

SU ÜRÜNLERİ SEKTÖRÜNDE YAPAY SİNİR AĞLARI UYGULAMALARI

MEHMET ÖZSOY



SU ÜRÜNLERİ SEKTÖRÜNDE YAPAY SİNİR AĞLARI UYGULAMALARI

MEHMET ÖZSOY

EĞİTİM
yayınevi

SU ÜRÜNLERİ SEKTÖRÜNDE YAPAY SİNİR AĞLARI UYGULAMALARI

Mehmet Özsoy

Genel Yayın Yönetmeni: Yusuf Ziya Aydoğan (yza@egitimyayinevi.com)

Genel Yayın Koordinatörü: Yusuf Yavuz (yusufyavuz@egitimyayinevi.com)

Sayfa Tasarımı: Eğitim Yayınevi Grafik Birimi

Kapak Tasarımı: Eğitim Yayınevi Grafik Birimi

T.C. Kültür ve Turizm Bakanlığı

Yayıncı Sertifika No: 47830

E-ISBN: 978-625-6489-20-2

1. Baskı, Haziran 2023

Kütüphane Kimlik Kartı

SU ÜRÜNLERİ SEKTÖRÜNDE YAPAY SİNİR AĞLARI UYGULAMALARI

Mehmet Özsoy

81 s., 160x240 mm

Kaynakça var, dizin yok.

E-ISBN: 978-625-6489-20-2

Copyright © Bu kitabın Türkiye'deki her türlü yayın hakkı Eğitim Yayınevi'ne aittir. Bütün hakları saklıdır. Kitabın tamamı veya bir kısmı 5846 sayılı yasanın hükümlerine göre kitabı yayımlayan firmanın ve yazarlarının önceden izni olmadan elektronik/mekanik yolla, fotokopi yoluyla ya da herhangi bir kayıt sistemi ile çoğaltılamaz, yayımlanamaz.

EĞİTİM
yayınevi

Yayınevi Türkiye Ofis: İstanbul: Eğitim Yayınevi Tic. Ltd. Şti., Atakent mah. Yasemen sok. No: 4/B, Ümraniye, İstanbul, Türkiye

Konya: Eğitim Yayınevi Tic. Ltd. Şti., Fevzi Çakmak Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye
+90 332 351 92 85, +90 533 151 50 42, 0 332 502 50 42
bilgi@egitimyayinevi.com

Yayınevi Amerika Ofis: New York: Egitim Publishing Group, Inc. P.O. Box 768/Armonk, New York, 10504-0768, United States of America
americaoffice@egitimyayinevi.com

Lojistik ve Sevkiyat Merkezi: Kitapmatik Lojistik ve Sevkiyat Merkezi, Fevzi Çakmak Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye
sevkiyat@egitimyayinevi.com

Kitabevi Şubesi: Eğitim Kitabevi, Şükran mah. Rampalı 121, Meram, Konya, Türkiye
+90 332 499 90 00
bilgi@egitimkitabevi.com

İnternet Satış: www.kitapmatik.com.tr
+90 537 512 43 00
bilgi@kitapmatik.com.tr

 **kitapmatik**
İnternetteki kitabınız

İÇİNDEKİLER

TABLOLAR DİZİSİ.....	V
ŞEKİLLER DİZİSİ.....	V
KISALTMALAR.....	VI
ÖNSÖZ.....	VII
GİRİŞ.....	8

BİRİNCİ BÖLÜM TAHMİN YÖNTEMLERİ

1.1. Tahminin Tanımı ve İlkeleri.....	11
1.2. Tahmin Yöntemleri.....	13
1.2.1. Kalitatif Tahmin Yöntemleri.....	14
1.2.1.1. Delphi Yöntemi.....	15
1.2.1.2. Satış Elemanları ve Ürün Hattı Yöneticileri ile Tahmin.....	16
1.2.1.3. Pazar Araştırması.....	16
1.2.2. Kantitatif Tahmin Yöntemleri.....	17
1.2.2.1. Regresyon Yöntemi.....	17
1.2.2.2. Korelasyon Yöntemi.....	18
1.2.2.3. Zaman Serisi Analizleri.....	20
1.2.2.3.1. Ortalama Yöntemleri.....	20
1.2.2.3.2. Üstel Düzleştirme Yöntemi.....	22
1.2.2.3.3. Box-Jenkins Yöntemi.....	22

İKİNCİ BÖLÜM YAPAY SİNİR AĞLARI

2.1. Biyolojik Sinir Hücresi.....	24
2.2. Yapay Sinir Hücresi.....	25
2.2.1. Yapay Sinir Hücresinin Elemanları.....	27
2.2.1.1. Girdiler.....	27
2.2.1.2. Çıktılar.....	28
2.2.1.3. Ağırlıklar.....	28
2.2.1.4. Toplam Fonksiyonu.....	28
2.2.1.5. Aktivasyon Fonksiyonu.....	29

2.3. Yapay Sinir Ağlarındaki Katmanlar	34
2.3.1. Girdi Katmanı	34
2.3.2. Gizli Katman	34
2.3.3. Çıktı Katmanı.....	35
2.4. Yapay Sinir Ağlarının Sınıflandırılması	35
2.4.1. Tiplerine Göre Yapay Sinir Ağları	36
2.4.2. Katman Sayılarına Göre Yapay Sinir Ağları.....	38
2.4.3. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları	40
2.5. Yapay Sinir Ağlarında Öğrenme Kuralları.....	42
2.5.1. Hebb Kuralı	42
2.5.2. Hopfield Kuralı	43
2.5.3. Delta Kuralı.....	43
2.5.4. Kohonen Kuralı.....	43
2.6. Yapay Sinir Ağlarının Avantaj ve Dezavantajları.....	44
2.6.1. Yapay Sinir Ağlarının Avantajları	44
2.6.2. Yapay Sinir Ağlarının Dezavantajları	45

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI YÖNTEMİ İLE TÜRKİYE SU ÜRÜNLERİ SEKTÖRÜNDE BİR TAHMİN UYGULAMASI

3.1. Su Ürünleri Sektörü	46
3.2. Dünya'da Su Ürünleri Sektörü	48
3.3. Türkiye'de Su Ürünleri Sektörü.....	51
3.4. Araştırmanın Amacı ve Önemi.....	55
3.5. Araştırmanın Sınırlamaları.....	55
3.6. Tahmin Yönteminin Seçimi	55
3.7. Literatür Taraması.....	56
3.8. Verilerin Toplanması ve Düzenlenmesi.....	63
3.9. Model Tasarımı	66
3.10. Modelin Eğitimi	69
3.11. Bulgular.....	69
SONUÇ VE ÖNERİLER	73
KAYNAKÇA	75

TABLolar DİZİSİ

Tablo 2.1: Yapay Sinir Hücresinin Elemanları ve Görevleri.....	26
Tablo 3.1: Yıllara Göre Dünya Su Ürünleri Üretimi (Avcılık)	50
Tablo 3.2: Yıllara Göre Dünya Su Ürünleri Üretimi (Yetiştiricilik)	51
Tablo 3.3: Türkiye Su Ürünleri Üretim Miktarları.....	52
Tablo 3.4: Türkiye Su Ürünleri Dış Ticaret Verileri	54
Şekil 3.5: Türkiye Nüfusu Yıllık Değişimi	65
Tablo 3.5: Farklı Nöron Sayılarına Göre Oluşturulan Yapay Sinir Ağı Modelleri	66
Tablo 3.6: Yıllık YSA Tahmin Değerleri ve Gerçekleşen Değerler	70
Tablo 3.7: Gizli Nöron Sayılarına Göre YSA'ların Hata Oranları	72

ŞEKİLLER DİZİSİ

Şekil 1.1: Tahmin Yöntemlerinin Sınıflandırılması.....	14
Şekil 1.2: En Küçük Kareler Yöntemi	18
Şekil 1.3: Korelasyon Katsayılarına Göre İlişki Kuvvetleri.....	19
Şekil 2.1: Biyolojik Sinir Hücresi	25
Şekil 2.2: Yapay Sinir Hücresi.....	27
Şekil 2.3: Eşik Fonksiyonu Grafiği	30
Şekil 2.4: Rampa Fonksiyonu Grafiği	31
Şekil 2.5: Sigmoid Fonksiyonu Grafiği.....	32
Şekil 2.6: Tanjant Hiperbolik Fonksiyonu Grafiği.....	33
Şekil 2.7: Sinüs Fonksiyonu Grafiği	33
Şekil 2.8: Tek Gizli Katmanlı YSA Modeli.....	35
Şekil 2.9: İleri Beslemeli Tek Katmanlı Yapay Sinir Ağı	37
Şekil 2.10: İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı	37
Şekil 2.11: Geri Beslemeli Yapay Sinir Ağı	38
Şekil 2.12: Yapay Sinir Ağı Öğrenme Aşamaları	41
Şekil 3.1: Avcılık ve Yetiştiricilik Miktarlarının Yıllar İçindeki Dağılımı.....	49
Şekil 3.2: Su Ürünleri Üretim Miktarları (1970-2020)	63
Şekil 3.3: Su Ürünleri İthalat Verilerinin Yıllık Değişimi.....	64
Şekil 3.4: Su Ürünleri İhracat Verilerinin Yıllık Değişimi.....	64
Şekil 3.6: Oluşturulan YSA Modeli.....	67
Şekil 3.7: Tek Gizli Katmanlı 10 Gizli Nöronlu YSA Modeli R Değerleri.....	68
Şekil 3.8: Su Ürünleri Tahmin Değerleri ve Gerçekleşen Değerler	71
Şekil 3.9: Model Tahmininin Hata Dağılımı	71

KISALTMALAR

APE: Ortalama Yüzde Hata

BSGM: Balıkçılık ve Su Ürünleri Genel Müdürlüğü

EKK: En Küçük Kareler

FAO: Birleşmiş Milletler Gıda ve Tarım Örgütü

MAPE: Ortalama Mutlak Yüzde Hata

RMSE: Kareler Ortalamasının Karekökü

TÜİK: Türkiye İstatistik Kurumu

YSA: Yapay Sinir Ağı

ÖNSÖZ

Bu çalışmanın tüm aşamalarında desteğini esirgemeyen hem akademik hem de sosyal anlamda beni her zaman doğru yönlendiren kıymetli hocalarım Prof. Dr. Mustafa Zihni TUNCA ve Doç. Dr. Yakup AKGÜL'e teşekkürlerimi sunarım.

Hayatımın her aşamasında her ne olursa olsun beni gitmem gereken istikamete yönlendiren ve bu yolda hiçbir zaman desteklerini esirgemeyen aileme de sonsuz teşekkürler.

Mehmet ÖZSOY

ISPARTA, 2023

Bu kitap; Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü İşletme Programı kapsamında tamamlanmış ve onaylanmış olan ve danışmanlığını Prof. Dr. Mustafa Zihni TUNCA ve ikinci danışmanlığını Doç. Dr. Yakup AKGÜL'ün yaptığı "Su Ürünleri Üretiminin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi Üzerine Bir Uygulama" isimli tezden üretilmiştir.

GİRİŞ

Yeryüzünün yaklaşık %71'i sularla kaplıdır. Bu suların büyük bir bölümünde çok sayıda su canlısı yaşamaktadır. İnsanlar bu su canlılarından tarih boyunca yararlanmışlar ve besin kaynağı olarak kullanmışlardır.

Yapılan son araştırmalara göre 2023 yılı dünya nüfusu 8 milyar civarındadır. Bu sayının 2050 yılında 10 milyara yaklaşması beklenmektedir. Dünyadaki bu nüfus artışı beraberinde beslenme sorunlarını da getirmektedir. Dünya'da yaklaşık 800 milyon insan beslenme yetersizliği çekmektedir. Bu durum eldeki kıt kaynakların daha verimli kullanılmasını geçmişe göre çok daha önemli bir hale getirmiştir. Beslenme ile ilgili en önemli hususlardan birisi de insanların yeterli protein miktarını alabilmeleridir. Su ürünlerinin hem sağlıklı beslenme hem de zengin bir protein kaynağı olduğu bilinmektedir.

1950'li yıllardan bu yana su ürünleri sektörü gelişmeye devam etmektedir. Her yıl hacimsel olarak artış gösteren sektör hem ekonomik anlamda hem de insanların sağlıklı besine ulaşımını kolaylaştırma anlamında çok büyük bir büyük potansiyele sahiptir. 2020 yılında toplam su ürünleri üretimi miktarı 178 milyon ton civarında olduğu gözlemlenmiştir. Bu miktarın %49'unu yetiştiricilik, %51'ini ise avcılık oluşturmaktadır. Yine 2020 yılındaki su ürünlerinden elde edilen gelir yaklaşık olarak 406 milyar dolar civarındadır (FAO, 2022).

Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO)'nun yayınladığı veriler doğrultusunda 2020 yılında üretilen su ürünleri miktarının %89'u doğrudan kişi tüketimi için kullanılmıştır. Su ürünlerinin gıda olarak kullanımı 1961 yılından bu yana her yıl bir önceki yıla göre ortalama %3 artış göstermektedir (FAO, 2022). Bu artışın; ülke içi ve dışı dağıtım kanallarının gelişimi, nüfus artışı ve kişilerin ekonomik durumları ile alakalı olduğu düşünülmektedir.

Yıllar içerisinde ilerleyen teknoloji ve uluslararası ticarete sınırların kalkması ile birçok sektör oldukça gelişmiştir. Su ürünleri sektörü de bu sektörlerden bir tanesi olarak gösterilebilir. Su ürünleri yetiştiriciliği veya üreticiliği imkânına sahip olmayan ülkeler/bölgeler bahsi geçen gelişmeler ışığında ürünlere ulaşılabilir hale gelmiştir. Ürünlerin dünya çapında ulaşılabilir hale gelmesi ile de sektör hacminde önemli artışlar meydana

gelmiştir. Yetiştiriciliğin yaygınlaşması ise su ürünlerinin ihracat miktarlarını etkilemektedir.

Sektörün zaman içerisindeki gelişimi sağlıklı beslenme ve kaynakların optimizasyonu noktasında katkı sağlarken aynı zamanda sektör ile ilgilenen ülkeler için istihdam noktasında da çok önemli katkılar sağlamaktadır. Su ürünlerinin kişi tüketimi için kullanılmasının dışında endüstriyel alanda kullanımları da önem arz etmektedir. Su ürünlerinin işlenip gerekli aşamalardan (dondurulması, paketlenmesi vb.) geçtikten sonra iç ve dış piyasaya sunulması daha işlevsel olabilmektedir.

Bahsi geçen faktörler doğrultusunda su ürünleri sektörünün ilerleyen zamanlarında daha da gelişeceği ve ülke ekonomilerine kayda değer katkı sağlayacağı öngörülmektedir. Bu önemi anlayan ve sektöre yatırım yapan ülkeler stratejik politikalar geliştirmektedir.

Su ürünleri sektörü ile ilgili teknolojik gelişmeler insanların sektöre olan ilgisini artırmış ve su ürünlerinin üretimini kolaylaştırmıştır. Bu gelişmeler doğrultusunda sektörde birim zamanda üretilen miktar orantısız bir şekilde artış göstermiştir. Bu artış su ürünleri stoklarını tehlikeye atmış ve ekolojik dengeyi bozma noktasına getirmiştir. Bir stoktan avlanılan miktarın o stoğun yıllık doğal artışını geçmesi kaynağın kendini yenilemesinin önüne geçmekte ve stoğun tükenmesine yol açmaktadır (Şahin, 2002:4). Bu bağlamda sektörde bir planlama ihtiyacı doğmaktadır.

Yapılan çalışmanın birinci bölümünde su ürünleri sektörünün Türkiye ve Dünya'daki durumu ve potansiyelinden bahsedilmiştir. Su ürünleri sektöründe yatırım yapmayı düşünen yatırımcılar ve sektörünün içinde bulunan işletmeler stratejik kararlar alabilmek için güvenilir kaynaklara ihtiyaç duymaktadırlar. Karar verilirken ileriye dönük belirsizliklerin azaltılması amacıyla geçmiş verilerden yararlanılarak tahmin işleminin yapılması karar vericilerin sıklıkla kullandığı yöntemlerden birisi olarak karşımıza çıkmaktadır.

Çalışmanın ikinci bölümünde ise tahmin kavramı, tahmin aşamaları, tahmin periyotları ve tahmin metotları açıklanmıştır. Tahmin işlemleri gerçekleştirilirken araştırmacıların ellerinde ne tür veriler bulunduğu ve verilerin karakteristik özelliklerinin hangi yöntemlere ne derece uygun olduğu önem arz etmektedir. Bu bölümde tahmin yöntemleri kalitatif ve

kantitatif olmak üzere ikiye ayrılmış ve yöntemler açıklanmaya çalışılmıştır. Çalışmanın son bölümünde ise seçilen Yapay Sinir Ağları yöntemi ile ilgili literatür taraması ve yöntemin bulguları sunulmuştur.

BİRİNCİ BÖLÜM

TAHMİN YÖNTEMLERİ

1.1. Tahminin Tanımı ve İlkeleri

Günümüzde gerek kamu kuruluşları gerek özel işletmeler risk ve belirsizlik koşullarına sahip dinamik bir çevrede faaliyet göstermektedirler. Belirsizlik karar verme aşmasında minimuma indirilmek istenen bir durumdur. Tahmin, bu belirsizliği azaltarak karar vericilerin geçmişte toplanan veriler ışığında ileride gerçekleşebilecek bir durumu öngörmesidir. Üretimin birçok aşamasında yapılan işler ile alakalı belirli ölçütlerde tahminleme işlemlerinin yapılmaması o işler için gerekli kaynakları optimize etmeyi ve gerçekçi planlar yapmayı zorlaştırmaktadır (Lewis, 2012:24). Tahminin amacı karar verme riskini azaltmak ve mümkün olan en doğru şekilde gelecek ile ilgili gelişmeleri öngörebilmektir. Tahmin, işletmenin tüm fonksiyonlarında kalitenin iyileştirilmesi ve verimliliğin artırılması için kullanılan en önemli araçlardan biri olarak sayılabilir. Çünkü tahmin sonuçları performans değerlendirmesi yapılırken ve stratejik kararlar alınırken oldukça etkili olmaktadır. Tahminleme geçmiş verilerin, müşterilerin satın alma planlarının veya her ikisinin matematiksel modeller doğrultusunda geleceğe yansıtılmasını içerebilmektedir (Heizer vd., 2016:108).

İşletmelerde, tahmin ile elde edilen veriler stratejik planlama, AR-GE planlamaları, işgücü planlaması, bütçeleme, stok planlaması, finansal planlama, üretim planlama, kapasite planlama gibi süreçlerin temelini oluşturmaktadır (Shim, 2009).

Tahmin işlemi sistematik olarak dört aşama ile gerçekleştirilmektedir. Bunlar (Kobu, 1984:82; Tekin, 2010:229):

- Veri toplanması: Tahmin işleminde kullanılacak olan veriler eksiksiz ve doğru olarak geniş bir pazar araştırması yardımıyla toplanır. Toplanan verilerin kapsamı, cinsi ve detayı belirlenirken hangi amaca yönelik veri toplanacağı göz önünde bulundurulmalıdır. Detaylı bir araştırma gerektiren bir tahmin uygulaması için dar kapsamlı ve az ayrıntılı veriler kullanılması tahmin işleminin güvenilirlik ve geçerliliğini azaltacak ve karar vericilerin yanlış kararlar vermesine sebep olacaktır. Tam tersi durumda ise, fazla detaylı veya ihtiyaç dışı toplanmış veriler araştırmanın maliyetini artıracaktır.
- Tahmin döneminin belirlenmesi: Tahmin işlemi gerçekleştirileceği zaman toplanan verilerin periyodu ile hangi dönem için tahmin yapılacağı önemlidir. Günlük planlara yönelik veriler ile yıllık planların tahmin edilmeye çalışılması karar vericilerin yanlış çıkarımlarda bulunmalarına sebep olacaktır. Günlük verilerdeki dalgalanmalar yıllık verilerin dalgalanmalarını yansıtmayabilir.
- Tahmin yöntemi seçimi ve hata hesaplaması: Toplanan verilerin niteliksel özellikleri tahmin yöntemi seçilirken dikkate alınmalıdır. Çok detay gerektirmeyen operasyonel kararlarda kullanılacak olan tahminler için yüksek maliyetli ve meşakkatli yöntemleri seçmek işletmenin kaynaklarını boşa kullanmasına yol açacaktır.
- Sonuçların geçerliliğinin araştırılması: Toplanan veriler kullanılarak gerçekleştirilen tahmin işleminin sonuçları ile gerçekleşen değerler karşılaştırılmalıdır. Tahmin sonuçlarının gerçekleşen değerlere yakınlığı tahmin işleminin geçerli olup olmadığına karar vermek için kullanılmaktadır.

