

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EDİRNE İLİNİN AYÇİÇEĞİ ÜRETİM
MİKTARININ MAKİNE ÖĞRENME
YÖNTEMLERİYLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Olca EYDEMİR

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Prof. Dr. Semra BORAN

Temmuz 2022

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EDİRNE İLİNİN AYÇİÇEĞİ ÜRETİM
MİKTARININ MAKİNE ÖĞRENME
YÖNTEMLERİYLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Olca Y EYDEMİR

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 07.07.2022 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

**Dr. Öğr. Üyesi
Yıldız ŞAHİN
Jüri Başkanı**

**Prof. Dr.
Semra BORAN
Üye**

**Dr. Öğr. Üyesi
Mümtaz İPEK
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Olcay EYDEMİR

07.07.2022

TEŐEKKÜR

Eđitim hayatım boyunca desteklerini hi eksik etmeyen EYDEMİR ailesine ve yüksek lisans eđitimimde bilgi ve tecrubesini aktaran danıŐman hocam Prof. Dr. Semra BORAN'a teŐekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vi
ÖZET	vii
SUMMARY	vii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	7
2.1. Yapay Sinir Ağları ile İlgili Literatür Çalışmaları.....	7
2.2. ANFIS ile İlgili Literatür Çalışmaları.....	8
2.3. Karar Ağacı ve Doğrusal Regresyon Literatür Çalışmaları.....	9
2.4. Makine Öğrenmesi Literatür Çalışmaları.....	10
2.5. Ayçiçeği Üretim Literatür Çalışmaları.....	11
BÖLÜM 3.	
MATERYAL VE YÖNTEM.....	12
3.1. Veri Elde Etme.....	12
3.2. Yapay Sinir Ağları.....	12
3.3. Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi	15

3.3.1. ANFIS yöntemi	16
3.3.2. ANFIS yapısındaki katmanlar	17
3.4. Doğrusal Regresyon	19
3.5. Karar Ağacı	20
3.6. K-ortalamlar Algoristması ile Kümeleme.....	22
3.7. Performans Kriterleri.....	23
BÖLÜM 4.	
ARAŞTIRMA BULGULARI	24
4.1. Uygulamanın Amacı.....	24
4.2. Yapay Sinir Ağları Yöntemi	25
4.2.1. Veri setinin oluşturulması.....	25
4.2.2. Verilerin normalize edilmesi.....	27
4.2.3. Yapay sinir ağları modelinin oluşturulması.....	30
4.3. ANFIS Yöntemi.....	31
4.3.1. K-ortalamlar kümeleme yöntemiyle ANFIS üyelik fonksiyonu sayısının belirlenmesi.....	31
4.3.2. Veri setinin hazırlanması.....	33
4.3.3. Üyelik fonksiyonun tipinin ve sayısının belirlenmesi.....	33
4.3.4. Modelin eğitilmesi.....	34
4.4. Doğrusal Regresyon Yöntemi.....	36
4.5. Karar Ağacı Yöntemi.....	37
4.6. Önerilen Modellerin Karşılaştırılması.....	37
BÖLÜM 5.	
SONUÇ VE ÖNERİLER	41
KAYNAKLAR	44
ÖZGEÇMİŞ	50

SİMGELER VE KISALTMALAR LİSTESİ

ANFIS	: Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
CART	: Regresyon ağacı
ÇKA	: Çok katmalı algılayıcı
FIS	: Bulanık çıkarım sistemi
MAE	: Hatanın mutlak ortalaması
MSE	: Hata kareler ortalaması
RMSE	: Hata kareler ortalamasının karekökü
YSA	: Yapay Sinir Ağları
R^2	: Belirlilik katsayısı

ŞEKİLLER LİSTESİ

Şekil 3.1. Yapay sinir hücresi	13
Şekil 3.2. Çok katmanlı algılayıcı yapısı.....	14
Şekil 3.3. 2 girdi, 1 çıktı ve 2 kuraldan oluşan örnek bir ANFIS yapısı	16
Şekil 3.4. Karar ağacı örneği.....	20
Şekil 4.1. Bulanık çıkarım sistem yapısı	33
Şekil 4.2. Yağış miktarı üyelik fonksiyon grafiği (gaussmf).....	34
Şekil 4.3. Verilerin eğitimi	34

TABLolar LİSTESİ

Tablo 1.1. 2020 yılına göre dünyada ayçiçeđi üreten ülkeler ve üretim payları....	2
Tablo 1.2. 2004-2021 yılları arası Türkiye ayçiçeđi ekim alanı ve üretim miktarları.....	3
Tablo 1.3. 2015-2020 yılları arasın Türkiye ayçiçeđi ithalat, ihracat miktarları ve deđerleri.....	4
Tablo 1.4. 2021 yılı Türkiye'deki illerin ayçiçeđi ekim alanı ve üretim miktarları.....	4
Tablo 4.1. Veri seti.....	26
Tablo 4.2. Normalize edilmiş veriler.....	28
Tablo 4.3. YSA algoritmaları kullanılarak elde edilen sonuçlar.....	30
Tablo 4.4. K-ortalamlar algoritması uygulama sonuçları	32
Tablo 4.5. ANFIS 4 4 6 2 3 kümesine ait tüm varyasyonlar.....	35
Tablo 4.6. Doğrusal regresyon parametreleri	36
Tablo 4.7. Karar ağacı parametreleri.....	37
Tablo 4.8. YSA tahmin sonuçları.....	38
Tablo 4.9. ANFIS tahmin sonuçları.....	38
Tablo 4.10. Doğrusal regresyon tahmin sonuçları.....	39
Tablo 4.11. Karar ağacı tahmin sonuçları.....	39
Tablo 4.12. Performans deđerlendirme sonuçları.....	40
Tablo 5.1. Ayçiçeđi maliyetleri.....	43

ÖZET

Anahtar kelimeler: Ayçiçeği üretim tahmini, makine öğrenmesi, K-ortalamalar, ANFIS, YSA, doğrusal regresyon, karar ağacı.

Son yıllarda Türkiye’de en önemli yağ bitkisi olan ayçiçeği üretiminin az, tüketimin çok olması nedeniyle ihtiyacı karşılamak için yurt dışından satın alma yoluna gidilmektedir. Ancak ayçiçeği ithalatında dünyada baş gösteren salgın hastalıklar, doğal afetler ve savaşlardan dolayı zorluklar yaşanmaktadır. Özellikle yağ ihtiyacının karşılanması noktasında ayçiçeğine olan ihtiyacın sürekli karşılanabilmesi için ayçiçeği üretim miktarının doğru olarak tahmin edilmesi gerekiyor ki uygun miktarlarda ithal edilebilsin. İthalat miktarının çok olması fazla stok oluşmasına, az olması talebin karşılanamamasına neden olacaktır. Bu çalışmada ayçiçeği üretim miktarını tahmin etmek amacıyla niceliksel tahmin yöntemlerinin yerine makine öğrenmesi yöntemlerinden yararlanılması amaçlanmaktadır. Çünkü makine öğrenmesi yöntemleri veriler arasındaki bilinmeyen veya modellenmesi zor olan ilişkilerin kolayca belirleyebilme ve eksik verilerle tahmin yapabilme özelliklerine sahiptir. Çalışmada makine öğrenme yöntemlerinden Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS), Yapay Sinir Ağları (YSA), doğrusal regresyon ve karar ağacından yararlanılmıştır. ANFIS yöntemi hızlı öğrenme kapasitesine ve uyum yeteneğine sahip olması nedeniyle kullanılmıştır. YSA yöntemi ise sadece karşılaştırma için sunulmuştur. ANFIS modelinin öğrenme kabiliyetini arttırmak amacıyla K-ortalamalar algoritması ile girdi değişkenlerinin üyelik fonksiyon sayıları belirlenmiştir. ANFIS, YSA, doğrusal regresyon, karar ağacı modellerinde ekilen alan büyüklüğü, nem, sıcaklık, güneşlenme süresi ve yağış miktarı gibi kriterlere göre ayçiçeği üretim miktarı tahmin edilmesi sağlanmıştır. Edirne bölgesinde bu modeller uygulanmış ve en az hata (MSE) değerini ANFIS yöntemi vermiştir. Böylece ANFIS modeli ile girdilerin değişen miktarına göre gelecek yılların üretim miktarı tahmin edilebilecektir.

ESTIMATION OF SUNFLOWER PRODUCTION AMOUNT OF OF EDIRNE PROVINCE BY MACHINE LEARNING METHODS

SUMMARY

Keywords: Sunflower production forecasting, machine learning, K-means, ANFIS, ANN, linear regression, decision tree

Sunflower, the most important oil plant in Turkey, in recent years, has decreased in production, and as a result of the increase in consumption, it has preferred to be imported to supply the need. However, there are also difficulties in the importation of sunflower due to epidemics, natural disasters and wars in the world. Especially in terms of satisfying the need for oils, in order to meet the need sunflower, it is essential to calculate the sunflower production accurately so that it can be imported in a appropriate quantities. A large amount of imports will cause excess stocks, and a small amount will cause the demand not to be supplied. In this study, it is aimed to use machine learning methods instead of quantitative estimation methods to calculate the amount of sunflower production. Because machine learning methods have features of easily determining the unknown or difficult to model relationships between data and making predictions with missing data. In the study, machine learning methods, Adaptive Network Based Fuzzy Inference System (ANFIS), Artificial Neural Networks (ANN), linear regression and decision tree have been used. The ANFIS method has used because of its has fast learning capacity and adaptability. ANN method is presented for comparison only. In order to increase the learning capacity of ANFIS, the input variables' membership functions have been determined via K- means algorithm. The estimated production in ANFIS, ANN, linear regression, decision tree models has been calculated in accord with the such as the cultivated area, humidity, temperature and the duration of insolation and the amount of rainfall. These models have been applied in Edirne region and ANFIS has given the least error (MSE). Thus, with the ANFIS model it is to be possible to estimate the amount of production in following years depending on the changing amount of inputs.

BÖLÜM 1. GİRİŞ

Türkiye’de ayçiçeği yetiştirilen bölge ve alanlarda yeterince üretim yapılmadığı gerekçesi ile ihtiyaç miktarı kadarı dış ülkelerden karşılanmaktadır. Ancak dünyada baş gösteren salgın hastalıklar, doğal afetler ve ayçiçeğini ihtiyaçtan fazla yetiştiren ülkelerde savaş çıkması nedeniyle; tedarik zincirinde çok büyük aksamalar yaşanmasına neden olmuştur. Ayrıca ülkemizde ayçiçeğinden yemeklik yağ elde edilmesinden dolayı yağ fiyatlarında bir fiyat artışı yaşanmaktadır. Bu nedenle ülkemizde ihtiyaç miktarı kadar ayçiçeği yetiştirilmesinin önemi bir kez daha ortaya konulmuştur. Bu yaşanan sorunlardan dolayı çalışmada; ayçiçeği üretim tahmini yapılması amaçlanmıştır.

Yağlı tohumlu bitkiler içerisinde; ekonomik olarak en çok öne çıkan ayçiçeği bitkisidir. İçeriğindeki yağ muhteviyatı % 50 civarında olup, büyük oranını canlılar için elzem olan doymamış yağ asitlerini barındırmaktadır. Yağı çıkarıldıktan sonra geriye kalan küspesi hayvan beslenme mamüllerinde kullanılmaktadır. Ayrıca; sapı ve tablaları yakacak, gübre takviyesi, süs bitkisi gibi kullanım alanlarına sahiptir (İncekara, 1979; Geçit ve ark., 2009). Dünyada en çok talep gören palm yağı, soya, kolza, ayçiçeği yağlı tohum bitkileri olarak belirlenmiştir. Türkiye’de ise yüksek yağ oranına sahip olması nedeniyle ayçiçeği bitkisi tercih edilmektedir. (Gül ve ark., 2016).

Ayçiçeği bitkisi çoğunlukla yağ elde etmek amacıyla üretimi yapılırsa da, yeryüzünde ve ülkemizde çerezlik, kuşyemi, sanayi bitkisi (sabun, lif, mum ve yapımında), süs bitkisi olarak da kullanım alanı bulunmaktadır. Tohumları kavrulup tüketilmesinin yanında iç dane olarak da direk veya unlu mamullere (kek, ekmek vb.) katılmaktadır. (Şahin, 2019).

Yemeklik yağ kalitesi bakımından ayçiçeği yağı bitkisel yağlar arasında ilk sırada yer almaktadır. Ayçiçeği birçok ülkede ekonomiye katkı sağlamak amacıyla üretimi yapılmaktadır. Ayçiçeği yetiştiriciliğinde; Rusya (% 26,50) ve Ukrayna (% 26,10) önde gelen ülkeler arasında yer almaktadır. Bu iki ülke dünya üretiminin % 52,6'sını gerçekleştirmektedir. Türkiye, dünya üretiminde 6. sırada olup, % 4,12'lik bir paya sahiptir. 2020 yılı içerisinde dünyada ayçiçeği ekim alanı 27.874.284 ha, üretimi 50.229.567 ton, verim ise 18.020 hg/ha olarak tespit edilmiştir. (Fao, 2021). Tablo 1.1.'de dünyada ayçiçeği üreten ülkelere yer verilmektedir (Fao, 2021).

Tablo 1.1. 2020 yılına göre dünyada ayçiçeği üreten ülkeler ve üretim payları (Fao, 2021)

Ülkeler	Üretim (Ton)	2020
Rusya	13.314.418	26,50%
Ukrayna	13.110.430	26,10%
Arjantin	3.232.649	6,43%
Çin	2.375.000	4,73%
Romanya	2.198.670	4,38%
Türkiye	2.067.004	4,12%
Bulgaristan	1.733.530	3,46%
Macaristan	1.697.960	3,39%
Fransa	1.607.080	3,19%
ABD	1.352.800	2,69%
Diğer Ülkeler	7.540.026	15,01%
Toplam	50.229.567	100%

Ayçiçeği, Trakya, Ege Bölgesi ve Karadeniz Bölgesi olmak üzere birçok bölgemizde yetiştirilmektedir. Ancak yetersiz üretim nedeniyle, yıldan yıla artış gösteren bitkisel yağ açığımız 500 bin tonu aşmıştır. Bu açığın kapatılması için yağlı tohumlu bitkilerin mevcut potansiyeli ile ekili alandaki verimin artırılması ve ayrıca, ikinci ürün tarımına daha fazla yer verilmesi gerekmektedir (Tan, 2007). Tablo 1.2.'de Türkiye'de ayçiçeği ekim alanı ve üretim miktarları verilmiştir (TÜİK, 2021).

