



Journal of Economics and Financial Researches, 2022, 4(1): 46-55

Ayçiçeği Üretim Miktarının ANFIS Metodu ile Tahmini*

Olca EYDEMİR^a & Semra BORAN^b

Öz

Son yıllarda Türkiye’de en önemli yağ bitkisi olan ayçiçeği üretiminin az, tüketimin çok olması nedeniyle ihtiyacı karşılamak için yurt dışından temin edilmektedir. 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. Çalışmada ayçiçeği üretim miktarını tahmin etmek için makine öğrenme yöntemlerinden ANFIS yöntemi kullanılmıştır. ANFIS modelinin öğrenme kabiliyetini arttırmak amacıyla K-ortalamlar algoritması ile girdi değişkenlerinin üyelik fonksiyon sayıları belirlenmiştir. ANFIS modelinde ekilen alan, nem, sıcaklık, güneşlenme süresi ve yağış miktarı gibi kriterlere göre ayçiçeği üretim miktarı tahmin edilmesi sağlanmıştır. Bu model Edirne bölgesinde uygulanmış ve 0,003243778 hata (MSE) ile tahmin sağlanmıştır. Böylece ANFIS modeliyle girdilerin değişen miktarına göre gelecek yıllar için üretim miktarı tahmin edilebilecektir.

Anahtar

Kelimeler:

Ayçiçeği Üretim Tahmini, Makine Öğrenmesi, K-ortalamlar, ANFIS Metot.

JEL

Sınıflandırması:

C45, C88, S19

Prediction of Sunflower Production Amount by ANFIS Method

Abstract

Sunflower, the most important oil crop plant in Turkey, In recent years, has decreased in production, and as a result of the increase in consumption, it has come to be imported in recent years. Especially in terms of satisfying the need for oils, it is essential to calculate the need so that it can be imported accordingly. In this study, ANFIS, a machine learning method, has been employed to estimate the quantity of production of sunflower. To increase the learning capacity of ANFIS, the input variables' membership functions have been specified via K-means clustering. The estimated production has been calculated in accord with the cultivated area, humidity, temperature and the duration of insolation and the amount of rainfall. This model has been applied to Edirne and the estimation has been reached with a mean squared error of 0,003243778. Thus, it is to be possible to estimate the amount of production in following years depending on the changing amounts of inputs.

Keywords:

Sunflower Production Forecasting, Machine Learning, K-means, ANFIS Method.

JEL

Classification:

C45, C88, S19

* Bu çalışma Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Yüksek Lisans Programı’nda yapılan tez çalışmasından türetilmiştir.

^a Yüksek Lisans Öğrencisi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Yüksek Lisans Programı, olcayeydemir@gmail.com, ORCID: 0000-0002-7119-344X

^b Prof. Dr., Sakarya Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, boran@sakarya.edu.tr, ORCID: 0000-0002-0532-937X

1.Giriř

Ayçiçeęi yaęlı tohumlu bitkiler ierisinde; ekonomik olarak en ok ne ıkan bitkilerden biridir. İerięindeki yaę oranı yaklaşık % 50 olup, doymamıř yaę asitlerini barındırmaktadır. Yaęı ıkarıldıktan sonra geriye kalan ks pesi hayvan beslenme mamullerinde kullanılmaktadır. Ayrıca; sapı ve tablaları yakacak, gbre takviyesi, ss bitkisi gibi kullanım alanlarına sahiptir (İncekara, 1979; Geit vd., 2009). Tohumları kavrulup tk etilmesinin yanında i dane olarak da doęrudan veya unlu mamullere (kek, ekmek vb.) katılarak tk etilmektedir (řahin, 2019).

Yaęlı tohum retimi, ekonomiye yaratmıř olduęu artı katkısından dolayı byk nem arz etmektedir. Dnyada kendi tk etim ihtiyacından, daha fazla yaęlı tohum reten lkeler, finansal kazanç saęlarken dnyada; gıda krizinin yařandığı bu gnlerde, ihtiya duyduęu yaęlı tohumu ithal eden lkeler ise yaę retiminde ciddi anlamda ok zor duruma dřmektedir (Kakilli Acaravcı ve Ergven, 2015).