Tahmin işleminin başlayabilmesi için öncelikle tahmin ihtiyacının ortaya çıkması gerekmektedir. Bir problem doğrultusunda ortaya çıkan tahmin ihtiyacında problemin tam ve doğru tanımlanması önemlidir. Problemin tanımlanması yapılırken “neyi tahmin ediyorum, neden tahmin ediyorum ve hangi dönemde tahmin ediyorum” gibi sorulara cevap aranmalıdır. Bu gibi sorular ile problemin tanımı yapıldıktan sonra veri toplama aşamasına

geçilerek sayısal veya sözel veriler bir araya getirilir. Probleme uygun tahmin dönemi için yine probleme uygun tahmin yöntemi/yöntemleri seçilir, uygun model kurulur ve sonuçlar ilgili parametreler doğrultusunda karşılaştırılır. İşlemin bir yerinde yetersizlik durumu ile karşılaşırsa hangi adıma dönülmesi gerekiyorsa o adıma dönülür ve sürece tekrar başlanır. (Hoshmand, 2010:6)

İşletme faaliyetlerinin sorunsuz bir şekilde aksamadan devam edebilmesi için tahmin önemli bir konumdadır. Tahmin, yöneticilere ihtiyaç duydukları amaçlar doğrultusunda karar verirken güvenilir bilgiler sağlamaktadır. Karar vericiler tahmin verilerine hem operasyonel hem de stratejik kararları verebilmek için ihtiyaç duymaktadırlar. İşletmeler genellikle talep tahminleri ile ilgilenirler ancak işgücü planlaması, stok düzeyi gibi faaliyetler için de tahmin verilerine ihtiyaç duyulmaktadır (Monks, 1996:39). Kararların operasyonel veya stratejik olması ise verilen kararın ne kadar süreyi kapsadığına göre değişmektedir. Dolayısı ile tahminler de bu zaman aralıklarına göre değişim göstermektedir. Tahminler genellikle üç farklı zaman aralığına göre sınıflandırılmaktadır (Heizer vd., 2016:109). Bunlar kısa, orta ve uzun süreli tahminlerdir.

- Kısa süreli tahmin: Bir yıla kadar yapılan tahminlerdir fakat genellikle üç aylık veya daha az bir süreyi kapsamaktadır. Makine ve işgücü planlaması, stok düzeyi belirlenmesi vb. işler için kullanılır.
- Orta süreli tahmin: Genellikle üç ay ile üç yıl aralığını kapsayan tahminlerdir. Satış planlaması, üretim planlaması, bütçeleme vb. işler için kullanılır.
- Uzun süreli tahmin: Üç yıl ve daha fazlasını kapsayan tahminlerdir. Araştırma geliştirme, kuruluş yeri seçimi, genişleme vb. işler için kullanılır.

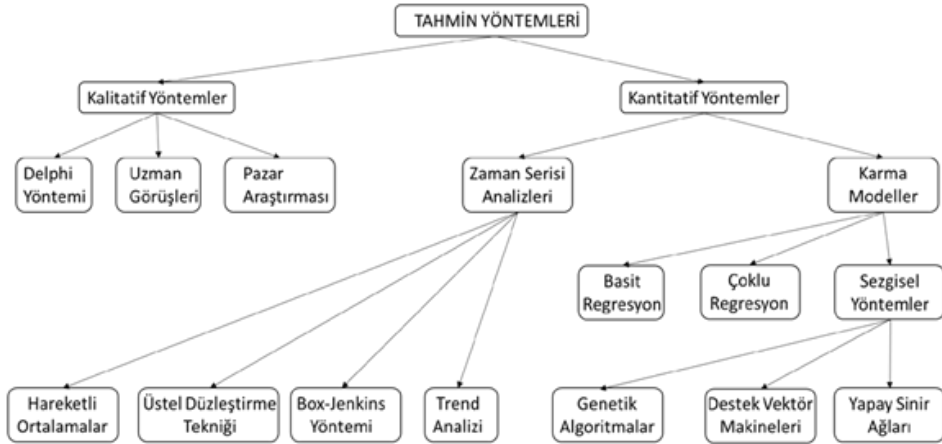
1.2. Tahmin Yöntemleri

Tahminlemede kullanılabilecek çok fazla yöntem bulunmaktadır. Genel itibari ile tahmin yöntemleri dayandıkları verilerin özelliklerine göre iki ana gruba ayrılır. Bunlar; kalitatif tahmin yöntemleri ve kantitatif tahmin yöntemleridir.

Kalitatif tahmin yöntemleri tahmin yapılması gereken durum ile alakalı yeterli sayısal veri bulunmadığında veya hızlı karar verilmesi gereken durumlar ile karşılaşıldığında tercih edilmektedir. Bu yöntemler çoğunlukla öznel verilerden yararlanır ve tahmin işlemini gerçekleştiren kişilerin bireysel yeterlilik, bilgi birikimi veya deneyimi gibi değişkenlerden fazlasıyla etkilenebilmektedir (Heizer vd., 2016:111).

Kantitatif tahmin yöntemlerinde ise nesnel verilerden yararlanılır. Geçmiş yıllara ait istatistikî veriler doğrultusunda matematiksel modeller kurulur ve bu modeller vasıtası ile tahmin işlemi gerçekleştirilir. Günümüzde talebi etkileyen faktör sayısı fazlalaşmış ve bu faktörlerin birbirleri ile arasındaki ilişkileri tespit etmek zorlaşmıştır. Toplanan verilerin karmaşık yapısı kalitatif tahmin yöntemlerinde kullanılan sezgisel ve kişinin bireysel tecrübesine dayanan yöntemleri yetersiz hale getirebilmektedir (Frechtling, 2001:211).

Tahmin yöntemlerinin kalitatif ve kantitatif ana başlıkları altında daha detaylı gösterimi Şekil 1.1' de sunulmuştur.



Şekil 1.1: Tahmin Yöntemlerinin Sınıflandırılması

Kaynak: Küçükdeniz, 2010

1.2.1. Kalitatif Tahmin Yöntemleri

Kalitatif tahmin yöntemleri daha önce de bahsedildiği üzere sezgiselliğe dayanmaktadır. Yöntemler temel olarak dört aşama ile yürütülmektedir (Frechtling, 2001:211).

- Karar verici grubun seçilmesi
- Sorunun karar verici gruba sunulması
- Cevapların aranması
- Tahmin işleminin gerçekleştirilmesi

Kalitatif tahmin yöntemlerinin kantitatif tahmin yöntemlerine göre avantaj ve dezavantajları bulunmaktadır. Bu avantajlar ve dezavantajlar Frechtling (2001) tarafından şu şekilde sıralanmıştır:

Avantajlar;

- Pahalı olmaması
- Yüksek seviyede istatistiksel bilgi birikimine ihtiyaç duymaması
- Belirlenen konu dışına çıkmaması

Dezavantajlar

- Karar verici olarak seçilen kişilerin tecrübe yetersizliği veya önyargısı
- İnsanların geleceği algılamak üzere geleceğe dair arzuları tahmin ile karıştırma eğilimi

1.2.1.1. Delphi Yöntemi

Delphi yönteminin ismi 1950lerin başında Amerikan Hava Kuvvetleri tarafından Rand şirketi ile birlikte yürüttüğü bir projenin isminden gelmektedir (Dalkey ve Helmer, 1963:458). Eldeki verilerin istatistiksel bir metot uygulamak için kullanılmasının yetersiz kaldığı durumlarda ihtiyaç duyulan Delphi Yöntemi temel olarak üç farklı grup oluşturularak uygulanır. Tahmin edilecek konu ile ilgili bilgi birikimine sahip insanlardan oluşan bir grup oluşturulur ve bu gruptan ham veri toplanır. Verilerin oluşturulan gruptan toplanması ve düzenlenmesinden bir diğer grup sorumludur. Son grup ise toplanan ve düzenlenen veriler doğrultusunda tahmin işlemini gerçekleştirecek olan karar verici gruptur.

Delphi Yöntemi doğası gereği subjektiflik içerdiği için tahmin çıktılarında da uygulayan kişilerin tecrübeleri doğrultusunda değişkenlik gözlenmektedir (Kobu, 1984:114). Tahmin çıktılarının sübjektif olmasına karşın işlem diğer yöntemlere göre daha basit bir şekilde uygulandığı ve çok fazla zamana ihtiyaç duyulmadığı için tercih edilmektedir.

1.2.1.2. Satış Elemanları ve Ürün Hattı Yöneticileri ile Tahmin

Bu yöntem şirketler tarafından en çok tercih edilen yöntemlerden birisidir. Şirketler uygulanmasının kolaylığından ve geçmiş veriye çok az ihtiyaç duymasından dolayı bu yöntemi kullanmayı tercih edebilmektedirler.

Yöntem temel anlamı ile şirket üst düzey yöneticilerini bir araya getirerek ileride gerçekleşmesi beklenen olaylarda rol oynayabilecek belirli bazı değişkenlerin değerlerinin tahmini noktasında ortak bir paydaya ulaşılması üzerine kurulmuştur (Frechtling, 2001:213). Katılımcılar bir araya gelmeden önce herkese tahmin yapılacak konu ile ilgili iyimser ve kötümser fikirleri sorulur ve toplantı bitiminde yöneticilerin bireysel görüşler ile toplantı sırasında ulaşılan ortak görüş birlikte değerlendirilir (Tekin, 2010:235).

1.2.1.3. Pazar Araştırması

Pazar araştırması yönteminde diğer yöntemden farklı olarak tahminler iç kaynaklardan değil dış kaynaklardan yararlanarak yapılmaktadır. Veri kaynağının müşteriler veya potansiyel müşterilerin olması hem olumlu hem de olumsuz sonuçlar doğurabilmektedir. Özellikle konunun cevap veren muhatapların çekineceği veya abartacağı bir niteliğe sahip olması bu yöntemin yorumlanmasını ve ileriye yönelik doğru tahminler yapılmasını zorlaştırabilmektedir (Frechtling, 2001:227).

Bunun yanı sıra veriler direkt olarak müşteriler ve potansiyel müşterilerden elde edildiği için şirket bu durumdan tahminlemenin dışında da yararlanabilmektedir. Örneğin, ürün tasarımı, ürün özelliği, müşteri memnuniyeti ve hizmet kalitesi gibi konularla alakalı bilgiler bu yöntem uygulanırken elde edilebilmektedir (Heizer vd., 2016:112).

1.2.2. Kantitatif Tahmin Yöntemleri

Kantitatif yöntemler nesnel verilerden yararlanılarak oluşturulan istatistiksel modeller doğrultusunda tahmin işlemini gerçekleştirmeyi hedeflemektedir. Kantitatif yöntemler aynı zamanda istatistiksel yöntemler olarak da bilinmekte ve tahmin işlemine sistematik bir yaklaşım getirmektedirler (Hoshmand, 2010:18). Kantitatif yöntemler zaman serileri ve karma yöntemler olarak ikiye ayrılmaktadır (Heizer vd., 2016:112).

1.2.2.1. Regresyon Yöntemi

Regresyon yönteminde temel olarak iki farklı değişken grubu bulunmaktadır. Bu değişken grupları literatürde bağımlı değişken ve bağımsız değişken/değişkenler şeklinde tanımlanmıştır. Bağımlı değişken tahmin edilmek istenen değişkeni ifade etmektedir. Bağımsız değişken ise belirlenen bağımlı değişkeni etkileyen veya etkileyebilecek değişkenleri ifade etmektedir. Regresyon yöntemi belirlenen bağımlı değişken ile bağımsız değişken veya değişkenler arasındaki ilişkiyi araştırmayı hedeflemektedir. Bu ilişki doğrultusunda bağımsız değişkenin bağımlı değişkeni hangi oranda ve ne yönde etkilediği tespit edilebilecek ve uygun stratejiler geliştirilebilecektir (Çağlar, 2007: 25)

Regresyon yöntemi bağımsız değişken sayısına ve kurulan denklem tipine göre farklılaşabilmektedir. Kurulan denklemde eğer tek bağımsız değişken bulunuyor ise bu yöntem “Basit Regresyon”, eğer birden fazla bağımsız değişken içeriyor ise “Çoklu Regresyon” olarak adlandırılır. Regresyon denklemi birinci dereceden kurulduğunda “Doğrusal”, iki veya daha yüksek dereceden kurulduğunda “Doğrusal Olmayan” olarak adlandırılmaktadır. Eşitlik 1.1, 1.2, 1.3, 1.4’te “y” bağımlı değişkeni, “x” bağımsız değişkeni, “α” regresyon denkleminin sabitini ve “β” doğrunun eğimini göstermektedir. Bu denklemlerin matematiksel gösterimi aşağıdaki gibidir.


$$\text{Basit Doğrusal Regresyon} : Y = \alpha + \beta x_i \quad (1.1)$$

$$\text{Çoklu Doğrusal Regresyon} : Y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (1.2)$$

$$\text{Eğrisel Regresyon} : Y = \alpha + \beta_1 x + \beta_2 x^2 + \dots + \beta_n x^n \quad (1.3)$$

$$\text{Üstel Regresyon} : Y = \alpha \beta^x \quad (1.4)$$

Basit doğrusal regresyon için tahmin denklemi $Y = \alpha + \beta x_i + \varepsilon$ şeklinde ifade edilir. Matematiksel olarak kurulan denklemlerin hata payları bulunmaktadır. Denkleme eklenen “ ε ” değeri rassal hata payını ifade etmektedir. Problemin çözülebilmesi için α ve β katsayılarının hesaplanması gerekmektedir. Bu işlem En Küçük Kareler yöntemi (EKK) kullanılarak yapılmaktadır. EKK yöntemi regresyon doğrusu ile gerçekleşen değerler arasındaki farkın toplamının “0” olmasını ve hata karelerinin toplamının da minimum olmasını hedefler. Aşağıdaki Şekil 1.2’de bu durum gösterilmiştir.



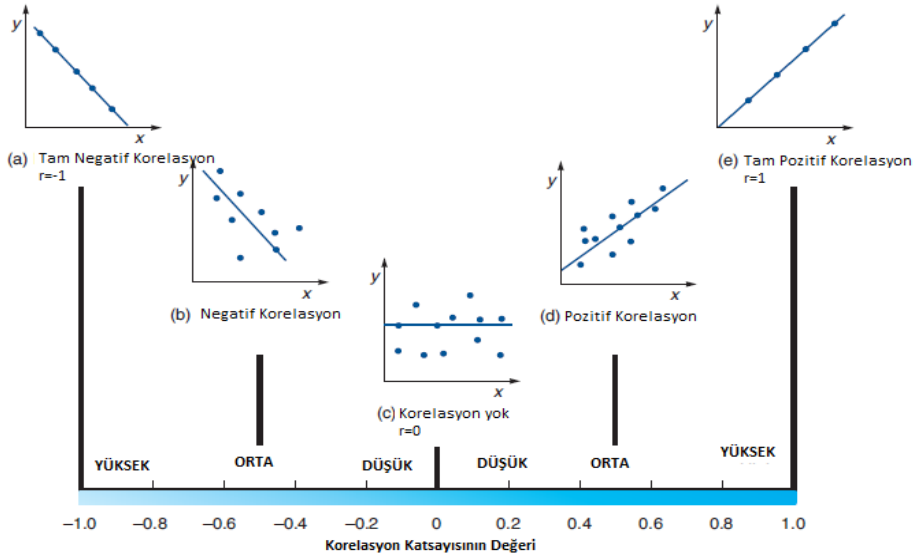
Şekil 1.2: En Küçük Kareler Yöntemi

Şekil 1.2’de satışların harcamalara göre değişim dağılımı verilmiş ve bu regresyon doğrusu çizilmiştir. Şekilde görülen noktalar gerçekleşen değerleri, doğrusal çizgi regresyon doğrusunu ve nokta ile doğru arasındaki uzaklık hata değerini göstermektedir. EKK yönteminde noktaların doğruya olan uzaklıklarının (hata değerlerinin) toplamının 0 olması hedeflenmektedir.

1.2.2.2. Korelasyon Yöntemi

Regresyon analizi bağımsız değişkendeki birim artışın bağımlı değişkendeki değişimini belirlemek için kullanılır. Fakat değişkenler arasındaki ilişkiyi göstermemektedir (Heizer vd., 2016:134). Değişkenler arasındaki ilişkiyi belirlemenin bir yolu ise korelasyon katsayısının hesaplanmasıdır. Korelasyon katsayısı “r” ile gösterilmektedir ve -1 ile +1 aralığındaki tüm değerleri alabilmektedir. Korelasyon katsayısının aldığı değere

iki değişken arasındaki ilişkinin kuvvetini göstermektedir. Şekil 1.3'te farklı korelasyon katsayılarının ne anlama geldikleri gösterilmiştir.



Şekil 1.3: Korelasyon Katsayılarına Göre İlişki Kuvvetleri

Kaynak: Heizer vd., 2016

Şekil 1.3'ten de anlaşılacağı gibi korelasyon katsayısının 0 değerinden uzaklaşması iki değişken arasındaki ilişkiyi kuvvetlendirmektedir. Aradaki ilişkinin (korelasyon katsayısı) 1 olması pozitif tam korelasyonu, -1 olması ise negatif tam korelasyonu (perfect correlation) ifade etmektedir. Korelasyon katsayısının -1 ile 0 aralığında olması negatif korelasyonu ve 0 ile 1 aralığında olması ise pozitif korelasyonu ifade etmektedir. Katsayının 0'a eşit olması ise iki değişken arasında bir korelasyonun bulunmadığını ifade etmektedir.

Korelasyon katsayısının hesaplanmasında iki değişkenin de gözlem değerleri kullanılmaktadır. Bağımlı değişken ile bağımsız değişken arasındaki korelasyon ve bağımsız değişkenlerin kendi aralarındaki korelasyon ayrı ayrı hesaplanabilmektedir (Hoshmand, 2010:181). İki değişken arasındaki korelasyon katsayısı Eşitlik 1.5'teki gibi hesaplanmaktadır.

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (1.5)$$

1.2.2.3. Zaman Serisi Analizleri

Zaman serisi bir değişkenin zamana bağlı olarak gözlemlenen değerlerinden oluşmaktadır. Tahmini yapılmak istenen değişkenlerin daha öncesine ait zaman serileri kullanılarak tahmin işlemini gerçekleştirmeye zaman serisi analizi denilmektedir (Hamzaçebi, 2011:3).

Zaman serisi analizi yardımı ile incelenen serilerin ne tür karakteristik özelliklere sahip oldukları tespit edilebilmektedir. Zaman serilerinde uzun süreli bir artış ya da azalış gözlemlendiğinde bir eğilimin söz konusu olduğu söylenebilir (Üreten, 2005:142). Örneğin bir ürünün satış miktarları ile ilgili zaman serisi incelendiğinde satışların zamanla sabit kaldığı, düzenli bir artış veya azalış eğiliminde olduğu gözlemlenebilir. Bunun yanı sıra karışık bir modelin de gözlenmesi mümkündür. Belirli dönemlerde azalış veya artış gösteren zaman serilerinde mevsimsellikten de söz edilebilir.

1.2.2.3.1. Ortalama Yöntemleri

Ortalama yönteminde isminden de anlaşılacağı üzere belirli dönemlerin ortalamaları alınarak tahminin gerçekleştirilmesi hedeflenmektedir. Ortalama yöntemler genel olarak basit ortalama, hareketli ortalama ve ağırlıklı hareketli ortalama olmak üzere üçe ayrılmaktadır. Bu yöntemler genellikle eldeki verilerin çok dalgalı olmadığı ve ileride de büyük ölçüde durağan bir yapıya sahip olacağı varsayımı kabul edilerek kullanılmaktadır (Heizer vd., 2016:114).

• Basit Ortalama Yöntemi

Az sayıda veri olduğunda ve eldeki verilerin mevsimsellik göstermediği durumlarda kullanılabilir. Tahmin edilmek istenen dönemden önceki verilerin kümülatif toplamının alınarak dönem sayısına bölünmesi sonucu elde edilen değer tahmin değeri olarak kullanılır. Basit ortalama yönteminin matematiksel gösterimi Eşitlik 1.6'daki gibidir.

$$F_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i \quad (1.6)$$

F_{t+1} , $t+1$ dönemi için tahmin değerini Y_i ise i döneminde gerçekleşen talep değerini göstermektedir. Yöntem bir sonraki dönem için uygulanacağı zaman tahmin edilen değer (F_{t+1}) de devam edilir.

- **Hareketli Ortalama Yöntemi**

Hareketli ortalama basit ortalama dan farklı olarak bir periyot belirlenir ve bu periyotlara göre yöntem uygulanır. Tahmin işleminin gerçekleştirilebilmesi için, tahmin edilmek istenen dönemden önce belirlenen periyot kadar veri bulunması gerekmektedir (Üreten, 2005:146). Eğer hareketli ortalama periyodu üç aylık olarak belirlenmiş ise yöntemin tahmin işlemine dördüncü aydan itibaren başlatılması gerekmektedir.

Hareketli ortalama yönteminde en önemli unsurlardan bir tanesinin dönem sayısının belirlenmesi olduğu söylenebilir (Özsoy, 2006:27). Dönem sayısını belirleyebilmek için ise tahmin hataları belirlenmelidir. En düşük tahmin hatasına sahip dönem sayısı seçilir ve yeni verilere ulaşıldığı zaman belirlenen dönem sayısına göre tahmin işlemi gerçekleştirilir. Hareketli ortalama yöntemini matematiksel olarak gösterimi Eşitlik 1.7’de verilmiştir.

$$F_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-n+1}}{n} \quad (1.7)$$

- **Ağırlıklı Hareketli Ortalama Yöntemi**

Veriler ile ilgili tespit edilebilen bir mevsimsel etki ya da eğilim olduğu zaman değişkenler ağırlıklandırılarak daha anlamlı sonuçlara ulaşılabilir (Heizer vd., 2016:115). Bu sayede yöntemin çıktıları daha doğru ve hata oranının daha düşük olması beklenebilir. Değişkenlere atanacak ağırlıkların belirli bir formülü literatürde bulunmamaktadır. Bu yüzden ağırlıklandırma işlemi gerçekleştirecek kişinin tecrübesi doğrultusunda yöntemin performansı etkilenecektir. Eşitlik 1.8’de ağırlıklı hareketli ortalama yönteminin matematiksel gösterimi verilmiştir. Eşitlikteki W_i her bir dönem için belirlenen ağırlıkları ifade etmektedir.

$$F_{t+1} = \sum_{i=t-n+1}^t W_i Y_i \quad (1.8)$$

Heizer vd. (2016) hareketli ortalamaların ani dalgalanmalara karşı kullanılabileceğini fakat buna karşın üç farklı problemi de içerisinde barındırdığını ifade etmişlerdir. Bunlar;

- Periyot sayısının artırılması talepteki dalgalanmaları gidermekte başarılı olmakla birlikte yöntemin duyarlılığını düşürmektedir

- Hareketli ortalamalar verilerin ortalamasını aldıkları için eğilimi tahmin etmede başarısız olmaktadır.
- Yöntem geniş bir geçmiş veri setine ihtiyaç duymaktadır.

