

Nohut ve Mercimek Üretim Miktarı Tahmini İçin Meteorolojik Faktörler Odaklı Makine Öğrenmesi Yaklaşımı: Türkiye Örneği

Hasan Arda BURHAN^{*1}, **Naciye Tuba YILMAZ**²

¹Kütahya Dumlupınar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü, Kütahya, Türkiye

²Marmara Üniversitesi İktisat Fakültesi Ekonometri Bölümü, İstanbul, Türkiye

Öz: Yemelik tane baklagiller en temel karbonhidrat, lif ve protein kaynakları olarak sağlıklı beslenme için gerekli başlıca vitamin ve mineralleri sağlamaktadırlar. Türkiye’de ise yemelik tane baklagiller, tahıllardan sonra yetiştiriciliği en fazla yapılan tarla bitkileri olup; baklagiller için gen merkezi konumunda olan ülkemizde üretilen başlıcaları; nohut, yeşil ve kırmızı mercimek, fasulye ve bakludur. Öte yandan tarımsal üretimin hava koşullarına karşı oldukça duyarlı olması, hali hazırdaki küresel iklim değişikliğinin çevre, doğal kaynaklar ve üretim sistemleri üzerindeki olumsuz etkilerini daha da önemli kılmaktadır. Bu çalışmada ortalama nem, ortalama sıcaklık ve ortalama yağış meteorolojik faktörleri ile ekiliş ve üretim değerlerini içeren veri seti kullanılarak Destek Vektör Regresyon (DVR), Karar ağacı Regresyon (KAR) ve Rastgele Orman Regresyon (ROR) makine öğrenmesi yöntemleriyle Türkiye’de üretimi en fazla yapılan yemelik tane baklagil türleri olan nohut ve mercimek için 2021-2022 yılı üretim miktarı ve verim tahmini yapılmıştır. Elde edilen tahminlerin doğruluğu ve buna bağlı olarak kullanılan yöntemlerin geçerliliği, tahminlerin gerçek değerlerle karşılaştırılmasına ek olarak çeşitli performans ölçütleri ile değerlendirilmiştir. Her üç yöntemle elde edilen sonuçlara göre 2022 yılında nohut üretiminde bir önceki yıla göre yaklaşık %25 azalma; mercimek üretiminde ise bir önceki yıla kıyasla %25 ile %65 arası artış tahmin edilmiştir. Tüm yöntemler bağlamında ağaç temelli makine öğrenmesi regresyon modellerinin daha başarılı sonuçlar verdiği ifade edilebilmektedir.

Anahtar kelimeler: Destek vektör regresyon, karar ağacı regresyon, rastgele orman regresyon, nohut, mercimek, baklagiller, verim

Meteorological Factors-Oriented Machine Learning Approach for Chickpea and Lentil Production Estimation: The Case of Turkey

Abstract: Legumes are the most basic carbohydrate, fiber and protein sources and provide essential vitamins and minerals for a healthy nutrition. As a gene center for legumes, edible legumes are the most cultivated field crops after cereals in Turkey and mainly produced ones are chickpeas, green and red lentils, beans and broad beans. Besides, as the agricultural production is very sensitive to weather conditions, it makes the current global climate change even more important because of its negative effects of on the environment, natural resources and production systems. In this study, by using a data set including meteorological factors as average humidity, average temperature, average precipitation in addition to cultivation and production values, estimations of production amounts and yields were performed for chickpeas and lentils by using Support Vector Regression (SVR), Decision Tree Regression (DTR) and Random Forest Regression (RFR) machine learning methods for 2021 and 2022. Also, accuracy and validity of the methods were evaluated by comparing obtained predictions with actual values and by considering various performance evaluation criteria. According to the obtained results by all three methods, in 2022 a 25% decrease in chickpea production and an increase of 25-65% in lentil production is predicted compared to the previous year. In addition, it can also be stated that tree-based machine learning methods yielded more successful outcomes in both predictions

Keywords: Support vector regression, decision tree regression, random forest regression, chickpeas, lentils, legumes, yield

GİRİŞ

Protein zengini gıdaların sürdürülebilir üretimi artan dünya nüfusu için büyük önem taşımaktadır. Baklagiller, yüksek miktarda protein içermelerinin yanı sıra, lizin, lösin, aspartik asit, glutamik asit, arginin gibi temel aminoasitlerle birlikte önemli yağ, lif, karbonhidrat, vitamin ve mineral kaynakları olarak öne çıkmakta ve bu nedenle yüksek derecede besleyici gıda olarak tanınmaktadırlar (Boye ve ark., 2010; Ton ve ark., 2014). Bu bağlamda farklı nedenlerden hayvansal proteinlerin sağlamadığı veya tercih edilmediği koşullarda baklagiller ikame protein kaynağı olarak değerlendirilmektedir (Adak ve ark., 2015).

Diğer taraftan baklagillerin, kardiyovasküler hastalıklar, diyabet ve kanser riskini azalttığı, yüksek kolesterolü düzenlediği ifade edilmektedir (Pastor-Cavada ve ark., 2011).

Çevreleriyle ilişkileri açısından ise baklagiller, köklerinin yapısal özellikleri dolayısıyla havadaki serbest azotu tutarak bunu toprağa kazandırmakta, böylece hem toprakta birlikte olduğu diğer bitkilere hem de kendisini takiben ekilecek bitkilere fayda sağlamaktadırlar (Dumlu Gül ve Tan, 2013). Ayrıca toprağın kimyasal ve fiziksel özelliklerini iyileştirerek verimliliği artırmakta, erozyon tehlikesi taşıyan arazilerde besin ve toprak kaybını azaltmakta, toprakta sıkışmaya da engel olmaktadır (Ton ve ark., 2014). Hasat sonrasında kayda değer kullanım potansiyeli taşıyan yan ürünler (saman, anız, vb.) bırakan baklagiller, bilhassa yüksek verimli hayvan

*Sorumlu Yazar: arda.burhan@dpu.edu.tr

Geliş Tarihi: 04 Temmuz 2022

Kabul Tarihi: 27 Nisan 2023

beslenmesi için de dengeli enerji, protein ve mineral içeren yem sağlayarak dolaylı yoldan gıda güvenliğine de katkıda bulunmaktadır (Sherasia ve ark., 2018). Baklagil türleri içinde insan beslenmesi için önem taşıyan yemeklik tane baklagiller bezelye, börülce, bakla, fasulye, mercimek ve nohuttan oluşmaktadır (Pekşen ve Artık, 2005). Bunlar içinde geçmişi 8-10 bin yıllık bir zaman öncesine dayanan ve serin iklim baklagilleri içerisinde yer alan nohut ve mercimek ise Türkiye’de ekimi ve üretimi en fazla yapılan yemeklik tane baklagil türleri olarak öne çıkmakta olup, 2020 yılı itibarıyla toplam yemeklik tane baklagil ekim alanının %48,6’sını nohut, %31’ini ise mercimek oluşturmaktadır; üretim miktarında ise bu rakamlar sırasıyla toplam üretimin %48,5 ve %29’u olarak hesaplanmaktadır (Adak ve ark., 2015; Burucu, 2021; Gülaç, 2021).