Ayçiçeęi, Trakya, Ege Blgesi ve Karadeniz Blgesi olmak zere birok blgemizde yetiřtirilmektedir. Ancak ayçiçeęinin retim miktarı i talebi karřılayamadığı iin dıř lkelerden satın alma yoluna gidilmektedir (Gl vd., 2016). Yılda n yıla artıř gsteren bitkisel yaę aıęımız 500 bin tonu ařmıřtır. Son yıllarda dnyada bař gsteren salgın hastalık ve ayçiçeęini ihtiyatan fazla yetiřtiren lkelerde savař ıkması nedeniyle; tedarik zincirinde ok byk aksamalar yařanmasına neden olmuřtur.

Literatrde ayçiçeęi retimiyile ilgili tahminlerde bulunmak amacıyla, birka alıřma yer almaktadır. Trpos vd. (2020) hasattan birka hafta nce simlasyon ve zaman serisi gibi yntemlerle tahıl toplama ve depolama faaliyetlerini optimize etmek amacıyla ayçiçeęi tane verimi tahmininde bulunmuřlardır. Semerci ve zer (2011) zaman serisi ve quadratik tipi fonksiyon kullanılarak, Trkiye'nin ayçiçeęi ekim alanı, retim miktarı ve verim deęerleri ile ilgili olası tahminlerde bulunmuřlardır. Yerdelen vd., (2008) nce Coęrafi Bilgi Sistemleri ve Uzaktan Algılama Yntemleri kullanarak, Edirne ilindeki ayçiçeęi retim alanını belirlemiřler ve daha sonra agrometeorolojik simlasyon modeli ile verim tahmini yapmıřlardır.

Bu alıřmada yıllık ayçiçeęi retim miktarının tahmin edilmesi amalanmaktadır. Tahminlerin doęruluęu talebin srekli karřılanması aısından talebin tahmini kadar nemlidir. İthalat miktarı talep ve yurt ii retim miktarının farkı ile belirlenecektir. İthalat miktarının fazla olması gereksiz stoklara az olması ise talebin karřılanamamasına neden olacaktır.

Ayçiçeęi retim miktarını tahmin etmek amacıyla istatistiksel ve makine ęrenmesi yntemlerinden yararlanılabilir. Literatrdeki alıřmalarda daha ok istatistiksel yntemlerin kullanıldığı grlmektedir. Ancak makine ęrenmesi yntemlerinin veriler arasındaki bilinmeyen iliřkileri kolayca belirleyebilme ve eksik verilerle tahmin yapabilme gibi stn zellikleri vardır. Yapılan alıřmalar makine ęrenmesi yntemlerinin istatistiksel yntemlere gre daha iyi sonular verdięini gstermektedir (Can ve Gerřil, 2018). Bu alıřmada yaygın olarak kullanılan makine ęrenme yntemlerinden Adaptif Aę

Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS) yöntemi hızlı öğrenme kapasitesine ve uyum yeteneğine sahip olması nedeniyle kullanılmıştır.

ANFIS yönteminin tarımsal ürünlerle ilgili tahmin yapmada kullanıldığı birkaç çalışma literatürde yer almaktadır. Aboukarima ve Minyawı (2013) Mısır ülkesinde yetiştirilen ayçiçeği tohum verimini tahmin etmek için ANFIS modeli kullanmışlardır. Bağımsız değişkenler ayçiçeği tabla çapı, tabla kısmındaki tohum sayıları, tohum nem içeriği ve hasat öncesi kayıplardır. Bağımlı değişken ise ayçiçeği tohumu verimidir. Kouchakzadeh vd. (2011) sıcaklık, yağış, net radyasyon ve nem değişkenlerini esas alarak buğday verimini Yapay Sinir Ağı (YSA) ve ANFIS yöntemleri ile tahmin etmişler ve ANFIS modelinin YSA modeline göre daha başarılı sonuçlar verdiğini göstermişlerdir.