1.2.2.3.2. Üstel Düzleştirme Yöntemi

Üstel düzleştirme yöntemi ağırlıklı hareketli ortalama ile benzer bir yapıya sahip olmakla birlikte daha az geçmiş veriye ihtiyaç duymaktadır (Heizer vd., 2016:116). Ağırlıklı hareketli ortalama yönteminden ayrıldığı nokta ise yakın geçmişteki değere yüksek, daha önceki değerlere ise azalan ve düşük ağırlıklar atanmasından kaynaklanmaktadır (Çuhadar vd., 2009:104). En yakın geçmişteki değer ağırlığına eğer “ α ” değeri verilirse bir önceki dönemin ağırlığı “ $\alpha(1-\alpha)$ ”, iki önceki dönemin ağırlığı “ $\alpha(1-\alpha)^2$ ” olarak belirlenir. Üstel bir şekilde ağırlıklandırılmasından dolayı da yöntem Üstel Düzleştirme olarak adlandırılmıştır.

1.2.2.3.3. Box-Jenkins Yöntemi

Box-Jenkins yöntemi zaman serileri analizleri arasında yaygın olarak kullanılan yöntemlerden bir tanesidir. Yöntemde kullanılması düşünülen veri setindeki gözlem değerlerinin arasında eşit zaman aralıkları olduğu ve veri setinin kesikli ve durağan olduğu varsayılmaktadır. Yöntemin kullanılmasındaki ana amaç minimum parametre kullanan en uygun modeli seçmektir. Hareketli ortalamalarda olduğu gibi otomatik süreçler bu yöntemde kısmi olarak bulunmaktadır. Box-Jenkins yönteminde veri setinin mevsimsel etki taşıyıp taşıymasına ve durağanlığına göre farklı modeller geliştirilebilmektedir (Karahan, 2011:50).

• Otoregresif Hareketli Ortalama Yöntemi

Araştırmacılar veri setlerini inceledikleri zaman bazı durumlarda birden fazla tahmin yöntemine uygun olabilecek karakteristik özellikler ile karşılaşabilmektedirler. Bu durum Otoregresif Hareketli Ortalamalar (AR-MA) yönteminin geliştirilmesinde rol oynamıştır. Yöntemin otoregresif sürecinde (AR) verilerin gelecek dönemlerdeki değerinin zaman içerisinde değişmeyeceği varsayılmaktadır. Hareketli ortalamalar (MA) sürecinde ise geçmiş dönemde gerçekleşen tahmin hatalarının bir sonraki dönemin tahmin değerini etkileyeceği varsayılmaktadır. AR-MA modelleri birbirinden

bağımsız gibi görünen iki farklı yöntemin harmanlanarak, gözlem değerleri ve geçmiş dönemlerin tahmin hatalarının birlikte değerlendirilmesi ile gerçekleştirilmektedir.

Bu tip durumlarda AR-MA modellerinin tahmin işlemindeki performansı, içerdiği farklı iki yöntemin ayrı ayrı kullanılmasından elde edilecek performanslardan daha başarılı olmaktadır. Bu sebeple AR-MA modelleri araştırmacılar tarafından yaygın olarak kullanılmaktadır.

- **Otoregresif Bütünleşik Hareketli Ortalama Yöntemi**

AR-MA modelinde de olduğu gibi Box-Jenkins yöntemlerinin uygulanabilmesi için veri setinin durağan bir yapıda olması gerekmektedir. Veri setinin durağan olmadığı durumlarda AR-MA modelinin olduğu gibi uygulanması mümkün olmayacağından veri seti öncelikle durağanlaştırılmalıdır. Bu durağanlaştırma işlemi yapılarak model kurulduğunda bu modele Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average) adı verilmektedir. Model ARIMA modeli olarak da bilinmektedir. Zaman serilerini durağan hale getirebilmek amacıyla seriye bir veya daha çok kez integrasyon işlemi uygulanabilmektedir (Adıyaman, 2007:59).

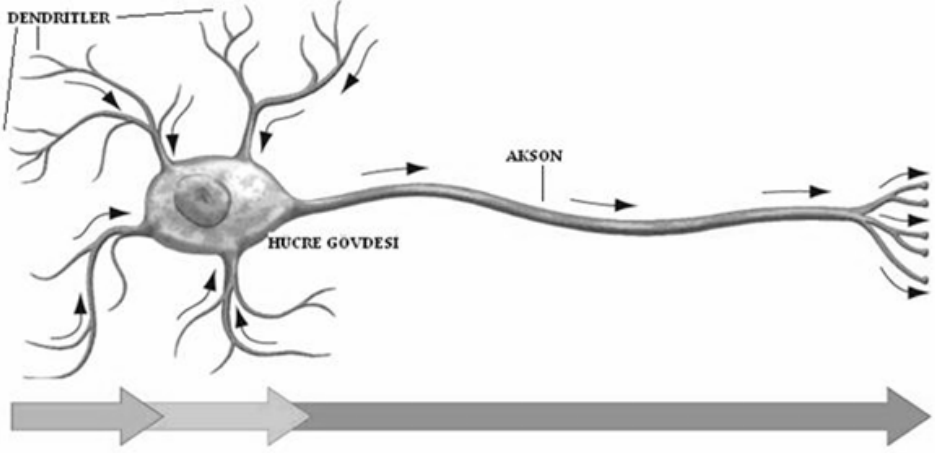
İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

Yapay sinir ağı (YSA) insan beyninin sinir yapısı ve biyolojik sinir hücresi örnek alınarak geliştirilmiş bir öğrenme ve genelleştirme yöntemi olarak tanımlanabilmektedir. Biyolojik sinir ağı, içerisindeki sinir hücreleri vasıtası ile iletişimi sağlamaktadır. Her bir biyolojik sinir hücresi diğer biyolojik sinir hücresine bağlanarak sinir ağını oluşturmaktadır.

2.1. Biyolojik Sinir Hücresi

İnsan beyni milyarlarca sinir hücresinden oluşan büyük bir iletişim ağı oluşturmaktadır (Brasspenning vd., 1995:14). İnsan beyninin yaklaşık $8,6 \cdot 10^{10}$ sinir hücresi ve her bir sinir hücresinin 7.000 sinaptik bağlantısı olduğu varsayılmaktadır. Birçok farklı sinir hücre çeşidi bulunmaktadır ve sinir hücresinin yapısal olarak dört elamanının olduğunu söylemek mümkündür. Bunlar; dentritler (alıcı), akson (iletici), soma (hücre gövdesi) ve sinaps (bağlantı düğümü)tür. Şekil 2.4'te görüldüğü gibi diğer sinir hücrelerinden veriyi almaya yarayan birçok sayıda dentrit, işlenen veriyi iletmeye yarayan bir akson bulunmaktadır.



Şekil 2.1: Biyolojik Sinir Hücresi

Kaynak: Çelik, 2008

Sinir hücreleri birbirlerine aksonlar ve dendritler vasıtası ile bağlanır. Akson ve dendritin bağlantı noktasına ise sinaps adı verilmektedir. Sinir ağının giriş hücresinin dendritleri ile başlayan süreç kendinden sonraki sinir hücresinin dendritlerine sinapslar vasıtası ile bağlanarak devam eder.

YSA yöntemi yukarıdaki yapıyı ve insan beyninin bilgiyi işleme ve geliştirme özelliğini taklit etmeyi hedefleyen bir yöntemdir. YSA öğrenme ve karar verme açısından biyolojik sinir sisteminin özelliklerini taşımaktadır.

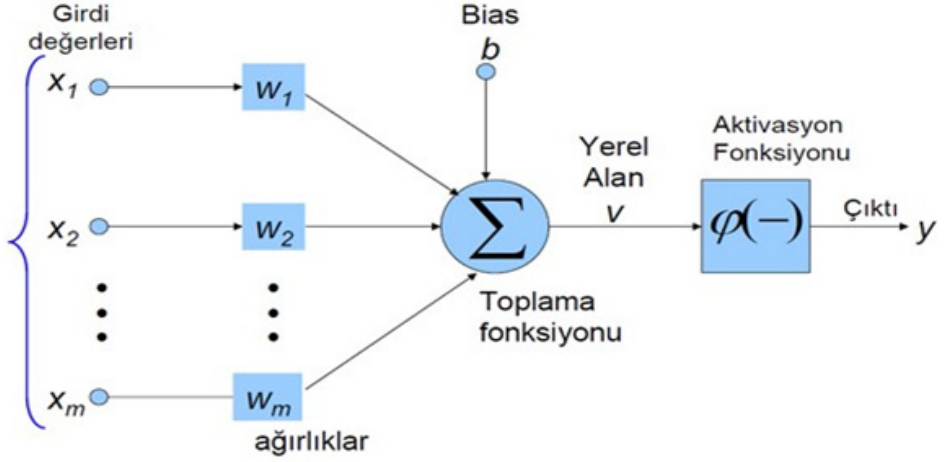
2.2. Yapay Sinir Hücresi

YSA insan vücudundaki sinir hücreleri gibi yapay sinir hücrelerini içerisinde barındırmaktadır. Yapay sinir hücreleri tıpkı biyolojik sinir hücrelerinde olduğu gibi veriyi alır, işler ve iletir. Tablo 2.1’de yapay sinir hücrelerinin elemanları ve görevleri verilmiştir.

Tablo 2.1: Yapay Sinir Hücresinin Elemanları ve Görevleri

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi	Görevi
Dentrit	Alıcı	Gelen veriyi alır.
Akson	Verici	İşlenen veriyi iletir.
Hücre Gövdesi	Aktivasyon Fonksiyonu	Gelen veriyi toplar ve çıktıyı oluşturur.
Sinaptik Ağırlıklar	Bağlantı Ağırlıkları	Öğrenilenleri hafızada saklar.

Yapay sinir ağı işlem yapabilmek için öncelikle girdi ve çıktı değişkenlerine ihtiyaç duymaktadır. Ağa tanıtılan girdi değişkenleri, insan beyinde olduğu gibi, öncelikle ağa giriş yapar. Daha sonra girdi değişkenleri ağ tarafından ağırlıklandırılır ve ağırlıklı değerlere göre çıktı tahmini elde edilir. İşlemin yalnızca bir kez yapılması durumunda gerçekleşen değerden çok uzak bir değer elde edilme ihtimali yüksektir. Bu noktada ise yapay sinir ağının öğrenme fonksiyonu devreye girecek ve fonksiyon yardımı ile girdi değişkenlerinin ağırlıkları gerçekleşen değerlere en yakın çıktı değişkenini verene kadar YSA tarafından değiştirilecektir. Şekil 2.5'te bir yapay sinir hücresi gösterilmiştir.



Şekil 2.2: Yapay Sinir Hücresi

Şekilde görülen girdiler (x_1, x_2, \dots, x_m) yapay sinir ağına tanımlanan veya diğer sinir hücrelerinden gelen verileri göstermektedir. Ağırlıklar (w_1, w_2, \dots, w_m) ise girdilerin bir sonraki aşamaya geçerken sahip olacağı önem derecesini ifade etmektedir. Girdiler ve ağırlıklar çarpıldıktan sonra toplam fonksiyonu bu değerleri birleştirir. “b” ile gösterilen değer ise eşik değerini temsil etmektedir. Toplam fonksiyonu yardımı ile elde edilen değer aktivasyon fonksiyonunda çıktıya dönüştürülür ve tahmin değeri elde edilir.

2.2.1. Yapay Sinir Hücresinin Elemanları

Yapay sinir ağları bünyesinde temel olarak 4 eleman bulundurmaktadır. Bunlar; girdiler, nöronların aralarındaki ağırlıkları, elde edilen ağırlıkların anlamlı hale getirebilmesi için toplam fonksiyonu ve sonuç üretimi için aktivasyon fonksiyonudur.

2.2.1.1. Girdiler

YSA daha önce de bahsedildiği üzere insan beynini ve işleyişini taklit etme yolu ile üretilmiş bir yöntemdir. Sinir ağları birbirine bağlı sinir hücrelerinden oluşmaktadır. Dolayısıyla sinir hücresine gelen girdi dış çevreden olabileceği gibi kendisinden önceki sinir hücresinin çıktısı da olabilmektedir.

2.2.1.2. Çıktılar

Yapay sinir ağına giren bilgiler toplam fonksiyonunda aktivasyon fonksiyonuna yönlendirilir. Burada aktivasyon işleminden sonra elde edilen değer hücrenin çıktısı olmaktadır. Bu çıktı nihai sonuç olabileceği gibi, kendinden sonraki hücreye/hücrelere girdi de olabilmektedir.

2.2.1.3. Ağırlıklar

Yapay sinir hücresine giren bilgilerin toplam fonksiyonuna geçmeden önce bir ağırlığa sahip olması gerekmektedir. Yapay sinir ağı tahmin işlemini bu ağırlıklar doğrultusunda gerçekleştirmektedir. YSA atanmış bu ağırlıkları farklı kombinasyonlarda kullanarak performansı artırmayı ve daha tutarlı çıktılar üretmeyi hedeflemektedir. Genellikle başlangıç ağırlıkları $[-1, 1]$ aralığında seçilmektedir (Hamzaçebi, 2011:65).

2.2.1.4. Toplam Fonksiyonu

Toplam fonksiyonu girdilerin ilgili ağırlıkları ile çarpıldıktan sonra net girdi hesaplaması için kullanılmaktadır. Net girdi hesabı; her bir girdinin ilgili ağırlık ile çarpılması ve elde edilen çarpımların toplanması ile yapılmaktadır. Toplam fonksiyonun matematiksel gösterimi Eşitlik 2.1'da gösterildiği gibidir.

$$net = \sum_{i=1}^n X_i W_i \pm b \quad (2.1)$$

Eşitlikte, “x” girdi değişkenlerini, “w” girdi değişkenlerinin ağırlıklarını, “n” girdi sayısını, “b” eşik değerini ve “net” ise aktivasyon fonksiyonuna iletilecek olan toplam değeri ifade etmektedir. Ancak toplam fonksiyonunun bazı kullanımlarında eşik değeri eşitliğe dâhil edilmeyebilmektedir.

Literatürdeki çalışmalarda ağırlık birden fazla toplam fonksiyonu kullanabileceği belirtilmiştir. Ağırlık aynı katmanındaki hücreler farklı toplam fonksiyonlarına sahip olabileceği gibi farklı katmanlar farklı toplam fonksiyonuna da sahip olabilmektedirler. Seçilecek fonksiyon çeşidi uygulayıcı kişilerin tercihlerine bağlı olarak değişmektedir (Öztemel, 2006:49-50).

2.2.1.5. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu toplam fonksiyonu ile elde edilen verilerin işlenerek bir çıktı haline gelmesini sağlayan fonksiyondur. Yapay sinir ağı uygulamalarında birçok aktivasyon fonksiyonu kullanımından bahsetmek mümkündür. Aktivasyon fonksiyonu girdi ile çıktı arasındaki doğrusalsızlık (nonlinearity) derecesini ifade etmektedir (Zhang vd., 1998:47).

Türevi alınabilen tüm fonksiyonların aktivasyon fonksiyonu olabileceği literatür incelendiğinde görülmektedir. Bu sebeple farklı aktivasyon fonksiyonları yapay sinir ağlarında uygulanmaktadır. Buna karşın genellikle kullanılan fonksiyon çeşitleri; sigmoid fonksiyonu, doğrusal fonksiyon, sinüs fonksiyonu ve hiperbolik tanjant fonksiyonu olarak gözlemlenmektedir. Toplam fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da farklı hücreler farklı aktivasyon fonksiyonunu kullanabilmektedir.

Yapay sinir ağları yönteminin uygulama alanlarının birçoğunda karmaşık problemler ile karşılaşmaktadır. Bu durum ağın modellenmesi noktasından belirleyici bir faktördür. Aktivasyon fonksiyonu seçilirken de bu karmaşık yapıyı en iyi algılayabilecek, öğrenebilecek ve tahminleyebilecek YSA modeli kurulması hedeflenmektedir.

- **Doğrusal Fonksiyon**

Doğrusal fonksiyon gelen ağırlıklandırılmış girdiyi çıktı olarak iletmektedir. Doğrusal aktivasyon fonksiyonu Widrow ve Hoff' tarafından 1959 yılında geliştirilmiş ve ADALINE (Adaptive Linear Neuron) olarak adlandırılmıştır. Doğrusal aktivasyon yöntemi girdiyi olduğu gibi çıktı olarak iletmediği için genellikle sınıflandırma problemlerinde kullanılmaktadır.

Bu yöntem daha sonrasında geliştirilen yöntemlerin temeli oluşturmuştur. Ayrıca MADALINE (Multiple ADALINE) yöntemi gerçek bir probleme uygulanan ilk YSA modeli olmuştur (Keskenler ve Keskenler, 2017:13). Doğrusal aktivasyon fonksiyonunun matematiksel gösterimi Eşitlik 2.2 ve Eşitlik 2.3'teki gibidir.

$$v = net = \sum_{i=1}^n X_i W_i \pm b \quad (2.2)$$

$$y = F(v) = Av \quad (2.3)$$


Denklemdaki "A" sabit bir katsayıyı ifade etmektedir.

• Eşik (Step) Fonksiyonu

Eşik fonksiyonun ikili sisteme dayandığı söylenebilir. Eşik fonksiyonu matematiksel olarak 1 veya 0 sonucunu üretmektedir. Problem evet (1) veya hayır (0) cevabına ihtiyaç duyan bir yapıya sahipse YSA aktivasyon fonksiyonu olarak eşik fonksiyonunu kullanabilmektedir. Eğer sinir hücresi belli bir eşiğin üstünde veya altında ise fonksiyon tanımlanan değeri olduğu gibi iletir ve 0 veya 1 çıktısını üretir. Kümeleme çalışmaları bu fonksiyonu kullanan yapay sinir ağı modellerine örnek olarak gösterilebilmektedir.

Kümeleme çalışmalarında, birden fazla sinir hücresinin evet/hayır sonucunu vermesi eşik fonksiyonunun handikaplarından birisi olarak sayılabilmektedir. Eşik fonksiyonunun matematiksel gösterimi Eşitlik 2.4'te verilmiştir. Girdi değişkeninin eşik değerinden küçük veya büyük olması durumunda üretilen çıktı değerleri Şekil 2.3'te görülmektedir.

$$F(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.4)$$



Şekil 2.3: Eşik Fonksiyonu Grafiği


- **Rampa (Parçalı Doğrusal) Fonksiyonu**

Rampa fonksiyonu, doğrusal aktivasyon fonksiyonu ve eşik aktivasyon fonksiyonunun birleşimi gibidir. Sinir hücrelerinden aktivasyon fonksiyonuna gelen değerlerin bulunduğu aralığına göre fonksiyon çıktı değeri üretmektedir.

Rampa fonksiyonu aktivasyon ihtimali düşük olan değerler için doğrusal fonksiyon gibi ağırlıklandırılmış çıktı değeri üretir. Eğer fonksiyona gelen değerler $-\infty$ veya $+\infty$ değerlerine doğru gidiyorsa basamak fonksiyonunda olduğu gibi 1 ve 0 değerleri çıktı olarak üretilir.

Rampa fonksiyonunda genellikle üst eşik olarak 1, alt eşik olarak -1 değeri seçilmektedir (Hamzaçebi, 2011:46). Aktivasyon fonksiyonunun matematiksel ve şekilsel olarak gösterimi sırasıyla Eşitlik 2.5 ve Şekil 2.4'te gösterildiği gibidir.

$$y = F(v) = \begin{cases} 1, & v \geq 1/2\alpha \\ \alpha v + 1/2, & |v| < 1/2\alpha \\ 0, & v \leq -1/2\alpha \end{cases} \quad (2.5)$$




Şekil 2.4: Rampa Fonksiyonu Grafiği

- **Sigmoid Fonksiyonu**

Sigmoid fonksiyonu çalışmalarda en çok kullanılan yöntemlerden bir tanesidir. Sigmoid fonksiyonu şekil olarak “S” harfini andırmaktadır ve yapısı gereği doğrusal değildir. Gerçek hayatta karşılaşılan problemlerin doğrusal olmayan bir yapıya sahip olması bu fonksiyonun yaygın kullanım sebeplerinden bir tanesi olarak gösterilebilir. Sigmoid fonksiyonunun matematiksel gösterimi Eşitlik 2.6'deki gibidir.

$$y = \sigma(z) = F(z) = 1/1e^{-z} \quad (2.6)$$




Şekil 2.5: Sigmoid Fonksiyonu Grafiği

Şekil 2.5'te de görüldüğü gibi fonksiyon belirli z değerleri aralığında parabolik bir grafik çizmektedir. Girdi değişken değerinde yapılacak küçük bir değişiklik, diğer aralıklara göre, çıktı değerinde daha büyük bir değişim yaratacaktır. Dolayısı ile bu durum tahmin yapılacağı zaman araştırmacılara avantaj sağlamaktadır.

- **Tanjant Hiperbolik (Tanh) Fonksiyonu**

Tanjant fonksiyonu ölçeklenmiş (scaled) sigmoid fonksiyonudur. Literatürde “Tanh” olarak da geçmektedir. Sigmoid fonksiyonu gibi oldukça yaygın bir kullanıma sahiptir. Tanjant Hiperbolik fonksiyonunun matematiksel gösterimi Eşitlik 2.7'de verilmiştir.

$$y = \tanh(z) F(z) = \frac{2}{1+e^{-2z}} - 1 \quad (2.7)$$




Şekil 2.6: Tanjant Hiperbolik Fonksiyonu Grafiği

Şekil 2.5 ve Şekil 2.6 birlikte incelendiğinde iki farklı aktivasyon fonksiyonunun grafiklerinin birbirlerine oldukça benzediği görülmektedir.