Tablo 1.2. 2004-2021 yılları arası Türkiye ayçiçeği ekim alanı ve üretim miktarları (TÜİK, 2021)

Yıl	Ekilen Alan (da)	Üretim (ton)	Verim(kg/da)
2004	4.800.000	800.000	167
2005	4.900.000	865.000	177
2006	5.100.000	1.010.000	198
2007	4.857.000	770.000	159
2008	5.100.000	900.387	177
2009	5.150.000	960.300	186
2010	5.514.000	1.170.000	212
2011	5.560.000	1.170.000	210
2012	5.046.160	1.200.000	238
2013	5.202.600	1.380.000	265
2014	5.524.651	1.480.000	269
2015	5.689.950	1.500.000	264
2016	6.167.800	1.500.000	244
2017	6.813.976	1.800.000	264
2018	6.489.344	1.800.000	277
2019	6.759.834	1.950.000	289
2020	6.508.696	1.900.000	292
2021	8.113.116	2.215.000	273

Yağlı tohum üretimi, ekonomiye yaratmış olduğu artı katkısından dolayı büyük önem arz etmektedir. Kendi tüketim ihtiyacından daha fazla yağlı tohum üreten ülkeler finansal kazanç sağlarken, dünyada genel olarak gıda krizinin yaşandığı bu günlerde, ihtiyaç duyduğu yağlı tohumu ithal eden ülkeler ise yağ üretiminde ciddi anlamda sıkıntı yaşamaktadır (Kakilli Acaravcı ve Ergüven, 2015). Ülkemizde yağlı tohum ve çeşitlerine gün geçtikçe ihtiyacımız artmakta, buna bağlı olarak dış ülkelerden satın aldığımız yağlı tohum ve cinsleri bakımından her geçen gün ihtiyaç miktarı çoğalmaktadır. Oysa ülkemizde önemli yağ bitkilerinden ayçiçeği, soya, pamuk, yarfıstığı, haşhaş, aspir, kolza, susam yetiştirilmesi mümkündür. Bu noktada bitkisel yağ ihtiyacını kapatmak adına ayçiçeği ve diğer yağlı tohumlu bitkilerin agronomik olarak verim ve verim unsurlarını artırmak için yapılan ve yapılacak olan çalışmalar her geçen gün daha da önem arz etmektedir (Top ve Uçum, 2012). Tablo 1.3.'de Türkiye'nin ayçiçeği ithalat, ihracat miktarları ve değerleri verilmiştir (TÜİK, 2021).

Tablo 1.3. 2015-2020 yılları arası Türkiye ayçiçeği ithalat, ihracat miktarları ve değerleri (TÜİK, 2021)

Yıl	İthalat Miktarı(ton)	İhracat Miktarı(ton)	İthalat Değeri(\$)	İhracat Değeri(\$)
2015	798170	617924	1101230	680055
2016	738405	599663	1015540	636101
2017	660682	537436	661019	548735
2018	498352	416895	400501	421678
2019	604955	544593	437380	492592
2020	892027	740510	707317	728164

Edirne ili bölgesi ayçiçeğinin yetiştirilmesinde nem, sıcaklık, yağmur, güneşlenme süresi bakımından uygun koşullara sahip olması nedeniyle Türkiye’de ayçiçeği yetiştiriciliğinde Tekirdağ ve Konya’dan sonra üçüncü sırada yer almaktadır. Edirne ili 2021 yılında, 1.073.508 dekar ekili alandan, 285.286 ton ayçiçeği üretimini gerçekleştirmesiyle yapılan çalışmada yer alınmıştır. İllere göre ayçiçeği ekilen alan ve üretim miktarı Tablo 1.4.’te verilmiştir (TÜİK, 2021).

Tablo 1.4. 2021 yılı Türkiye’deki illerin ayçiçeği ekim alanı ve üretim miktarları (TÜİK, 2021)

Yıl	Şehir	Ekilen alan (da)	Üretim miktarı (ton)
2021	Tekirdağ	1663007	399531
	Konya	852400	324790
	Edirne	1073508	285286
	Kırklareli	911619	226163
	Adana	652083	201366
	Çorum	448130	94293
	Eskişehir	195025	68427
	Çanakkale	218754	62319
	Tokat	208643	58069
	Samsun	196969	51617
	Balıkesir	208669	50216
	İstanbul	181676	49017
	Amasya	210745	47754
Diğer	1091888	296152	

Anadolu’nun verimli topraklarında düne kadar tarım ürünleri bakımından kendi kendine yeten bir ülke konumunda iken son yıllarda Türk çiftçisi mazot ve gübre gibi

girdi maliyetlerinin çok yüksek olması nedeni ile zarar etmemek için verimli topraklarını boş bırakmaktadır. Temel ihtiyaç maddelerinden ve yemeklik yağ elde edilmesinde kullanılan, ayçiçeğinin üretim miktarı iç talebi karşılayamadığı için ihtiyaç duyulan ayçiçeği miktarını dış ülkelere satın alarak gidermektedir. Dış ülkelere yüksek fiyatlara aldığımız ayçiçeğini, ülkemizde daha uygun fiyata üretebiliriz. Bu nedenle ayçiçeği üretim miktarının tahmin edilmesine gereksinim duyulmaktadır.

Ayçiçeği üretim miktarını tahmin etmek amacıyla kullanılacak yöntemler arasında istatistiksel öğrenme ve makine öğrenmesi yöntemlerinden yararlanılabilir. İstatistiksel öğrenmelerin makine öğrenmesi yöntemlerine göre dezavantajları bulunmaktadır. Bu kapsamda istatistiksel öğrenmede model oluşturmak için yararlanılan girdi değişkenlerinde ortaya çıkan değişikliklerin çıktı değişkeninde oluşturulması muhtemel değişimleri ile ilgili yorum yapılabilir. Yorumda bulunulmasının nedeni üretilen öngörü fonksiyonunun lineer olmasıdır. İstatistiksel öğrenme tasarımları varsayımlara ve varsayımların denetimlerine ihtiyaç duyar, optimal vaziyetlerde bile yorumlama bölümlerinde bazı varsayımlar yapılır. Günlük hayatta lineer tasarımların varsayımlarını sağlamak hayli zordur. Eksik gözlem, aykırı gözlem gibi durumlar fazlaca önem arz eder. Makine öğrenmesi yöntemlerinde ise varsayımlar oldukça azdır ve tasarımların kullanılması daha basittir. Direk hedefe yönelmektedir. Makine öğrenmesi yöntemleri aykırı gözlem, eksik gözlem gibi vaziyetlerden çok az etkilenir. Bunun nedeni data içerisindeki oluşuma vekalet etmek için yaratılan fonksiyonların esnek yapıya sahip olmasıdır. Makine öğrenmesi yöntemlerinin varsayımlara ihtiyaç duymaması, basit bir şekilde uygulanabilir olmasından dolayı çalışmada kullanılmaktadır. Ayrıca literatürdeki çalışmalarda makine öğrenmesi yöntemlerinin istatistiksel öğrenmelere göre daha iyi sonuçlar verdiği ortaya konulmuştur (Can ve Gerşil, 2018).

Bu çalışmada makine öğrenme yöntemlerinden yararlanılarak geliştirilen modellerde üretim miktarının, ekilen arazi, nem, sıcaklık, yağmur ve güneşlenme süresi gibi beş bağımsız değişken esas alınarak tahmin yapılması amaçlanmaktadır. ANFIS, YSA, doğrusal regresyon ve karar ağacı yöntemleriyle oluşturulan modellerle ayçiçeği

retim miktarının tahmin edilmesi saęlanmıřtır. Edirne blgesinde yapılan uygulamada ANFIS modelinin yukarıda adı geen dięer modellere gre daha dřk hata deęeri ile tahmin yapılabileceęi ortaya konulmuřtur. Yapılan uygulamada ANFIS modelinin 0,003243778 hata (MSE) deęeri ile tahmini saęlanmıřtır. Bylece ANFIS modeliyle girdilerin deęiřen miktarına gre gelecek yıllara ait retim miktarı tahmin edilebilecektir.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Yapay Sinir Ağları ile İlgili Literatür Çalışmaları

Literatürde yapay sinir ağı yöntemine dayanan birçok model bulunmaktadır. Ancak söz konusu çalışmada, ayçiçeği üretim tahmini amaçlandığından bu bölümde sadece tarım alanındaki çalışmalara yer verilmiştir.

Sungur ve Altun (2010) Konya bölgesinde yapılan çalışmaları kapsamın da elma, armut, kiraz gibi meyve ağaçlarının çiçeklenme zamanı don olaylarına maruz kalması nedeniyle meyve veriminde düşüş yaşandığı belirtilmiştir. Bu sebeple sıcaklık ve nem değişkenleri kullanılarak Yapay Sinir Ağı (YSA) tabanlı tahmin yöntemine sunulmuştur. Bu tahmin sonucunda don tehlikesinin yaşanıp yaşanmayacağı belirlenmiştir. Tasarımın don riski olduğu vaziyetlerde minimum hata ile çalıştığı görülmektedir.

Sabancı (2013) tarafından şeker pancarı yetiştirilen tarlada çıkan yabancı otların belirlenmesi üzerine ilaçlanmanın yapılması için bir robot tasarlanmıştır. Yapılan çalışmada geliştirilen robotta görüntü işleme ve YSA yöntemleri ile yabancı otları belirleyerek, ilaç uygulaması gerçekleştirilmektedir. Söz konusu robot ile klasik ilaçlama yöntemine göre %53 oranında ilaç tasarrufu yapıldığı görülmektedir.

Can ve Gerşil (2018) çalışmalarında, Manisa Tarım Borsasından senelik pamuk fiyatlarını temin ederek, zaman serisi ve yapay sinir ağları yöntemlerinden yararlanarak 2017 yılına ait fiyatların değer öngörülerini yapmıştır. Yapılan karşılaştırma sonucunda yapay sinir ağı modelinin daha başarılı neticeler verdiği görülmektedir.

Turhal ve Turhal (2014) arařtırmalarında buęday bařaklarını hasat etmeden önce hasarlı olanlar ile hasarsız olanların ayrılması gerektięini öngörmüşlerdir. Yapılan çalışmada hasarlı olan buęday bařaklarını saptamak için yapay sinir aęlarına dayalı otomatik görüntü tanıma sistemi kullanılmıştır.

2.2. ANFIS ile İlgili Literatür Çalışmaları

Literatürde ANFIS yönteminden yararlanılan birçok uygulama bulunmaktadır. Ancak sözü edilen arařtırmada, ayçiçeęi üretim tahmini hedeflendięinden bu kısımda yalnızca tarım alanındaki çalışmalara yer verilmiştir.

Adelkhani ve ark., (2013) tarafından yapılan çalışmada ANFIS yöntemi kullanılarak, 300 tane portakalın tat deęerine göre Thompson, Bam, Khooni çeřitleri içinde sınıflandırması yapılmıştır. Portakal meyvesinin rengi, renk tonu doygunluk deęeri, doku özellikleri, çapı, çevresi girdi deęişkenleri olarak kullanılmaktadır. Tat deęişkeni ise çıktı deęişkeni olarak belirlenmiştir.

Kouchakzadeh ve ark., (2011) çalışmalarında, İran'ın Horosan Eyaletinde sıcaklık, yağış, net radyasyon, nem deęişkenleri kullanılarak kuru buęday verimi, YSA ve ANFIS yöntemleri ile tahmin edilmesi hedeflenmiştir. Yapılan uygulamalar neticesinde ANFIS modelinin YSA modeline göre daha başarılı sonuçlar verdięi ortaya konulmuştur.

Aboukarima ve Minyawı (2013) tarafından yapılan çalışmada Mısır ülkesinde yetiřtirilen ayçiçeęi tohum verimini tahmin etmek için ANFIS modeli kullanılmıştır. Bağımsız deęişkenler ayçiçeęi tabla çapı, tabla kısmındaki tohum sayıları, tohum nem içerięi ve hasat öncesi kayıplardır. Bağımlı deęişken ise ayçiçeęi tohumu verimidir. Yapılan tasarım neticesinde ANFIS modelinin başarılı bir şekilde uygulanabileceęi vurgulanmıştır.

2.3. Karar Ağacı ve Doğrusal Regresyon Literatür Çalışmaları

Literatürde karar ağacı ve doğrusal regresyon yöntemlerine dayanan tarım alanına yönelik birçok çalışma bulunmaktadır. Bu çalışmalardan bazılarında bu bölümde yer verilmiştir.

Suraparaju (2016) tarafından yapılan çalışmada Hindistan'ın Pradesh bölgesinde karar ağacı yöntemi kullanılarak soya fasulyesi verim tahmini yapılmıştır. Yapılan tahminde yağış, buharlaşma, sıcaklık, nem değişkenleri kullanılmaktadır. Makine öğrenmesi yöntemlerinden biri olan karar ağacı modeli başarılı sonuç vermiştir.

Sowmya ve ark., (2020) tarafından yapılan çalışmada karar ağacı algoritması kullanılarak tarım arazilerinde hangi ürünün yetişeceğini belirleyen bir uygulama geliştirilmiştir. Bu uygulama kapsamında yağış, sıcaklık, nem, ph değeri, toprak türü değişkenleri kullanılarak tarım arazisinde hangi bitkinin yetiştirileceği belirlenmektedir.

Kalichkin ve ark., (2021) tarafından yapılan çalışmada yağış, buharlaşma, sıcaklık, nem değişkenleri kullanılarak karar ağacı yöntemi ile buğday verimi tahmin edilmiştir. Kullanılan yöntemin başarılı sonuçlar verdiği görülmektedir.

Leng ve Hall (2020) tarafından yapılan çalışmada ABD'nin tüm eyaletlerinde makine öğrenmesi yöntemlerinden karar ağacı, rastgele orman ve doğrusal regresyon yöntemleri kullanılarak mısır verimi tahmin edilmiştir. Yapılan tahminde yağış, sıcaklık, buharlaşma, toprak nemi, güneş radyasyonu değişkenleri kullanılmaktadır. En başarılı sonucu doğrusal regresyon modelinin verdiği görülmüştür.

Bayrakçı ve ark., (2021) tarafından yapılan araştırmada yetiştirilen her bitkinin su ihtiyacının farklılık gösterdiği tespit edilmiştir. Bölgede bulunan, il, ilçe, bitki türü, bitki su isteği değişkenleri kullanılarak regresyon türlerinin su harcama miktarı tahminlerini veren bir arayüz uygulaması geliştirmişlerdir. Bu uygulama kapsamında en iyi sonucu veren algoritmanın değeri kullanıcıya sunulmaktadır.