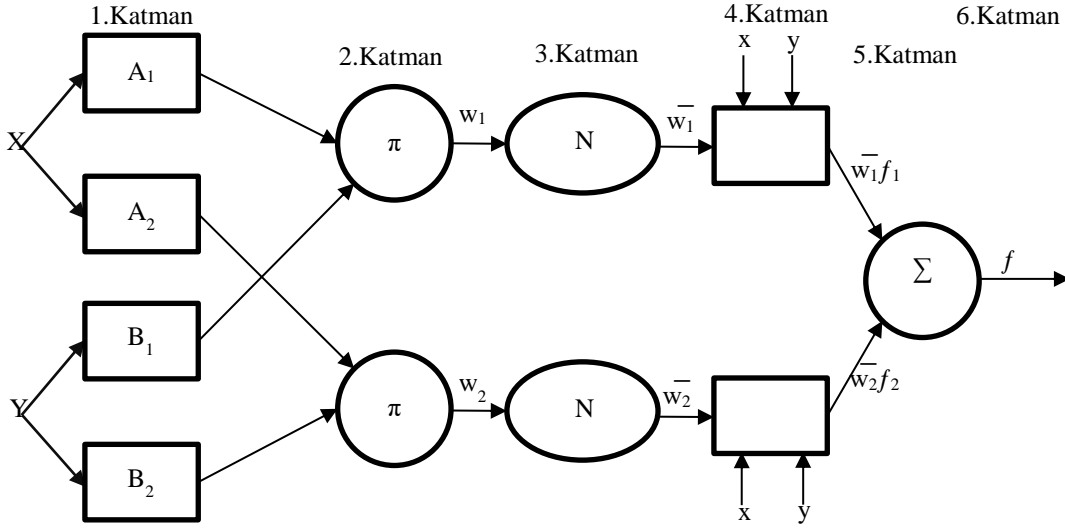
Literatürdeki çalışmalardan farklı olarak bu çalışmada ANFIS modeli geliştirerek ayçiçeği üretim miktarının, ekilen arazi, nem, sıcaklık, yağmur ve güneşlenme süresi gibi 5 bağımsız değişken esas alınarak tahmin edilmesi amaçlanmaktadır. Model Edirne ilinin ayçiçeği üretim miktarı tahmini amacıyla uygulanmıştır. Edirne ili ayçiçeği yetiştirilmesinde uygun koşullara sahip olması nedeniyle üretim miktarı açısından 2021 yılı baz alındığında; 1.073.508 dekar ekili alandan 285.286 ton üretim ile Tekirdağ ve Konya ilinden sonra üçüncü sırada yer almaktadır (TÜİK, 2022). Edirne bölgesinde yapılan uygulamada 0,003243778 MSE değerine sahip ANFIS modelinin çok düşük hata ile tahmin yapabileceği değerlendirilmektedir.

Bu çalışma dört bölümden oluşmaktadır. Giriş bölümünden sonra ikinci bölümde kullanılan yöntemler açıklanmıştır. Üçüncü bölümde yapılan uygulamayla ilgili olarak analiz sonuçlarına yer verilmiştir. Dördüncü bölümünde genel bir değerlendirme yapılarak çalışma sonlandırılmıştır.

2. Yöntemler

2.1. ANFIS

Jang (1993) tarafından geliştirilen ANFIS, yapay sinir ağları ve bulanık mantık çıkarım sisteminin bileşiminden oluşan bir metottur. ANN'nin öğrenme yeteneği ve modelin eğitim sürecinde geliştirilen eğer-ise kuralları ile bulanık mantık özelliklerini içerir. 2 girdi, 1 çıktı ve 2 kuraldan oluşan ANFIS yapısı Şekil 1'deki gibidir.



Şekil 1. 2 Girdi, 1 Çıktı ve 2 Kuraldan Oluşan Örnek Bir ANFIS Yapısı
Kaynak: Hmouz vd. (2012)

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

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

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

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

Burada A ve B, x ve y üyelik fonksiyonları için tanımlanmış öncü bölümdeki bulanık kümeler; p, q ve r ise uç değişkenlerdir. Model aynı katmandaki nöronların aynı fonksiyon ailesinden olduğu altı katman içerir.