- **Sinüs Fonksiyonu**

Problem verilerinin dağılımının sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda sinüs aktivasyon fonksiyonu kullanılmaktadır. Sinüs fonksiyonunun matematiksel gösterimi Eşitlik 2.8’de verilmiştir.

$$y = F(v) = \sin(v) \quad (2.8)$$



Şekil 2.7: Sinüs Fonksiyonu Grafiği

2.3. Yapay Sinir Ağlarındaki Katmanlar

Tahmin için kurulan bir YSA modelinde; girdi sayısı, gizli katman sayısı ve çıktı sayısı çözüm için belirlenmesi gereken parametrelerdir (Hamzaçebi, 2011:70). Yapay sinir ağlarını temel olarak üç katmanda incelemek mümkündür. Bunlar; girdi katmanı, gizli katman ve çıktı katmanıdır.

Yapay sinir ağlarının avantaj ve dezavantajları kısmında da bahsi geçen varsayıma gerek duymama özelliği katmanlar belirlenirken de rol oynamaktadır. Öyle ki yapılan çalışmalarda bir kural olmaksızın gizli katman için sigmoid veya hiperbolik tanjant fonksiyonu kullanılmış fakat çıktı katmanı için bir birlik sağlamamıştır (Hamzaçebi, 2011:74).

2.3.1. Girdi Katmanı

Girdi katmanı yapay sinir hücrelerinde işlemin başladığı, dış çevreden bilginin alındığı katmandır. Bu katmanda problem ile alakalı olduğuna karar verilen bağımsız değişkenler bulunmaktadır. Girdi katmanında herhangi bir işlem uygulanmaz. Girdi katmanındaki nöronlar bir sonraki katmandaki tüm nöronlara bağlanır fakat kendi aralarında bir bağlantı bulunmamaktadır (Bayır, 2006:19).

2.3.2. Gizli Katman

Gizli katman değişkenler arasındaki doğrusal olmayan ilişkinin belirlendiği katmandır ve bu yüzden yapay sinir ağının çok önemli bir parçasıdır (Zhang vd., 1998:38). Gizli katman değerleri girdi katmanındaki değerlerin ağırlıklandırma işlemi yapıldığında elde edilmektedir. Hangi nöronun hangi ağırlığa sahip olacağı ve sonucu ne yönde ne kadar etkileyeceği bu katmanda belirlenmektedir.

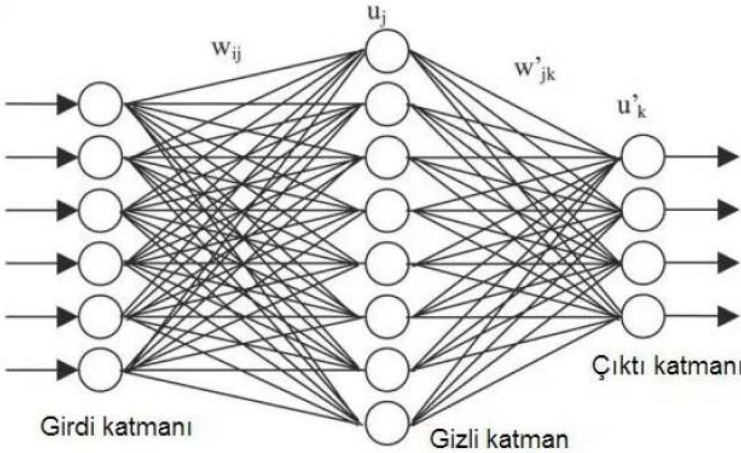
Girdi ve çıktı katmanları sinir hücresinde yalnızca birer tane bulunurken gizli katman sayısı birden çok olabilmektedir. Bu sayının belirlenmesinde belirli bir kural bulunmamakla birlikte literatürde bazı araştırmacıların birçok problemde tek katmanın yeterli olacağı, problemin karmaşıklaştığı ve gözlem sayısının yeterli olduğu durumlarda ise iki gizli katmanın kullanılabileceği gibi önerileri yer almaktadır (Hamzaçebi, 2011:72).

Gizli katman sayısı belirlenirken bir kural olmamasından dolayı deneme yanılma yöntemi kullanılmaktadır. Problemin yapısına ve araştırmacının

tecrübelerine göre bu sayı belirlenebilir. Gizli katman sayısının artması durumunda çözüme ulaşma süresi de artmaktadır. Bu sebeple birden çok gizli katman kullanılacağı durumlarda hesaplama zamanı ve dolayısı ile maliyeti göz önünde bulundurulmalıdır.

2.3.3. Çıktı Katmanı

Çıktı katmanında bir diğer sinir hücresini girdi değeri veya nihai çıktı değeri hesaplanır. Girdi katman değerleri ağırlıklandırıldıktan sonra gizli katmanlardan geçer ve toplama fonksiyonu ile birleştirilip aktivasyon fonksiyonu yardımı ile çıktı değerine dönüştürülür. Bu dönüşüm gerçekleştirildikten sonra oluşturulan katman çıktı katmanıdır.



Şekil 2.8: Tek Gizli Katmanlı YSA Modeli

Şekilde tek gizli katmana ve birden çok çıktı değerine sahip bir YSA modeli görülmektedir. Çıktı değerinin birden fazla olması problemin birkaç dönemlik çıktı üretmeyi amaçlamasından kaynaklanmaktadır.

2.4. Yapay Sinir Ağlarının Sınıflandırılması

Yapay Sinir Ağları farklı kriterlere göre sınıflandırılabilir. YSA'ların; tiplerine, katman sayılarına ve öğrenme yöntemlerine göre sınıflandırılmaları bu sınıflandırma çeşitlerinden birkaçıdır.

2.4.1. Tiplerine Göre Yapay Sinir Ağları

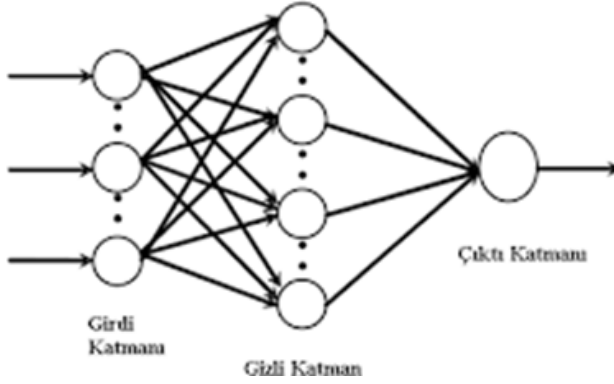
Birbirine bağlı yapay sinir hücrelerinin bütünü yapay sinir ağını oluşturmaktadır. Yapay sinir hücrelerinin aralarındaki bağlantıya göre ise ağların karakteristik özellikleri değişebilmektedir. Gizli katman veya katmanlardaki sinir hücrelerinin birbirlerine veriyi ne yönde ilettiklerine göre ağın yapısı farklılaşmaktadır. Temel olarak yapay sinir ağları hücrelerinin arasındaki bağlantıya göre ikiye ayrılmaktadır. Bunlar; ileri beslemeli ağlar ve geri beslemeli ağlardır.

• İleri Beslemeli Ağlar

İleri beslemeli ağlarda katmanlar birbirleri ile bağlantıya sahipken aynı katmandaki hücreler arasında bağlantı bulunmamaktadır. Girdi katmanında ağırlıklandırılan veri ilk gizli katmana sonrasında, eğer mevcut ise, bir sonraki gizli katmana ve son olarak çıktı katmanına ulaşır (Çuhadar ve Kayacan, 2005:26). Aralardaki bağlantı tek yönlüdür ve girdi katmanından çıktı katmanına doğru devam edilir.

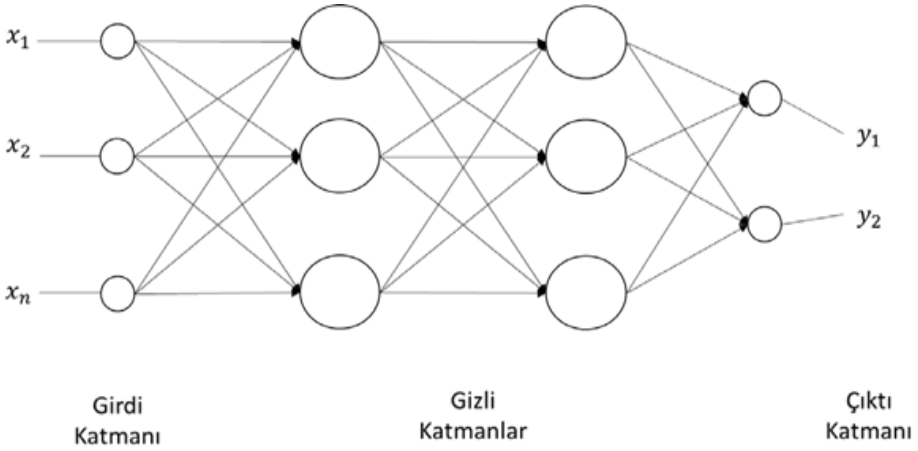
Hücrelerin çıktıları aynı katmandaki diğer hücreleri etkilemez. Örneğin iki gizli katmana sahip ileri beslemeli bir yapay sinir ağı ele alındığında, gizli katmanlardaki hücrelerin sonuçları yalnızca bir sonraki katmanı etkiler (Saygılı, 2008: 45). Dolayısı ile ağın ilk gizli katmanında bulunan x hücresinin sonucu aynı katmandaki y hücresinin sonucundan bağımsızdır.

Daha önce de bahsedildiği gibi katman sayıları ve katmanlardaki hücre sayılarının belirlenmesinde belirli bir görüş birliği sağlanamamış olup genellikle deneme yanılma yöntemine göre karar verilir. Şekil 2.9 ve Şekil 2.10'da tek gizli katmanlı ve çok gizli katmanlı yapay sinir ağları görülmektedir.



Şekil 2.9: İleri Beslemeli Tek Katmanlı Yapay Sinir Ağı

Şekil 2.9’da girdi katmanı, gizli katman ve çıktı katmanı görülmektedir. Verilerin akış yönü ve hangi nöronun hangi katmandaki nöronu etkilediği görülmektedir.



Şekil 2.10: İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı


Şekilde çok katman ifadesi birden fazla gizli katmanı ifade etmektedir. YSA’larda girdi ve çıktı katmanları değişmezken gizli katman sayıları problemlerin yapılarına göre değişebilmektedir.

- **Geri Beslemeli Ağlar**

Geri beslemeli yapay sinir ağlarında ise hücreler arasındaki bağlantılar çift yönlü olabilmektedir. Yani bir sinir hücresinin çıktısı kendisine veya

başka bir sinir hücresine tekrar girdi olarak gönderilmekte ve önceki çıktı değeri doğrultusunda yeni bir çıktı değeri üretmektedir (Saygılı, 2008:45).

Geri besleme işlemi tüm katmanlardaki sinir hücrelerinde ve katmanlar arasında gerçekleşebilir. Bu sayede YSA bir doğrusal olmama ve bu doğrusal olmama ile dinamik bir özellik kazanmaktadır. Geri beslemeli yapay sinir ağları karmaşık bir yapıya sahiptir ancak geri besleme yardımı ile öğrenme işlemi dinamik hale geldiği için kullanımı oldukça yaygındır. Geri beslemeli yapay sinir ağı basit anlamıyla Şekil 2.14'te gösterildiği gibidir.



Şekil 2.11: Geri Beslemeli Yapay Sinir Ağı

Şekil 2.11'de nöronları arasındaki veri akış yönünün çift taraflı olduğu görülmektedir. Şekilde katmanlar arasında bir geri besleme işlemi görülmektedir fakat geri besleme işlemi aynı katmandaki farklı nöronlar arasında da gerçekleşebilmektedir.

2.4.2. Katman Sayılarına Göre Yapay Sinir Ağları

Yapay sinir hücrelerinin bir araya gelerek oluşturdukları öbeğe katman denilmektedir. Katmanın hangi işlem için kullanıldığı o katmanın isimlendirilmesinde kullanılmaktadır. Eğer sinir hücresinin giriş kısmında ise girdi katmanı, giriş ile çıkış arasında ise gizli katman ve çıkış kısmında ise çıktı katmanı olarak adlandırılır.

Yapay sinir ağlarını içerdikleri katman sayılarına göre sınıflandırmak mümkündür. Eğer bünyesinde yalnızca birer adet girdi ve çıktı katmanı bulunduruyorsa "Tek Katmanlı"; birer adet girdi ve çıktı katmanı fakat

bir veya birden fazla gizli katman bulunduruyorsa “Çok Katmanlı” olarak sınıflandırılır (Hamzaçebi, 2011:23).

- **Tek Katmanlı Yapay Sinir Ağları**

Tek katmanlı ağlar birden fazla nörona sahip bir girdi katmanından ve çıktı katmanından oluşmaktadır. Tek katmanlı algılayıcılar bu ağlara örnek olarak verilebilir. Girdi katmanındaki nöronların çarpılıp toplanması ile çıktı değeri üretilir. Eğer üretilen toplam değeri belirli bir eşik değerini aşıyor ise 1, altında kalıyor ise 0 çıktısı üretilmiş olur (Bayır, 2006:45). Tek katmanlı yapay sinir ağlarının aktivasyon fonksiyonu doğrusal bir fonksiyondur. Tek katmanlı yapay sinir ağları genellikle sınıflandırma uygulamaları için uygundur.

- **Çok Katmanlı Yapay Sinir Ağları**

Çok katmanlı ağlar bünyelerinde tek katmanlı ağlarda olduğu gibi girdi ve çıktı katmanlarını bulundururlar fakat bu iki katman arasında gizli katmanlar da bulunmaktadır. Yapay sinir ağları için daha önceden bahsedildiği üzere belirli bir kuraldan bahsetmek çoğu zaman mümkün değildir. Gizli katman sayısı ve bu katmandaki nöron sayısı ile alakalı da bir kural bulunmamaktadır. Bu sayılar deneme yanılma yöntemi ile belirlenir ve ağın performansını maksimum yapacak sayıya ulaşılması hedeflenir.

Çok katmanlı algılayıcılar (ÇKA) çok katmanlı sinir ağlarına örnek olarak gösterilebilir. ÇKA daha önce Widrow tarafından geliştirilen MADALINE çalışmalarına dayanmakta ancak geri yayılım algoritmasının kullanılması ile MADALINE’den ayrılmaktadır (Hamzaçebi, 2011:43).

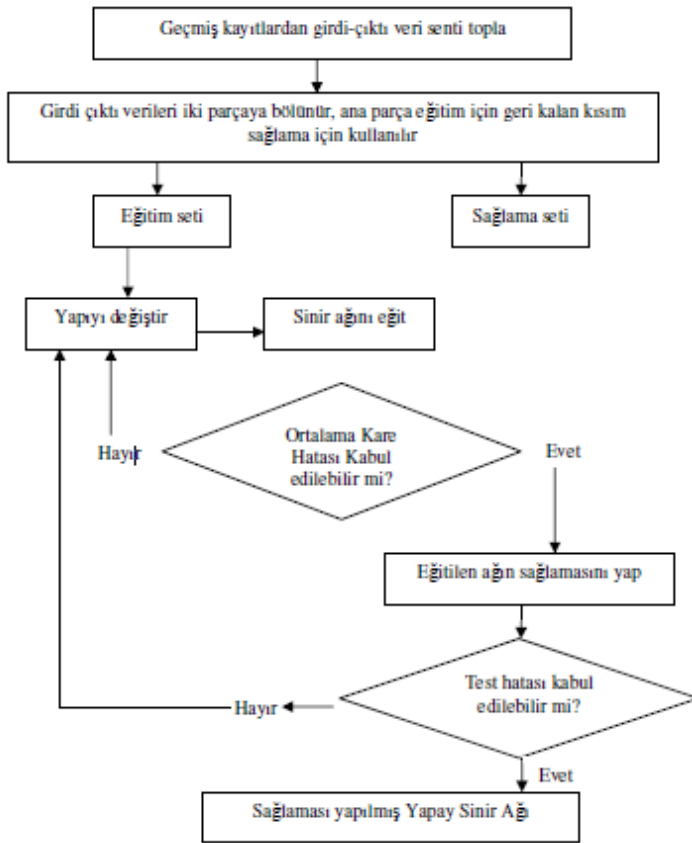
ÇKA ileri besleme ve geri yayılım olmak üzere iki aşamadan oluşmaktadır (Öztemel, 2003). Girdi değişkenlerinin ilgili ağırlıklar ile kendinden bir sonraki katmana (gizli katman) transfer edilmesi ve daha sonra gizli katmanların da aynı işlemi çıktı üretilene kadar devam ettirmesine ileri besleme adı verilmektedir. İleri beslemede her katmandaki hücre ancak kendinden bir sonraki katmandaki hücrelerle bağlantılıdır. Aynı katmandaki hücrelerin birbiri ile bağlantısı bulunmamaktadır (Hagan vd., 2002). Geri yayılım algoritması çıktı katmanında üretilen çıktının hata değerinin girdi katmanına doğru ağırlıklar yardımı ile dağıtılmasıyla uygulanmaktadır.

2.4.3. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları

Yapay sinir ağlarını diğer yöntemlerden ayıran en önemli özelliklerinden birisi de öğrenme yeteneğidir. YSA öğrenme işlemini nöronlar arasındaki bağlantılarda ağırlıklar yardımı ile gerçekleştirir. Nöronların ağırlıkları ağın performansını doğrudan etkilemektedir. Dolayısı ile bu ağırlıklar değiştirildiğinde elde edilecek çıktı istenen değere yaklaşacak veya istenenden uzaklaşacaktır. YSA bu yaklaşma ve uzaklaşmaya göre ağırlıkları öğrenme algoritmaları ile değiştirerek öğrenme işlemini gerçekleştirir.

YSA öğrenme performansı aynı zamanda ağa tanımlanan veriler ile de alakalıdır. Ne kadar fazla örnek ağa tanımlanırsa ağ o kadar iyi öğrenecek ve gerçekleşmiş olan değere en yakın değeri çıktı olarak üretecektir. YSA kullanımının avantajlarında da bahsedildiği üzere; yöntem ekstra hazırlık gerektirmemekte ve öğrenme işlemi ağın kendi algoritması tarafından gerçekleştirilmektedir (Öztemel, 2006:24).

Yapay Sinir ağlarında öğrenme iki ana başlıkta toplanmaktadır (Çuhadar ve Kayacan, 2005:26). Bunlar; danışmanlı öğrenme (supervised) ve danışmansız öğrenme (unsupervised) olarak karşımıza çıkmaktadır.



Şekil 2.12: Yapay Sinir Ağı Öğrenme Aşamaları

Kaynak: Rajpal vd., 2006:812

• Danışmanlı Öğrenme

Danışmanlı öğrenmede girdi ve çıktı verileri ağa verilmektedir. YSA kendisine verilen girdi verilerini işleyerek çıktı üretir ve bu çıktı değerleri istenen değerler ile karşılaştırılarak hata değeri elde edilir. Bu hatalar sistem geneline dağıtılır ve yeni ağırlıklar doğrultusunda tekrar çıktı üretilir (DARPA, 1988:10). Bu işlem istatistiksel olarak hata değeri yeterli düzeye düştüğü zaman sonlanır ve öğrenme işlemi tamamlanmış olur.

Bazı ağlar öğrenme işlemi bitiminde sinir hücreleri arasındaki ağırlıkları sabitler ve tahmin aşamasına geçiş yapar. Bunun yanı sıra bazı yapay sinir ağları ise ağırlıkları sabitlemeyerek tahmin aşamasında da öğrenmeye devam edebilmektedir.

Danışmanlı öğrenmede bir danışmana ihtiyaç duyulmaktadır. YSA danışman tarafından gerçek girdi ve çıktı değerleri ile beslenir ve öğrenim süresi yine danışman tarafından belirlenir. Danışmanlı öğrenmenin yaygın olarak kullanılan çeşitlerinden bazıları; perceptron kuralı, geri yayılım algoritması, delta kuralı ve genişletilmiş delta kuralıdır (Şen, 2004:98).

- **Danışmansız Öğrenme**

Danışmansız öğrenmede çıktı değerleri ağa tanımlanmaz. Sistemde yalnızca girdi verileri bulunur ve bu veriler YSA tarafından analiz edilerek içerilerinde buldukları istatistiksel bağlantı keşfedilmeye çalışılır. YSA yalnızca girdi verilerinin aralarındaki bağlantı yardımı ile çıktı üretir. Adaptif Rezonans Teorisi (ART), Hopfield Ağı ve Kohonen Ağı en çok kullanılan danışmansız öğrenmeli ağlardandır (Hamzaçebi, 2011:22).

2.5. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarının performansı temelde öğrenme yeteneğine göre değişmektedir. Ağın tutarlı ve güvenilir çıktılar üretebilmesinde öğrenme işlemi çok büyük bir rol oynamaktadır. Öğrenme işleminin altında çok değişkenli ve ifade edilmesi oldukça zor matematiksel işlemler yatmaktadır (Saygılı, 2008:46).

Yapay sinir ağı öğrenme işlemini nöronlar arasındaki bağlantı ağırlıkları aracılığı ile gerçekleştirmektedir. Bu ağırlıkların farklı varyasyonlar ile değiştirilerek istatistiksel olarak yeterli çıktı değerine ulaşılması öğrenme işleminin bittiğini ve nihai çıktı değerinin üretilebileceğini göstermektedir.

