninth edition Prentice-Hall, Upper Saddle River, NJ., 30-52.
- He, Q., Si, J., Tylavsky, D., 2000. Prediction of top-oil temperature for transformers using neural networks. *IEEE Transactions on Power Delivery*, 15 (4): 1205-1211.
- Hin, L. Z., Othman Z., 2019. Lake Chini Water Level Prediction Model using Classification Techniques. *Computational Science and Technology*. 29-30 Ağustos 2019, Kota Kinabalu. 215-226.
- Hines, W.W., Montgomery, D.C., 1990. *Probability and Statistics in Engineering and Manavgement Science*. 1.Basım. John Wiley & Sons, Amerika Birleşik Devletleri. 752.
- İspir, E., 2017. *Hatay Amik Ovası Kumlu Bölgesindeki Yeraltı Suyu Seviyesinin Yapay Sinir Ağları Yöntemi ile Tahmini* (yüksek lisans tezi, basılmamış). İTÜ, Fen Bilimler Enstitüsü, Hatay.
- James, G., Witten, D., Hastie, T., Tibshirani, R., 2021. *An Introduction to Statistical Learning: with Applications in R*. First edition. Springer, Almanya. 612.
- Karaatlı, M., Helvacıoğlu, Ö., Ömürbek, N., 2012. Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8 (17): 87-100.
- Kartalopoulos, S., 1995. *Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications*. Secon edition. Wiley-IEEE Press, Amerika Birleşik Devletleri. 232.

- Kaya, İ., Oktay, S., Demirkoparan, F., 2010. Ham Petrol Fiyatlarının Yapay Sinir Ağları ile Tahmini. *Ege Akademik Bakış*, **10** (2): 559-573.
- Keskenler M.F., Keskenler E.F., 2017. Geçmişten Günümüze Yapay Sinir Ağları. *Takvim-i Vekayi*, **5** (2): 8-18.
- Kılıç, S., 2013. Doğrusal Regresyon Analizi. *İstatistiki İfadeyle*, **3**(2): 90-92.
- Kızılaslan, M. A., Doğan, E., Demir, F., Sönmez., Çeribaşı, G., 2014. Daily Water Level Estimation of Lake Iznik Using Artificial Neural Networks. *International Civil Engineering Architecture Symposium for Academicians*. 17-20 Mayıs 2014, Antalya. 1-5.
- Kızılırmak, B., 2022. Doğrusal Regresyon Modeline Matris Yaklaşımı. <http://kisisel.ankara.edu.tr/politics.ankara.edu.tr/burca/ekonometri/6-%20Matris.pdf>. Ankara Üniversitesi Siyasal Bilgiler Fakültesi, Ankara. Erişim tarihi: 04.07.2022.
- Kohonen, T., 1990. The Self-organizing Map. *Proceedings of the IEEE*, **78** (9): 1464-1480.
- Kökçam, A. H., Doğan, E., Erden, C., 2018. Meriç Nehri Akımlarının Yapay Sinir Ağları ile Tahmini. *ISHAD2018*, **1** (1): 796-802.
- Mackay, C., David, J., 1992. Bayesian Interpolation. *Computation and Neural Systems, California Institute of Technology*, **139** (74): 415-447.
- MathWorks, 2022. Matlab. <https://www.mathworks.com/products/Matlab.html>. The MathWorks, Inc., United States. Erişim tarihi: 02.11.2022.
- Mayılvganan, M. K., Naidu, K. B., 2011. Application of Artificial Neural Network for the Prediction of Groundwater Level in Hard Rock Region. *International Conference on Computational Science, Engineering and Information Technology*. 23-25 Eylül 2011, Tirunelveli. 673-682.
- Nabiyeve, V., 2021. *Yapay Zeka*. 6. Basım. Seçkin Yayıncılık, Ankara. 816.
- Sağıroğlu, Ş., Erler, M., Beşdok, E., 2003. *Mühendislikte Yapay Zeka Uygulamaları 1 / Yapay Sinir Ağları*. First edition. Ufuk Kitap, Kayseri. 426.
- Neter, J., Wasserman, W., Kutner, M.H., 1983. *Applied Linear Regression Models*. 1. Basım. Irwin Inc, Amerika Birleşik Devletleri. 547.
- Nguyen, H.H., 2007. *A neural fuzzy approach to modeling the thermal behaviour of power transformer* (yüksek lisans tezi, basılmamış). Victory University, School of Electrical Engineering Faculty of Health, Engineering & Science, Avustralya.
- Okutkan, C., 2014. *Borsa İstanbul Şirketlerinin Hisse Senedi Getirilerinin Yapay Sinir Ağları ve Çoklu Regresyon Yöntemleri Kullanarak Analizi* (yüksek lisans tezi, basılmamış). KÜ, Fen Bilimler Enstitüsü, Kocaeli.
- Öztemel, E., 2016. *Yapay Sinir Ağları*. 3. Basım. Papatya Bilim, İstanbul. 232.
- Öztürkcan, M., 2009. *Regresyon Analizi*. First edition. Maltepe Üniversitesi Yayınları, Türkiye. 119.
- Piasecki, A., Jurasz, J., Skowron R., 2015. Application of artificial neural networks (ANN) in Lake Drwęckie water level modelling. *Sciend*, **15** (1): 21-30.
- Rosenblatt F., 1958. The Perceptron: A Probabilistic Model For Information Storage And Organization In The Brain. *Psychological Review*, **65** (6): 386-408.
- Saraç, T., 2004. *Yapay Sinir Ağları* (Seminer Projesi). Gazi Üniversitesi, Endüstri Mühendisliği Bölümü, Ankara.