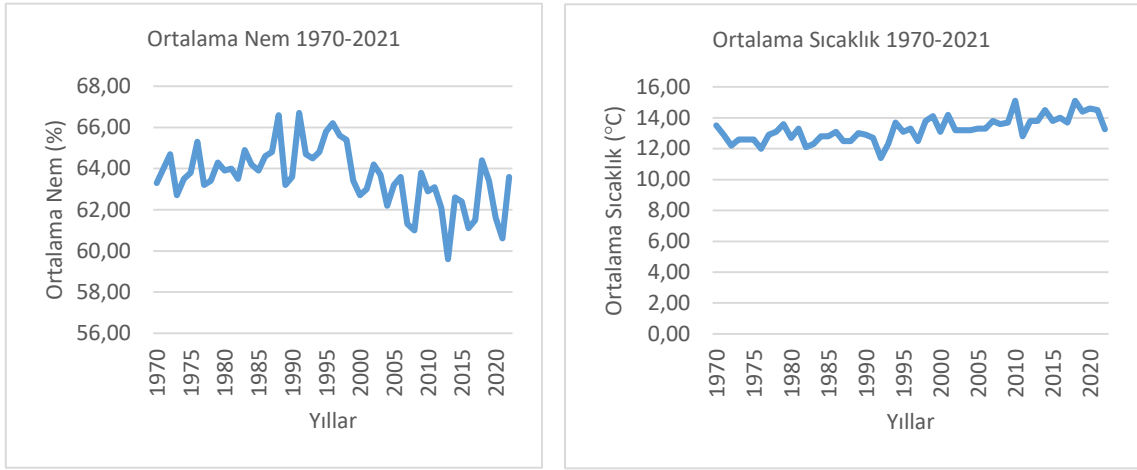
Öte yandan son yıllarda çevresel faktörlerin üretim miktarı üzerindeki doğrudan etkisine uygun olarak hali hazırdaki küresel iklim değişikliğinin sebep olduğu CO₂ yoğunlaşması, kuraklık, sıcaklık ve nem artışı ile yağış miktarlarındaki dalgalanmaların tarımsal ürünler üzerindeki olumsuz yansımalarına ilgili literatürde açıklıkla değinilmektedir (Ahmed ve ark., 2010; Jeong ve ark., 2016). Örneğin mercimekten sonra kuraklık ve düşük sıcaklığa en dayanıklı bitki olarak ifade edilen nohut için olası normalden fazla yağış, sıcaklık ve yüksek nemin düşük verime sebep olduğu bilinmektedir (Ton ve ark., 2014). Benzer şekilde mercimek de fazla yağıştan olumsuz etkilenmekle birlikte dayanıklılığına karşın aşırı kuraklık halinde verim kaybı söz konusu olabilmektedir (Şahin, 2016). Bu nedenle üretim miktarı ve verim tahminlerinde meteorolojik faktörlerin göz önünde bulundurularak hesaplamalara dahil edilmesi, daha isabetli sonuçların elde edilmesi açısından önem taşımaktadır. Söz konusu değişkenlerin tarımsal üretim miktarı ve verim tahminleri üzerindeki etkilerinin incelendiği çalışmalara Doran ve ark. (2009), Jeong ve ark. (2016), Suzan ve Gürgülü (2019), Deniz ve Hiç (2022) örnek olarak verilebilir. Türkiye’de tarımsal ürünlerin üretim miktarı ve verim tahminini yapan çalışmalarda sıklıkla kullanılan yaklaşımlar otoregresif temelli modeller, çiftli üstel düzeltme yöntemi, Koyck modeli, gri tahmin ve bulanık zaman serisi, geliştirilmiş momentler gibi yöntemlerdir (bkz. Özçelik ve Özer, 2006; Bolat ve ark., 2017; Bars ve ark., 2018; Dörtok ve Aksoy, 2018; Berk ve Uçum, 2019; Başakın ve ark., 2020). Diğer taraftan son yıllarda makine öğrenmesi yöntemleri özellikle tarımsal üretim miktarı ve verim tahmininde kullanılmakta olup; bu alandaki artan ilgi, Benos ve ark. (2021), Bali ve Singla (2022) gibi yayınlanmış literatür taraması niteliğindeki yayınlarda açıklıkla görülebilmektedir. Söz konusu çalışmalar göz önünde bulundurulduğunda en sık kullanılan makine öğrenmesi yöntemleri Yapay Sinir Ağları (YSA), Derin Sinir Ağları (DSA), Karar Ağacı Regresyon (KAR), Rastgele Orman Regresyon (ROR), K-En Yakın Komşu (KEYK),