Günümüzde birçok öğrenme kuralı bulunmaktadır. Zaman içerisinde araştırmacılar seçtikleri problemin yapısına göre farklı öğrenme kuralları geliştirmişlerdir. Temelde dört öğrenme kuralı bulunmaktadır ve geliştirilen diğer kurallar bu dört kuraldan türetilmiştir (Karahana, 2011:87). Bunlar; Hebb, Hopfield, Delta ve Kohonen öğrenme kurallarıdır.

2.5.1. Hebb Kuralı

Hebb kuralı Donald Hebb tarafından 1949 yılında geliştirilmiş olup bilinen ilk öğrenme kuralıdır (Bayır, 2006:30). Hebb kuralı daha sonra geliştirilecek kuralların da temelini oluşturması sebebiyle yapay sinir ağlarının gelişiminde önemli bir role sahiptir.

Kural temelde basit bir mantığa dayanmaktadır; eğer girdi sağlayan nöron ve girdiyi alan nöron aktif ise aralarındaki bağlantı kuvvetlendirilir. Bir nöron aktif olması durumunda girdi sağladığı nöronu da aktif yapmaya meyillidir (Öztemel, 2006:29).

2.5.2. Hopfield Kuralı

John Hopfield tarafından geliştirilen bu öğrenme kuralı Hebb kuralı ile neredeyse aynı özelliklere sahiptir. Aralarındaki fark ise Hopfield kuralında ilişkinin kuvvetlendirilme veya zayıflatılma derecesinin bilinmesidir. Her iki nöronunda aktif olması durumunda iki nöron arasındaki bağlantı öğrenme katsayısı oranında güçlendirilir. Aynı durum iki nöronun da pasif olması durumunda da geçerlidir ve bağlantının zayıflatılması ile gerçekleştirilir. Öğrenme katsayısı araştırmacı tarafından genellikle 0 ile 1 aralığında bir sayı olarak belirlenmektedir.

2.5.3. Delta Kuralı

Delta öğrenme kuralı Widrow ve Hoff tarafından geliştirilmiştir. Hebb kuralından türetilen kural üretilen çıktılar ve gerçekleşen değerler arasındaki farkın (delta) minimize edilmesine dayanmaktadır. Kural uygulanırken, nöronların bağlantı ağırlıkları tahmin değeri ve gerçekleşen değer arasındaki hata karelerinin ortalaması (Least Mean Square) minimize edilene kadar sürekli olarak değiştirilir. Bu sebeple kural En Küçük Kareler Öğrenme Kuralı olarak da bilinmektedir.

Delta kuralının kullanılmasında en önemli faktör ise eğitim verilerinin sıralı olmamasıdır. Eğer eğitim verileri rasgele dağılmamışsa ve düzgün bir sırada ise bu durum öğrenme işleminin önüne geçmektedir.

2.5.4. Kohonen Kuralı

Teuvo Kohonen tarafından 1982 yılında geliştirilen kural biyolojik sistemlerin öğrenme şeklerinden esinlenerek geliştirilmiştir. Kohonen öğrenme kuralında nöronlar arasında bir yarış söz konusudur. En uygun çıktı değerini üreten nöron kuralın kazananı olarak tanımlanmaktadır. Kazanan nöronun komşu nöronları ile arasındaki bağlantı ağırlıkları değiştirilerek öğrenme işlemi gerçekleştirilir.

2.6. Yapay Sinir Ağlarının Avantaj ve Dezavantajları

YSA çalışmaları tarih olarak 1940 yıllarına uzanmaktadır fakat yaygın kullanımının 1980 sonrasında başladığını söylemek mümkündür (Keskenler ve Keskenler, 2017:11). İlk çalışmaların daha çok yapısal ve kuramsal çalışmalar olduğu görülmektedir. Toplama fonksiyonları, aktivasyon fonksiyonları, gizli katman sayısı, öğrenme algoritmalarının oluşturulması gibi farklı çalışmalar eklenerek YSA bugünkü haline gelmiştir (Ataseven, 2014:113).

Çalışmalarda YSA kullanımının veri setine, problemin karakteristik özelliklerine ve YSA'nın kendi karakteristik özelliklerine göre hem avantajları hem de dezavantajları bulunmaktadır.

2.6.1. Yapay Sinir Ağlarının Avantajları

YSA'nın avantajları; genelleme, hata toleransı, uyum gösterme, paralel çalışma ve varsayıma gerek duymama olmak üzere 5 başlık altında toplanabilmektedir (Schalkof, 1997; akt. Aktaş, 2003).

Genelleme: Yapay sinir ağlarının en önemli avantajlarından birisi eksik veya hatalı veriler olması durumunda da doğru sonuca ulaşabilmesidir. Diğer tahmin yöntemlerinde bu durum modelin kurulamamasına yol açarken yapay sinir ağı modellerinde yalnızca performans düşüşüne sebep olmaktadır.

Hata Toleransı: Yapay sinir ağı içerisinde birçok yapay sinir hücrelerini barındırmaktadır. Bu durum yapay sinir ağına, hücrelerin bir kısmının hatalı sonuç üretmesine rağmen doğru sonuç üretme yeteneği sağlamaktadır. Geleneksel tahmin yöntemlerinden sürecin bir noktasında meydana gelecek bir hata YSA modellerine göre süreci çok daha fazla etkilemektedir.

Uyum Gösterme: Yapay sinir ağlarının bir diğer önemli avantajı ise ağ eğitildikten sonra yeni verileri daha hızlı analiz edebilmesi ve farklı problemler için de kullanılabilmesidir.

Paralel Çalışma: YSA insan beynini taklit etme üzerine kurulduğu için barındırdığı tüm hücrelerden neredeyse aynı anda işlem gerçekleştirebilmektedir. Bu sayede çok daha hızlı sonuca ulaşabilmektedir.

Varsayıma Gerek Duymaması: Geleneksel tahmin yöntemleri belirli varsayımlar üzerine kurulmaktadır. Yapay sinir ağında ise hem model

kurma aşamasında hem de sonuç üretme aşamasında bir varsayıma ihtiyaç duymamaktadır. Dolayısı ile sayılar ile kodlanabilecek her türlü veriyi yapay sinir ağlarında kullanmak mümkün hale gelmektedir.

2.6.2. Yapay Sinir Ağlarının Dezavantajları

YSA kullanım yaygınlığı dolayısı ile avantajları ile öne çıkar bir yöntem olsa da bununla birlikte birtakım dezavantajlara da sahiptir. Bu dezavantajlar genellikle problem yapısına ve veri setine göre değişkenlik göstermektedir. Bunlardan bazıları çözüm yönteminin tam olarak bilinmemesi, geniş kapsamlı veriye ihtiyaç duyulması ve kapsam genişledikçe ağın eğitim süresinin artmasıdır.

Çözüm: Yapay sinir ağının çözümü nasıl ve neye göre verdiği bilinmemektedir. Bu durum model çıktısının en uygun çözüm olduğu garantisini verememektedir ve yalnızca belirli aralıklar arasında çıktı ürettiği anlamına gelmektedir (Öztemel, 2006:34).

Veri Seti: YSA daha iyi çıktı üretebilmek için çok kapsamlı veri setlerine ihtiyaç duymaktadır. Kimi problemler için araştırmacılar yalnızca kısıtlı miktarda veriye ulaşabildikleri için bu durum yapay sinir ağları kullanımının bir dezavantajı olarak gösterilebilir.

Eğitim Süresi: Yapay sinir ağları ile anlamlı bir sonuca ulaşabilmek için öncelikle ağın eğitilmesi gerekmektedir. Problemin yapısına göre bu eğitim süresi çok fazla zaman ve paraya ihtiyaç duyabilmektedir (Tolon ve Tosunoğlu, 2008:253).

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI YÖNTEMİ İLE TÜRKİYE SU ÜRÜNLERİ SEKTÖRÜNDE BİR TAHMİN UYGULAMASI

Türkiye coğrafi olarak üç tarafı denizlerle çevrili bir ülkedir. Geniş kıyılara sahip olması sebebi ile Türkiye'nin su ürünleri sektöründe yüksek bir potansiyele sahip olduğunu söylemek mümkündür. Türkiye'nin bu konumundan dolayı su ürünleri üretiminde dağınık bir yapıya sahiptir. Ayrıca su ürünleri üretim miktarlarını net ve sık aralıklarla kaydedebilmek çok masraflı ve zahmetli bir iş olabilmektedir. Bu sebeple sektör ile ilgili veriler genellikle yaklaşık değerler şeklinde kaydedilmektedir. Su ürünleri üretimindeki dalgalanmalar farklı birçok sebebe dayanabilmekte ve bu sebeplerin doğru bir şekilde matematiksel olarak ifade edilmesi her zaman mümkün olmamaktadır.

3.1. Su Ürünleri Sektörü

Tarımın bir alt başlığı olan su ürünleri sektörü; insanlar için önemli bir besin kaynağı olması, endüstriyel gelişime katkı sağlaması, istihdam oluşturması, farklı sektörlerde faaliyet gösteren işletmelere hammadde sağlaması ve ihracat potansiyelinin yüksek olması dolayısı ile çok önemli bir konumdadır (Şahin, 2002:3).

Su ürünlerinde üretim temel olarak; avcılık ve yetiştiricilik olmak üzere iki farklı şekilde yapılmaktadır. Her iki tür de hem iç sularda hem de açık denizlerde yapılabilmektedir. Sektörün günümüzdeki kadar gelişmediği dönemlerde yetiştiricilik çok fazla yaygın değilken, günümüzde yetiştiricilik

yöntemi ile üretilen su ürünleri miktarı neredeyse avcılık yöntemi ile üretilen miktarı yakalamıştır. Bu durumun bilinçsiz avcılık ile stokların riske atılmasından ve yetiştiricilik konusu ile ilgili bilgi ve teknoloji düzeyinin artmasından kaynaklandığını söylemek mümkündür.

Sektörün gelişimi ile ilgili zaman içerisinde temel olarak üç önemli dönem gerçekleşmiştir. Bunlar; 1960'larda yaşanan artış eğilimi, 1970'lerdeki durgunluk ve 1980 sonrasındaki artış eğilimidir (Hoşsucu vd., 2001:595). Yaşanan ilk artışın sektörle alakalı teknolojik gelişmelerden kaynaklandığını söylemek mümkündür. 1970'lerde yaşanan durgunluğun da yine teknolojik gelişmeler doğrultusunda insanların bilinçsiz avlanması ve denizlerdeki balık stoklarını tehlikeye atması nedeniyle gerçekleşmiştir. 1980 ve 1990 yılları arasındaki sektörde yine bir artış eğilimi gözlenmiştir. Bir önceki dönemde yaşanan stokların tükenme riskinin atılması ve daha bilinçli avcılık yapılmaya başlanması ile bu artışın gerçekleştiğini söylenebilir.

Su ürünleri sektörünün en önemli katkısı insan beslenmesinde görülmektedir. Su ürünleri zengin hayvansal protein kaynaklarından bir tanesidir ve beslenmede çok önemli bir yere sahiptir. Sindiriminin kolay olması ve yüksek protein içermesi bakımından insan vücuduna pek çok yararı bulunmaktadır. Dünya nüfusu tarafından tüketilen protein miktarının genel protein kaynaklarının %7'sini, hayvansal protein kaynaklarının ise %17'sini su ürünleri oluşturmaktadır (FAO, 2022:86).

Sektörün ve dünya pazarındaki ulaşım kanallarının gelişimine bağlı olarak ülkelerdeki kişi başına tüketilen balık miktarı da artış göstermiştir. 1961 yılında kişi başına tüketim 9,9 kg iken bu rakam 2011 yılında 18,5 kg, 2016 yılında 20,3 kg ve 2019 yılında 20,5 kg olarak gözlenmiştir. Bu rakamın 2030 yılında kişi başına 21,8 kg olacağı FAO tarafından öngörülmektedir. (FAO, 2022:82)

Su ürünlerinin insan vücuduna faydaları ve tüketim açısından ulaşılabilirliği dışında ekonomiye de büyük katkıları bulunmaktadır. Dünyada çoğu gelişmekte olan ülkelerde yaşayan ve su ürünleri üretiminde aktif olarak çalışmakta olan 41 milyondan fazla insan bulunmaktadır (Finegold, 2009:353). Su ürünleri özellikle gelişmemiş ülkelerde birçok insanın geçim ve yiyecek kaynağıdır. Dünya çapında su ürünleri sektörüne bağlı olarak geçimini sürdüren yaklaşık 200 milyon insan olduğu varsayılmaktadır. Sektörün üretim


kısımında bulunan bu insanların haricinde tüketici konumundaki insanlar da gün geçtikçe artmaktadır. Günümüzde ekonomik durumların iyileştiği ve kentleşmenin arttığı şehir ve ülkelerde balık tüketiminin de buna bağlı olarak arttığı gözlemlenmektedir (Helfman vd., 2009:623).

Özellikle gelişmekte olan ülkelere hem üretim alanında hem de endüstriyel alanda istihdam sağlaması nedeniyle su ürünleri sektörünün önemi giderek artmaktadır. Su ürünlerinin endüstriyel alanda istihdam sağlamasının dışında katma değerli ürünler vasıtası ile ihracata da oldukça fazla katkısı bulunmaktadır.

Tüm bu katkıların yanında sektörün gelişiminin olumsuz etkileri de bulunmaktadır. Sektörün hızlı gelişmesi ile insanlar yatırımlarını bu alanda yoğunlaştırmışlardır. Bu durum finansal olarak büyümeye katkı sağlarken balık türlerinden bazılarını tehlikeye atmıştır. Aşırı avlanma, avlanma yasaklarına uyulmaması, kimi türlerin gelişiminin tamamlanmadan avlanması bu durumun sebeplerinden yalnızca birkaçıdır. Yetiştiricilik ile ilgili problemlerden bir tanesi de kıyı yetiştiriciliği yapılırken birbirlerinin besin kaynağı olabilecek türlere dikkat edilmemesi olarak gösterilebilir.

3.2. Dünya’da Su Ürünleri Sektörü

İnsanlar geçmişte genellikle su kaynaklarının yanında yaşamayı tercih etmişlerdir. Bunun temel sebeplerinden bir tanesi de bu su kaynaklarının insanlara sunduğu imkânlardır. Bu nedenle su ürünlerinin neredeyse insanlık tarihi kadar eski olduğunu söylemek yanlış olmaz. Medeniyet tarihinin başlangıcından kalma kalıntılar da bu durumu destekler niteliktedir. Su ürünlerinin insanlara sağladığı en temel fayda besin kaynağı olarak kullanılabilmesidir. Bu nedenle insanlığın su ürünlerine olan ihtiyacı gün geçtikçe artmaktadır. 2015 yılında dünya nüfusu tarafından tüketilen toplam hayvansal protein miktarının %17’sini su ürünleri oluşturmuştur (FAO, 2018:86).



Şekil 3.1: Avcılık ve Yetiştiricilik Miktarlarının Yıllar İçindeki Dağılımı

Kaynak: FAO, 2022:4

FAO tarafından yayınlanan veriler doğrultusunda hazırlanan Şekil 3.1’de de görülebileceği üzere zaman içerisinde avcılık ile üretilen miktarın artışı durmuş ve buna karşın yetiştiricilik ile üretilen miktarda önemli derecede artış gözlemlenmiştir. 1969 yılında üretilen toplam su ürünleri miktarı 62 milyon ton olarak kaydedilmiş ve bunun yalnızca 2,36 milyon tonu yetiştiricilik yöntemi ile üretilmiştir. 2016 yılında kaydedilen verilerde ise toplamda üretilen miktar 171 milyon tona ulaşmıştır. 2016 yılında yetiştiricilik ile üretilen su ürünleri miktarı 80 milyon ton olarak kaydedilmiş ve avcılık ile üretilen miktarı neredeyse yakalamıştır. 2020 yılında ise yetiştiricilik 88 milyon tona ulaşırken avcılık ise 90 milyon ton olarak kaydedilmiştir. Şekilden de anlaşılacağı üzere su ürünleri yetiştiriciliğinin hızlı gelişen sektörlerden bir tanesi olduğunu söylemek mümkündür.

Tablo 3.1: Yıllara Göre Dünya Su Ürünleri Üretimi (Avcılık)

	AVCILIK (ton)		
	Deniz	İçsu	Toplam
2012	77.780.981	10.872.119	88.653.099
2013	78.800.858	10.899.792	89.700.650
2014	79.303.773	11.024.644	90.328.417
2015	80.438.718	11.134.146	91.572.864
2016	78.206.872	11.314.670	89.521.542
2017	81.491.055	11.877.368	93.368.423
2018	84.520.639	11.985.462	96.506.101
2019	80.105.137	12.090.295	92.195.432
2020	78.795.376	11.470.557	90.265.933

Kaynak: FAO

Tablo 3.1’de avcılık ile su ürünleri üretiminin son yıllarda durağanlaştığını ve hatta son birkaç yılda gerilemeye başladığını görmek mümkündür. Buna karşın Tablo 3.2’de ise yetiştiricilik ile üretilen miktarların yıllar içindeki gelişimi görülmektedir. Yetiştiricilik ile üretim yapıldığında avcılıkta olduğu gibi canlı türlerinin nesillerinin tükenmesi ile ilgili bir sorunla karşılaşılmamaktadır. Ancak yetiştiricilikte kullanılan yemlerin de yine balıklardan (balık unu ve yağı) gelmesi dolayısı ile avcılık miktarlarından oldukça etkilenmektedir. Aşırı avlanma sonucu belirli türlerin yok olması yetiştiricilikte yem fiyatlarını büyük oranda etkilemektedir.

Tablo 3.2: Yıllara Göre Dünya Su Ürünleri Üretimi (Yetiştiricilik)

	YETİŞTİRİCİLİK (ton)		
	Deniz	İçsu	Toplam
2012	23.936.250	39.580.025	63.516.275
2013	24.889.518	42.069.856	66.959.374
2014	26.254.568	44.304.447	70.559.016
2015	27.068.357	45.861.641	72.929.997
2016	28.609.670	47.960.247	76.569.918
2017	30.083.077	49.545.170	79.628.248
2018	30.877.296	51.601.032	82.478.328
2019	31.862.628	53.349.551	85.212.180
2020	33.118.115	54.384.495	87.502.609

Kaynak: FAO

Her yıl küresel balık üretiminin yaklaşık olarak %40'ı uluslararası ticarete ayrılmakta ve bu miktarın %60'ını geliştirmekte olan ülkelerin ihracatı oluşturmaktadır (Finegold, 2009:356). Su ürünleri sektörünün en önemli avantajlarından bir tanesi de ihracat noktasında potansiyelinin çok yüksek olmasıdır. Özellikle geliştirmekte olan ülkelerin bu potansiyeli değerlendirmeleri durumunda ekonomilerinde önemli katkılar gözlemlenebilir.

3.3. Türkiye'de Su Ürünleri Sektörü

Gelişmekte olan Türkiye üç tarafı denizlerle çevrili bir ülkedir. Daha önce bahsedildiği gibi su ürünleri sektörünün özellikle geliştirmekte olan ülkelere çeşitli faydalar sağladığını söylemek mümkündür. Türkiye'nin kuzeyinde Karadeniz, güneyinde Akdeniz, batısında Ege ve kuzeybatısında Marmara denizleri bulunmaktadır. Toplamda 8333 km'lik kıyı şeridi bulunan ülke, akarsu, göl ve göletleri ile su ürünleri açısından çok yüksek bir potansiyele sahiptir. Su ürünlerinin ekonomiye sağladığı katkılar şu şekilde özetlenmiştir (Doğan, 1997:15);

- Besin kaynağı olarak zengin bir hayvansal protein kaynağı olması
- Diğer bazı sanayilere hammadde sağlaması
- Hem üretim hem endüstriyel alanda geniş istihdam olanakları sağlaması

- İhracat potansiyelinin yüksek olması
- Üretimi ve ticareti sırasında kullanılan araç ve gereçlerdeki teknolojik gelişmeler

Bu katkılar göz önünde bulundurulduğunda Türkiye'nin su ürünleri sektörüne yatırım yapması ülkenin gelişimi açısından önem arz etmektedir.

Türkiye'de su ürünleri sektörünün 2000'li yıllarda gelişimini hızlandırdığını söylemek mümkündür. Daha önceki tarihlerde su ürünleri sektörü yalnızca yerel olarak ülke ekonomisine katkı sağlarken bu yıllardan sonra sektör ile ilgili ithalat ve ihracat artış göstermeye başlamıştır. Su ürünleri sektörünün potansiyelinin kavranması ile bu sektördeki yatırımlarda artış göstermeye başlamıştır. Türkiye'de 2007 yılında 772 bin ton olan toplam su ürünleri üretim miktarı 2021 yılında 799 bin ton olarak kayıtlara geçmiştir. Yayınlanan son Türkiye İstatistik Kurumu (TÜİK) verilerine göre ise 2022 yılı toplam su ürünleri üretim miktarı 849 bin ton olarak gerçekleşmiştir. Zaman içerisinde üretim miktarlarının dalgalı olduğunu söylemek mümkündür. Aşağıdaki Tablo 3.3'te Türkiye'nin yıllara göre su ürünleri üretim miktarları verilmiştir.