- Sarı, M., 2016. *Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması* (yüksek lisans tezi, basılmamış). SÜ, Fen Bilimleri Enstitüsü, Sakarya.
- Sönmez Çakır, F., 2020. *Yapay Sinir Ağları Matlab Kodları ve Matlab Toolbox Çözümleri*. 3.Basım. Nobel Akademik Yayıncılık, Yay. No: 2104, Türkiye. 108.
- Uğur, L. O., 2007. *Yapı Maliyetinin Yapay Sinir Ağı ile Analizi* (doktora tezi, basılmamış). GÜ, Fen Bilimler Enstitüsü, Ankara.
- Vurşan, H., 2017. *Beton Çelik Çubuklarında Mukavemet Özelliklerinin Yapay Sinir Ağları ve Çoklu Regresyon Yöntemleri ile Tahmini* (yüksek lisans tezi, basılmamış). KÜ, Fen Bilimler Enstitüsü, Karabük.
- Yarar, A., Onüçyıldız, M., 2009. Yapay Sinir Ağları ile Beyşehir Gölü Su Seviyesi Değişimlerinin Belirlenmesi. *Selçuk Üniversitesi Mühendislik Bilim ve Teknoloji Dergisi*, 24 (2): 21-30.
- Yıldız, M. Z., 2005. Kapalı Havza Göllerinde Seviye Değişimlerinin Kıyı Yerleşmelerine Etkisi: Van Gölü Örneği. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 15 (1): 15-31.
- Yılmaz, B., 2009. *Finansal Analizde Yapay Zeka*. 1.Basım. Detay Yayıncılık, Ankara. 296.
- Yurtoğlu, H., 2005. *Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği* (Uzmanlık Tezi). Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Ankara.
- Yüksek, A. G., 2006. *Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağları Yönteminin Karşılaştırılması* (doktora tezi, basılmamış). CÜ, Sosyal Bilimleri Enstitüsü, Sivas.
- Yüzük, F., 2019. *Çoklu Regresyon Analizi ve Yapay Sinir Ağları ile Türkiye Enerji Talep Tahmini* (yüksek lisans tezi, basılmamış). CÜ, Sosyal Bilimler Enstitüsü, Sivas.
- Zhang, G., Patuwo, B., Hu, Y., 1998. Forecasting with Artificial Neural Networks. *The State of The Art. International Journal of Forecasting*, 14 (1): 35-62.
- Wen, J., Han, P. F., Zhou, Z., Wang, X. S., 2018. Lake-Level Prediction Leveraging Deep Neural Network. *13th International Conference, QShine 2017*. 16-17 Aralık 2017, Dalian. 23-32.
- Widrow, B., Hoff M.E., 1960. Adaptive switching circuits. *IRE WESCON Convention Record*, 94-104

ÖZ GEÇMİŞ

Ortaöğretimini Van Anadolu Teknik Lisesi'nde tamamladı. 2014 yılında Burdur Mehmet Akif Ersoy Üniversitesi Yönetim Bilişim Sistemleri bölümünü kazandı ve 2018 yılında mezun oldu.

2014 yılından beri çeşitli kurumların bilgi işlem departmanlarında çalışmıştır. Mayıs 2018'de Van Su ve Kanalizasyon İdaresi Genel Müdürlüğü'nde bilişim sistemleri uzmanı olarak çalışmaya başladı ve halen devam etmektedir. 2018 yılından itibaren Türkiye Bilişim Derneği Van Şubesi'nde Yönetim Kurulu Üyesi olarak görev yapmaktadır. 2020 yılında Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü İstatistik Ana Bilim Dalı'nda yüksek lisan öğrenimine başladı. Yapay sinir ağları, veri madenciliği, mobil ve web uygulamalar ile alakalı çalışmalar yapmaktadır.

**VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ FEN BİLİMLERİ
ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU**

Tarih: 03/01/2022

Tez Başlığı / Konusu: Van Gölü Su Seviyesi Değişiminin Yapay Sinir Ağları ile Tahmini

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 91 sayfalık kısmına ilişkin, 03/01/2022 tarihinde şahsım/tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 12 (yüzde on iki) dır.

Uygulanan filtreler aşağıda verilmiştir:

- Materyal ve yöntem hariç,
- Kaynaklar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimedenden daha az örtüşme içeren metin kısımları hariç (Eşleme boyutunu 7 kelimeyle sınırlayın)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

Furkan SİDAL
03/01/2022
Tarih ve İmza

Adı Soyadı: Furkan SİDAL Öğrenci

No: 19910001404

Anabilim Dalı: İstatistik A.B.D.

Programı: İstatistik

Statüsü: ☐ Yüksek Lisans ☐ Doktora

Doç. Dr. Yener ALTUN
DANIŞMAN ONAYI
UYGUNDUR

ENSTİTÜ ONAY
UYGUNDUR