2.4. Makine Öğrenmesi Literatür Çalışmaları

Literatürde makine öğrenmesi yöntemlerine dayanan tarım alanına yönelik birçok çalışma bulunmaktadır. Bu çalışmalardan bazılarında bu bölümde yer verilmiştir.

Paudel ve ark., (2021) tarafından yapılan çalışmada Almanya, Fransa, Hollanda ülkelerinde; ortalama sıcaklık, yağış, iklim su dengesi, minimum sıcaklık, maksimum sıcaklık, toplam su tüketimi, toprak nemi değişkenleri kullanılarak Buğday, arpa, ayçiçeği, şeker pancarı ve patates gibi tarım ürünleri veriminin kıyaslanması doğrusal regresyon, k-en yakın komşu, destek vektör makineleri, karar ağacı yöntemleri ile yapılmıştır.

Mishra ve ark., (2016) tarafından yapılan çalışmada tarımsal ürün yönetimi alanında; makine öğrenimi tekniklerinin uygunluğuna ilişkin araştırmalara yer verilmiştir. Topraktaki fosfor, potasyum, tuz, organik madde, magnezyum değişkenleri kullanılmış ve soya fasulyesi verimini tahmin etmek amacıyla YSA, ANFIS, karar ağacı, bayes, markov zinciri, doğrusal regresyon yöntemleri kullanılmıştır.

Jain ve ark., (2017) tarafından yapılan çalışmada Hindistan bölgesinde; mahsul verimi, toprak türü, ph, azot, fosfat, potasyum, organik karbon, kalsiyum, manganez, bakır, demir, derinlik, sıcaklık, yağış, nem değişkenleri kullanılarak; pirinç, çay, buğday, kenevir, mısır, hardal, şeker kamışı gibi ürünlerin hangi topraklarda daha verimli bir şekilde yetişmesine YSA, ARIMA, karar ağacı ve destek vektör makineleri yöntemleri ile karar vererek, mahsul üretimini arttırmak ve gıda kıtlığını azaltmak amaçlanmıştır.

Şenel (2020) tarafından yapılan çalışmada kayısı çekirdeğinin tatlı yada acı olduğunu k-en yakın komşu, destek vektör makineleri, karar ağacı, rasgele orman, gaussian naive bayes yöntemleri ile sınıflandırılması amaçlanmaktadır. Bu sınıflandırma yöntemi neticesinde en iyi sonucu rasgele orman algoritması vermektedir.

2.5. Ayçiçeği Üretimi Literatür Çalışmaları

Bu bölümde literatürde ayçiçeğiyle yapılan diğer çalışmalar yer almaktadır.

Doğan (2018) tarafından yapılan bu çalışmada Türkiye’de tüketimden doğan ihtiyaca yönelik ayçiçeği, soya, aspir ve kolza ekiliş alanlarına fark ödemesi yardımlarının neticeleri incelenmiştir. Çalışma, 1994-2016 yıllarını içermektedir. Granger Nedensellik Testi ve Johansen Cointegration Testi’nden faydalanılmıştır. Söz konusu neticelere göre, fark ödeme yardımlarının ayçiçeği yetiştirici kararlarının önemsenme etkisi istatistiksel olarak kayda değer bulunmuştur.

Gündüz (2021) tarafından yapılan bu çalışmada mikroekonomi teorileri ve zaman serisi analizlerinden faydalanılarak Türkiye’de Ayçiçek yağı parasal değer yükselmesi sebeplerinin tespit edilmesi hedeflenmiştir. Ayçiçek yağı elde edilmesinde tohum fiyatları, üretim ve dış ticaret istatistikleri, Ayçiçek yağı fiyatları ve döviz kuru gibi datalardan yararlanılmıştır. Dış ülkelere satın alınan ayçiçeği yağı pazarının idaresi için kısa dönemde kuru korumak, uzun dönemde ise üretim planı yapılması gerekmektedir.

Semerci ve Durmuş (2021) tarafından yapılan çalışmada Türkiye’de yetiştirilen ayçiçeği üretimi hakkında gerekli araştırmalar yapılarak, ekilen alan, üretim miktarı, fark destekleri, verim, ithalat ve ihracat verileri göz önünde bulundurularak 1998-2018 yılları arasında ayçiçeği üretim analizleri ortaya konulmuştur.

Gül ve ark., (2016) tarafından yapılan araştırmada üretilen ayçiçeğinden elde edilen yağ miktarı iç tüketime cevap vermediği gerekçesiyle, ihtiyacın büyük bir çoğunluğu dış ülkelere satın alma yöntemiyle karşılandığı tespit edilmiştir. Bu çalışmanın amacı ise ülkemizde yetiştirilen ayçiçeği üretiminin önemini ve yağ açığının kapatılmasındaki rolünü ortaya koymaktadır.

BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Veri Elde Etme

Yapılan çalışmada Edirne ilindeki ayçiçeği üretim miktarı YSA, ANFIS, doğrusal regresyon ve karar ağacı yöntemleriyle tahmin edilmesi amaçlanmaktadır. 1960-2021 yılları arası veriler baz alınarak, yukarıda belirtilen yöntemlerle en az tahminleme hata değerini veren model belirlenmiştir. Bu model ile girdilerin değişen miktarına göre gelecek yıllara ait ayçiçeği üretim miktarının tahmini yapılması hedeflenmektedir. Çalışmada ayçiçeği ekilen alan büyüklüğü, sıcaklık, nem, yağış miktarı, güneşlenme süresi gibi bağımsız değişkenler kullanılmıştır. Ayçiçeği ekilen alan büyüklüğü ve üretim miktarı verileri, Türkiye İstatistik Kurumu'ndan, iklim elemanları verileri ise Meteoroloji Genel Müdürlüğü'nden alınmıştır.

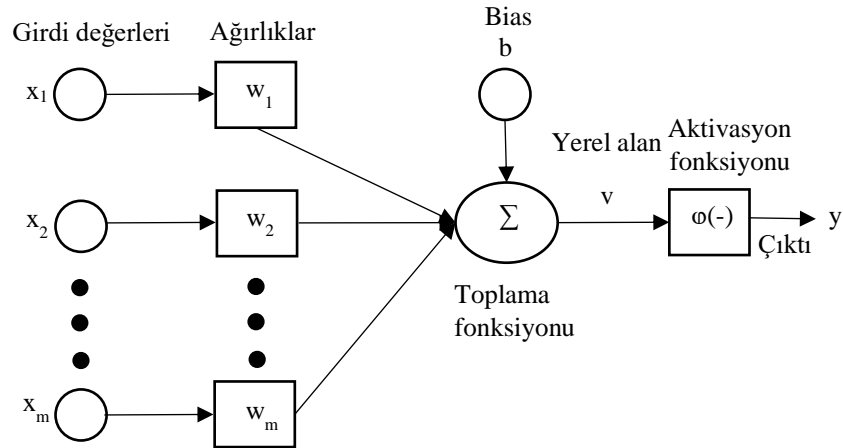
Uygulamaya başlamadan önce verilerin normalize edilmesi gerekmektedir. Bu işlem için aşağıdaki Denklem 3.1 kullanılmaktadır.

$$X_{\text{normal}} = \frac{X - X_{\text{asgari}}}{X_{\text{azami}} - X_{\text{asgari}}} \quad (3.1)$$

3.2. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin öğrenme kabiliyetinden, etkilenecek yeni bilgileri ortaya koyan bilgisayar sistemleridir. YSA ile basit biyolojik sinir sistemi çalışma prensibinin aynısı kopyalanır. Kopya edilen sinir hücreleri nöronları barındırır ve bu nöronlar farklı biçimlerde birbirlerine eklenerek ağı oluştururlar. Bu ağlar öğrenme,

belleğine alma ve datalar arasındaki bağlantıyı açığa çıkarma becerisine sahiptirler. (Öztemel, 2006).




Şekil 3.1. Yapay sinir hücresi

Yapay sinir ağırları, Şekil 3.1.'de görülen ve fonksiyonu Denklem 3.2'de sunulan yapay nöronlardan oluşmaktadır (Kuncheva, 2004).

$$y = f\left(\sum_i^d w_m * x_m\right) \quad (3.2)$$

Burada d toplam girdi sayısını, w ağırlıkları, x ise girdileri göstermektedir.

Bir katmandan oluşan yapay sinir ağırları nonlinear bağlantıları öğrenemez. Bu sebeple oluşturulmuş değişik ağ tasarımları vardır. Giriş ve çıkış değişkenleri arasındaki bağlantı lineer olmadığında Şekil 3.2.'de sözü edilen çok katmanlı algılayıcı (ÇKA) kullanılmaktadır.



Şekil 3.2.Çok katmanlı algılayıcı yapısı (Sağiroğlu, 2003)

En fazla tercih edilen, yapay sinir ağı tasarımı olan ÇKA, girdi, gizli ve çıktı olmakla birlikte üç tabakadan meydana gelmiştir. Her tabaka da veri iletişimini kurmak için proses unsurları vardır. Tabakalar birbirlerine proses unsurları yardımıyla bağlı kalmaktadır. Veriler sisteme giriş tabakasından bağlanır bu tabakada herhangi bir veri eğitimi olmaz. Bu tabakadan gönderilen veriler gizli tabakada eğitilir. Gizli tabaka adedi girdi/çıkış arasındaki irtibatın durumuna ve karışıklığına bağlı olarak değişir. Sonunda sistemin yarattığı çıktının hesap edilerek kullanıcıya iletiildiği çıktı tabakası mevcuttur. Öte yandan girdi ve çıktı tabakasındaki proses unsuru adedi uygulamaya göre saptanırken, gizli tabakadaki unsur adedi ise en iyi başarıyı elde etmek için deneme yanılma yolu ile bulunmaktadır (Öztemel, 2003).

En çok tercih edilen YSA öğrenme yöntemi, geri yayımlı sinir ağı algoritmasıdır. Geri yayımlıdaki amaç; ağıdaki ağırlıkların her birini güncel halde bulundurmaktır ve bundan dolayı tahmin sonucunun gerçek sonuca daha yakın olması hedeflenmektedir. Bu yöntem, eğitim örneklerinde olası bir hata yaşanması halinde kullanılabilir olması ve uzun zamanlı bir eğitim süresi kabul gördüğü için tercih edilmektedir.

Yapay sinir ağlarının en ana görevi, girdi değişkenlerine aktivasyon fonksiyonu uygulamaktır. Bu sayede çıktı değişkenlerine ulaşılır. Aktivasyon fonksiyonları arasında en çok kullanılanlar; Doğrusal Aktivasyon Fonksiyonu, Log Sigmoid Aktivasyon Fonksiyonu ve Hiperbolik Tanjant Aktivasyon Fonksiyonu olduğu belirtilmektedir (Yadav ve ark, 2015).

Transfer fonksiyonları arasından literatürde en sık kullanılan fonksiyon Denklem 3.3'te görüldüğü gibi hesaplanan lojistik sigmoid fonksiyonudur (Özmen ve Gülbandılar, 2020).

$$y = \frac{1}{1 + e^{-(\sum_i w_i x_i + w_0)}} \quad (3.3)$$

burada, x_i , girdiler; w_i , ağırlık faktörü ve w_0 , hata terimini ifade etmektedir.

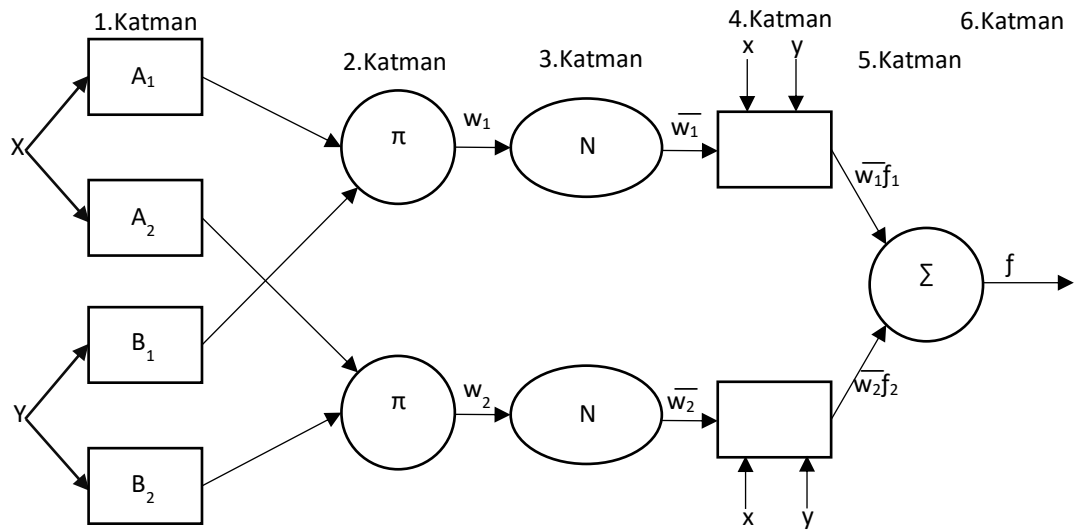
Yapay sinir ağları kararsızdır, çünkü eğitim datalarındaki değişimler, yapısında ve parametrelerinde değişime neden olabilir. Eğitimin sonlanacağı noktanın bulunması zaman almaktadır. Ancak; eksik veri durumunda ve belirsiz konumlarda pürüzsüzce çalışarak hesaplama yapabilmektedir.

3.3. Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS)

Yapay sinir ağlarının öğrenme yeteneği ve bulanık mantığın çıkarım yaratma niteliği ile birlikte kullanabilen bu melez yapay zeka sistemi Jang (1993) tarafından bulunmuştur. Bu sistemden yararlanmak için girdi ve çıktı biçiminde ifade edilebilecek bir veri setine gereksinim duyulur. İlk olarak veri seti için üyelik fonksiyonu miktarı tanımlanır. Sonrasın da kendi içerisinde kaideler belirlenerek öğrenme gerçekleştiren sistemin neticelerini oluşturur. Yöntemin başarısı, sistemden elde edilen sonuçlar ve gerçek sonuçların kıyaslanmasıyla belirlenir (Özel ve Büyükyıldız, 2019).

3.3.1 ANFIS yöntemi

ANFIS yapısını sade bir biçimde açıklamak için örnek olarak iki kurallı ve iki girdili bir ANFIS yapısı uygulanmıştır (Şekil 3.3.). Düğümlerin 4. katmana kadar öne hareketlerinde uç değişkenler en küçük kareler yöntemi ile teyit edilmekte, arka yöne hareketlerinde ise bu defa öncü değişkenler gradyent azaltım tekniğiyle belirlenmekte.