Tablo 3.3: Türkiye Su Ürünleri Üretim Miktarları

	Avcılık (ton)	Yetiştiricilik (ton)	Toplam
2012	432.442	212.410	644.852
2013	374.121	233.394	607.515
2014	302.212	235.133	537.345
2015	431.907	240.334	672.241
2016	335.320	253.395	588.715
2017	354.318	276.502	630.820
2018	314 094	314 537	628 631
2019	463 168	373 356	836 524
2020	364 400	421 411	785 811
2021	328 158	471 686	799 844
2022	335 003	514 805	849 808

Kaynak: TÜİK

İnsanların genel olarak kişi başına tükettikleri su ürünleri miktarları artarken Türkiye için durum farklılaşmaktadır. Türkiye’de kişi başına düşen su ürünleri miktarı 2000 yılında 8 kg olarak rapor edilmiş ve 2007 yılında 8,6 kg ile en yüksek düzeyine ulaşmıştır. 2017 yılında ise bu rakam oldukça düşerek 5,5 kg olarak kayıtlara geçmiştir. Dünya genelinde pozitif trende sahip kişi başına tüketimin, Türkiye’de tam zıt yönde ilerlemesinin ülkede o yıl gerçekleşen üretim miktarlarına bağlı olarak değişim göstermiş olabileceği düşünülmektedir (Saygı vd., 2015:252).

Dünyadayaklaşık 20.000’den fazla balık çeşidi bulunduğu varsayılmaktadır. Bu türlerden yaşadıkları yerlere göre sınıflandırılabilirler. Denizlerde taban ve yüzeyden bağımsız, aktif olarak hareket edebilen canlılara pelajik canlılar adı verilmiştir. Denizin tabanında yaşayan canlılar ise demersal canlılar olarak adlandırılmıştır.

Pelajik balık türlerinden Türkiye’de avcılığı yaygın olarak yapılan türler; hamsi, sardalya, istavrit, palamut, lüfer ve çaça olarak sayılabilmektedir. Yaygın olarak avlanan demersal balık türleri ise; mezigit, berlam, tekir, barbunya ve kalkandır.

Türkiye’de yetiştiricilik faaliyetleri ekonomik olarak ilk defa 1970’li yıllarda alabalık ve sazan üretimi ile başlamıştır (Aydın, 2017:64). Türkiye’de yetiştiriciliği yaygın olarak yapılan üç farklı tür bulunmaktadır. Bunlar; alabalık çipura ve levreklerdir. Bu türler arasında alabalık yetiştiriciliği diğerlerine göre çok daha yaygın olarak yapılmaktadır. Alabalığın piyasada çok daha kolay kabul görmesi, yem kullanım verimliliğinin fazla olması bu durumun temel etmenlerindedir.

2000’li yıllarda su ürünlerinin öneminin anlaşılması ile birlikte sektörün ithalat ve ihracat miktarları da artış göstermiştir. Türkiye’nin 2003 yılında ihracat miktarı 29 bin ton ve ithalat miktarı 45 bin ton, 2007 yılında ise ihracatın 47 bin ton ithalatın 58 bin ton ve 2012 yılında bu rakamların ihracatta 74 bin ton ithalatta 65 bin ton olduğu TÜİK tarafından hesaplanmıştır. Özellikle 2012 yılından sonra dış ticaret miktarları önemli derecede artmıştır. Bu durumun ülkenin potansiyeli fark etmesi ve bu bağlamda planlar yapmasına bağlamak mümkündür. Tablo 3.4’te yıllar içindeki değişim görülmektedir.

Tablo 3.4: Türkiye Su Ürünleri Dış Ticaret Verileri

Yıl	Üretim	İhracat	İthalat
2000	582.376	14.533	44.230
2001	594.977	18.978	12.971
2002	627.847	26.860	22.532
2003	587.715	29.937	45.606
2004	644.492	32.804	57.694
2005	544.773	37.655	47.676
2006	661.991	41.973	53.563
2007	772.323	47.214	58.022
2008	646.310	54.526	63.222
2009	622.962	54.354	72.686
2010	653.080	55.109	80.726
2011	703.545	66.738	65.698
2012	644.852	74.007	65.384
2013	607.515	101.063	67.530
2014	537.345	115.682	77.545
2015	672.241	121.053	110.761
2016	588.715	145.469	82.074
2017	630.820	156.681	100.444
2018	628 631	177.500	98.315
2019	836 524	200.226	90.684
2020	785 811	201.375	85.269
2021	799 844	238.732	104.708

Türkiye'nin 2010 yılında avcılık ve yetiştiricilik ile ürettiği miktarlardan elde ettiği toplam değer yaklaşık olarak 2 milyar Türk lirasıdır. Bu miktarın neredeyse yarısı yetiştiricilikten elde edilmiştir. Ancak daha önce de vurgulandığı üzere su ürünleri sektörünün yetiştiricilik alanı çok hızlı bir

şekilde gelişmektedir. Bu bağlamda Türkiye’de üretilen su ürünlerinden 2017 yılında elde edilen değer yaklaşık 5,5 milyar Türk lirası olmuştur. Bu miktarın yalnızca 1,5 milyar Türk lirasının avcılık ile elde edilmiş olması yetiştiriciliğin Türkiye’de benimsenmeye başladığını kanıtlar niteliktedir.

3.4. Araştırmanın Amacı ve Önemi

Küresel rekabet ortamında işletmeler stratejik kararlar alırken, hedeflere en az sapma ile ulaşabilmek için somut bilgilere ihtiyaç duymaktadırlar. Geleceğe yönelik kararların alınmasında geçmiş verilerden yararlanarak tahminlerde bulunmak hedeflenen sonuçlara ulaşılmasını kolaylaştırmaktadır. Bu kararlar alınırken belirsizliklerin azaltılması hem fırsatları değerlendirme noktasında hem de karşılaşılabilecek bir olumsuzluğu engelleme veya önlem alma noktasında çok önemli bir yere sahiptir.

Bu araştırmanın temel amacı, ilgili değişkenler kullanılarak su ürünleri sektörünün üretim verilerinin ileriye dönük başarılı ve tutarlı bir şekilde tahmin edilmesidir. Üretilen tahmin sonuçları doğrultusunda ise sektör paydaşlarının dengeli bir üretim planı oluşturmalarına katkıda bulunulması hedeflenmektedir.

3.5. Araştırmanın Sınırlamaları

Araştırma yalnızca Türkiye’nin su ürünleri sektörünü kapsayacak şekilde yapılmış ve diğer ülkelerin verileri çalışmaya dâhil edilmemiştir. Türkiye’ye ait üretim verilerinin FAO tarafından yıllık olarak açıklanması dolayısı ile tüm veriler yıl bazında toplanmış ve bu şekilde modele dâhil edilmiştir.

Su ürünleri üretimini etkileyebileceği sonucuna ulaşılan ithalat ve ihracat verilerine 1970 yılından itibaren ulaşılabilmesinden dolayı çalışma 1970-2020 yılları ile sınırlandırılmıştır. 1970 yılı öncesindeki veriler çalışmaya dâhil edilememiştir.

3.6. Tahmin Yönteminin Seçimi

Zaman serileri ile tahmin yöntemleri arasında en yaygın olarak kullanılan yöntem Box-Jenkins yöntemidir ve bu yöntem kesikli, doğrusal stokastik süreçlere dayanmaktadır (Karahan, 2011:84). Gerçek hayatta karşımıza çıkan problemler ise genelde doğrusal olmayan bir yapıya sahiptir. Dolayısı ile bu problemlere çözüm üretebilmek için doğrusal olmayan yöntemlere

ihtiyaç duyulmaktadır. YSA yöntemi özellikle son 20 yıl içerisinde oldukça fazla tercih edilen ve doğrusal yapıda olmayan problemlere tutarlı çözümler üretebilen bir zaman serileri tahmin yöntemidir.

Çalışmanın daha önceki bölümlerinde de bahsedildiği üzere yapay sinir ağları geleneksel tahmin yöntemlerinin uygulanamadığı veya yetersiz kaldığı durumlarda başarılı bir şekilde kullanılabilir. YSA'ların kullanıldığı birçok çalışmada elde edilen sonuçların performansları farklı tahminleme yöntemleri ile karşılaştırılmış ve daha yüksek performansa sahip olduğu tespit edilmiştir. YSA'ların; eksik veri ile çalışabilmesi, ön hazırlık gerektirmemesi, hataların ağa yayılması ile öğrenme işlemini gerçekleştirebilmesi bu durumun temel sebeplerinden bazılarıdır.

3.7. Literatür Taraması

Yapay sinir ağları (YSA) uygulamaları herhangi bir konu ile ilgili çeşitli verilerin sınıflandırılması, birbirleriyle ilişkilendirilmesi, yorumlanması ve ileriye dönük olarak tahmin edilmesi için kullanılır. Yapılan literatür araştırmasında Türkiye'nin su ürünleri üretimi ile ilgili bir YSA çalışmasına ulaşamamakla birlikte YSA'nın farklı uygulamaları ile ilgili çok sayıda çalışma bulunmaktadır. Bu çalışmalar endüstri için önemli bir girdi olan enerji ile ham petrol ve elektrik fiyatlarının tahmini, makro ve mikro ekonomik kararlar için enflasyon tahminleri, çeşitli endüstriyel ürünlerindeki üretimin ve taleplerin tahmini, ihracat tahminleri, turizme yönelik tahminler, altın fiyatlarının ve borsadaki değişimlerin tahmini gibi çok farklı alanlar için yapılan çalışmaları içermektedir.

Türkiye net enerji talebini tahmin etmek için, 1970-2020 yılları arasındaki Gayri Safi Yurtiçi Hasıla, nüfus, ithalat, ihracat gibi değişkenleri ağırlıklı ve enerji talebini de çıktı olarak kullanan bir model geliştirilmiştir (Es vd., 2014). Bu modelde nöron sayısı deneme yanılma yöntemi ile belirlenmiş, öğrenme metodu olarak Bayesyen düzeltmeye dayanan geri yayılım algoritmasını kullanılmıştır. Yapılan çalışma sonucunda kurulan YSA modeli %4,21 ortalama mutlak yüzde hata değeri ile karşılaştırılan çoklu doğrusal regresyon modelinden daha başarılı bir performans sergilemiştir.

Türkiye'nin aylık elektrik talebini YSA ile tahmin etmek için yapılan çalışmada 4 farklı model kurulmuş (Hamzaçebi vd., 2017), modelde 2002-

2014 yılları arasındaki aylık elektrik talebi verileri kullanılmıştır. Kurulan modellerinin birbirinden farkı, farklı kurallar doğrultusunda girdi verilerinin seçilmiş olmasıdır. Bunlar; bir önceki gözlemin girdi olması, önceki gözlemin ve önceki mevsimsel gözlemin girdi olması gibi iterasyonları içermektedir. Modellerin kurulduktan sonra her bir modelin performans kriterleri incelenmiş ve en iyi performans değerine sahip model belirlenmiştir. Seçilen bu model YSA'nın tahmin yeteneğini vurgulamak amacı ile SARIMA modelinin değerleri ile karşılaştırılmıştır. SARIMA modelinin MAPE değeri 2.53 ve YSA modelinin MAPE değeri de 1.97 olarak hesaplanmıştır. Yine Türkiye'nin elektrik talebini tahmin edebilmek için üç katmanlı geri beslemeli ve Tekrarlayan YSA modellerinin uygulandığı çalışmada (Çunkaş ve Altun, 2010), girdi olarak nüfus, hane sayısı, ham petrol fiyatı gibi değişkenler kullanılmıştır. Modellerin performanslarını belirlemek ve karşılaştırmak amacı ile Mutlak Yüzde Hata (APE) kullanmıştır. Modeller arasında Tekrarlayan YSA modelinin performans açısından daha iyi sonuçlar verdiği görülmüştür. 2008-2014 arasındaki yıllar için yapılan tahminlerin gerçekleşen değerler ile tutarlı olmasının elektrik talebinin Türkiye'nin ekonomik durumundan etkilendiğini kanıtlar nitelikte olduğu yazarlar tarafından vurgulanmıştır.

Kısa dönem elektrik yükünü YSA kullanarak tahmin eden çalışmada (Chae vd., 2017), gizli katman sayısının, gizli nöron sayısının ve öğrenme algoritmalarının ağın performansını ne derecede etkilediği incelenmiş, yapılan tahminin %10 hata ile gerçeğe yaklaştığı görülmüştür.

Çok katmanlı geri yayımlı YSA modelini kullanarak elektrik fiyatını tahmin edilmesinde (Singhal ve Swarup, 2011), elektrik fiyatının elektrik yükü ile bağlantısından yola çıkarak YSA modeli oluşturulmuştur. Hafta içi ve hafta sonu için tahmin edilen ve gerçekleşen değerler karşılaştırılmıştır. YSA modelinin elektrik fiyatını tahmin etmede kullanılabileceği, farklı yöntemlerle YSA birleştirilerek daha başarılı modeller kurulabileceği vurgulanmıştır.

Kandananond'ın (2011) çalışmasında YSA, otoregresif hareketli ortalamalar ve çoklu lineer regresyon yöntemleri kullanılarak Tayland elektrik talebinin tahmin edilmesi hedeflemiştir. 1986-2010 yılları arasındaki nüfus, borsa endeksi, endüstriyel ihracat ve elektrik tüketimi verileri ışığında YSA, ARIMA ve Çoklu Lineer Regresyon modellerinin MAPE değerleri

sırasıyla %0,996, %2,809 ve %3,260 olarak bulunmuştur. En iyi değere YSA modelinde ulaşılmış, modellerin t-testleri incelendiğinde anlamlı bir farklılık olmadığı görülmüş ve diğer modellerin daha kolay bir yapıda olmasından dolayı YSA yöntemi yerine tercih edilebileceği ifade edilmiştir.

İhracat miktarlarını tahmin etmede YSA ve ARIMA modellerinin kullanıldığı çalışmada (Karahan, 2015), 2004-2010 yılları arasındaki tahminler çerçevesinde iki modelinde birbirine yakın sonuçlar alınmıştır. Modellerin gerçekleşen değerlere yakınlığı ve hassasiyeti bakımından YSA modelinin daha başarılı olduğu görülmüştür.

İthalat ve ihracat değişkenleri doğrultusunda ekonomik büyümeyi tahmin etmeye çalışan analizde, geri yayılım ve ELM (Extreme Learning Machine) öğrenme algoritmalarını kullanan iki farklı YSA modeli (Sokolov-Mladenovic vd., 2016) kurulmuştur. Elde edilen sonuçlar doğrultusunda ELM algoritmaları için RMSE değeri 0.428 ve geri yayılım algoritmaları için RMSE değeri 1.128 olarak tespit edilmiştir. ELM öğrenme algoritması ile kurulan modelin ekonomik büyümeyi tahmin etmede daha başarılı olduğu sonucuna ulaşılmıştır.

Hindistan'daki enflasyonu YSA ile tahmin etmek için 2000-2012 yılları arasındaki veriler (Thakur vd., 2016) kullanılmıştır. Bu çalışmada ithalat, ihracat verileri, altın ve petrol fiyatları, gibi veriler bağımsız değişken olarak seçilerek enflasyon değeri (bağımlı değişken) tahmin edilmeye çalışılmıştır. Kurulan YSA modeli doğrultusunda %95'lik bir R^2 oranına ulaşılmış ve modelin değişkenler doğrultusunda enflasyonu tahmin etme başarısının yüksek olduğu tespit edilmiştir.

Türkiye'deki enflasyonun tahmini için TÜFE verilerini kullanarak Box-Jenkins ve YSA yöntemlerinin karşılaştırıldığı çalışma Akdağ ve Yiğit (2016) tarafından yapılmıştır. Elde edilen analiz sonuçları, enflasyonun kontrol edilemeyen değişkenlere göre belirlenmesinin kurulan modellerin başarısına etki ettiği görülmüştür. Çalışmanın sonucunda Box-Jenkins yönteminin YSA yöntemine göre bir miktar daha iyi sonuç elde edilmiştir.

Ham petrol fiyatlarını tahmini için 1986-2009 tarihleri arasındaki aylık verilerden yararlanarak yapılan çalışmada ARIMA ve MLP (çok katmanlı), RBP (radyal tabanlı) YSA modelleri kullanılmıştır (Kaynar vd., 2010).

Modellerin sonuçları ortalama mutlak yüzde hata (MAPE) değerlerine göre karşılaştırılıp en iyi sonucu radyal tabanlı YSA modelinden elde edilmiştir.

Türkiye’de geleneksel bir yatırım aracı olarak görülen altın fiyatlarını öngörebilmek amacıyla modeller oluşturulmuştur (Yüksel vd. 2016). Analizlerde girdi olarak gümüş ve petrol fiyatları, ABD doları/EUR paritesi, EuroNext100 endeksi, Amerika Dow Jones Endeksi, 13 Hafta vadeli ABD bonusu faiz oranı ve ABD TÜFE endeksi parametreleri kullanılmıştır. Oluşturulan modellerin test edilmesi sonucunda YSA modelinin altın fiyatlarını tahmin etmedeki başarılı bulunmuş, en iyi sonuca 16 nöron sayısına sahip modelde ulaşılmıştır. Yine Türkiye’deki altının gram fiyatının değişim yönünü dolar endeksi, ham petrol fiyatı, BIST100 endeksi, enflasyon ve faiz oranları gibi bağımsız değişkenler kullanarak YSA ile tahmini, Kocatepe ve Yıldız (2016) tarafından yapılmıştır. Uygulanan yöntemin tahmin başarısının altın gram fiyatının artış yönünde olduğu zaman azalış yönünde olduğu zamana göre daha iyi olduğu belirtilmiştir. Çalışmada kullanılan yöntemin genel tahmin başarısının %75,24 olduğu vurgulanmıştır.

Hisse senedinin günlük fiyatlarını ve değişim yönlerini YSA yöntemi ile tahminine yönelik yapılan çalışmada (Çalışkan ve Deniz, 2015) 32 farklı girdi değişkeni modele tanımlanmış ve bu değişkenleri doğrultusunda beş günlük tahmin gerçekleştirilmiştir. Literatürde %50 ile %75 aralığı doğru tahmin olarak verilmiş olup kurulan modelde fiyat yönü tahmin oranı %58 olarak gerçekleşmiştir.

Borsa endeksi verilerinden yararlanarak yapılan çalışmada (Sheta vd., 2015) Regresyon, YSA ve Destek Vektör Makineleri (DVM) yöntemleri birlikte değerlendirilmiştir. Borsa verilerindeki dalgalanmayı DVM yönteminin diğer yöntemlere göre çok daha başarılı tahmin ettiği görülmüştür. Karşılaştırma kriteri olarak hata değerleri kullanılmış, Regresyon, YSA ve DVM yöntemleri için RMSE sırasıyla 5.7, 6.6 ve 3 olarak belirlenmiştir.

Sheta vd. (2015) borsa endeksi verilerinden yararlanarak Regresyon, YSA ve Destek Vektör Makineleri (DVM) yöntemlerini karşılaştırmışlardır. Çalışmalarının sonucunda borsa verilerindeki dalgalanmayı DVM yönteminin karşılaştırılan diğer yöntemlere çok daha başarılı tahmin ettiği yazarlar tarafından belirtilmiştir. Karşılaştırma kriteri olarak hata değerlerini kullanan

yazarlar Regresyon, YSA ve DVM yöntemleri için RMSE değerlerini sırasıyla 5.7, 6.6 ve 3 olarak tespit etmişlerdir.

Çuhadar'ın (2013) çalışmasında 2001-2013 yılları arasında Antalya Belek turizm merkezinde gerçekleşen aylık golf oyun sayılarını girdi olarak kullanıldığı çalışmada 2014 yılı aylık golf turizm talebini Box-Jenkins yöntemi ile tahmin edilmiştir. Yine Çuhadar (2014) tarafından Muğla iline yönelik dış turizm talebi, Üstel Düzleştirme ve Box- Jenkins yöntemleri ile modellenmiş ve 2012-2013 yılları için tahmin işlemini gerçekleştirmiştir. Kurulan modeller arasında en doğru sonucu Holt-Winters Üstel Düzleştirme yönteminin verdiği görülmüştür.

Aylık turizm talebini tahmin etmek için hava sıcaklığı, döviz kuru ve turizm geliri gibi bağımsız değişkenlerle diğer tahmin yöntemlerine alternatif olarak YSA yöntemi kullanılmıştır. Kurgulanan model ile 48 aylık verilerden faydalanarak 6 aylık turizm talebi tahmin edilmeye çalışılmıştır (Karahan, 2015). Modelin performansı ortalama mutlak yüzde hata (MAPE) ve ortalama hata kareleri (MSE) değerleri incelenerek belirlenmeye çalışılmıştır. YSA modelinin mevsimsel etkiler yansıtılmadığında bile diğer modellere göre daha tutarlı sonuçlar verdiği görülmüştür.

Konaklama işletmelerinin talep tahminini gerçekleştirebilmek amacıyla 2013-2016 yılları arasında satılan oda sayılarını kullanarak oluşturulan YSA modelinde 2017-2018 yılları için talep tahmininde gerçeğe çok yakın tahminler elde edilmiştir (Ulucan ve Kızılırmak, 2018). Yazarlar giriş katmanındaki verileri ve gizli katmandaki nöron sayılarını farklı tutarak iki farklı model oluşturulmuş, modellerin MAPE değerlerinin karşılaştırılmasında bir modelin %50, diğer modelin ise %9 MAPE değerine sahip olduğu görülmüştür.

İspanya için turizm talep verilerinin kullanıldığı çalışmada (Cleaveria vd., 2015), Çok Katmanlı Algılayıcı (ÇKA), Radyal Tabanlı Fonksiyon (RBF) ve Elman Ağları yöntemleri ile modeller kurulmuştur. Turizm talebi tahmininde ÇKA ve RBF ağlarının Elman ağına göre daha iyi performans sergilediği görülmüştür.

Lin ve arkadaşları (2011) tarafından yapılan çalışmada ARIMA, MARS ve YSA yöntemleri karşılaştırılmıştır. Tayvan turizm verileri ile kurulan modeller ortalama hata değerlerine göre karşılaştırılmış, ARIMA modelinin daha

başarılı olduğunu belirlenmiştir. YSA modelinin tahmin etme yeteneğinin ise %14,71 ortalama hata yüzdesi ile kabul edilebilir olduğu görülmüştür.