Destek Vektör Regresyon (DVR), yöntemleri olarak ifade edilebilir (Benos ve ark., 2021). Türk tarım sektöründe makine öğrenmesi yaklaşımlarının kullanıldığı az sayıda çalışmaya ise Şimşek ve ark. (2007), Varjovi ve Talu (2016), Başakın ve ark. (2020), Vanli ve ark. (2020), Bregaglio ve ark. (2021), Kaya ve Polat (2021) örnek olarak verilebilir. Bu çalışmanın kapsamı doğrultusunda nohut ve mercimek üretim miktarı tahmini ile ilgili literatür incelendiğinde ise oldukça sınırlı sayıda çalışma bulunmaktadır (bkz. Singh ve Virmani, 1996; Soltani ve ark., 1999; Anwar ve ark., 2001; Sarker ve ark., 2003; Bolat ve ark., 2017; Berk ve Uçum, 2019; Bagheri ve ark., 2020). Öte yandan, Başakın ve ark. (2020) tarafından değinildiği üzere yukarıda verilen çalışmaların büyük çoğunluğunda halihazırdaki üretim değerleri ile karşılaştırarak model başarısının test edilmesi söz konusu olmamıştır. Ayrıca, iklim değişkenlerinin tarımsal üretim miktarı ve verim tahminlerine dahil edilmesinin önemi tarım literatüründe sıklıkla vurgulanan bir husustur. Tüm bunlar gözetilerek bu çalışmada, Türkiye’de ekimi ve üretimi en fazla yapılan yemeklik tane baklagil türleri olan nohut ve mercimek için meteorolojik faktörlerin de dahil olduğu DVR, KAR, ROR makine öğrenmesi modelleri kullanılarak 2021-2022 yılları üretim miktarı ve verim tahmini yapılmıştır. DVR yöntemi, makine öğrenmesi uygulamalarındaki en önemli hususlardan biri olan aşırı öğrenme (overfitting) probleminde karşı dirençli oluşu ve ayrıca zaman serisi tahmin uygulamalarında başarılı genelleştirme kapasitesine sahip olması ile; KAR modeli, sınıflandırmada olduğu gibi regresyon için de kullanılabilmesi, eğitim verisi kullanılarak her öznetiliğin düğümlerle temsil edildiği bir model yardımıyla sınıf (hedef) değişkenini tahmin etmesi ve böylece kolay bir yorumlama imkanı sağlaması ile; KAR yöntemine benzer şekilde hem sınıflandırma hem regresyon için kullanılabilir bir yaklaşım olan ROR yöntemi ise içerdği birçok karar ağacının, aralarındaki olası korelasyondan kaçınmak için torbalama (bagging) işlemi ile farklı eğitim verisi altkümelerlerinden yetiştirilmesi ile öne çıkmaktadır (Basak ve ark., 2007; Fan ve ark., 2008; Millán-Castillo ve ark., 2019; Rodriguez-Galiano ve ark., 2015).

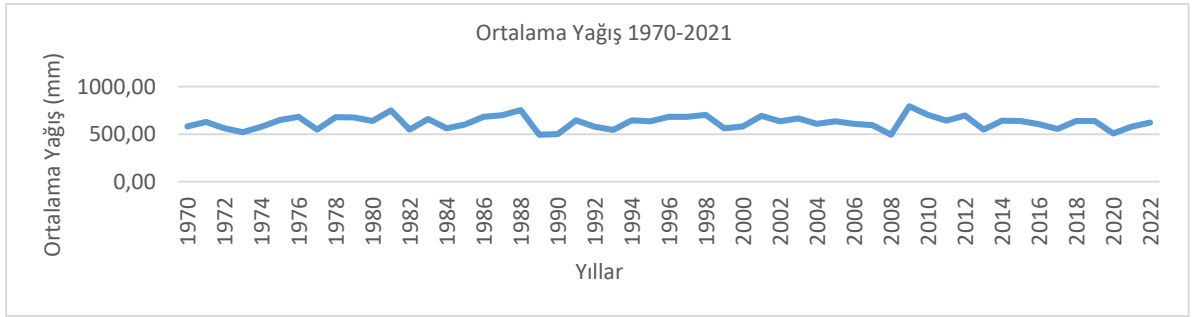
MATERYAL VE YÖNTEM

Materyal

Bu çalışmanın materyalini Toprak Mahsulleri Ofisi (TMO) tarafından sağlanan ve 1938-2021 yılları arasını kapsayan nohut ve mercimek (yeşil ve kırmızı toplam olmak üzere) yıllık ekiliş, üretim değerleri ile Meteoroloji Genel Müdürlüğü (MGM) veri bankasından elde edilen 1970-2021 yıllarına ait ortalama nem, ortalama sıcaklık ve ortalama yağış değerlerinin yer aldığı veri seti oluşturmaktadır. Meteorolojik faktörlere ilişkin zaman serisi grafikleri Şekil 1 ve 2’de verilmiştir:



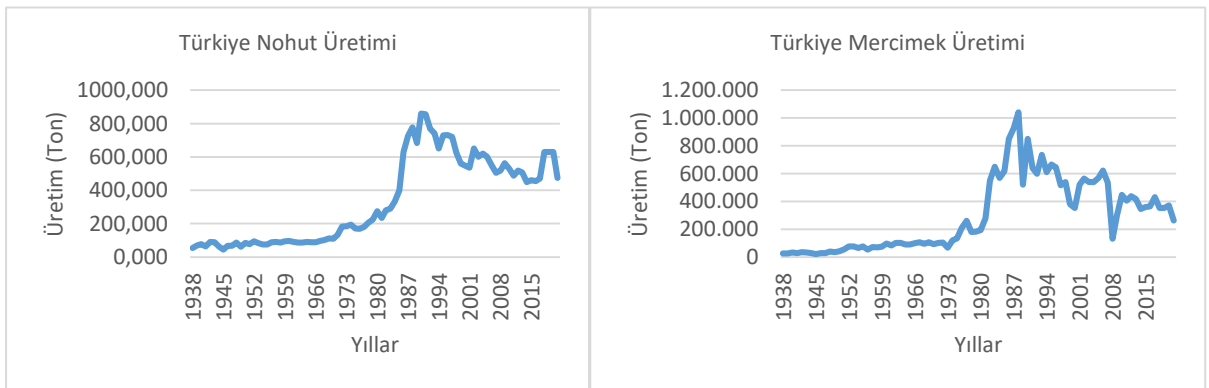
Şekil 1. Türkiye ortalama nem ve sıcaklık zaman grafiği (Kaynak: MGM)



Şekil 2. Türkiye ortalama yağış zaman grafiği (Kaynak: MGM)

Şekil 1'den görülebileceği üzere son 25 yılda Türkiye'de nem oranında bir düşüş ve sıcaklıklarda artış eğilimi olduğu söylenebilmektedir. Öte yandan Şekil 2'ye göre ortalama yağış değerinde 2020'de görülen düşüşün son iki yılda

toparlanma eğilimine girdiği ifade edilebilmektedir. Türkiye nohut ve mercimek üretim miktarlarına ilişkin zaman serisi grafikleri ise Şekil 3'te verilmiştir:



Şekil 3. Türkiye nohut ve mercimek üretimi zaman grafiği (Kaynak: TMO)

Şekil 3'ten görülebileceği üzere nohut üretim miktarında 1990'lara kadar süren artışın, sonraki yıllarda düşüş yönünde eğilim gösterdiği ifade edilebilmektedir. Ayrıca 1980'li yılların ortalarına kadar süren yeşil ve kırmızı toplam mercimek üretimindeki pozitif görünümün bu yılların sonunda keskin bir düşüşle karşılaştığı ve devamında toparlanma sürecine

girdiği görülmektedir. Ancak 1990'lı yıllardan itibaren mercimek üretiminde yeniden bir düşüş eğilimi ve bu eğilimin günümüze kadar devamı söz konusudur.