Şekil 3.3. 2 girdi, 1 çıktı ve 2 kuraldan oluşan örnek bir ANFIS yapısı

Şekil 3.3.'te gösterilen ANFIS modeli 2 girdi, 1 çıktı değeri ve 2 kuraldan oluşmaktadır.

Kural 1: Eğer x değeri A_1 ve y değeri B_1 ise,

$$f_1 = p_{1x} + q_{1y} + r_1 \quad (3.4)$$

Kural 2: Eğer x değeri A_2 ve y değeri B_2 ise,

$$f_2 = p_{2x} + q_{2y} + r_2 \quad (3.5)$$

Burada ANFIS yapısını sade bir biçimde açıklamak için misal olarak iki girişli ve tek çıkışlı bir ANFIS yapısı uygulanmıştır. A ve B, x ve y üyelik fonksiyonları için tanımlanmış öncü bölümdeki bulanık kümeler; p, q ve r ise uç değişkenlerdir. Böylelikle her bir kaide için bir çıktı değeri sağlanır.

ANFIS yapısının çalışmasında belirtildiği gibi giriş parametreleri ve sonuç parametrelerinin değerlerinin bilinmesi önem arz etmektedir. ANFIS'in öğrenme algoritması, giriş ve sonuç parametrelerini optimize etmektedir. Bahse konu olan öğrenme işlemi devam ederken ANFIS hybrid öğrenme algoritması kullanılmaktadır. Hybrid öğrenme algoritması, en küçük kareler yöntemi ile geri yayımlı öğrenme algoritmasının birlikte kullanılmasından meydana gelmektedir.

Hybrid öğrenme algoritması, ileri ve geri besleme olmak üzere iki bölümden meydana gelmektedir. İleri beslemede, giriş değişkenleri sabit alınarak çıkış değişkenlerinin değerleri en küçük kareler yöntemi ile hesaplanması yapılırken, geri beslemede ise çıkış değişkenleri sabit alınarak giriş değişkenleri geri yayımlı öğrenme algoritması ile hesaplanmaktadır.

İleri ve geri besleme çalışma prensibi, tüm sistem hatası tespit edilen bir hata değerinden küçük oluncaya kadar devam eder ya da hata değerinde fazla bir değişim olmaz ise işleyiş sonlanmaktadır.

3.3.2. ANFIS yapısındaki katmanlar

Şekil 3.3.'te görüldüğü üzere ANFIS yapısı 6 katmandan oluşmaktadır. ANFIS yapısındaki her katmana ait düğüm işlevleri ve katmanların çalışma prensibi sırasıyla şöyledir (Hocaoğlu ve Kurban, 2005):

1. Katman: Girdi katmanı olarak isimlendirilir. Katman tüm uyarlanabilir düğümleri içerir. Her bir düğümün girdisi üyelik fonksiyonudur ve düğüm çıktısı, O, Denklem 3.6 ve 3.7'deki gibi hesaplanır.

$$O_{1,i} = \mu_{A_i}(x), i = 1,2 \quad (3.6)$$

$$O_{1,i} = \mu_{B_{i-2}}(y), i = 1,2 \quad (3.7)$$

Burada x ve y, i düğümü için girdi, A ve B bu düğüm fonksiyonu ile ilgili düşük, orta, yüksek gibi dilsel ifadeleri ve $\mu_{A_i}(x)$ ve $\mu_{B_{i-2}}(y)$ üyelik fonksiyonlarından (üçgen, yamuk ve gauss) biridir.

2. Katman: Bulanıklaştırma katmanıdır. Girdiler bulanıklaştırılır ve modelde π olarak tanımlanır.

3. Katman: Kural katmanıdır. Katmandaki her bir düğüm, Sugeno bulanık mantık yöntemine göre oluşmuş kuralları anlatmaktadır. Söz konusu her bir kural düğümünün çıkışı μ_i , ikinci katmandan gelen üyelik kademelerinin çarpımı olmaktadır. μ_i değerlerinin elde edilişi ise, ($j=1,2$) ve ($i=1,\dots,n$) olmak üzere,

$$y_i^3 = \Pi_i = \mu_{A_j}(x) \times \mu_{B_i}(y) = \mu_i \quad (3.8)$$

şeklindedir. Burada, y_i^3 , üçüncü katmanın çıkış değerlerini; n ise, bu katmandaki düğüm sayısını ifade etmektedir.

4. Katman: Normalizasyon katmanıdır. Üçüncü katmandan gelen bütün düğümleri giriş değeri olacak şekilde kabul edilerek her bir kaidenin normalleştirilmiş ateşleme düzeyi bulunur. Normalleştirilmiş ateşleme seviyesi μ_i aşağıdaki Denklem 3.9 ile hesaplanır.

$$y_i^4 = N_i = \frac{\mu_i}{\sum_{i=1}^n \mu_i} = \mu_i \quad , (i=1,n) \quad (3.9)$$

5. Katman: Durulaştırma katmanıdır. Katmanda yer alan her bir düğümde verilen bir kaidenin ağırlıklandırılmış neticeleri hesaplanır.

6. Katman: Çıkış katmanıdır. Bu katmanda yalnız bir düğüm vardır. Adı geçen beşinci katmandaki her bir düğümün çıkış değeri toplamı ANFIS yönteminin gerçek değeri olarak elde edilir. Sistemin çıkış değeri olan y Denklem 3.10 ile bulunur.

$$y = \sum_{i=1}^n \bar{\mu} [p_i x_1 + q_i x_2 + r_i] \quad (3.10)$$

3.4. Doğrusal Regresyon

Regresyon analizi, çıktı değişkeni ile bir veya daha fazla girdi değişkenleri arasındaki bağlantıları tahminde bulunmak için yararlanılan bir yöntemdir. Değişkenler arasındaki bağlantının kuvvetini incelemek ve gelecekte aralarındaki bağlantıyı tasarlamak için kullanılabilir. Regresyon analizi, doğrusal, çoklu doğrusal ve doğrusal olmayan gibi çeşitli versiyonları içerir. Yaygın olarak kullanılan tasarımlar basit doğrusal ve çoklu doğrusaldır (Andrews, 1974).

Basit lineer regresyon, bir bağımlı değişken ile bir bağımsız değişken arasında ilişkilidir. Basit bir lineer regresyon modeli, ε ' un bir hata olduğu Denklem 3.11 ile ifade edilebilir.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3.11)$$

Çoklu lineer regresyon iki ve daha fazla bağımsız değişken ve bir bağımlı değişken arasındaki lineer bağlantıyı değerlendirir. Çok değişkenli lineer regresyon tasarımı Denklem 3.12'de gösterilmiştir. Burada ε hata terimi, β_n regresyon katsayısı ve n gözlemleri temsil eder.

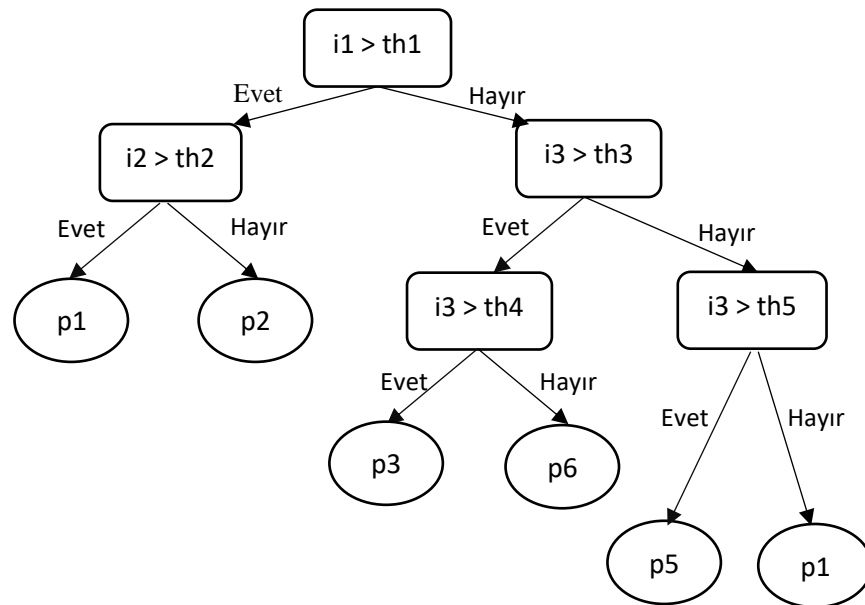
$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (3.12)$$

β regresyon katsayısını hesap etmek için çoğunlukla en küçük kareler yöntemi kullanılır. Regresyon katsayılarının hesaplanması için kullanılan en küçük kareler yöntemi genel ifadesi Denklem 3.13 ile gösterilmiştir.

$$\beta = (X.X^T)^{-1}X^TY \quad (3.13)$$

3.5. Karar Ağacı

Karar ağaçları; kolay yorumlanabilir olması ile sınıflandırma ve regresyon problemlerinde hesaplama bedelinin az oluşundan dolayı çokça istifade edilmektedir. Karar ağacı basit ve anlaşılır bir tasarıma sahiptir. Bir karar ağacı, kök, dallar, yapraklar ve düğümlerden meydana gelmiştir (Vega ve ark., 2009). Karar ağacı oluşumunda; bir değişken kök olarak belirlenir ve sonrasında kök, değişkenlerin özelliklerine tabi olarak düğümlere ayrılır. Kök, dal ve düğümden oluşan bir dizilişin uç kısmı yaprak olarak isimlendirilir (Tiryaki, 2008). Karar ağacında ayırma işi, girdi değişkenlerinden biri tarafından uygulamaya alınır ve bunların ara mesafesi, hata değerinin en aza indirgenmesine göre seçilir. Tasarımın çıktı değeri ayırık değerlerden oluşması durumunda, sınıflandırma ağacı meydana gelir. Tasarımın çıktısı gerçek değerlerden meydana geldiğinde ise regresyon ağacı oluşmaktadır (Lewis, 2000). Şekil 3.4.'te bir karar ağacının şematik olarak yapısı görülmektedir.



Şekil 3.4. Karar ağacı örneği (Swetapadma ve Yadav, 2016)

Şekil 3.4.'de $I=\{i_1,i_2,i_3\}$ girdi değişkenlerini, $Th=\{th_1,th_2,th_3,th_4,th_5\}$ başlangıç değerlerini ve $P=\{p_1,p_2,p_3,p_4,p_5,p_6\}$ ise öngörü değerlerini belirtmektedir. Tahminler girdi değişkenlerine uygulanan eğer-ise kaidelerine göre yapılmaktadır.

Karar ağaçlarını tespit etmek için bütün yöntemler içerisinde, sınıflandırma ve regresyon ağacı (CART) yoğun olarak tercih edilmektedir. Ayçiçeği üretim tahmini bir regresyon uygulaması olduğundan dolayı söz konusu çalışmada regresyon ağaçlarının ilkelerine yoğunlaşmıştır.

CART algoritması, en az kare hatasına yönelik en uygun niteliklerin ve ayırma noktalarının belirlenmesi ile yinelenen ağaç yaratma oluşumudur. Ağacın data setinin niteliklerine göre düzenlenebilme özelliğinden dolayı fonksiyon modelini öncelikle tasarlanmasına ihtiyaç duyulmamaktadır. Kesikli ve sürekli değişkenlerle çalışma yapılabilmektedir. Karar ağacı kategorik, sayısal ve eksik veriler ile çalışabilme, çoklu giriş değerlerini tahmin edebilme gibi yeteneklere sahiptir. Ancak bazı engelleri de beraberinde taşımaktadır (De'ath ve Fabricius, 2000). Karar ağacı regresyonu, datalardaki küçük değişikliklere dikkat edilmelidir. Yoksa sonucun farklı bir ağaçla neticelenebileceğinden kararsız olabilir. Denemelerde ideal bir doğrulama için küçük dokunuşlardan kaçınılmalıdır aksi bir durumda aşırı öğrenme ile sonuçlanabilir. Bu problemi engellemek için karar ağacı regresyon parametrelerinin düzenlemesi istenmektedir.

CART algoritmasında veri setindeki ayırma ve dallardaki niteliklerin incelenmesi için Gini katsayısından istifade edilmektedir. (Breiman ve ark.,1984).

$$Gini\ katsayısı = \frac{f(c_i,t)}{|T|} \quad (3.14)$$

Denklem 3.14'te verilen gini katsayısı denkleminde T eğitim verisini C_i i. sınıfı ifade etmektedir.

3.6. K-ortalamlar Algoritması ile Kümeleme

K-ortalamlar en fazla tercih edilen kümeleme yöntemlerinin başında yer almaktadır. Veri setini k tane merkezli kümelere bölen bir algoritmadır. Adı geçen yöntemde değerler yalnız bir kümede yer almalıdır. Bu nedenden dolayı küme sınırları, sayıları ve ortalamaları bellidir (Sarıman, 2011). Bu algoritma da öngörülen küme adedi kadar, küme içinden rastgele veriler alınır. Bu veriler kümelerin merkez noktalarıdır. Data setindeki öğelerin her biri, bu merkeze olan uzaklıkları ile kümeye katılırlar. Uzaklıkların hesaplanmasında Denklem 3.15'te kullanılan formüllerden biridir. (Goyal ve Gupta, 2014; Saphioğlu ve Acar, 2020).

$$X = \sum_{j=1}^k \sum_{i=1}^M |Y_i^{(j)} - C_j|^2 \quad (3.15)$$

Burada X uzaklığı, Y eleman sayısını, C küme merkezini, i veri sayısını, j küme sayısını ifade etmektedir. Sonrasında tüm değerlerin ağırlığı alınıp, kümelerin merkez noktaları yeniden hesaplamaya tabii tutulur. Küme merkezlerini tespit etmek için Denklem 3.16'dan yararlanılır. Kümelerin merkez noktalarında bir değişiklik olana kadar işlem yapmaya devam edilir. Kümeler arası geçiş yok ise işlemler sona erdirilir. (Xu ve Wunsch, 2005; Saphioğlu ve ark, 2019).

$$Z_j = 1/n_j \sum_{\forall Y_p \in C_j} Y_p \quad (3.16)$$

Söz konusu formülde Z kümelerin ağırlık merkezlerinin yeniden hesaplanmasını ifade etmektedir. Bu algoritmada küme elemanlarının mümkünse birbirine yakın olması, kümeler arasındaki aralığın oldukça birbirinden irak olması istenir. Küme adedi de bu hususlara göre seçilir (Dalton ve ark, 2009; Saphioğlu ve ark, 2019). K-ortalamlar kümeleme yönteminin neticelendirilmesi için çoğunlukla karesel hata kullanılmaktadır.