1. Katman (girdi): Katman tüm uyarlanabilir düğümleri içerir. Her bir düğümün girdisi üyelik fonksiyonudur ve düğüm çıkışı, 0, Eşitlik 3 ve 4'teki gibi hesaplanır.

$$O_{1,i} = \mu A_i(x), i = 1,2 \quad (3)$$

$$O_{1,i} = \mu B_{i-2}(y), i = 1,2 \quad (4)$$

Burada x ve y, i düğümü için girdi, A ve B bu düğüm fonksiyonu ile ilgili düşük, orta ve 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): Girdiler bulanıklaştırılır ve modelde π olarak tanımlanır.

3.Katman (Kural): 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 edilmesi ise, (j=1,2) ve (i=1,...,n) olmak üzere,

$$\Pi_i = \mu A_j(x) \times \mu B_i(y) = \mu_i \quad (5)$$

şeklinde dir. Buradaki n 3.katmandaki düğüm sayısını ifade etmektedir.

4. Katman (Normalizasyon): Üçüncü katmandan gelen bütün düğümleri giriş değeri olacak şekilde kabul edilerek her bir kaidenin normalleştirilmiş ateşleme düzeyi bulunur. Normalleştirilmiş ateşleme seviyesi $\bar{\mu}$ aşağıdaki Eşitlik 6 ile hesaplanır.

$$N_i = \frac{\mu_i}{\sum_{i=1}^n \mu_i} = \bar{\mu} \quad , (i = 1, n) \quad (6)$$

5. Katman (Durulaştırma): Her bir düğümde verilen bir kuralın ağırlıklandırılmış sonuçları hesaplanır.

6. Katman (Çıktı): Bu katmanda yalnız bir düğüm vardır. Sistemin çıktı değeri olan y Eşitlik 7 ile bulunur.

$$y = \sum_{i=1}^n \bar{\mu} [p_i x_1 + q_i x_2 + r_i] \quad (7)$$

2.2. K-ortalamlar

K-ortalamlar en fazla tercih edilen kümeleme yöntemidir. Veri kümesini k tane kümeye bölünmesini sağlar. Öngörülen küme adedi kadar, küme içinden rastgele veriler alınır. Bu veriler kümelerin merkez noktalarıdır. Veri kümesindeki verilerin her biri, bu merkeze olan uzaklıkları ile kümeye katılırlar. Uzaklıkların hesaplanmasında Eşitlik 8 kullanılır (Goyal ve Gupta, 2014; Saplıoğlu ve Acar, 2020).

$$X = \sum_{j=1}^k \sum_{i=1}^M |Y_i^{(j)} - C_j|^2 \quad (8)$$

Burada X uzaklığı, Y eleman sayısını, C küme merkezini, i veri sayısını, j küme sayısını göstermektedir. Sonraki adımda bütün değerlerin ağırlığı alınır, kümelerin merkez noktaları yeniden hesaplanır (Eşitlik 9). Kümelerin merkez noktalarında bir değişiklik olana kadar işlem yapmaya devam edilir. Kümeler arası geçiş yok ise işlemler sona erdirilir (Xu ve Wunsch, 2005; Saplıoğlu vd., 2019).

$$Z_j = 1/n_j \sum_{v Y_p \in C_j} Y_p \quad (9)$$

Burada Z kümelerin ağırlık merkezlerinin yeniden hesaplanmasını tanımlar. Bu yöntemde, küme elemanlarının birbirine yakın olması, kümeler arasındaki aralığın oldukça birbirinden uzak olması istenir. Küme sayısı da bu özelliği sağlayacak şekilde belirlenir (Dalton vd., 2009; Saplıoğlu vd., 2019).

2.3. Performans Kriterleri

ANFIS yönteminin test aşamasında elde edilen üretim tahmin sonuçları ile orijinal tahmin sonuçları verilerini karşılaştırma kriteri olarak ortalama hata karesi karekökü (RMSE), ortalama hata karesi (MSE), ortalama mutlak hata (MAE) ve belirlilik katsayısı R² esas alınır.

$$RMSE = \frac{1}{n} \sum_{i=1}^n \sqrt{(f_i - f_i^*)^2} \quad (10)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - f_i^*)^2 \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - f_i^*| \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (f_i - f_i^*)^2}{\sum_{i=1}^n (f_i - \bar{f}_i)^2} \quad (13)$$

Eşitlik 10-13 f_i i'inci veriye ait tahmin değerini, f_i* i'inci yıla ait gerçekleşen değerini ve f_i i'inci veriye ait ortalama tahmin değeri göstermektedir.