Yöntem

Çalışmada öncelikle öznelik (girdi) veri setindeki 2021 ve 2022 yıllarına ait eksik değerler ayrı bir veri ön-ışleme (data pre-processing) uygulaması altında Python programlama dili ve Scikit-learn kitaplığındaki *SimpleImputer* sınıfı kullanılarak tamamlanmıştır. Söz konusu sınıfa ait *missing_values* parametresi aracılığıyla eksik verilerin olduğu yıllar belirlenmekte, *strategy* parametresinin varsayılan değeri olan ve az sayıda eksik değer içeren veri setleri için kullanışlı bir yaklaşım olan *mean* (ortalama) yöntemi ile ilgili eksiklikler giderilmektedir (Paper, 2020; Uğuz, 2021). Devamında DVR uygulaması için öznelik ölçeklendirme işlemi yapılmıştır. Zira ilgili literatürde, yapılan ölçeklendirme işlemiyle birlikte elde edilecek sonuçların, yapılmadığı duruma kıyasla daha iyi sonuç verdiği belirtilmektedir (Lin ve ark., 2018). Öte yandan ağaç temelli KAR ve ROR yöntemlerinde öznelik ölçeklendirme işlemine gerek duyulmamaktadır (Liu ve ark., 2021). Ayrıca makine öğrenmesinde kurulan modeller, veri seti dışındaki verilerle sınanarak modelin geçerliliği ve kullanılabilirliği incelenmektedir (Uğuz, 2021). Bu bağlamda öncelikle veri seti, eğitim ve test seti olmak üzere ikiye ayrılır ve eğitim seti ile optimize edilen model, test setindeki verilerle karşılaştırılarak performans değerlendirmesine tabi tutulur (Alpaydın, 2004). Literatürde farklı yaklaşımlar olmakla birlikte genellikle verilerin bölünme oranı eğitim seti için %80, test seti için %20 ya da buna yakın değerler olarak belirlenir (Müller ve Guido, 2016). Çalışmadaki veri seti de bu doğrultuda %80'i eğitim, %20'si test seti olmak üzere ikiye ayrılmıştır. Sonraki adımda 1970-2021 yılları arasındaki nohut ve mercimek ekim ve üretim değerleri ve meteorolojik verilerin yer aldığı veri seti ile DVR, KAR, ROR makine öğrenmesi yöntemleri kullanılarak 2021 ve 2022 yılları için nohut ve mercimek üretim miktarları tahmin edilmiştir. Uygulamanın devamında 2022 yılı için elde edilen nohut ve mercimek üretim miktarı tahminlerine bağlı olarak söz konusu ürünler için verim değerleri hesaplanarak nohut ve mercimek üretimi için 2022 yılı öngörülerini yorumlanmıştır. Öte yandan 2021 yılı için elde edilen sonuçların gerçek verilerle kıyaslanması ile tahminlerin doğruluğu ve buna ek olarak literatürde kullanılan performans değerlendirme ölçütleri ile de kurulan modeller ve bu bağlamda ilgili makine öğrenmesi yöntemlerinin kullanılabilirliği de değerlendirilmiştir. Çalışmada faydalanılan DVR yönteminin temel hedefi, eğitim için kullanılan ve gerçek değer olan y' 'den en çok sapma gösteren veriler için bir fonksiyon bulmak olarak belirtilebilir. Bu doğrultuda DVR uygulamalarında ϵ -duyarsız kayıp fonksiyonu;

$$e_{\epsilon}(r^t, f(x^t)) = \begin{cases} 0 & \text{eğer } |r^t - f(x^t)| < \epsilon \\ |r^t - f(x^t)| - \epsilon & \text{aksi halde} \end{cases} \quad (1)$$

kullanılmaktadır (Alpaydın, 2004). Tahmin edilen değerin regresyon doğrusu çevreleyen ϵ -tüpü içerisinde olması halinde kayıp sıfır olacağı belirtilmektedir (bkz. Alpaydın, 2004; Kaynar ve ark., 2016). Karar ağaçları ise bileşen ve sonuçların hiyerarşik modelleme ile gösterimine dayanan, sınıflandırmada kullanılabilirdiği gibi regresyon için de tercih edilebilen ve parametrik olmayan, bir yaklaşımdır (Rokach ve Maimon, 2015). Bu bağlamda KAR, dallar, iç karar düğümleri ve uç yapraklardan ibaret ağaç modelinin veri kümesiyle bağlantılı olarak çalıştırılarak yaprak seviyesinde sayısal değer elde edilmesine dayanmaktadır (Halepmollası, 2016). Regresyondaki m düğümü için tahmin edilen değer g_m , E_m ise m 'deki varyans ile ilgili olduğunda;

$$g_m = \frac{\sum_t b_m(x^t) r^t}{\sum_t b_m(x^t)}, N_m = |X_m| = \sum_t b_m(x^t), E_m = \frac{1}{N_m} \sum_t (r^t - g_m)^2 b_m(x^t) \quad (2)$$

formülleri ile hesaplanan hata, düğüm için kabul edilebilir olursa ($E_m < \vartheta_r$) bir yaprak düğümü yaratılır ve bu düğüm g_m değerini içerir; aksi halde m düğümüne erişen veri dallardaki hata toplamları minimum olana kadar yine dallara ayrılır (Günaydın ve ark., 2019). KAR yöntemine benzer şekilde hem sınıflandırma hem regresyon için kullanılabilir bir yaklaşım olan ROR yöntemi ise temel olarak birçok karar ağacına ait sonuçlara dayanmaktadır (Lischeid ve ark., 2022).