3.7. Performans Kriterleri

Tarım ürünleri tahmin çalışmalarında; performans kriterleri olarak literatürde en çok kök ortalama kare hata (RMSE), ortalama kare hata (MSE), ortalama mutlak hata (MAE), belirlilik katsayısı R^2 kullanılmaktadır (Paudel ve ark., 2021). Bu nedenle performans kriterleri olarak RMSE, MSE, MAE, R^2 tercih edilmiştir.

$$RMSE = \frac{1}{n} \sum_{i=1}^n \sqrt{(f_i - f_i^*)^2} \quad (3.17)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - f_i^*)^2 \quad (3.18)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - f_i^*| \quad (3.19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (f_i - f_i^*)^2}{\sum_{i=1}^n (f_i - \bar{f}_i)^2} \quad (3.20)$$

Denklem 3.17’de, Denklem 3.18 ’de ve Denklem 3.19’da belirtilen f_i i’inci veriye ait tahmin değerini, f_i^* i’inci yıla ait gerçekleşen değeri ifade etmektedir. Denklem 3.20’de ise \bar{f}_i i’inci veriye ait ortalama tahmin değeridir.

BÖLÜM 4. ARAŞTIRMA BULGULARI

4.1. Uygulamanın Amacı

Dünya Covid-19 salgın hastalığını tam olarak atlatmadan, küresel gıda krizi baş göstermiştir. İhtiyaçtan fazla ayçiçeği yetiştiren ülkelerde savaş çıkması nedeniyle, tedarik zincirinde çok büyük aksamalar yaşanmasına neden olmuştur. Türkiye'nin tarıma elverişli bölgelerinde ayçiçeği ekimi yapılmaktadır. Ancak ülkemizde tarım politikası olarak çiftçimize yeterli seviyede mazot ve gübre desteği sağlanamadığı gerekçesi ile büyük ölçüde ayçiçeği ekimine ara verilmek zorunda kalınmıştır (ZMO, 2022). Yurt içi üretim tüketimi karşılayamadığından, dış ülkelere tedarik edilmeye çalışılmaktadır. Yukarıda belirtilen olumsuzluklardan dolayı verimli topraklarımızda ayçiçeği yetiştirilmesinin önemi bir kez daha ortaya konulmuştur.

Bu çalışmada, yapay zeka yöntemlerinden yararlanılarak ayçiçeği üretim tahmini yapılması amaçlanmaktadır. Tahmin yapılırken Yapay Sinir Ağları, K-ortalamlar, ANFIS, doğrusal regresyon, karar ağacı yöntemlerinden yararlanılmıştır. Çalışmadaki hedefimiz yukarıda belirtilen hususları ortadan kaldırmak ve YSA, ANFIS, doğrusal regresyon, karar ağacı yöntemlerinin hangisinin gerçeğe daha yakın tahminler ürettiğini ortaya koymaktır.

Amaçlanan uygulamanın oluşturulmasında takip edilecek aşamalar:

Aşama 1. Verilerin normalize edilmesi.

Aşama 2. YSA ile modelin oluşturulması.

Aşama 3. K-ortalamlar metoduyla bulanık kümenin oluşturulması.

Aşama 4. ANFIS modelinin oluşturulması.

Aşama 5. Doğrusal regresyon modelinin oluşturulması.

Aşama 6. Karar ağacı modelinin oluşturulması.

Aşama 7. ANFIS, YSA, doğrusal regresyon, karar ağacı performans değerlerinin karşılaştırılması.

4.2. Yapay Sinir Ağları Yöntemi

4.2.1. Veri setinin oluşturulması

Çalışmada değişkenleri belirlemek için literatür araştırılması yapılmıştır. Toplam altı değişken belirlenmiştir. Ayçiçeği ekilen alan ve üretim miktarı yıllık bazda ele alınırken, iklim elemanları (sıcaklık, nem, yağış, güneşlenme süresi) ise ayçiçeğinin üretim periyodu olan Nisan – Eylül ayları arasındaki 6 ayın ortalaması olarak alınmıştır (Mishra ve ark, 2016; Jain ve ark, 2017; Paudel ve ark, 2021). Edirne iline ait 62 yıllık veri Tablo 4.1.'de verilmiştir. Kullanılan değişkenler aşağıda açıklanmaktadır.

Ekilen alan tahıl ve baklagil gibi tek yıllık ürünlerin yetiştirildiği tarım arazileridir. Üretim miktarı ise tarıma uygun bölgelerde hektar veya dekar başına yetiştirilen mahsulün ton olarak ifade şeklindedir. Öte yandan ekilen ve dikilen tarım arazilerinin güneşten edindiği ısı miktarı sıcaklığı belirtir. Havadaki su buharının sıvı olarak yer yüzüne inmesi yağışı oluşturur. Herhangi bir bölgede güneşin gökyüzünde görüldüğü süreye güneşlenme süresi denilmektedir. Nem ise havada bulunan su buharıdır.

Tablo 4.1. Veri Seti

Tarih	Ekilen Alan (Hektar)	Ortalama Nem (%)	Ortalama Sıcaklık (°C)	Toplam Güneşlenme Süresi (saat/gün)	Ortalama Yağış Miktarı (mm)	Üretim Miktarı (Ton)
1960	25080	65,216667	18,766667	261,3	64,05	21198
1961	20440	61,716667	19,816667	295,36667	40,316667	15582
1962	14600	57,9	20,5	316,16667	33,316667	8613
1963	14950	59,183333	20,4	311,2	36,4	11109
1964	28100	60,816667	19,266667	286,13333	50,366667	30000
1965	27773	58,55	19,516667	288,46667	26,166667	29773
1966	42643	63,233333	20,133333	288,58333	37,783333	48865
1967	44324	61,416667	19,833333	287,11667	42,566667	54025
1968	46175	55,933333	20,883333	299,46667	28	38556
1969	52700	59,083333	20,05	288,96667	30,7	71433
1970	67875	58,7	20,266667	292,75	37,533333	81085
1971	71185	62,2	19,55	270,63333	64,183333	90790
1972	138011	61,016667	20,65	268,11667	50,716667	161031
1973	133239	61,2	19,733333	274,36667	25,716667	159225
1974	116847	59,483333	19,233333	274,41667	34,366667	92254
1975	134295	65,2	20,3	264,36667	71,216667	152627
1976	126200	59,9	18,783333	269,83333	30,216667	147100
1977	108600	59,016667	19,883333	289,08333	50,916667	129739
1978	107965	65,366667	19	257,9	49,383333	101290
1979	97523	61,45	19,866667	258,13333	31,916667	131730
1980	117077	64,733333	18,916667	267,58333	47,983333	172620
1981	95700	57,95	19,75	282,33333	21,083333	93225
1982	115391	62,533333	19,516667	253,2	31,8	118338
1983	122407	62,816667	19,616667	241,35	56,916667	159211
1984	110356	63,3	19,1	264,06667	38,2	128105
1985	120899	60,966667	20,116667	270,7	28,45	155016
1986	129220	58,383333	20,65	299,93333	17,516667	179947
1987	130969	61,766667	19,633333	257,68333	33,183333	182830
1988	141179	64,383333	20,1	236,13333	20,6	207645
1989	142665	66,416667	19,7	249,78333	35,65	260534
1990	135556	60,716667	19,783333	263,6	39,416667	135897

Tablo 4.1. (Devamı)

Tarih	Ekilen Alan (Hektar)	Ortalama Nem (%)	Ortalama Sıcaklık (°C)	Toplam Güneşlenme Süresi (saat/gün)	Ortalama Yağış Miktarı (mm)	Üretim Miktarı (Ton)
1991	103995	65,666667	19,416667	239,46667	34,433333	143844
1992	124926	62,983333	19,35	256,23333	41,266667	213933
1993	119469	62,083333	19,55	268,3	44,05	141602
1994	115260	60,616667	21,6	281,15	29,283333	164215
1995	124997	62,533333	20,05	276,4	38,883333	208415
1996	120293	59,766667	20,2	283,71667	35,333333	156585
1997	122291	62,4	18,916667	263	40,15	224929
1998	124270	62,433333	20,65	278,21667	65,816667	190648
1999	142415	64,716667	21,033333	296,48333	52,6	240383
2009	109337,1	59	20,95	250,6	43,03333	198437
2010	115312,4	64,78333	21,61667	274,9833	36,5	332894
2011	112056,1	62,4	21,03333	292,8333	31,95	240417
2012	89605,4	59,36667	22,9	268,1	28,63333	176862
2013	77538,5	58,53333	22,1	289,4	28,8	175857
2014	90393	69,53333	20,75	270,3	73,66667	258568
2015	98406,1	60,41667	21,78333	292,3	47	226573
2016	98828,6	58,6	22,06667	264,5	36,85	222064
2017	100811,4	53,2	21,75	299	54,78333	244655
2018	95450,2	59,25	22,46667	294,4167	35,76667	237136
2019	95049,8	60,75	21,78333	296,65	40,6	249569
2020	90915,5	61,15	21,83333	259,6167	39,36667	240434
2021	107350,8	64,11667	21,43333	254,8333	35,5	285286

4.2.2. Verilen normalize edilmesi

YSA, ANFIS, doğrusal regresyon, karar ağacı yöntemlerinde; kullanılacak değişkenlerin formülleri gereği farklı birimlerde hesaplama işlemi yapılmıştır. Bu maksatla daha yüksek aralıkta farklılık gösteren değişkenlerin uygulamada baskın hale gelmesine neden olacaktır. Bu durum yanıltıcı öngörü neticelerinin elde edilmesine sebep olabilir. Bu maksatla öngürüden elde edilecek başarıyı arttırmak için data setinin normalleştirilmesi istenmektedir (Asadi ve ark., 2012). Bu sebeple Tablo 4.1.'deki verilere denklem 3.1 kullanılarak normalizasyon işlemi uygulanmış ve Tablo 4.2.'ye ulaşılmıştır.

Tablo 4.2. Normalize edilmiş veriler

Tarih	Ekilen Alan (Hektar)	Ortalama Nem (%)	Ortalama Sıcaklık (°C)	Toplam Güneşlenme Süresi (saat/gün)	Ortalama Yağış Miktarı (mm)	Üretim Miktarı (Ton)
1960	0,081833	0,735714	0	0,344484	0,828733	0,038809
1961	0,045602	0,521429	0,254032	0,751493	0,406055	0,021491
1962	0	0,287755	0,419355	1	0,281389	0
1963	0,002733	0,366327	0,395161	0,940661	0,336302	0,007697
1964	0,105415	0,466327	0,120968	0,641179	0,58504	0,065952
1965	0,102862	0,327551	0,181452	0,669056	0,154052	0,065252
1966	0,218975	0,614286	0,330645	0,67045	0,360938	0,124127
1967	0,232101	0,503061	0,258065	0,652927	0,446126	0,140039
1968	0,246554	0,167347	0,512097	0,800478	0,186702	0,092337
1969	0,297505	0,360204	0,310484	0,67503	0,234788	0,193721
1970	0,416	0,336735	0,362903	0,720231	0,356486	0,223485
1971	0,441846	0,55102	0,189516	0,455994	0,831107	0,253413
1972	0,963659	0,478571	0,455645	0,425926	0,591273	0,470018
1973	0,926397	0,489796	0,233871	0,500597	0,146037	0,464449
1974	0,798399	0,384694	0,112903	0,501195	0,300089	0,257928
1975	0,934643	0,734694	0,370968	0,381123	0,956367	0,444102
1976	0,871432	0,410204	0,004032	0,446436	0,22618	0,427059
1977	0,734002	0,356122	0,270161	0,676424	0,594835	0,373522
1978	0,729044	0,744898	0,056452	0,303863	0,567527	0,285792
1979	0,647507	0,505102	0,266129	0,306651	0,256456	0,379661
1980	0,800195	0,706122	0,03629	0,419554	0,542594	0,505756
1981	0,633272	0,290816	0,237903	0,595779	0,06352	0,260922
1982	0,78703	0,571429	0,181452	0,24771	0,254378	0,338364
1983	0,841815	0,588776	0,205645	0,106133	0,701692	0,464406
1984	0,747714	0,618367	0,080645	0,377539	0,368359	0,368483
1985	0,830039	0,47551	0,326613	0,45679	0,194717	0,45147
1986	0,895014	0,317347	0,455645	0,806053	0	0,52835
1987	0,908671	0,52449	0,209677	0,301274	0,279015	0,537241

Tablo 4.2. (Devamı)

Tarih	Ekilen Alan (Hektar)	Ortalama Nem (%)	Ortalama Sıcaklık (°C)	Toplam Güneşlenme Süresi (saat/gün)	Ortalama Yağış Miktarı (mm)	Üretim Miktarı (Ton)
1988	0,988397	0,684694	0,322581	0,043807	0,054912	0,613764
1989	1	0,809184	0,225806	0,20689	0,322944	0,77686
1990	0,944489	0,460204	0,245968	0,371963	0,390027	0,392511
1991	0,698044	0,763265	0,157258	0,083632	0,301276	0,417018
1992	0,861484	0,59898	0,141129	0,283951	0,422974	0,633155
1993	0,818873	0,543878	0,189516	0,428116	0,472544	0,410104
1994	0,786007	0,454082	0,685484	0,581641	0,209558	0,479837
1995	0,862039	0,571429	0,310484	0,52489	0,380528	0,616138
1996	0,825307	0,402041	0,346774	0,612306	0,317305	0,456308
1997	0,840909	0,563265	0,03629	0,364795	0,403087	0,667063
1998	0,856362	0,565306	0,455645	0,546595	0,860196	0,56135
1999	0,998048	0,705102	0,548387	0,764835	0,624814	0,71472
2004	0,673588	0,777551	0,314516	0,397451	0,368062	0,504911
2005	0,701917	0,879592	0,370968	0,47272	0,557435	0,551364
2006	0,718724	0,75	0,435484	0,592593	0,689225	0,638018
2007	0,686198	0,385714	0,673387	0,140581	0,289997	0,491605
2008	0,730802	0,431633	0,576613	0	0,396557	0,532057
2009	0,739758	0,355102	0,528226	0,216647	0,454438	0,585369
2010	0,786416	0,709184	0,689516	0,507965	0,338083	1
2011	0,760989	0,563265	0,548387	0,721227	0,25705	0,714824
2012	0,585682	0,377551	1	0,425727	0,197982	0,518837
2013	0,491457	0,326531	0,806452	0,680207	0,20095	0,515738
2014	0,591832	1	0,479839	0,452011	1	0,770798
2015	0,654403	0,441837	0,729839	0,714855	0,525082	0,672133
2016	0,657702	0,330612	0,798387	0,382716	0,344316	0,658229
2017	0,673185	0	0,721774	0,794902	0,663698	0,727893
2018	0,631322	0,370408	0,895161	0,740143	0,325022	0,704707
2019	0,628195	0,462245	0,729839	0,766826	0,411101	0,743047
2020	0,595912	0,486735	0,741935	0,324373	0,389136	0,714877
2021	0,724248	0,668367	0,645161	0,267224	0,320273	0,853189

4.2.3. Yapay sinir ağıları modelinin oluşturulması

Tablo 4.2.'de yer alan normalleştirilmiş 62 yıllık veri seti yapay sinir ağına aktarılır. Eldeki verilerin %65'i (40 adet) eğitim, %15'i (9 adet) doğrulama ve %20'si (12 adet) test seti için kullanılmıştır. Veri setinin bu şekilde ayrılmasının sebebi, diğer makine öğrenmesi yöntemlerinin tahmin değerleriyle karşılaştırılacak olmasıdır.