3. Uygulama

3.1. Veri Setinin Oluşturulması

Ayçiçeği üretim miktarı tahmini modelinde 5 girdi değişkeni literatürdeki çalışmalardan belirlenmiştir (Mishra vd., 2016; Jain vd., 2017; Paudel vd., 2021). Ekilen alan üretim yapılan tarım arazisidir. Sıcaklık ekilen tarım arazilerinin güneşten edindiği ısı miktarıdır. Nem ise havada bulunan su buharıdır. Yağış havadaki su buharının sıvı olarak yeryüzüne inmesidir. 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. Veriler 1960-2021 yıllarını içermektedir (Tablo 1).

Tablo 1. Veri Seti (1960-2021)

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
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

Kaynak: https://biruni.tuik.gov.tr/medas/?locale=tr_, <https://mgm.gov.tr/>

3.2. Veri Setinin Normalleştirilmesi

Tahmin doğruluğunu arttırmak için farklı birimlerle tanımlanan girdi değişkenleri Eşitlik 14 ile normalleştirilir (Asadi vd., 2012). Normalleştirilmiş veriler Tablo 2’de yer almaktadır.

$$X_{\text{normal}} = \frac{X - X_{\text{asgari}}}{X_{\text{azami}} - X_{\text{asgari}}} \quad (14)$$

Tablo 2. Normalize Edilmiş Veriler (1960-2021)

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
.....						
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

3.3. K-ortalamlar Kümeleme Yöntemiyle ANFIS Üyelik Fonksiyonu Sayısının Belirlenmesi

K-ortalamlar yöntemi uygulanarak modelin öğrenmesinde hatayı azaltmak amacıyla ekilen alan için dört küme, nem için dört küme, sıcaklık için altı küme, güneşlenme süresi için iki küme, yağış için üç küme bulunmuştur.

3.4. ANFIS Yönteminin Uygulanması

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 denenerek en az test hatası 0,056954 veren kombinasyon girdi üyelik fonksiyonu gaussmf, çıktı üyelik fonksiyon tipi linear, optimizasyon metodu hybrid elde edilmiştir. ANFIS modeline ait performans değerlendirme sonuçları Tablo 3’te verilmiştir. Tabloda belirtilen değerlendirme sonuçlarına göre k-ortalamlar yöntemiyle üyelik fonksiyon sayısı belirlenen ANFIS modelinin başarılı sonuçlar verdiği görülmektedir.

Tablo 3. Performans Deęerlendirme Sonuları

	RMSE	MSE	MAE	R ²
ANFIS	0,05695	0,003243778	0,045698399	0,924989138

4. Sonu

Türkiye için öncelikle temel gıda maddesi olarak sayılan ayieęine olan ihtiyacın sürekli karřılanabilmesi için üretim miktarının doęru olarak tahmin edilmesi önemlidir. Doęru tahmin edilmesi ile ithal edilecek miktar doęru belirlenecektir. ok düşük hata oranı veren ANFIS modeli ile gelecek yıllara ait baęımsız deęiřkenler kullanılarak, yıllık doęru tahminler elde edilmekte kullanılacaktır. Talebin doęru tahmin edilmesiyle birlikte ithalat miktarının doęru belirlenmesi saęlanacaktır. Böylece yurt ii ayieęi talebinin zamanında ve sürekli karřılanması mümkün olacaktır.

Arařtırma ve Yayın Etięi Beyanı

Etik kurul izni ve/veya yasal/özel izin alınmasına gerek olmadan bu alıřmada arařtırma ve yayın etięine uyulmuřtur.

Arařtırmacıların Katkı Oranı Beyanı

Yazarlar, makaleye katkı oranlarının yazar sıralamasına göre sırasıyla %90 ve %10 olduęunu beyan eder.

Arařtırmacıların ıkar atıřması Beyanı

Bu alıřmada herhangi bir potansiyel ıkar atıřması bulunmamaktadır.