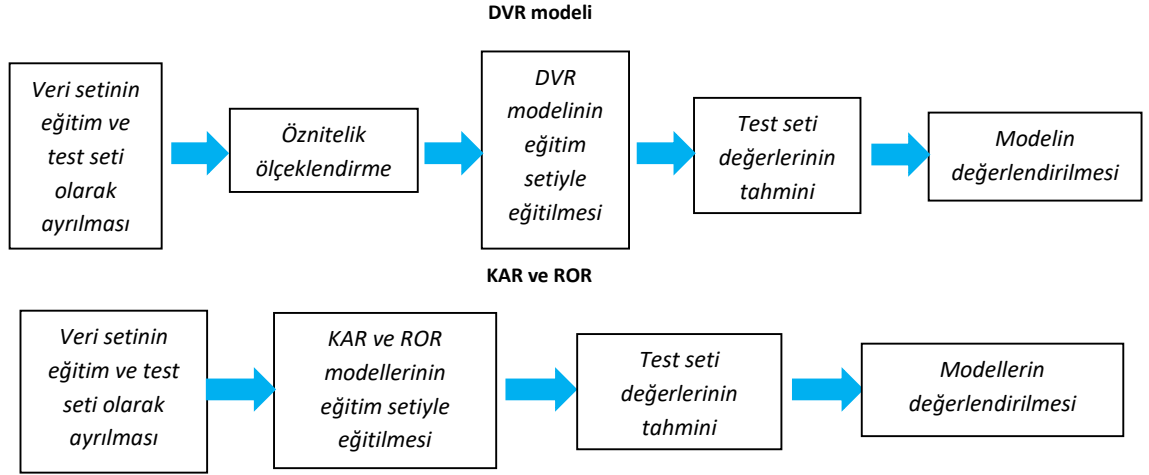
Dolayısıyla $h(x; \theta_k)$ ve $k = 1, \dots, K$ şeklinde gösterilebilecek ağaç tahmincilerine dayanan bir rastgele ormanda x , p uzunluğundaki gözlenen girdi (ortak değişken) vektörünü, X ile θ_k ise bağımsız ve özdeş dağıtılmış rastgele vektörleri temsil etmekte olup ROR tahmincisi;

$$h(x) = \frac{1}{K} \sum_{k=1}^K h(x; \theta_k) \quad (3)$$

şeklinde gösterilir (Segal, 2003).

BULGULAR VE TARTIŞMA

Araştırmada nohut ve mercimek ekiliş ve üretim değerleri ile meteorolojik faktörlere ilişkin değerlerin yer aldığı tahmin modellerinin eğitilmesi ve üretim miktarlarının tahmini, Python programlama dili ve NumPy, Pandas ve Scikit-learn kitaplıklarındaki ilgili paketler kullanılarak gerçekleştirilmiştir. Öncelikle DVR ve aynı süreçlere sahip KAR ile ROR modellerine ilişkin model değerlendirmeleri yapılmıştır. İlgili süreç Şekil 4'te verilmektedir:



Şekil 4. Modellere ilişkin değerlendirme adımları

Yukarıda değinildiği üzere denetimli modellerin geçerliliklerinin değerlendirilmesinde, veri seti ilk olarak eğitim ve test veri setleri olmak üzere iki bölüme ayrılmakta -DVR için ek olarak öznitelik ölçeklendirme işlemi gerçekleştirilmekte- ve *fit* işlevi aracılığıyla eğitilen model,

score işlevi ile test verisi üzerinden değerlendirilmektedir (Müller ve Guido, 2016). Eğitim uygulaması ile elde edilen test seti tahmin değerleri (**T**) ve gerçekleşen üretim miktarları (**G**) ve sapmaları gösteren yüzdelik değerleri nohut için Çizelge 1’de, mercimek için Çizelge 2’de verilmektedir:

Çizelge 1. Nohut için test seti tahminleri ile gerçek değerlerin karşılaştırılması

	DVR			KAR			ROR		
	T	G	Sapma (%)	T	G	Sapma (%)	T	G	Sapma (%)
Nohut	616303,5	560000	9,136	535000	560000	-4,673	559154,8	560000	-0,151
	356182	235000	34,022	225000	235000	-4,444	210200	235000	-11,798
	216137,5	275000	-27,234	280000	275000	1,786	243100	275000	-13,122
	627713,2	770000	-22,667	860000	770000	10,465	791800	770000	2,753
	233288,3	183000	21,556	180000	183000	-1,667	197200	183000	7,201
	649950,1	625000	3,839	650000	625000	3,846	689000	625000	9,289
	414444	460000	-10,992	455000	460000	-1,099	380000	460000	-21,053
	673651,9	650000	3,511	725000	650000	10,345	694500	650000	6,407
	740752,2	732000	1,182	730000	732000	-0,274	727000	732000	-0,688
	167320	195000	-16,543	180000	195000	-8,333	188600	195000	-3,393
659541,7	600000	9,028	535000	600000	-12,150	572574,6	600000	-4,790	

Çizelge 2. Mercimek için test seti tahminleri ile gerçek değerlerin karşılaştırılması

	DVR			KAR			ROR		
	T	G	Sapma (%)	T	G	Sapma (%)	T	G	Sapma (%)
Mercimek	458081,5	380000	17,045	353000	380000	-7,649	535387,2	380000	29,023
	297800,4	280000	5,977	302181	280000	7,340	340536,2	280000	17,777
	195037	195000	0,019	183000	195000	-6,557	175900	195000	-10,858
	584105,5	600000	-2,721	735000	600000	18,367	674300	600000	11,019
	206920,5	105000	49,256	92000	105000	-14,130	103500	105000	-1,449
	522685,6	540000	-3,313	515000	540000	-4,854	681500	540000	20,763
	348961,6	360000	-3,163	405952	360000	11,320	401658,1	360000	10,372
	550586,7	565000	-2,618	622624	565000	9,255	582587,2	565000	3,019
	594149,5	645000	-8,559	515000	645000	-25,243	688000	645000	6,250
	134362,7	120000	10,689	92000	120000	-30,435	112800	120000	-6,383
	520358,7	540000	-3,775	622624	540000	13,270	580312	540000	6,947