Literatürdeki çalışmalarda; ağ tipi olarak çoğunlukla ileri beslemeli geriye yayılım tekniği (Feed-forward backprop) kullanılmış olup, bu tekniğin öncelikle kullanılmak istenilmesinin sebebi; hızlı bir şekilde programlanabilme özelliğine sahip olmasıdır (Cıgızoğlu, 2003; Yakupoğlu ve ark., 2015). Hata azaltma tekniği olarak ortalama karesel hata (MSE) fonksiyonu kullanılmıştır. Geriye kalan tüm parametre değerleri deneme yanılma yoluyla tespit edilmiştir. Tablo 4.3.'te görüldüğü üzere en iyi sonucu birinci sırada bulunan deneme vermiştir. Bu denemenin aktivasyon fonksiyonu Lojistik Sigmoid, eğitim fonksiyonu Trainlm, nöron sayısı 9 ve katman sayısı 3'tür.

Tablo 4.3. YSA algoritmaları kullanılarak elde edilen sonuçlar

Sıra	Nöron sayısı	Eğitim fonksiyonu	Aktivasyon fonksiyonu	Katman sayısı	MSE
1	9	Trainlm	Logsig	3	0,0959
2	8	Trainlm	Tansig	3	0,108
3	10	Trainlm	Logsig	4	0,110
4	8	Trainlm	Tansig	4	0,127
5	11	Trainscg	Logsig	3	0,111
6	9	Trainscg	Tansig	3	0,160
7	9	Trainscg	Logsig	4	0,144
8	8	Trainscg	Tansig	4	0,145
9	10	Traincgf	Logsig	3	0,113
10	8	Traincgf	Tansig	3	0,108
11	8	Traincgf	Logsig	4	0,141
12	9	Traincgf	Tansig	4	0,104
13	9	Trainrp	Logsig	3	0,101
14	9	Trainrp	Tansig	3	0,100
15	9	Trainrp	Logsig	4	0,107
16	10	Trainrp	Tansig	4	0,140

4.3. ANFIS Yöntemi

4.3.1. K-ortalamlar kümeleme yöntemiyle ANFIS üyelik fonksiyonu sayısının belirlenmesi

Literatürde k-ortalamlar ile belirlenen ANFIS alt küme modelinin klasik ANFIS modellerine göre daha az hata değeri (RMSE) verdiği görülmektedir (Saplıoğlu ve Acar, 2020). Bu sebeple girdi değişkenleri (ekilen alan, sıcaklık, nem, yağış miktarı, güneşlenme süresi) kendi içerisinde k-ortalamlar algoritması ile kümelenecektir. Değişkenlerin kümeleneceği sonucunda gerçekleştirilecek ANFIS yönteminde her bir değişkene ait üyelik fonksiyon sayısı belirlenmiş olacaktır. K-ortalama yöntemiyle alt kümesi belirlenen ANFIS modelinin eğitiminde tüm parametrelerin (girdi ve çıktı üyelik fonksiyon tipi, optimizasyon metodu) kombinasyonları deneyerek en az hataya ulaşılabilecektir. Ayrıca ANFIS de oluşturulan klasik modeller genellikle deneme yanılma yöntemi ile yapıldığından çok zaman almaktadır. Bu kapsamda k-ortalamlar ile belirlenen ANFIS alt küme modeli ile zaman tasarrufu sağlanacaktır. K-ortalamlar algoritması kullanılarak elde edilen kümeler Tablo 4.4.'te sunulmuştur.

Tablo 4.4. K-ortalamlar algoritması uygulama sonuçları


	Küme	Küme1		Küme2		Küme3		Küme4		Küme5		Küme6	
		Sayı	E.S	Ort.	E.S	Ort.	E.S	Ort.	E.S	Ort.	E.S	Ort.	E.S
E. Alan	2	12	37987	50	112900	-	-	-	-	-	-	-	-
	3	29	99002	10	31679	23	126660	-	-	-	-	-	-
	4	23	108780	10	31679	12	89039	17	130230	-	-	-	-
	5	25	101700	9	136390	6	21824	7	57492	15	119850	-	-
	6	24	101340	6	21824	9	136390	16	119250	4	46461	3	72200
Nem	2	26	64,3038	36	59,6185	-	-	-	-	-	-	-	-
	3	20	58,5383	27	61,6451	15	65,532	-	-	-	-	-	-
	4	18	58,3944	13	65,6967	15	62,696	16	60,730	-	-	-	-
	5	13	62,8436	16	60,9688	2	54,566	18	58,979	13	65,764	-	-
	6	3	66,6278	24	61,8076	11	64,869	2	54,566	1	69,533	21	59,17
Sıcaklık	2	37	19,7153	25	21,3720	-	-	-	-	-	-	-	-
	3	23	20,4717	15	21,764	24	19,437	-	-	-	-	-	-
	4	10	21,033	22	19,3977	11	21,95	19	20,275	-	-	-	-
	5	13	20,2282	16	19,6573	12	21,926	8	18,997	13	20,878	-	-
	6	12	20,5194	12	19,5931	8	22,085	8	18,997	11	21,239	11	20,01
G. Süresi	2	28	292,43	34	260,10	-	-	-	-	-	-	-	-
	3	15	249,84	23	295,13	24	270,67	-	-	-	-	-	-
	4	15	286,87	14	249,14	12	300,72	21	268,18	-	-	-	-
	5	8	243,40	7	304,45	10	277,96	15	291,54	22	263,65	-	-
	6	5	238,73	10	301,97	14	271,71	11	261,80	16	288,36	6	253,4
Yağış	2	46	34,2870	16	56,5396	-	-	-	-	-	-	-	-
	3	30	38,7144	14	57,8321	18	28,375	-	-	-	-	-	-
	4	31	37,6247	15	27,3889	5	67,786	11	51,427	-	-	-	-
	5	19	30,9509	5	67,7867	24	38,747	11	51,427	3	19,733	-	-
	6	12	40,7583	5	67,7867	12	29,3	3	19,73	11	51,42	19	35,64

E.S: Eleman sayısı Ort: Ortalama

Ulaşılan neticelere göre, homojen dağılım gösteren elemanların ekilen alan için dört küme, nem için dört küme, sıcaklık için altı küme, güneşlenme süresi için iki küme, yağış için üç küme olduğu görülmektedir. Bu sonuçlar dahilinde ANFIS yönteminde kullanılacak bulanık küme: 4 4 6 2 3 olmaktadır. Oluşturulan bu küme ANFIS tasarımındaki üyelik fonksiyon sayısını ifade etmektedir. ANFIS modelinin eğitiminde parametrelerin (girdi ve çıktı üyelik fonksiyon tipi, optimizasyon metodu) tüm varyasyonlarını denemek amacıyla, 4 4 6 2 3 bulanık kümesi oluşturulmuştur.

4.3.2. Veri setinin hazırlanması

Tablo 4.2.'deki normalleştirilmiş veri seti beş girdi bir çıktı olarak ANFIS sistemine girişi sağlanır. Literatürdeki çalışmada veri seti %80 eğitim %20 test olarak ayrılmıştır (Erten ve ark., 2020). Söz konusu 62 yıllık veri setinin %80'i (50) eğitim, %20'si (12) test verisi olarak ANFIS tasarımına aktarılır Şekil 4.1.'de ANFIS tasarımı gösterilmiştir. Uygulamada bulanık çıkarım sistem (FIS) tipi olarak sugeno seçeneği tercih edilmektedir.




Şekil 4.1. Bulanık çıkarım sistemi yapısı

4.3.3. Üyelik fonksiyonunun tipinin ve sayısının belirlenmesi

Her bir girdi elemanına ait üyelik fonksiyonu sayısının belirlenmesi gerekir. İlk iki girdi (ekilen alan, nem) dört üyelik fonksiyonu sayısından, üçüncü girdi (sıcaklık) altı üyelik fonksiyonu sayısından, dördüncü girdi (güneşlenme süresi) iki üyelik fonksiyonu sayısından, son girdi (yağış miktarı) ise üç üyelik fonksiyonu sayısından oluşmaktadır. İlk iki girdinin dilsel ifadeleri; çok düşük, düşük, orta, yüksek olarak belirlenmiştir. Üçüncü girdinin dilsel ifadeleri ise çok düşük, düşük, orta, iyi, yüksek, çok yüksek olarak belirlenmiştir. Dördüncü girdinin dilsel ifadeleri; düşük, yüksek olarak belirlenmiştir. Son girdinin dilsel ifadeleri ise düşük, orta, yüksek olarak tanımlanmıştır.

Şekil 4.2.'de yer alan yağış miktarı değişkenine ait bir grafik oluşturulmuştur. Bu grafikte üyelik fonksiyon sayısı üç olarak belirlenmiştir. Yağış miktarı değişkeninin dilsel ifadeleri düşük, orta, yüksek olarak tanımlanmıştır.




Şekil 4.2. Yağış miktarı üyelik fonksiyon grafiği (gaussmf)

Üyelik fonksiyonu sayısının ve dilsel ifadelerin oluşturulmasının ardından girdi üyelik fonksiyonu tipinin gaussmf, çıktı üyelik fonksiyon tipinin linear ve optimizasyon metodu hybrid belirlenir ve modelin eğitime başlanır.

4.3.4. Modelin eğitilmesi

En küçük kareler yöntemi ile geri yayımlı öğrenme algoritmasının birlikte kullanılmasından melez öğrenme algoritması oluşmaktadır. Söz konusu algoritma yardımıyla eğitim işlemi gerçekleştirilmektedir. Bu işlemlere tahminleme hatasının en düşük değere ulaşmaya kadar devam edilecektir. Şekil 4.3.'te 4 4 6 2 3 kümesine ait eğitim grafiği verilmiştir.



Şekil 4.3. Verilerin eğitimi

4 4 6 2 3 kümesine ait ANFIS uygulamasında 8 adet girdi üyelik fonksiyon tipi, 2 adet çıktı üyelik fonksiyon tipi ve 2 adet optimizasyon metodu kullanılması sonucu toplam 32 adet (8*2*2) kombinasyon elde edilmiştir. Tablo 4.5.'te 32 kombinasyona ait parametreler ve test hata değerleri yer almaktadır.

Tablo 4.5. ANFIS 4 4 6 2 3 kümesine ait tüm varyasyonlar

No	A	B	C	D	E	F	Test hatası
1	trimf	4 4 6 2 3	Constant	100	Hybrid	2,9591e-06	0,10674
2	trapmf	4 4 6 2 3	Constant	100	Hybrid	0,0053312	0,20688
3	gbellmf	4 4 6 2 3	Constant	100	Hybrid	4,5953e-06	0,06621
4	gaussmf	4 4 6 2 3	Constant	100	Hybrid	2,8382e-06	0,06655
5	gauss2mf	4 4 6 2 3	Constant	100	Hybrid	2,9103e-06	0,16023
6	pimf	4 4 6 2 3	Constant	100	Hybrid	0,0053312	0,25204
7	dsigmf	4 4 6 2 3	Constant	100	Hybrid	2,636e-06	0,19878
8	psigmf	4 4 6 2 3	Constant	100	Hybrid	2,636e-06	0,19878
9	trimf	4 4 6 2 3	Linear	100	Hybrid	6,8047e-07	0,078801
10	trapmf	4 4 6 2 3	Linear	100	Hybrid	5,0748e-07	0,2251
11	gbellmf	4 4 6 2 3	Linear	100	Hybrid	8,1502e-07	0,16866
12	gaussmf	4 4 6 2 3	Linear	100	Hybrid	9,5487e-07	0,056954
13	gauss2mf	4 4 6 2 3	Linear	100	Hybrid	6,4174e-07	0,22248
14	pimf	4 4 6 2 3	Linear	100	Hybrid	5,4567e-07	0,25438
15	dsigmf	4 4 6 2 3	Linear	100	Hybrid	4,747e-07	0,25856
16	psigmf	4 4 6 2 3	Linear	100	Hybrid	4,7468e-07	0,25855
17	trimf	4 4 6 2 3	Constant	200	Backpropa	0,19864	0,20187
18	trapmf	4 4 6 2 3	Constant	200	Backpropa	0,074117	0,29598
19	gbellmf	4 4 6 2 3	Constant	400	Backpropa	0,11419	0,14077
20	gaussmf	4 4 6 2 3	Constant	200	Backpropa	0,11144	0,12536
21	gauss2mf	4 4 6 2 3	Constant	500	Backpropa	0,077713	0,27672
22	pimf	4 4 6 2 3	Constant	500	Backpropa	0,047643	0,2315
23	dsigmf	4 4 6 2 3	Constant	600	Backpropa	0,065084	0,13907
24	psigmf	4 4 6 2 3	Constant	600	Backpropa	0,036555	0,16892
25	trimf	4 4 6 2 3	Linear	200	Backpropa	0,095869	0,14454
26	trapmf	4 4 6 2 3	Linear	400	Backpropa	0,032495	0,28149
27	gbellmf	4 4 6 2 3	Linear	400	Backpropa	0,089164	0,13439
28	gaussmf	4 4 6 2 3	Linear	400	Backpropa	0,074255	0,093723
29	gauss2mf	4 4 6 2 3	Linear	400	Backpropa	0,0534	0,20717
30	pimf	4 4 6 2 3	Linear	600	Backpropa	0,029563	0,22642
31	dsigmf	4 4 6 2 3	Linear	600	Backpropa	0,016304	0,22161
32	psigmf	4 4 6 2 3	Linear	600	Backpropa	0,016243	0,2213

Yukarıdaki tabloda 4 4 6 2 3 üyelik fonksiyonuna sahip ANFIS tasarımının tüm varyasyonları bulunmaktadır. Tablo 4.5.'te A girdi üyelik fonksiyon tipini, B girdi üyelik fonksiyon sayısını, C çıktı üyelik fonksiyon tipini, D çevrim sayısını, E optimizasyon metodunu, F hata oranını ifade etmektedir. ANFIS öğrenimi ile ilgili olarak ortalama hata, eğitim ve test hata değerleri hesaplanmaktadır. Çalışmada yalnız test hata değerleri sonuç olarak kabul edilmiştir. Çünkü ANFIS eğitiminde önemli olan ileride gerçekleşecek üretim miktarlarını en az hatayla tahmin etmektir (Phootrakornchai ve Jiriwibhakorn, 2015; Gökler ve Boran, 2020). Tablo 4.5'te görüldüğü üzere en iyi sonucu on ikinci sıradaki yapılan deneme vermiştir. Bu denemenin girdi üyelik fonksiyonu gaussmf, çıktı üyelik fonksiyon tipi linear, optimizasyon metodu hybrid, test hata değeri RMSE ise 0,056954 olarak tespit edilmiştir.