Otomobil satış miktarlarını YSA ile tahmin etmeyi amaçlayan çalışmada (Karaatlı vd., 2012) 2007-2011 yılları arasındaki aylık veriler kullanılmıştır. Gayri safi yurtiçi hasıla, yatırım harcamaları, tüketim harcamaları, ABD doları kuru, zaman gibi bağımsız değişkenler kullanılarak satılan otomobil sayısı tahmin edilmiştir. Kurulan modelin performansı ortalama mutlak yüzde hatası %16,82 olarak tespit edilmiştir. Bu değer literatürde “doğru tahmin” olarak sınıflandırılmaktadır.

Yerli otomobil üreten bir firmanın 2011-2015 yılları arasında gerçekleşen aylık üretim miktarlarını tahmin etmeyi hedeflemiştir (Akyurt, 2015). Yapılan çalışmada geri yayılım algoritması ile eğitilmiş ileri beslemeli YSA modeli tercih edilmiştir. İncelenen verilerin mevsimsel bir yapıya sahip olduğu belirlenmiş ve incelenen literatür doğrultusunda bir tanesinin orijinal veri setini diğerinin ise mevsimsel etkilerden arındırılmış veri setini kullandığı iki farklı yapay sinir ağı modeli kurulmuştur. Çalışmanın sonucunda mevsimsellikten arındırılmış veri seti ile kurulan YSA modelinin performans açısından daha iyi değerler verdiği kanaatine ulaşılmıştır.

Parakende sektöründe faaliyet gösteren bir firmada yapılan çalışmada (Şatoğlu ve Eren, 2017) zaman serilerindeki zamana göre değişimin tek başına yeterli olmayacağını görülüp iki farklı YSA modeli önerilmiştir. Çalışmada bağımlı değişken olarak iki farklı ürüne ait satış miktarları seçilmiş ve bağımlı değişkenin hava sıcaklığı, indirim ve mağazaya gelen müşteri sayısına göre değişimi incelenmiştir. Kurulan zaman serisi YSA modelinin mevsimsellik gösteren ürün grubunun satış değerlerini daha başarılı bir şekilde tahmin ettiği görülmüştür.

Havayolu ulaşım talebini belirlemek için zaman serisi analizi tekniklerinin karşılaştırıldığı çalışmada (Kuzu vd., 2017), Box-Jenkins ve Gri tahmin yöntemleri kullanılmıştır. Yöntemler karşılaştırılırken MAPE değerleri incelenmiş, Box-Jenkins yönteminin %5,47, Gri tahmin yönteminin ise %7,31 hata oranı ile tahminde bulunduğu saptanmıştır.

İspanya'dan toplanan su tüketim verilerine farklı zaman serisi analizleri uygulanmış ve sonuçlar birlikte değerlendirilmiştir (Herrera vd., 2010).

Yapılan çalışmada kullanılan yöntemler; destek vektör regresyon modeli, çok değişkenli uyarlanabilir regresyon uzanımları modeli, izdüşüm takip regresyon modeli, monte carlo simülasyon modeli ve yapay sinir ağı modelidir. Kurulan modeller ve tahmin sonuçları doğrultusunda, en iyi performansın destek vektör regresyon modelinden elde edilmiş ve YSA modeli beklenenden daha düşük performansta tahminler gerçekleşmiştir.

Çağrı merkezine gelen arama sayılarını Yinelemeli (Dinamik) Sinir Ağı modelleri yardımı ile tahmin etmeye çalışıldığı çalışmada (Jalal vd., 2016) Elamn ve NARX sinir ağı modelleri birleştirilerek yeni bir model sunulmuştur. Sunulan yeni modelin diğer modellere göre daha iyi sonuç verdiği RMSE değerleri ile belirlenmiştir.

Kurumlara yemek hizmeti sağlayan özel bir firmanın veri tabanından elde edilen 2016-2018 yılları verilerinden kurumlardaki yemek talebi tahmini yapılmıştır (Calp, 2018). Çalışmada YSA yöntemi farklı gizli katman sayıları kullanılarak karşılaştırılmış, elde edilen sonuçlar doğrultusunda katmanların nöron sayılarının çok fazla veya çok az olduğu durumlarda modelin performansının düştüğü, hata oranının yükseldiği vurgulanmıştır. Uygun nöron sayısının belirlenmesinin modelin talebi tahmin etme konusundaki önemi vurgulanmıştır.

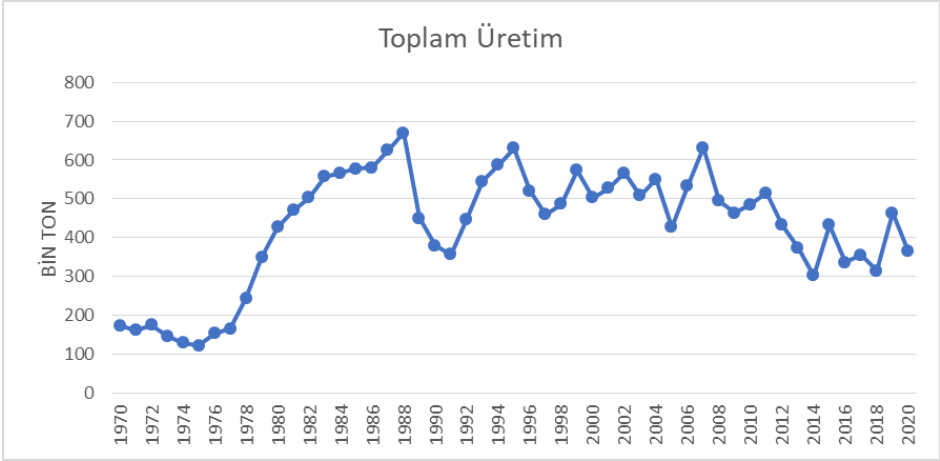
Bireyin iç göç nedenini cinsiyet, yaş, medeni durumunu da içeren 10 farklı bağımsız değişkene göre YSA yöntemini kullanarak tahmin edilmeye çalışılmış (Demirtaş, 2017), kurulan modelin doğruluk oranı %77,46 olarak tespit edilmiştir..

Su ürünlerinde tahmin uygulamaları ile ilgili literatür incelendiğinde tahmin işleminin genel üretim miktarları ile alakalı olmadığı görülmüştür. Bu nedenle literatür taraması farklı konularda tahmin işleminin YSA ile yapıldığı çalışmaları içermiştir. Bu çalışmada ise YSA yöntemi Türkiye'nin su ürünleri üretim miktarını tahmin etmede kullanılmıştır. Konu ile ilgili verilerin yaklaşık değerler ile ifade edildiği ve düzenli olarak tutulmamış olması YSA yönteminin seçilmesinin en önemli sebebidir.

3.8. Verilerin Toplanması ve Düzenlenmesi

YSA modeli ile tahmin işleminin gerçekleştirilebilmesi için problemin bağımlı ve bağımsız değişkene (girdi-çıktı) sahip olması gerekmektedir. Çalışmada su ürünleri ile ilgili ulaşılabilen ve kullanılabilir olan veriler tespit edilmiş ve düzenlenmiştir.


Çalışmada YSA modelinin bağımlı değişkeni olarak FAO (Food and Agriculture Organization)'nun yayınladığı 1970-2020 yılları arasındaki 50 gözlem değerine sahip su ürünleri üretim miktarları kullanılmıştır. FAO istatistiklerinde su ürünleri üretim miktarları türlere ve ülkelere göre ayrı ayrı verilmektedir. Çalışma Türkiye'nin genel su ürünleri üretimini tahmin etmeyi hedeflediği için genel toplamlar kullanılmıştır.



Şekil 3.2: Su Ürünleri Üretim Miktarları (1970-2020)


Şekil 3.2'de görüldüğü gibi üretim miktarlarında güçlü bir trend bulunmamaktadır. Su ürünleri üretimi birçok faktörden etkilenmektedir. Ancak bu faktörlerden bazılarının ait verilerin geçmişe yönelik verilerine ulaşamamaktadır. Bazı değişkenlerin ise matematiksel olarak ifade edilmesi ve verisinin düzenli bir şekilde kayıt altına alınması mümkün olmayabilmektedir. Bahsedilen bu kısıtlar doğrultusunda; bağımlı değişkenin ithalat, ihracat ve nüfustan etkilendiği su ürünleri alanında uzman kişiler ile görüşmeler sonucunda belirlenmiştir. Su ürünleri ithalat, ihracat verileri ve Türkiye nüfusu verileri Türkiye İstatistik Kurumu (TÜİK) tarafından yayınlanan istatistiklerden elde edilmiştir.

Şekil 3.3'te su ürünleri ithalat ve Şekil 3.4'te su ürünleri ihracat verilerinin yıllık değişimi verilmiştir.



Şekil 3.3: Su Ürünleri İthalat Verilerinin Yıllık Değişimi


Türkiye'nin ithal su ürünlerine olan ihtiyacının 2000'li yıllarda artış gösterdiği şekilde görülmektedir.



Şekil 3.4: Su Ürünleri İhracat Verilerinin Yıllık Değişimi

Türkiye'nin ihracat miktarı, ithalat verilerinde olduğu gibi, 2000'li yıllarda artış göstermiştir. Hem ithalatın hem de ihracatın 2000 yılı ve sonrasında artarak devam etmesinin bu yıllardaki ekonomik düzeye ve nüfus artışına bağlı olabileceğini söylemek mümkündür.

Şekil 3.5’te Türkiye nüfusunun 1970-2020 yıllarındaki dağılımı verilmiştir. Şekilden de görüleceği üzere Türkiye nüfusu düzenli olarak artış göstermiştir. Bu durum su ürünleri tüketimini doğrudan etkilemektedir. Dolayısı ile su ürünleri ihtiyacı artmakta ve üretim de buna göre artış göstermektedir.



Şekil 3.5: Türkiye Nüfusu Yıllık Değişimi

Çalışmalarda kullanılacak veriler çok büyük ve/veya çok küçük değerler içerebilmektedir. Aynı zamanda seçilen değişkenler ile ilgili veriler genellikle aynı birim şeklinde ifade edilememektedir. Bu sebeplerden dolayı hem değişkenlerin aynı birim şeklinde ifade edilebilmesi hem de uç değerlerin tahmin değerini olumsuz etkilememesi için verilere normalizasyon işlemi uygulanmaktadır (Yavuz ve Deveci, 2012:175). İlgili literatür incelendiğinde farklı normalizasyon yöntemleri ile karşılaşılmaktadır fakat yöntem seçiminde belirli bir standart bulunmamaktadır (Öztemel, 2006:102). Bu çalışmada, YSA modeli için öncelikle hem bağımlı değişken hem de bağımsız değişkenlerin verilerine modele anlamlı olarak tanıtılabilmesi ve model performansını olumlu yönde etkileyebilmesi için Min-Max normalizasyon yöntemi uygulanmıştır. Min-Max normalizasyon yöntemi Eşitlik 3.1’de matematiksel olarak ifade edilmiştir.

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

3.9. Model Tasarımı


YSA modelleri, kullanılan aktivasyon fonksiyonuna, katman sayısına, verilerin yapısal özelliklerine göre farklı şekillerde kurulabilmektedir. Literatürdeki tahmin çalışmaları incelendiğinde danışmanlı öğrenme yöntemlerinden olan ileri beslemeli geri yayımlımlı ağların sıklıkla kullanıldığı görülmektedir. Bu ağlara çok katmanlı algılayıcı denilmektedir. Bu tip ağlardaki öğrenme hızı ve tahmin tutarlılık performansı araştırmacıları bu ağları kullanmaya teşvik etmektedir. Yapılan çalışmada da bahsi geçen sebeplerden dolayı ÇKA tercih edilmiştir.

Çalışmada kullanılan YSA modelinin kurulmasında MATLAB 2022a paket programından yararlanılmıştır. YSA modellerinde, çalışmanın önceki bölümlerinde de belirtildiği üzere, gizli katman sayısı veya gizli nöron sayısının belirlenmesi ile ilgili bir kural bulunmamaktadır. Bu sayılar deneme yanılma yöntemi ile tespit edilmekte ve en düşük hata ortalaması ile en yüksek performansın ulaşıldığı sayı araştırmacılar tarafından seçilmektedir. Bu çalışmada da gizli katman sayısı ve gizli katmanlardaki nöron sayıları ile ilgili deneme yanılma yöntemi izlenmiş ve en iyi performans 10 gizli nörona sahip tek gizli katmanlı ağ yapısı ile elde edilmiştir. Aşağıdaki Tablo 3.1’de nöron sayılarına göre oluşturulan ağ modellerinin R değerleri görülmektedir.

Tablo 3.5: Farklı Nöron Sayılarına Göre Oluşturulan Yapay Sinir Ağı Modelleri

Gizli Nöron Sayısı	Eğitim R	Geçerlilik R	Test R
1	0,89231	0,91276	0,94213
2	0,91147	0,92641	0,91556
4	0,91106	0,89662	0,93182
6	0,93070	0,97657	0,94226
8	0,92421	0,94390	0,94425
10	0,98229	0,98847	0,95213

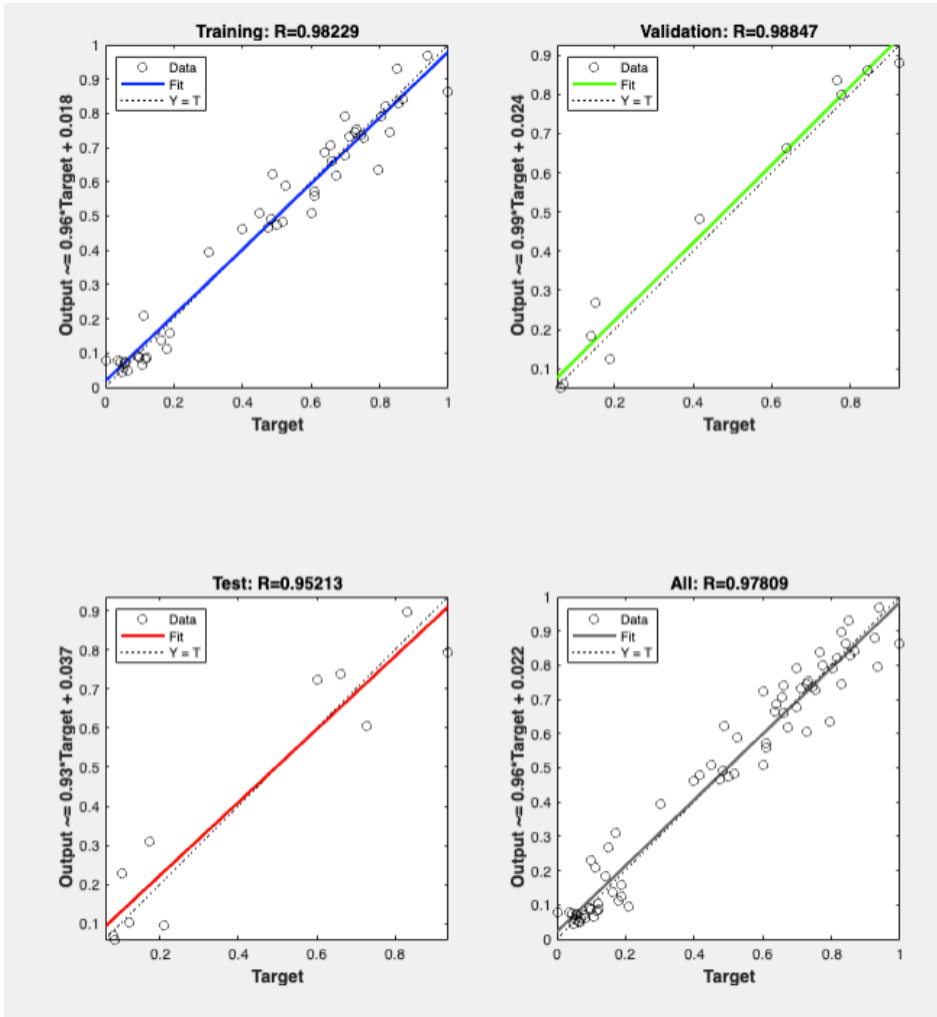
Tablo 3.5’te görüldüğü üzere gizli katmandaki nöron sayısının artması ağın performansını olumlu yönde etkilemektedir.



Şekil 3.6: Oluşturulan YSA Modeli

Modelde 3 girdi değişkenine sahip bir girdi katmanını, 10 gizli nörona sahip bir gizli katman ve bir değişkenli çıktı katmanını bulunmaktadır. Modelin aktivasyon fonksiyonu olarak Tanjant Hiperbolik fonksiyonu seçilmiştir.

Şekil 3.6’de kurulan modelin şekilsel olarak gösterimi verilmiştir. En başta görülen “Input” başlıklı kısım girdi katmanını göstermektedir. “Hidden Layer” başlığı altında gösterilen kısım ise gizli katmanını ifade etmekte ve altındaki 10 rakamı bu katmanda bulunan gizli nöron sayısını göstermektedir. Bu katmanın içerisinde bulunan “w” değeri girdi katmanının ağırlıklandırılma işlemini ifade eder ve bu değer eşik değeri (b) ile toplama fonksiyonu (+) yardımı ile birleştirilir. Aynı katmanda içerisinde bir grafik bulunan kısım ise aktivasyon fonksiyonunu ifade etmektedir. Bu grafik incelendiğinde grafiğin Tanjant Hiperbolik fonksiyonuna ait olduğu görülmektedir. “Output Layer” başlığı altında ise gizli katmanda bulunan elemanların tekrar ettiği görülmektedir. Bu tekrar 3 girdi değişkeninin 10 farklı gizli nöron vasıtasıyla çıktı değerine dönüştürülmesini sembolize etmektedir.



Şekil 3.7: Tek Gizli Katmanlı 10 Gizli Nöronlu YSA Modeli R Değerleri

Şekil 3.7’de, oluşturulan modelin R değerleri görülmektedir. Bu değerler eğitim kümesi için 0,98229, geçerlilik kümesi için 0,98847, test kümesi için 0,95213 ve modelin geneli için 0,97809 olarak elde edilmiştir. YSA modeli ile tahmin işleminin gerçekleştirilmesinde, her üç küme için de %90’ın üzerinden R değerinin hesaplanması model performansı açısından önemli bir konumdadır. Ulaşılan değerler doğrultusunda YSA modelinin uygulanan problem için başarılı tahminler ürettiğini söylemek mümkündür.

3.10. Modelin Eğitimi

YSA modeli; tek girdi katmanı, çerisinden 10 gizli nöron olan tek gizli katman ve tek çıktı katmanı olacak şekilde tasarlandıktan sonra ağı eğitilmesi işlemine geçilmiştir. Ağı eğitilebilmesi için kullanılacak veri setlerinin eğitim, test ve doğrulama olmak üzere üç farklı kümeye ayrılması gerekmektedir. Bu üç kümenin içereceği veri oranları sırasıyla; %60, %25 ve %15 olarak belirlenmiştir. Bu oranların belirlenmesinde genel geçer bir kural bulunmamakta ve deneme yanılma yöntemi kullanılarak belirlenmektedir.

Çalışmada Matlab paket programının “nftool” arayüzü kullanılarak YSA modeli oluşturulmuştur. Oluşturulan YSA modelinde öğrenme algoritması olarak “Levenberg - Marquardt”, performans değerlendirmesi için ise MSE kullanılmıştır.


Geri yayılım algoritması ile eğitim süreci YSA'nın her denemede ürettiği çıktı hata oranlarının ağa dağıtılması ile gerçekleşmektedir. Her iterasyonda üretilen hata değerlerinin dağıtılması ise nöronlar arasındaki bağlantı ağırlıklarının değiştirilmesi ile sağlanmaktadır. YSA bu bağlantı ağırlıklarını ağı MSE değeri minimize edilene kadar değiştirmektedir.

3.11. Bulgular

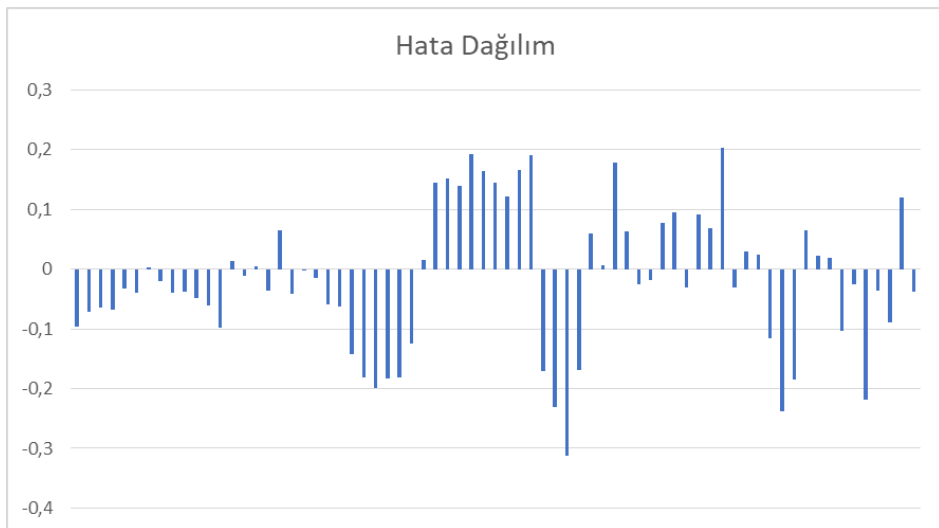
Çalışmada 10 gizli nörona sahip ileri beslemeli geri yayımlı bir YSA modeli kurulmuş ve bu model eğitildikten sonra tahmin değerleri üretilmiştir. Tahmin değerleri daha sonrasında gerçek değerler ile karşılaştırılmış ve hata değerleri hesaplanmıştır. Oluşturulan model ile üretilen tahmin değerleri ve gerçekleşen değerler Tablo 3.1'de verilmiştir. Şekil 3.7'de ise su ürünlerinin yıllık tahmin değerleri ile gerçekleşen değerleri görülmektedir. Şekilden de görüleceği üzere YSA bazı keskin iniş ve çıkışları öngörememiştir. Fakat su ürünleri üretim verilerinin dağılımı incelendiğinde; ani iniş ve çıkışların sayısının oldukça fazla olduğu görülmektedir. Bu değişimlerin hangi parametrelerden etkilendiği tespit edilememiştir. Etkilendiği parametrelerin bilinmesi durumunda YSA modeline bu parametrelerin eklenmesi ile tahmin performansının artırılabilceği düşünülmektedir.