Öte yandan literatürde genel olarak uygun görülen bölümlendirme olan eğitim seti için verinin %80'i, test seti için %20'si oranlarının tahmin aşamasında gösterdikleri başarının değerlendirilmesinde ise cross-validation (çapraz doğrulama) yönteminin uygulanması önerilmektedir (Matloff, 2017). Cross-validation (CV) sürecinde eğitim verisi

k adet (genel olarak k değeri 5 ya da 10 olarak alınır) parçaya ayrılmakta, ilk parçayı içeren model test verisi olarak ayrılıp, kalan parçalar eğitim seti olarak kullanılmakta ve böylece ilk parça için performans değerlendirilmesi yapılmakta; süreç benzer şekilde tüm parçalar için tekrar edilmektedir (Murphy, 2012). Çizelge 3'te tüm modeller için hesaplanan ortalama CV skorları verilmektedir:

Çizelge 3. Modellere ilişkin CV skorları

Nohut	Modeller	CV skorları
	Destek Vektör Regresyon	0.83
	Karar Ağacı Regresyon	0.76
	Rastgele Orman Regresyon	0.82
Mercimek	Modeller	CV skorları
	Destek Vektör Regresyon	0.52
	Karar Ağacı Regresyon	0.53
	Rastgele Orman Regresyon	0.60

Çizelge 3'te verilen sonuçlara göre, nohut için DVR ve ROR modellerinin %82 civarında tutarlı performans vermesi beklenebilecek iken, mercimek için en yüksek performans değerinin %60 ile ROR modeline ait olduğu belirtilebilmektedir. Diğer taraftan makine öğrenmesi literatüründe genel anlamda regresyon modellerinin


değerlendirilmesi için R^2 değerinin yeterli olduğu ifade edilmektedir (Müller ve Guido, 2016). Bu bağlamda model değerlendirme sürecinin son adımında uygun bir değerlendirme yöntemi olarak ifade edilen R^2 değerleri hesaplanmış ve Çizelge 4'te verilmiştir (detaylar için bkz. Pant ve ark., 2021):

Çizelge 4. Modellere ilişkin R^2 değerleri

Nohut	Modeller	R^2 değerleri
	Destek Vektör Regresyon	0.8944542
	Karar Ağacı Regresyon	0.9600416
	Rastgele Orman Regresyon	0.9681675
Mercimek	Modeller	R^2 değerleri
	Destek Vektör Regresyon	0.9464897
	Karar Ağacı Regresyon	0.870908
	Rastgele Orman Regresyon	0.847917

Elde edilen sonuçlara göre nohut için KAR ve ROR, mercimek için ise DVR modelleri oldukça yüksek R^2 değerleri vermekte, ancak bu durum aşırı öğrenme kaynaklı olabilmektedir. Bu doğrultuda analizin devamında, her üç model kullanılarak 2021-2022 için nohut ve mercimek üretim miktarı tahmini yapılmıştır. Öncelikle hesaplanan 2021 yılı tahmini, analizde

kullanılan veri setinde yer alan ve geçerleme (validation) değeri olarak kullanılan 2021 yılı gerçekleşen üretim miktarı ile karşılaştırılarak modellerin isabetli tahmin yeteneği değerlendirilmiştir. Sonraki adımda ise veri setinde yer almayan 2022 yılı üretim miktarı ve buna bağlı olarak verim tahminleri yapılmıştır. Her bir model için tahmin adımları Şekil 5'te verilmektedir:



Şekil 5. Modellere ilişkin tahmin adımları

Yukarıda verilen tahmin adımları incelendiğinde, DVR modeli için gereken öznitelik ölçeklendirme işlemi dışında üç modelde de veri setinin tamamıyla eğitilerek yeni değerlerin

tahmin edildiği görülebilmektedir. Nohut ve mercimek üretim miktarlarına ilişkin 2021 yılı tahmin ve gerçekleşen değer karşılaştırmaları Çizelge 5'te verilmektedir:

Çizelge 5. 2021 yılı için tahmin ve gerçek değerler karşılaştırması

	DVR		KAR		ROR	
	T	G	T	G	T	G
Nohut	511071.48	475000	280000	475000	333000	475000
	T	G	T	G	T	G
Mercimek	415046.32	263000	430000	263000	348044.9	263000

Çizelge 5'te verilen tahmin sonuçları incelendiğinde 2021 yılı için nohut üretim miktarı tahmininde en yakın sonuç DVR yöntemi ile elde edilirken; mercimek üretim miktarı tahmininde ise en yakın sonucun ROR yöntemiyle elde edildiği görülebilmektedir. Sonraki adımda modeldeki tüm öznitelikler için veri setinde yer almayan 2022 yılı değerleri

veri ön-işleme yöntemleriyle tamamlanmış olup 2022 nohut ve mercimek üretim miktarları tahmin edilmiştir. Bu bağlamda elde edilen tahmin sonuçları kullanılarak son 10 yıla ait nohut ve mercimek ekiliş, üretim ve verim değerlerini içerecek şekilde oluşturulan denge çizelgesi aşağıda verilmektedir:

Çizelge 6. Türkiye nohut ve mercimek denge çizelgesi

Yıl	Nohut			Mercimek		
	Ekiliş (Ha)	Üretim (Ton)	Verim (Kg/Da)	Ekiliş (Ha)	Üretim (Ton)	Verim (Kg/Da)
2012	408699	518000	126.74	234768	438000	186.57
2013	418889	506000	120.80	281151	417000	148.32
2014	388169	450000	115.93	243370	345000	141.76
2015	357222	460000	128.77	223772	360000	160.88
2016	351687	455000	129.38	246322	365000	148.18
2017	392673	470000	119.69	292455	430000	147.03
2018	514102	630000	122.54	259374	353000	136.10
2019	517785	630000	121.67	282252	353631	125.29
2020	511561	630000	123.15	247644	370815	149.74
2021	324085*	475000	146.57	285864*	263000	92
2022	323163*	354990.5 ^a	109.84	285864*	328681 ^a	114.97
2022	323163*	343247.7 ^b	106.21	285864*	430000 ^b	150.42
2022	323163*	355079.6 ^c	109.87	285864*	368416.6 ^c	128.87

Kaynak: TMO (2012-2021 yılları için)

* ile gösterilen değerler, veri ön-işleme yöntemleri ile veri setine dahil edilmiş olup, **a** simgesi DVR yöntemi ile tahmin sonucunu, **b** simgesi KAR yöntemi ile tahmin sonucunu, **c** simgesi ise ROR yöntemi ile tahmin sonucunu ifade etmektedir.