4.4. Doğrusal Regresyon Yöntemi

Doğrusal regresyon algoritmasında kullanılan parametrelerden bazıları Tablo 4.6.'da gösterilmektedir. Özellik seçiminde herhangi bir algoritma tercih edilmemiştir. Nedeni ise tüm değişkenleri doğrusal regresyon analizinde kullanmaktır. Minimum tolerans, programın varsayılan değeri olarak alınmıştır. Toleransın 0'a yaklaşması RMSE ve MSE hata değerlerini etkilememekte, 1'e yaklaştığında ise RMSE ve MSE hata değerlerinin yükseldiği görülmektedir. Regresyon katsayısı programın varsayılan değeri olarak alınmış olup, artırılması halinde RMSE ve MSE hata değerlerinin yükseldiği görülmektedir.

Tablo 4.6. Doğrusal regresyon parametreleri

Parametre	Değer
Özellik seçimi	None (Yok)
Minimum tolerans	0.05
Regresyon katsayısı	1.0e-8

Bu bölümde veri seti kullanılarak doğrusal regresyon tasarımı uygulanmıştır. Veri setini eğitim ve test kümesi olarak ikiye ayırmak için çapraz doğrulama yöntemi kullanılmıştır (Yavuz, 2020). Diğer makine öğrenmesi yöntemlerinin tahmin

değerleriyle karşılaştırmak üzere veri seti çapraz doğrulama tekniğiyle %80 eğitim %20 test seti olarak ayrılmıştır.

4.5. Karar Ağacı Yöntemi

Karar ağacı algoritması için kullanılan parametrelerden bazıları Tablo 4.7.'de gösterilmekle birlikte ağaçtaki bölme işlemi için en küçük kareler yöntemi kullanılmaktadır. Ayrıca veri setinin değerleri sayısal olduğundan, başka bir algoritma kullanıldığında program hata vermektedir. Ağacın derinliğini kısıtlamak için maksimum derinlik kullanılır, 0-20 arasında 21 değer denenerek 10 olarak seçilmiştir. Minimum kazanç, bir düğümün kazancını ifade eder ve düğümlerin bölünmesi kazanç değerlerine bağlıdır. 0-1 arasında 0,001 olarak minimum kazanç değeri seçilmiştir. Minimum yaprak boyutu 2 olarak belirlenmiştir. Minimum yaprak boyutu arttıkça ağaç boyutu küçülmektedir. Uygulanan yöntemde maksimum derinlik düştükçe, minimum kazanç ve minimum yaprak boyutu arttıkça RMSE ve MSE değerlerinin arttığı görülmektedir.

Tablo 4.7. Karar ağacı parametreleri

Parametre	Değer
Kriter	Least square (en küçük kareler yöntemi)
Maksimum derinlik	10
Minimum kazanç	0,01
Minimum yaprak boyutu	2

Bu bölümde veri seti kullanılarak karar ağacı tasarımı uygulanmıştır. Veri setini eğitim ve test kümesi olarak ikiye ayırmak için çapraz doğrulama yöntemi kullanılmıştır. Diğer makine öğrenmesi yöntemlerinin tahmin değerleriyle karşılaştırmak üzere veri seti çapraz doğrulama tekniğiyle %80 eğitim %20 test seti olarak ayrılmıştır.

4.6. Önerilen Modellerin Karşılaştırılması

Yapay sinir ağlarından elde edilen tahmin sonuçları Tablo 4.8.'de, ANFIS yönteminden elde edilen tahmin sonuçları ise Tablo 4.9.'da verilmiştir. Tablo 4.10.'da

doğrusal regresyon tahmin sonuçları, Tablo 4.11.'de ise karar ağacı tahmin sonuçları sunulmuştur. Literatürde yapılan çalışmaların çoğunda tahmin edilen yıllar rastgele seçilmiştir (Şahin ve Erol, 2017; Gökler ve Boran 2020).

Tablo 4.8. YSA tahmin sonuçları

Tarih	Gerçekleşen üretim miktarı	YSA tahmini
1961	15582	39297,054
1965	29773	31771,234
1970	81085	94776,799
1975	152627	255942,17
1980	172620	185863,15
1983	159211	157313,19
1990	135897	194094,40
1995	208415	201874,21
2002	149881	167236,73
2007	168031	239484,4
2012	176862	212512,15
2019	249569	241884,95

Tablo 4.9. ANFIS tahmin sonuçları

Tarih	Gerçekleşen üretim miktarı	ANFIS tahmini
1961	15582	30936,54
1965	29773	17436,71
1970	81085	103818,5
1975	152627	194075,5
1980	172620	153604,5
1983	159211	160240,2
1990	135897	119680,9
1995	208415	217896,2
2002	149881	165700,5
2007	168031	145607,5
2012	176862	178030,4
2019	249569	250372,3

Tablo 4.10. Doğrusal regresyon tahmin sonuçları

Tarih	Gerçekleşen üretim miktarı	Doğrusal regresyon tahmini
1961	15582	25365,77
1965	29773	4587,01
1970	81085	89101,99
1975	152627	233464,9
1980	172620	143705,2
1983	159211	167940,8
1990	135897	177839,8
1995	208415	188843,3
2002	149881	192978,2
2007	168031	201328,3
2012	176862	242770,7
2019	249569	210906,2

Tablo 4.11. Karar ağacı tahmin sonuçları

Tarih	Gerçek üretim miktarı	Karar ağacı tahmini
1961	15582	25599
1965	29773	25599
1970	81085	81111,5
1975	152627	199146,5
1980	172620	127484,8
1983	159211	233132
1990	135897	166026,6
1995	208415	199146,5
2002	149881	197672,7
2007	168031	170036
2012	176862	170036
2019	249569	240895,5

ANFIS, YSA, doğrusal regresyon ve karar ağacı modellerinin performansları RMSE, MSE, MAE, R^2 ile değerlendirilmiştir. Sonuçlar Tablo 4.12.'de sunulmuştur.

Tablo 4.12. Performans deęerlendirme sonuları

İstatistiksel parametreler	YSA	ANFIS	Doęrusal regresyon	Karar aęacı
RMSE	0,1314	0,05695	0,1251	0,10223
MSE	0,017254465	0,003243778	0,015501756	0,01045006
MAE	0,091161352	0,045698399	0,105491046	0,073107231
R ²	0,792272879	0,924989138	0,750041407	0,805365537

Tablo 4.12’de grldę zere ANFIS tasarımınn tahmin sonuları kullanılarak, RMSE deęeri 0,05695, MSE deęeri 0,003243778, MAE deęeri 0,045698399 ve R² deęeri 0,924989138 olarak bulunmuştur. Yukarıda belirtilen deęerlendirme sonularına gre ANFIS modeli dięer makine ęrenmesi yntemlerine gre daha bařarılı sonu vermektedir.

BÖLÜM 5. SONUÇ VE ÖNERİLER

Bu çalışmada makine öğrenme modelleri kullanılarak ayçiçeği üretim miktar tahmini yapılması amaçlanmaktadır. 1960-2021 yılları arasındaki veriler kullanılmak suretiyle Edirne bölgesinin ayçiçeği üretim miktarı tahmin hatası hesaplanmış, girdilerin değişen miktarına göre gelecek yıllara ait üretim miktar tahmini yapılabilecektir. Ayçiçeği ekilen alan büyüklüğü, nem, sıcaklık, güneşlenme süresi, yağış miktarı gibi bağımsız değişkenler esas alınarak, Yapay Sinir Ağları (YSA), Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS), doğrusal regresyon ve karar ağacı modellerinin ayçiçeği üretim miktarı tahmin karşılaştırılması yapılmaktadır. Yapılan uygulamada RMSE 0,05695, MSE 0,003243778, MAE 0,045698399, R^2 0,924989138 performans değerlerine sahip ANFIS tasarımının, diğer makine öğrenmesi yöntemlerinden oluşturulan modellerden daha başarılı olduğu görülmektedir.

Türkiye için öncelikle temel gıda maddesi olarak sayılan ayçiçeğine olan ihtiyacın sürekli karşılanabilmesi için üretim miktarının doğru olarak tahmin edilmesi önem arz etmektedir. Üretim miktarının doğru olarak tahmin edilmesi ile ihtiyaç miktarının belirlenmesi sağlanacaktır. Yapılan çalışmada en iyi sonucu veren ANFIS modeli ile önümüzdeki yıllara ait bağımsız değişkenler kullanılarak, yapılan tahmine göre gelecek yıllara ait ayçiçeği üretim miktarı tespit edilmiş olacaktır. İhtiyaç duyulacak talebin doğru tahmin edilmesiyle birlikte ithalat miktarının doğru belirlenmesi sağlanacaktır. Böylece yurt içi ayçiçeği talebinin zamanında karşılanması mümkün olacaktır.

Dünya ülkelerinde ve Türkiye’de her yıl oluşan orman ve tarla yangınları, sel taşkınları, aşırı yağışların etkileri ekili tarlalarda bulunan bitki tohumlarının oluşmaması veya çürümesi gibi nedenler kıtlığı oluşturacaktır. Öte yandan dünyada baş gösteren ve ardı arkası kesilmeyen salgın hastalıklar, ihtiyacından fazla ayçiçeği

yetiřtiren lkelerde ıkan savařlar gibi yařanan krizler temel gıda maddelerine ulařmada mađduriyet yaratacaktır. Sz konusu temel gıda maddesi olan ayieđi ihtiya krizinin yařanmaması iin retim miktarının dođru olarak tahmin edilmesi gerekmektedir. Talep miktarının da tahmin edilmesiyle birlikte ithalat miktarının dođru belirlenmesi sađlanacaktır. Bylece fazla ithalat yapıp stok oluřturma veya eksik ithal edip talebin karřılanmaması gibi durumlar ortaya ıkmayacaktır.

Ayieđi retim miktarının arttırılması maksadıyla Edirne blgesinde ayieđi retim alanlarına alternatif rnlerle rekabet etmesi (Buđday) yerine geniř alanlarda ayieđi retimine nem verilmelidir. Ayrıca Edirne blgesinde ayieđi retiminde rekoltenin yksek olması iin kuru tarım yerine sulu tarıma geilmelidir. Sz konusu blgede, ayieđi ekiminde sulu tarıma geildiđinde elektrik ve su giderlerin de reticiye yeterli destek verilmelidir. zellikle Edirne ilinde ayieđi ekim blgesinin daha fazla alana yayılması ve ekilmeyen tarla kalmaması iin iftiye fark desteđi daha yksek tutulmalıdır. Ayrıca Edirne blgesinde ekilmeyen kamu arazilerinin ayieđi retimine aılmasına msaade edilmelidir. Arařtırma enstitlerinin yađlık ayieđi retiminde yađ oranı yksek, suya, gbre, gneře anında reaksiyon gsteren ayieđi eřitlerinin yaygınlařtırılarak ıslahına nem vermesi gerekmektedir. Tarım kredi kooperatiflerince ayieđi retimi yapan iftilerimize tohum, gbre, mazot, ila desteđi verilmesi gzden geirilmelidir. Ayrıca kamu bankalarından ayieđi reten iftilere faiz oranı dřk uzun vadeye yayılmış ifti kredi desteđi sađlanması uygun olacaktır.

Tablo 5.1.'de belirtilen ayieđi ithalat deđerini (USD) Ortalama 1 USD satıř fiyatının TL karřılıđı ile arpmamız sonucunda Ayieđi ithalat deđerinin TL karřılıđı elde edilmektedir. Ayieđi ithalat deđerinin TL karřılıđını Ayieđi ithalat miktarına (Ton) blmemiz sonucunda 1 ton ayieđinin ithalat deđeri bulunmaktadır. 1 ton ayieđi ithalat deđeri 5.562 TL iken Yurt iinde 1 ton ayieđinin alıř fiyatı 3.500 TL'dir. Bu durumda ayieđi ithalat miktarı ile yurt ii ayieđi alıř fiyatı karřılařtırıldıđında ton bařına 2.062 TL kar elde edilmektedir. Yukarıda yapılan hesaplamalar dođrultusunda yurt iinde yapılacak ayieđi retimi daha ucuza gelecektir. Bu nedenle yurt ii ayieđi ekimine ađırlık verilmesi gerekmektedir. Tm

bu öneriler sağlandığı takdirde gelecekte ayçiçeği ithalatına gerek kalmayacak ve bu çalışma amacına ulaşmış olacaktır.

Tablo 5.1. Ayçiçeği maliyetleri

Tarih	2020
Ayçiçeği ithalat miktarı (Ton)	892027
Ayçiçeği ithalat değeri (USD)	707.317.000
Ortalama 1 USD satış fiyatının TL karşılığı	7,0234
Ayçiçeği ithalat değerinin TL karşılığı	4.967.770,2178
1 ton ayçiçeği ithalat değeri	792USD / 5.562TL
Yurt içinde 1 ton ayçiçeğinin alış fiyatı	3500TL

KAYNAKLAR

- Aboukarima, A. M., Minyaw, M. 2013. Prediction of Sunflower Crop Yield Using Computer Software Application. *J. Soil Sci. And Agric. Eng., Mansoura Univ*, 4(11): 1257-1272.
- Adelkhani, A., Beheshti, B., Minaei, S., Javadikia, P., Varnamkhasti, M. G. 2013. Taste Characterization of Orange Using Image Processing Combined with ANFIS. *Measurement*, 46(1): 3573-3580.
- Asadi, S. E., Hadavandi, F., Mehmanpazir, M.M., Nakhostin. 2012. Hybridization of Evolutionary LevenbergMarquardt Neural Networks and data Pre-Processing for Stock Market Prediction. *Knowledge-Based Systems*, 35(1): 245-258.
- Andrews, D. F. 1974. A robust method for multiple linear regression, *Technometrics*, 16(4): 523-531.
- Ataseven, B. 2013. Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*, 10(39): 101-115.
- Bayrakçı, H. C., Çiçekdemir, R. S., Özkahraman, M. 2021. Tarım Arazilerinde Harcanan Su Miktarını Yapay Zeka Teknikleri Kullanarak Belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(1): 237-250.
- Breiman, L., Friedman, J.H., Olshen, R.A. 1984. CART: Classification and Regression Trees. *Biometrics*, 40: 358–380.
- Can, Ş., Gerşil, M. 2018. Manisa Pamuk Fiyatlarının Zaman Serisi Analizi Ve Yapay Sinir Ağı Teknikleri İle Tahminlenmesi Ve Tahmin Performanslarının Karşılaştırılması. *Yönetim ve Ekonomi*, 25(3): 1017-1031.
- Crane, A. 2018. Machine learning methods for crop yield prediction and climate change impact assessment in agriculture. *Environmental Research Letters*, 13(11).
- Cıgızoğlu, H.K. 2003. Estimation, forecasting and extrapolation of flow data by artificial neural Networks. *Hydrological Sciences Journal*, 48(3): 349-361.
- Dalton, L., Balalrin, V., Brun, M. 2009. Clustering algorithms: on learning, validation, performance, and applications to genomics. *Current Genomics*, 10(1): 430-445.