Kaynakça

- Aboukarima, A. and Minyaw, M. (2013). Prediction of sunflower crop yield using computer software application. *Journal of Soil Sciences and Agricultural Engineering*, 4(11): 1257-1272.
- Can, Ş. ve Gerşil, M. (2018). Manisa pamuk fiyatlarının zaman serisi analizi ve yapay sinir ağı teknikleri ile tahminlenmesi ve tahmin performanslarının karşılaştırılması. *Yönetim ve Ekonomi*, 25(3): 1017-1031.
- Dalton, L., Balalrin, V. and Brun, M. (2009). Clustering algorithms: On learning, validation, performance, and applications to genomics. *Current Genomics*, 10(1): 430-445.
- Geçit, H.H., Çiftçi, C. Y., Emeklier, H.Y., İkincikarakaya, S., Adak, S., Kolsarıcı, Ö., Ekiz, H., Altunok, S., Sancak, C., Sevimay, C.S. ve Kendir, H. (2009). *Tarla Bitkileri*. Ankara: Ankara Üniversitesi Ziraat Fakültesi Yayınları.
- Goyal, M. and Gupta, V. (2015). Identification of homogenous rainfall regimes in northeast region on India using fuzzy cluster analysis. *Water Resources Management*, 28(1): 4491-4511.
- Gül, A., Öztürk, E. ve Polat, T. (2016). Günümüz Türkiye'sinde bitkisel yağ açığını kapatmada ayçiçeğinin önemi. *Alın Teri Ziraat Bilimler Dergisi*, 30(1): 70-76.
- Hmouz, A., Shen, J., Al-Hmouz, R. and Yan, J. (2012). Modeling and simulation of an adaptive neuro-fuzzy inference system (ANFIS) for mobile learning. *IEEE Transactions on Learning Technologies*, 5(3): 226-237.
- İncekara, F. (197). *Endüstri bitkileri ve ıslahı* (2. Cilt). İzmir: Ege Üniversitesi Ziraat Fakültesi Yayınları.
- Jain, N., Kumar, A., Garud, S., Pradhan, V. and Kulkarni, P. (2017). Crop selection method based on various environmental factors using machine learning. *International Research Journal of Engineering and Technology*, 4(2): 1530-1533.
- Jang, J. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3): 665-685.
- Kakilli, S. ve Ergüven, O.C. (2015). Yağlı tohumlar ve bitkisel yağ Sektörünün finansal analizi: Hatay ilinde bir uygulama. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12(29): 258-282.
- Kouchakzadeh, M., Khashei-Siuki, A. and Ghahraman, B. (2011). Predicting dryland wheat yield from meteorological data using expert system, Khorasan Province, Iran. *Journal of Agricultural Science and Technology*, 13(4): 627-640.
- Mishra, S., Mishra, D. and Santra, G. (2016). Applications of machine learning techniques in agricultural crop production: A Review Paper. *Indian Journal of Science and Technology*, 9(38): 1-14.
- Paudel, D., Boogaard, H., de Wit, A., Janssen, S., Osinga, S., Pylaniadis, C. and Athanasiadis, I. (2021). Machine learning for large-scale crop yield forecasting. *Agricultural Systems*, 187(1): 103016.
- Saplıoğlu, K., Senel, F. ve Küçükdem, 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. ve 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.
- Semerci, A. ve Özer, S. (2011). Türkiye'de ayçiçeği ekim alanı, üretim miktarı ve verim değerinde olası değişimler. *Tekirdağ Ziraat Fakültesi Dergisi*. 8(3): 46-52

- Trépos, R., Champolivier, L., Dejoux J.-F., Al Bitar, A., Casadebaig, P. and Debaeke, P. (2020). Forecasting sunflower grain yield by assimilating leaf area index into a crop model. *Remote Sensing*, 12(22): 3816.
- Xu, R. And Wunsch, D. (2005). Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, 16(3): 645-678.
- Yerdelen, A., Mermer, A., Dedeođlu, F., Yıldız, H., Kaya, Y., Süzer, S. ve Öcal, M.B. (2008). Edirne ilinde ürün deseninin cođrafi bilgi sistemleri ve uzaktan algılama yöntemleri kullanılarak belirlenmesi ve ayçiçeđi verim tahmini. *Tarla Bitkileri Merkez Arařtırma Enstitüsü Dergisi*, 17(1-2): 1-7.