Yukarıda verilen tahmin değerleri incelendiğinde 2022 yılı nohut üretiminde, tüm yöntemler dahilinde önceki yıllara ait gerçekleşen üretim miktarlarına göre azalış ve buna bağlı olarak verim değerinde de düşüş beklendiği söylenebilmektedir. Mercimek üretim tahmin değerleri göz önünde bulundurulduğunda ise 2022 yılında tüm yöntemler uyarınca bir önceki yıl gerçekleşen üretim miktarına göre artış olacağı, buna bağlı olarak verimde de yine bir önceki yıla göre belirgin bir artış gözlemlenebileceği ifade edilebilmektedir. DVR ve ROR yöntemine göre 2022 yılında nohut üretiminin yaklaşık 355 bin ton, buna bağlı olarak verim değerinin ise 109,8 kg/da; KAR yöntemine göre ise

üretiminin yaklaşık 344 bin ton, verimin 106,21 kg/da şeklinde gerçekleşeceği öngörülmekte iken; 2022 yılında mercimek üretiminin yaklaşık DVR yaklaşımına göre 328 bin, KAR yöntemine göre 430 bin, ROR yöntemine göre ise 369 bin ton olarak; verim değerlerinin ise sırasıyla yaklaşık 115, 150 ve 129 kg/da şeklinde gerçekleşeceği tahmin edilmektedir. Son olarak yapılan tahminlere ilişkin performans ölçütü olarak öngörü hatalarını yüzde olarak ifade eden ve pratikte sıklıkla kullanılan *Ortalama Mutlak Yüzde Hata* (Mean Absolute Percentage Error (MAPE)) tercih edilmiştir (Myttenaere ve ark., 2016). Elde edilen sonuçlar Çizelge 7'de verilmektedir:

Çizelge 7. Modellerle ilişkin MAPE değerleri

Nohut	Modeller	MAPE değerleri
	Destek Vektör Regresyon	0.1562
	Karar Ağacı Regresyon	0.0538
	Rastgele Orman Regresyon	0.0690
Mercimek	Modeller	MAPE değerleri
	Destek Vektör Regresyon	0.1445
	Karar Ağacı Regresyon	0.1294
	Rastgele Orman Regresyon	0.1337

Genel anlamda, elde edilen MAPE değeri %10'un altında ise tahminlemenin yüksek derecede isabetli olduğu, %10-20 arasında hesaplanan değer iyi derecede isabetli tahmini ifade ettiği, %20-50 arası MAPE değerinin ise makul olarak değerlendirilebileceği belirtilmektedir (Giraka ve Selvaraj, 2020). Buna göre MAPE değerleri göz önünde bulundurularak model başarıları incelendiğinde her iki ürün için de ağaç temelli modellerin, DVR modeline kıyasla daha başarılı oldukları söylenebilmektedir.

SONUÇ

Nüfusunun 2050 yılı itibarıyla 9,7 milyara ulaşacağıın tahmin edildiği dünyamızda, insan beslenmesinin en önemli kaynaklarından olan tarımsal üretimin de son on yıla nazaran %40 ila %54 arasında artması gerektiği ifade edilmektedir (FAO, 2021). Bu bağlamda yemeklik tane baklagiller, yüksek besin değerleriyle önemli protein ve karbonhidrat kaynakları olarak öne çıkmaktadırlar (Pastor-Cavada ve ark., 2011). Türkiye'de ise yemeklik tane baklagiller, tahılların ardından ekilen alan ölçeğinde ikinci sırada yer almakta olup bunların içinde nohut ile yeşil ve kırmızı olmak üzere mercimeğin toplam yemelik tane baklagil üretimindeki payı 2020 yılı itibarıyla yaklaşık %80 civarındadır (Burucu, 2021; Gülaç, 2021). Ancak her ne kadar Türkiye baklagiller için uygun bir ekolojik yapı sunuyor olsa da, bilhassa yemeklik tane baklagiller için üretim ve verim açısından yıldan yıla dalgalanmaların söz konusu olduğu söylenebilmektedir (Kün ve ark., 2005). Bilhassa küresel iklim değişikliklerine bağlı olarak azalan yağış miktarı ve artan sıcaklıkların yanı sıra sıcak hava dalgaları ve kuraklık gibi aşırı iklimsel olayların negatif yansımalarının her geçen yıl artacağı ve bu bağlamda tarımın da söz konusu etkilere maruz kalacağı açıklıkla belirtilmektedir (Araújo ve ark., 2021). Buna göre coğrafi açıdan bu etkilere açık bir konumda bulunan Türkiye için de tarımsal verim kaybı ile fiyat oynaklığı-karlılık farklılaşmalarının söz konusu olacağı, ayrıca tarım sektöründe uzun süreli hakimiyeti olan ürün deseninin de bu doğrultuda değişeceği söylenebilmektedir (Deniz ve Hiç, 2022). Bu bağlamda düşük sıcaklıklara dayanıklı oldukları bilinen nohut ve mercimek açısından da yağış rejimindeki belirgin değişiklikler ve olası kuraklık riskinin büyük önem taşıdığı, hatta bu bitkilerin ağırlıklı olarak yetiştirildiği Güney Doğu ve İç Anadolu Bölgeleri'nin küresel iklim değişikliğine bağlı sıcaklık artışından daha fazla etkileneceği ifade edilmiştir (Doran ve ark., 2009; Bolat ve ark., 2017). Dolayısıyla bilhassa tarımsal üretim ve verimle ilgili yapılan tahmin çalışmalarında meteorolojik faktörlerin dikkate alınması gerektiği söylenebilmektedir. Öte yandan son yıllarda makine öğrenmesi algoritmalarındaki gelişmeler göz önüne alındığında farklı makine öğrenmesi teknikleri de tarım sektöründe uygulama alanı bulmuştur (Tunca ve Köksal, 2021). Daha rekabetçi, üretken ve sürdürülebilir bir