- De'ath, G., Fabricius, K. E. 2000. Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology*, 81(11): 3178-3192.
- Diren, D. 2020. Çok deęişkenli kontrol diyagramında kontrol dıőı duruma sebep olan deęişkenlerin topluluk makine öğrenme algoritmaları ile tahmini. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Doktora Tezi.
- Doęan, H. G. 2018. Türkiye’de Fark Ödemesi Desteklerinin Seçilmiş Bazı Tarım Ürünlerinde Etkileri. *Türk Tarım – Gıda Bilim ve Teknoloji Dergisi*, 6(10): 1455-1462.
- Erten, K. M., Terzi, S., Akbulut, H., Eriőkin, E. 2020. ANFIS ve Bulanık Mantık Yöntemlerinin Köpük Bitümün Genleşme Oranı ve Yarılama Süresi Parametreleri Tahmininde Kullanılabilirliğinin Araştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(1): 2388-2399
- Es, H., Kalender, Y., Hamzaçelebi, C. 2014. Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(3): 495-504.
- FAO, 2022. Ülkeler bazında ayçiçeęi üretim miktarlarına ait sayısal veriler. <https://www.fao.org/home/en>, Eriőim Tarihi: 16.03.2022
- Geçit, H. H., Çiftçi, C. Y., Emeklier, H. Y., İkcikarakaya, S., Adak, S., Kolsarıcı, Ö., Ekiz, H., Altunok, S., Sancak, C., Sevimay, C. S., Kendir, H. 2009. Tarla Bitkileri. Ankara Üniversitesi Ziraat Fakültesi Yayınları, 1-521.
- Goyal, M., Gupta, V. 2015. Identification of homogenous rainfall regimes in northeast region on India using fuzzy cluster anlysis. *Water Resources Management*, 28(1): 4491-4511.
- Gökler, S. H., Boran, S. 2020. PCA Esaslı Hibrit ANFIS-Taguchi Yöntemi ile Kan Bankası için Talep Tahmini. *Biliőim Teknolojileri Dergisi*, 13(3): 225-233.
- Gül, M., Çelik, E. 2017. ANFIS kullanılarak Tunceli ili için global güneő radyasyonu tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 8(4): 891-899.
- Gül, A., Öztürk, E., Polat, T. 2016. Günümüz Türkiye’sinde Bitkisel Yaę Açıęını Kapatmada Ayçiçeęinin Önemi, *Alinteri Ziraat Bilimler Dergisi*, 30 (1): 70-76.
- Gündüz, O. 2021. Türkiye’de Ayçiçek Yaęı Fiyatı Niçin Artıyor ? Kısa ve Uzun Dönem Dinamik Analizi. *Gaziosmanpaőa Bilimsel Araştırma Dergisi*, 10(1): 30-48.
- İncekara, F. 1979. Endüstri Bitkileri ve Islahı, 2.Cilt. Ege Üniversitesi Ziraat Fakültesi Yayınları, 1-180.

- Ismail, F. H., Aziz, M. A., Hassanien, A. E. 2015. Optimizing the parameters of Sugeno based adaptive neuro fuzzy using artificial bee colony: A Case study on predicting the wind speed. *Proceedings of the Federated conference on Computer Science and Information Systems*, 8(1): 645-651.
- Işık, H., Şeker, M. 2021. Yapay Sinir Ağı (YSA) Kullanarak Farklı Kaynaklardan Türkiye’de Elektrik Enerjisi Üretim Potansiyelinin Tahmini. *Computer Science, 5th International Artificial Intelligence and Data Processing symposium*, 304-311.
- Jain, N., Kumar, A., Garud, S., Pradhan, V., Kulkarni, P. 2017. Crop Selection Method Based on Various Environmental Factors Using Machine Learning. *International Research Journal of Engineering and Technology*, 4(2): 56-72.
- Jang, J. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE*, 23(3), 665-685.
- Kakilli, S., Ergüven, O. C. 2015. Yağlı Tohumlar ve Bitkisel Yağ Sektörünün Finansal Analizi: Hatay İlinde Bir Uygulama. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12 (29): 259.
- Kalaycı, E. 2020. ANFIS ile Doğalgaz Talep Tahmini; Türkiye Örneği. *Uluslararası Sosyal Bilimler Akademi Dergisi*, 2(3): 495-511.
- Kalichkin, V. K., Alsova, O. K., Maksimovich, K. Y. 2021. Application Of The Decision Tree Method For Predicting The Yield Of Spring Wheat. *IOP Conference Series: Earth and Environmental Science*, 839, 032042.
- Karahan, M. 2015. Yapay Sinir Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi. *Ege Akademik Bakış*, 15(2): 165-172.
- Kouchakzadeh, M., Khashei-Siuki, A., Ghahraman, B. 2011. Predicting Dryland Wheat Yield from Meteorological Data Using Expert System, Khorasan Province, Iran. *J. Agr. Sci. Tech*, 13(1): 627-640.
- Kumaş, K., Ayan, M., Akyüz, A., Güngör, A. 2019. Antalya İli Meteorolojik Verileri Yardımıyla Hava Sıcaklığının Yapay Sinir Ağları Metodu ile Tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 10(1): 146-154.
- Kuncheva, L. 2004. *Combining Pattern Classifiers Methods and Algorithms*, Wiley - Interscience, 1.baskı, 68.
- Leng, G., Hall, J. 2020. Predicting spatial and temporal variability in crop yields: an inter-comparison of machine learning, regression and process-based models. *Environmental Research Letters*, 15, 044027.
- Lewis, R. J. 2000. An introduction to classification and regression tree (CART) analysis. İçinde: Annual meeting of the society for academic emergency medicine in San Francisco, California, 14.

- Mishra, S., Mishra, D., Santra, G. 2016. Applications of Machine Learning Techniques in Agricultural Crop Production: A Review Paper. *Indian Journal of Science and Technology*, 9(38).
- Özel, A., Büyükyıldız, M. 2019. Aylık buharlaşma tahmininde yapay zeka yöntemlerinin kullanılabilirliği, *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 8(1): 244-254.
- Özmen, S., Gülbandılar, E. 2020. İris Çiçeği Türünün YSA Yöntemleri ve ANFIS ile Tahmini. *ESTUDAM Bilişim Dergisi*, 1(1): 5-11.
- Öztemel, E. 2006. *Yapay Sinir Ağları*, 1.Cilt. Papatya Yayınları, 1-230.
- Paudel, D., Boogaard, H., de Wit, A., Janssen, S., Osinga, S., Pylaniadis, C., Athanasiadis, I. 2021. Machine learning for large-scale crop yield forecasting. *Agricultural Systems*, 187(1).
- Phootrakornchai, W., Jiriwibhakorn, S. 2015. Online critical clearing time estimation using an adaptive neuro-fuzzy inference system (ANFIS). *Int J Elec Power*, 73: 170-181.
- Sabancı, K. 2013. Şeker pancarı tarımında yabancı ot mücadelesi için değişken düzeyli herbisit uygulama parametrelerinin yapay sinir ağlarıyla belirlenmesi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Tarım Makineleri Anabilim Dalı, Doktora Tezi.
- Saplıoğlu, K., Senel, F., Küçükerdem, T. 2019. ANFIS ile Yapılan Modellemelerin Alt Modellere Bölünmesi ve Bu modellerin Alt Küme Sayılarının Belirlenmesinde K-Means Algoritmasının Kullanılması: Eksik Akış Verisi Tamamlama Örneği. *International Symposium on Innovations in Civil Engineering and Technology*, 2(1): 624-632.
- Saplıoğlu, K., Acar, R. 2020. K-Means Kümeleme Algoritması Kullanılarak Oluşturulan Yapay Zeka Modelleri ile Sediment Taşınımının Tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1): 306-322.
- Sarıman, G. 2011. Veri madenciliğinde kümeleme teknikleri üzerine bir çalışma: K-means ve k-medoids kümeleme algoritmalarının karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(1): 192-202.
- Semerci, A., Durmuş, E. 2021. Türkiye’de Yağlık Ayçiçeği Üretiminin Analizi. *Türk Tarım – Gıda Bilim ve Teknoloji Dergisi*, 9(1): 56-62.
- Sowmya, S., Sri, Meghana, J., Latha, P. 2020. Machine Learning Approach For Forecasting Crop Yield Based On Climatic Parameters. *Journal of Composition Theory*, 13(5): 9-11.
- Sungur, C., Altun, A. A. 2010. Konya Bölgesinde Don Olaylarına Karşı Mistleme Sisteminin Yapay Sinir Ağları İle Modellenmesi. *Selçuk Tarım ve Gıda Bilimleri Dergisi*, 24(4): 70-75.

- Suraparaju, V. 2016. Soybean Productivity Modelling using Decision Tree Algorithms. *International Journal of Computer Applications*, 27(1): 11-15.
- Şahin, M., Erol, R. 2017. A comparative study of neural networks and ANFIS for forecasting attendance rate of soccer games. *Math Comput Appl.*, 22(43).
- Şahin, S. 2019. Ayçiçeği hibritlerinde kuraklığa dayanımın bazı morfolojik ve biyolojik ölçütlerden yararlanarak belirlenmesi. Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Biyoteknoloji ve Genetik Anabilim Dalı, Yüksek Lisans Tezi.
- Şenel, F. A. 2020. Makine Öğrenmesi Algoritmaları Kullanılarak Kayısı İç Çekirdeklerinin Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(2): 807-815.
- Tan, A. Ş. 2007. Ayçiçeği Tarımı, Ege Tarımsal Araştırma Enstitüsü Müdürlüğü Çiftçi Broşürü No:136
- Taşar, B., Üneş, F., Demirci, M., Kaya, Y. 2017. Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1): 543-551.
- Tiryaki, B. 2008. Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks, and regression trees. *Engineering Geology*, 99(1-2): 51-60.
- Top, B. T., Uçum, İ. 2012. Türkiye’de bitkisel yağ açığı. *Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü*, 14(2): 1-8.
- Turhal, K., Turhal, Ü. Ç. 2014. Yapay Sinir Ağları ile Süne Zararlısının Buğday Danesi Üzerindeki Etkilerinin Belirlenmesi. *Trakya University Journal of Natural Sciences*, 15(1): 25-30.
- TÜİK, 2022. Ayçiçeği üretim miktarı, ekilen alan büyüklüğü, ithalat miktarı ve değeri, ihracat miktarı ve değeri gibi yıllar bazında sayısal veriler. <https://biruni.tuik.gov.tr/medas/?locale=tr>, Erişim Tarihi: 16.03.2022
- Vega, F. A., Matías, J. M., Andrade, M. L., Reigosa, M. J., Covelo, E. F. 2009. Classification and regression trees (CARTs) for modelling the sorption and retention of heavy metals by soil. *Journal of Hazardous Materials*, 167(1-3): 615-624.
- Yadav, M., Yadav, A., Kumar N. 2015. *An Introduction to Neural Network Methods for Differential Equations*, Springer.
- Yakupoğlu, T., Şişman, A. Ö., Gündoğan, R. 2015. Toprakların Agregat Stabilitesi Değerlerinin Yapay Sinir Ağları ile Tahminlenmesi. *Türkiye Tarımsal Araştırmalar Dergisi*, 2(2): 83-92.

- Yavuz, E. 2020. Konutlarda enerji tüketimi kestirimi için derin öğrenme ve makine öğrenme yöntemlerinin karşılaştırılması. İstanbul Üniversitesi, Cerrahpaşa Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Yazıcı, K. 2021. Makine öğrenmesi yöntemleri kullanılarak kısa dönem rüzgar gücü tahmini. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Yıldırım, D., Cemek, B., Küçüktopçu, E. 2019. Bulanık Yapay Sinir Ağları ve Çok Katmanlı Yapay Sinir Ağları ile Günlük Buharlaşma Tahmini. Toprak Su Dergisi, 24-31.
- ZMO, 2022. Türkiye'nin tarım politikasıyla ilgili bir yazı. https://www.zmo.org.tr/genel/bizden_detay.php?kod=36493&tipi=24&sube=0 Erişim Tarihi: 15.05.2022
- Zhang, G., Patuwo, B., Hu, M. 1998. Forecasting with Artificial Neural Networks: The State of the Art. International Journal of Forecasting, 14(1): 35-62.
- Xu, R., Wunsch, D. 2005. Survey of clustering algorithms. IEEE Transactions on Neural Networks, 16(3): 645-678.

ÖZGEÇMİŞ

Adı Soyadı : Olcay EYDEMİR

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	Devam ediyor
Lisans	Sakarya Üniversitesi / Bilgisayar ve Bilişim Bilimleri Fakültesi / Bilgisayar Mühendisliği	2019
Lisans	Sakarya Üniversitesi / Mühendislik Fakültesi / Endüstri Mühendisliği	2018
Lise	İlhami Ertem Anadolu Lisesi	2011

YABANCI DİL

İngilizce

ESERLER (makale, bildiri, proje vb.)

1. Cil, I., Çakar, G. S., Sarı, N., Eydemir, O. 2019. İkili Kümeleme Yaklaşımıyla Suç Bölgelerinin Tespiti ve İkili Kümeleme Yöntemlerinin Karşılaştırılması. Sakarya University Journal of Computer and Information Sciences, 2(3): 145-157.
2. Boran, S., Eydemir, O. 2022. Ayçiçeği Üretim Miktarının ANFIS Metodu ile Tahmini. Ekonomi ve Finansal Araştırmalar Dergisi, 4(1): 46-55.