Tablo 3.6: Yıllık YSA Tahmin Değerleri ve Gerçekleşen Değerler

YIL	Gerçekleşen Değer (bin ton)	YSA Tahmin Değeri (bin ton)
2000	503.352	531.516
2001	527.736	521.467,8
2002	566.682	530.534,7
2003	507.772	515.613,3
2004	550.482	538.379,2
2005	426.496	428.650
2006	533.048	529.696
2007	632.450	602.801,3
2008	494.118	500.099,8
2009	463.917	464.928,5
2010	485.928	463.223,7
2011	514.763	498.422,3
2012	432.444	444.284,1
2013	374.128	366.989,2
2014	302.214	352.727,1
2015	431.909	469.379,8
2016	335.326	342.218,4
2017	354.318	362.144,8
2018	314.243	369.063
2019	463.195	469.006
2020	364.411	388.050



Şekil 3.8: Su Ürünleri Tahmin Değerleri ve Gerçekleşen Değerler



Şekil 3.9: Model Tahmininin Hata Dağılımı

YSA modeli ile üretilen tahmin sonuçlarının hata dağılımı Şekil 3.9'de görülmektedir. YSA modelinin hata değerlerinin Şekil 3.8'deki ani iniş ve çıkış noktalarında artış gösterdiği görülmektedir.

Yapılan tahmin çalışmalarında YSA performansını belirlemek için araştırmacılar hata oranlarını kullanmaktadırlar. MAPE ve RMSE değerleri çalışmalarda kullanılan en yaygın performans ölçüm değerlerindedir. Yapılan

çalışmada da bu ölçütler kullanılmıştır. MAPE ve MSE hata oranlarının matematiksel formülasyonu sırasıyla Eşitlik 3.2 ve Eşitlik 3.3'teki gibidir.

$$MAPE = \frac{\sum_{i=1}^N \frac{|A_i - F_i|}{A_i}}{N} * 100 \quad (3.2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (A_i - F_i)^2}{N}} \quad (3.3)$$

$$MAE = \frac{\sum_{i=1}^N |A_i - F_i|}{N} \quad (3.4)$$

Eşitlik 3.2, 3.3 ve 3.4'te; i gözlem numarasını, N gözlem sayısını, A_i gerçekleşen değeri ve F_i tahmin değerini ifade etmektedir.

Tablo 3.7: Gizli Nöron Sayılarına Göre YSA'ların Hata Oranları

Gizli Nöron Sayısı	MAE	RMSE	MAPE
2N	44.360,77073	60.526,06618	12,206704
3N	52.238,90751	69.287,75474	15,170658
4N	42.058,54464	57.586,04489	10,169751
5N	28.848,60215	49.583,83283	7,5692495
6N	37.830,30081	53.615,19896	9,5428046
7N	21.868,14117	42.097,25666	6,2141228
8N	55.021,98877	75.559,33544	15,238674
9N	44.699,39389	59.173,43745	12,229361
10N	20.785,11244	28.428,37283	6,0909551

Tablo 3.7'de kurulan YSA modellerinin hata değerleri verilmiştir. Tek gizli katmanlı 10 gizli nöronlu YSA modelinin ortalama hata değerleri incelendiğinde diğer modellerden daha iyi sonuç verdiği görülmektedir.

Bir tahmin işleminde tahminin performansı; üretilen tahmin değerlerinin gerçek değerlere ne kadar yakın olduğunun tespit edilmesi ile ölçülmektedir. Lewis (1997) model performanslarında Ortalama mutlak yüzde hata (MAPE) değerinin %10'un altında olduğunda modelin tahmin gücünü "çok iyi", %10-20 arasında "iyi", %20-30 arasında "uygun" ve %30'un üstünde ise "hatalı" olduğunu belirtmiştir.

SONUÇ VE ÖNERİLER

Küreselleşen pazar şartlarında; ülke sınırlarının ticaretteki önemini yitirmesi, bilgi teknolojilerinin artması, elde edilen veri miktarının çok fazla ve karmaşık olması gibi sebeplerden dolayı geleneksel yaklaşımların yetersiz kalmasına yol açabilmektedir. Araştırmacılar bu yetersizliğe bir çözüm bulabilmek amacıyla doğayı ve doğadaki canlıları taklit etme yöntemine sıklıkla başvurmuşlardır. Yapay Sinir Ağları da insan beyninin çalışma mantığının taklit edilmeye çalışılması sonucu ortaya koyulmuş yöntemlerden bir tanesidir.

Stratejik bir karar alma sürecinde belirsizliklerin ortadan kaldırılması planlama ve uygulama süreçlerini çok daha kolay hale getirmektedir. Geleceğe yönelik tahminlerde bulunmak belirsizlikleri azaltmanın yollarından bir tanesidir. Tahmin, gelecekte olması beklenen bir olayın nasıl ve ne şartlarda olabileceğinin öngörülmesidir. İşletmelerde alınan kararların güvenilirliği, tahmin işleminin ne kadar düzgün yapıldığı ile doğrudan bağlantılıdır.

Yapay sinir ağları yöntemi birçok araştırmada denenmiş ve performans olarak geleneksel yöntemlerden çok daha başarılı bulunmuş bir zaman serisi tahmin yöntemidir. YSA esasında çok daha önce ortaya koyulmuş bir kavram olmasına rağmen son 20 yılda yaygınlaşmış ve gelişmiştir. YSA'nın hatalara olan toleransı, eksik veya hatalı verilerle dahi tutarlı sonuç üretebilmesi, öğrenme yeteneği ve belirsizlik altında çalışabilmesi gibi özellikleri araştırmacıların bu yöntemi kullanmalarındaki temel sebeplerdendir.

Bu çalışmada da Türkiye'nin su ürünleri üretimini tahmin etmek amacı ile zaman serileri yöntemlerinden yapay sinir ağları yöntemi seçilmiştir. Su ürünleri üretimini etkileyen temel faktörler uzman görüşleri doğrultusunda belirlenmiş ve model kurulmuştur. Model olarak, benzer çalışmalarda sıklıkla tercih edilen ve doğrusal olmayan problemlere tutarlı sonuçlar üretebilen ileri beslemeli geri yayılım ağı seçilmiştir. Kurulan modelin performansı test edilmiş ve farklı modeller ile karşılaştırılmıştır.

YSA modeli 1970-2020 yılları arasındaki yıllık veriler temel alınarak kurulmuş ve üretim tahmini yapılmıştır. Modelin genel R değeri %97,809 olarak bulunmuş ve yapılan tahmin sonuçlarının performansı hata oranları ile ölçülmüştür. Bulunan R değeri tahmin işleminin gerçekleştirildiği modelin

eđitilmesi sonucunda başarılı sonuçlar vereceđini göstermektedir. Bu deđerin yüksek olması hem eđitimin başarılı bir şekilde tamamlandığını hem de tahmin performansının yüksek olacağını göstermektedir. Sonuç olarak, ortalama mutlak yüzde hata (MAPE) deđeri %6,09 olarak hesaplanmıştır. MAPE deđerinin düşük olması yapılan tahminlerin gerçekteşen deđerlerden ne kadar farklı olduğunu göstermektedir. Daha önce de bahsedildiđi üzere MAPE deđerinin %10'un altında olması. Bu oran; çalışmanın kısıtları ve kullanılan veriler doğrultusunda YSA modelinin su ürünleri üretim miktarını tahmin etmede başarılı olduğunu göstermektedir.

Gelişmekte olan Türkiye ekonomisinin stratejik yatırımlar yapmaya ve uygun sektörlerde doğru adımlar atmaya ihtiyacı vardır. Su ürünleri sektörü, Türkiye'nin cođrafi konumu açısından çok büyük potansiyele sahip olmasına rağmen ekonomideki payı çok yüksek deđildir. Ülkenin bu alanda doğru adımları atabilmesi için tutarlı verilere ihtiyaç duyulmaktadır. Önerilen modelin bu ihtiyacı karşılayabileceđi düşünölmektedir.

Çalışmada Türkiye'nin genel su üretim verileri kullanılmıştır. İlgili verilerin detaylı bir şekilde tutulması ve/veya saha araştırmaları yardımı ile kurulan modeller daha başarılı sonuçlar üretebilir. Türkiye genelindeki su ürünleri üretimi yerine Akdeniz, Karadeniz gibi su ürünleri üretimine uygun bölgelerin verileri kullanılarak çalışma detaylandırılabilir. Ayrıca gelişimine hızla devam eden su ürünleri yetiştiriciliđi sektöründe YSA uygulamalarının yerel kalkınmaya yol gösterebileceđi düşünölmektedir.

KAYNAKÇA

- Adıyaman, F. (2007). Talep Tahmininde YSA, (Yayımlanmamış Yüksek Lisans Tezi). İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Akdağ, M. ve Yiğit, V. (2016). Box-Jenkins ve Yapay Sinir Ağı Modelleri ile Enflasyon Tahmini. Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 30(2), 269-283.
- Aktaş, R. (2003). Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırılması. Ankara Üniversitesi SBF Dergisi, 58(04).
- Akyurt, İ. Z. (2015). Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi, (23), 147-157.
- Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. Öneri Dergisi, 10(39), 101-115.
- Aydın, H. (2017). Türkiye’de Kültür Balıkçılığı Potansiyeli ve Akuakültür Sektörünün Ekonomiye Katkısı. Balkan Sosyal Bilimler Dergisi, 6(11), 62-67.
- Baxter, G. ve Srisaeng, P. (2018). The Use of An Artificial Neural Network to Predict Australia’s Export Air Cargo Demand. International Journal for Traffic and Transport Engineering, 8(1), 15-30.
- Bayır, F. (2006). Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama. (Yayımlanmamış Yüksek Lisans Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Calp, M. H. (2019). İşletmeler İçin Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi. Politeknik Dergisi, 22(3), 675-686.
- Chae, Y. T., Horesh, R., Hwang, Y. ve Lee, Y. M. (2016). Artificial Neural Network Model for Forecasting Sub-Hourly Electricity Usage in Commercial Buildings. Energy and Buildings, 111, 184-194.

- Claveria, O., Monte, E. ve Torra, S. (2015). Tourism Demand Forecasting with Neural Network Models: Different Ways of Treating Information. *International Journal of Tourism Research*, 17(5), 492-500.
- Çağlar, T. (2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletme Uygulaması. (Yayımlanmamış Yüksek Lisans Tezi). Kırıkkale Üniversitesi, Fen Bilimler Enstitüsü.
- Çalışkan, M. M. T. Ve Deniz, D. (2015). Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 10(3), 177-194.
- Çelik, B. (2008). YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama, (Yayımlanmamış Yüksek Lisans Tezi). Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Çuhadar, M. (2013). Development of Golf Tourism and Golf Tourism Demand Forecasts in Turkey: A Study of Belek Region Türkiye’de Golf Turizminin Gelişimi ve Golf Turizmi Talebi Tahminleri: Belek Bölgesine Yönelik Bir Çalışma. *Journal of Human Sciences*, 10(1), 1620-1639.
- Çuhadar, M. (2014). Muğla İline Yönelik Dış Turizm Talebinin Modellenmesi ve 2012 – 2013 Yılları için Tahminlenmesi. *International Journal of Economic and Administrative Studies*, (12).
- Çuhadar, M., Güngör, İ. ve Göksu, A. (2009). Forecasting Tourism Demand by Artificial Neural Networks and Time Series Methods: A Comparative Analysis In Inbound Tourism Demand to Antalya. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114.
- Çuhadar, M. ve Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye’deki Konaklama İşletmeleri Üzerine Bir Deneme. *Anatolia: Turizm Araştırmaları Dergisi*, 16(1), 24-30.
- Çunkaş, M. ve Altun, A. A. (2010). Long Term Electricity Demand Forecasting in Turkey Using Artificial Neural Networks. *Energy Sources, Part B: Economics, Planning, and Policy*, 5(3), 279-289.

- Dalkey, N. ve Helmer, O. (1963). An Experimental Application of The Delphi Method to The Use of Experts. *Management Science*, 9(3), 458-467.
- Demirtaş, Ö. (2017). Türkiye'deki İç Göçün Yapay Sinir Ağları ile İncelenmesi Proquest. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (Gazi Akademi Genç Sosyal Bilimciler Sempozyumu 2017 Özel Sayısı), 414-427.
- Doğan, K. (1997). Su Ürünleri Sektörü Türk Ekonomisinin Neresinde. *SÜMDER Aralık*, (1).
- Eren, U. ve Şatoğlu, Ş. I. (2017). Perakende Giyim Sektöründe Yapay Sinir Ağları ile Talep Tahmini.
- Es, H. A., Kalender, F. Y. ve Hamzaçebi, C. (2014). Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 29(3), 495-504.
- FAO (2018), The State of World Fisheries and Aquaculture, <http://www.fao.org/state-of-fisheries-aquaculture> (15.06.2019).
- Ferreira, R. P., Martiniano, A., Ferreira, A., Ferreira, A. ve Sassi, R. J. (2016). Study on Daily Demand Forecasting Orders Using Artificial Neural Network. *IEEE Latin America Transactions*, 14(3), 1519-1525.
- Finegold, C. (2009). The importance of fisheries and aquaculture to development. *Fisheries, sustainability and development*, 353-364.
- Frechtling, D. C. (2001). *Forecasting Tourism Demand: Methods And Strategies*. Oxford ;Boston: Butterworth-Heinemann.
- Ghomi, S. M. T. F. ve Forghani, K. (2016). Airline Passenger Forecasting Using Neural Networks and Box-Jenkins. 2016 12th International Conference on Industrial Engineering (ICIE) İçinde (Ss. 10-13). 2016 12th International Conference On Industrial Engineering (ICIE), Sunulmuş Bildiri, 12th International Conference On Industrial Engineering.
- Günay, M. E. (2016). Forecasting Annual Gross Electricity Demand by Artificial Neural Networks Using Predicted Values of Socio-Economic

Indicators and Climatic Conditions: Case of Turkey. *Energy Policy*, 90, 92-101.

Hamzaçebi, C. (2011). *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı*. Bursa: Ekin Basım Yayın Dağıtım.

Hamzaçebi, C., Es, H. A. ve Çakmak, R. (2017). Forecasting of Turkey's Monthly Electricity Demand by Seasonal Artificial Neural Network. *Neural Computing and Applications*, 1-15.

Heizer, J., Render, B. ve Munson, C. (2017). *Operations Management: Sustainability and Supply Chain Management (Twelfth Edition.)*. Boston: Pearson.

Helfman, G., Collette, B. B., Facey, D. E., ve Bowen, B. W. (2009). *The diversity of fishes: biology, evolution, and ecology*. John Wiley & Sons

Herrera, M., Torgo, L., Izquierdo, J. ve Pérez-García, R. (2010). Predictive Models For Forecasting Hourly Urban Water Demand. *Journal of Hydrology*, 387(1), 141-150.

Hoshmand, A. R. (2010). *Business Forecasting: A Practical Approach (2nd Ed.)*. New York: Routledge.

Hoşsucu, H., Akyol, O. ve Ünal, V. (2001). Türkiye Balıkçılık Sektörü ve 2000'li Yıllarda Beklenen Gelişmeler. *Ege Üniversitesi Su Ürünleri Dergisi*, 18(3-4), 593-601.

Jalal, M. E., Hosseini, M. ve Karlsson, S. (2016). Forecasting Incoming Call Volumes in Call Centers with Recurrent Neural Networks. *Journal of Business Research*, 69(11), 4811-4814.

Kandananond, K. (2011). Forecasting Electricity Demand In Thailand with An Artificial Neural Network Approach. *Energies*, 4(8), 1246-1257.

Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N. ve Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.

- Karahan, M. (2011). İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Talep Tahmin Uygulaması. (Yayımlanmamış Doktora tezi). Selçuk Üniversite Sosyal Bilimler Enstitüsü.
- Karahan, M. (2015a). Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 20(2), 195-209.
- Karahan, M. (2015b). Yapay Sinir Ağları Metodu ile İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi. Ege Akademik Bakış Dergisi, 15(2), 165-172.
- Kaynar, O., Taştan, S. ve Demirkoparan, F. (2010). Ham Petrol Fiyatlarının Yapay Sinir Ağları ile Tahmini. Ege Akademik Bakış Dergisi, 10(2), 561-575.
- Keskenler, M. F. ve Keskenler, E. F. (2017). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihi. Takvim-I Vekayi, 5(2), 8-18.
- Kobu, B. (2014). Üretim Yönetimi (17. Bs.). İstanbul: Beta Basım.
- Kocatepe, C. İ. ve Yıldız, O. (2016). Ekonomik Endeksler Kullanılarak Türkiye'deki Altın Fiyatındaki Değişim Yönünün Yapay Sinir Ağları ile Tahmini. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 4(3), 926-934.
- KUZU, S. ve YILDIRIM, B. F. (2017). Box-Jenkins ve Gri Tahmin Yöntemleri ile Türkiye'de Hava Yolu Ulaşım Talebinin Tahmini, 1(2), 36-49.
- Lewis, C. D. (1997). Demand Forecasting and Inventory Control: A Computer Aided Learning Approach. Cambridge, England: Woodhead Publishing in Association with the Institute of Operations Management.
- Lin, C. J., Chen, H. F. ve Lee, T. S. (2011). Forecasting Tourism Demand Using Time Series, Artificial Neural Networks and Multivariate Adaptive Regression Splines: Evidence from Taiwan. International Journal of Business Administration, 2(2), 14- 24.
- Monks, J. G. (1996). İşlemler Yönetimi Teori ve Problemler. (Çeviren: Sevinç Üreten). Ankara: Nobel Yayın Dağıtım.

- Öztemel, E. (2006). Yapay Sinir Ağları (2. Baskı). İstanbul: Papatya Yayıncılık.
- Özsoy, E. (2006). Talep Tahminine Dayalı Müşteri Odaklı Üretim Planının Oluşturulması ve Bir Uygulama. (Yayımlanmamış Yüksek Lisans Tezi). Üretim Yönetimi ve Endüstri İşletmeciliği Programı, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Rajpal, P.S., Shishodia, K.S. ve Sekhon, G.S. (2006). An Artificial Neural Network for Modeling Reliability, Availability and Maintainability of a Repairable System. *Reliability Engineering and System Safety*, 91, 809-819.
- Saygı, H., Bayhan, B. ve Hekimoğlu, M. A. (2015). Fishery Products Consumption in the Cities of Ankara and Izmir in Turkey. *Turkish Journal of Agriculture Food Science and Technology*, 3(5), 248-254.
- Saygılı, Y. S. (2008). İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi. (Yayımlanmamış Yüksek Lisans Tezi). Kara Harp Okulu Savunma Bilimleri Enstitüsü.
- Sheta, A., Elsir, S. ve Faris, H. (2015). A Comparison Between Regression, Artificial Neural Networks and Support Vector Machines For Predicting Stock Market Index. *International Journal of Advanced Research in Artificial Intelligence*, 4(7), 55-63.
- Singhal, D. Ve Swarup, K. S. (2011). Electricity Price Forecasting Using Artificial Neural Networks. *International Journal of Electrical Power and Energy Systems*, 33(3), 550- 555
- Sokolov-Mladenović, S., Milovančević, M., Mladenović, I. ve Alizamir, M. (2016). Economic Growth Forecasting by Artificial Neural Network with Extreme Learning Machine Based on Trade, Import and Export Parameters. *Computers in Human Behavior*, 65, 43-45.
- Şahin, T. (2002). Su Ürünleri Araştırmalarında Uygulanabilirlik. *Aquaculture Studies*, (2), 3.

- ŞEN, Zekai. (2004). Yapay Sinir Ağları ve İlkeleri, İstanbul, Su Vakfı Yayınları.
- Tekin, M. (2010). Üretim Yönetimi (7. Bs., C. 1-2, C. 1). Konya: Günay Ofset.
- Thakur, G. S. M., Bhattacharyya, R. ve Mondal, S. S. (2016). Artificial Neural Network Based Model for Forecasting of Inflation in India. Fuzzy Information and Engineering, 8(1), 87-100.
- Türkiye İstatistik Kurumu (2019), Su Ürünleri İstatistikleri-2013, No. 4349, Ankara: TÜİK Yayınları.
- ULUCAN, E. ve KIZILIRMAK, İ. (2018). Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları ile İlgili Bir Araştırma. Seyahat ve Otel İşletmeciliği Dergisi, 15(1), 89-101.
- Üreten, Sevinç (2005). Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri (5. Baskı). Ankara: Gazi Kitabevi.
- Yüksel, R. ve Akkoç, S. (2016). Altın Fiyatlarının Yapay Sinir Ağları ile Tahmini ve Bir Uygulama. Doğu Üniversitesi Dergisi, 17(1), 39-50.
- Zhang, G., Eddy Patuwo, B. ve Y. Hu, M. (1998). Forecasting with Artificial Neural Networks: The State of the Art. International Journal of Forecasting, 14(1), 35-62.