tarım sektörü için Türkiye, 11. Kalkınma Planı çerçevesinde veriye dayalı, sayısallaştırılmış tarımsal bilgi sistemlerini geliştirmeyi hedeflemekte olup, bu bağlamda makine öğrenmesi yöntemlerinin önemli bir potansiyeli beraberinde taşıdığı söylenebilmektedir (SBB, 2019). Bu çalışmada, Türkiye için en önemli yemeklik tane baklagil türlerinden nohut ve mercimek için 2021-2022 yılları üretim miktarları ve buna bağlı olarak verim değerleri, DVR, KAR ve ROR makine öğrenmesi yöntemleri kullanılarak hesaplanmıştır. Çalışmada kullanılan model değerlendirme ölçütleri, özellikle ağaç temelli makine öğrenmesi regresyon yöntemlerinin daha başarılı olmasının beklenebileceğini göstermiştir. Elde edilen tahmin sonuçlarına göre ise 2022 yılında nohut üretiminde önceki yıllara göre azalış, mercimek üretiminde ise özellikle bir önceki yıla kıyasla artış, ayrıca 2022 yılında nohut için azalan, mercimek için ise artan verimin söz konusu olacağı tahmin edilmiştir. İlgili literatür elde edilen tahminlerle karşılaştırma için tekrar gözden geçirilmiştir. Bu doğrultuda Berk ve Uçum (2019)'un 2022 yılı nohut öngörüsünün yaklaşık 1,47 milyon ton olduğu görülmektedir. Bu çalışmada 2022 yılı için elde edilen nohut üretim miktarı tahminleri ise DVR, KAR ve ROR makine öğrenmesi yöntemleri için sırasıyla yaklaşık 355 bin; 344 bin ve yine 355 bin ton olarak hesaplanmış olup, Berk ve Uçum (2019) tarafından öngörülen 2022 değerinin, bu çalışmada hesaplanan tahmin değerlerine kıyasla oldukça yüksek olduğu ifade edilebilmektedir. Söz konusu çalışma dışında literatürde 2022 yılı nohut ve mercimek üretim miktarı tahmin sonuçlarının kıyaslanabileceği başka bir araştırma yer almamaktadır. Bolat ve ark. (2017)'na ait çalışma, en ileri tarih olarak 2021 yılına ait tahmin değerleri sunduğu için karşılaştırmaya dahil edilmemiştir. Kapsam açısından ise bu çalışma, kullanılan veri seti ve yöntemler ölçeğinde önemli sınırlamalar içermektedir. Tarımsal üretim miktarının meteorolojik etmenlerin yanı sıra, tohum, insan etkisi, toprak türü, erozyon, kullanılan gübre ve ilaçlar gibi birçok faktörden etkilenmektedir (Gopal ve Bhargavi, 2019). Analizde kullanılan modellerin meteorolojik değişkenler odaklı olması, bu çalışmanın sınırlılıklarından biri olarak ifade edilebilir. Öte yandan çalışmada kullanılan algoritmalarının eğitilmesi ve yapılan tahminler, sınırlı sayıda veri içeren bir veri seti dahilinde gerçekleştirilmiş olup, daha büyük veri setleriyle çalışmanın modellerin tahmin kapasiteleri üzerinde daha olumlu etkide bulunabileceği açıklıkla belirtilebilir. Son olarak DVR, KAR ve ROR gibi üç temel makine öğrenmesi yönteminin kullanılması, bu çalışmaya dair bir diğer sınırlama olarak ifade edilebilir. Halihazırda Türkiye için en önemli yemeklik tane baklagil türleri olan nohut ve mercimek için meteorolojik değişkenler odaklı ve makine öğrenmesi yöntemleri kullanılarak üretim miktarı ve verim tahmininin, ayrıca yine nohut ve mercimek için gerçek verilerle karşılaştırılarak model ve yöntem değerlendirmesinin

yapıldığı bir çalışmanın bulunmaması, bu çalışmanın ilgili literatüre katkısı olarak ifade edilebilir. Gelecekteki çalışmalarda Türk tarım sektörü için önem taşıyan diğer ürünler göz önünde bulundurularak, ayrıca benzer veya farklı ürünler için daha büyük veri setleri ile farklı makine öğrenmesi yöntemlerinin ve tarımsal üretim miktarını etkileyen farklı değişkenlerin yer aldığı modeller kullanılarak bu çalışmanın sınırlamaları aşılabilecektir.

KAYNAKLAR

- Adak MS, Kayan N, Benlioğlu B (2015) Yemelik Tane Baklagiller Üretiminde Değişimler ve Yeni Arayışlar. In Ziraat Mühendisliği VIII. Teknik Kongresi Bildirileri, TMMOB Ziraat Mühendisleri Odası, Ankara, 387-399.
- Ahmed S, Muhammad I, Kumar S, Malhotra R, Maalouf F (2010) Impact of Climate Change and Variability on Diseases of Food Legumes in the Dry Areas. Proceedings of International Conference on Food Security and Climate Change in Dry Areas, International Center for Agricultural Research in the Dry Areas, Amman, 157-165.
- Alpaydın E (2004) Introduction to Machine Learning. The MIT Press. Cambridge, MA.
- Anonim (2022) Türkiye Nohut ve Mercimek Ekiliş-Üretim Verim ve TMO Alımları. TMO, Ankara. <https://www.tmo.gov.tr/Upload/Document/istatistikler/tablolari/9nohuteuva>, <https://www.tmo.gov.tr/Upload/Document/istatistikler/tablolari/8mercimekeuva.pdf> (Erişim Tarihi: 01/05/2022).
- Anwar M, McKenzie B, Hill G, Peri P (2001) A Predictive Model of Chickpea (*Cicer Arietinum* L.) Yield. *Agronomy New Zealand*, 31: 1-11.
- Araújo SO, Peres RS, Barata J, Lidon F, Ramalho JC (2021) Characterising the Agriculture 4.0 Landscape—Emerging Trends, Challenges and Opportunities. *Agronomy*, 11(4): 667.
- Bagheri A, Zargarian N, Mondani F, Nosratti I (2020) Artificial Neural Network Potential in Yield Prediction of Lentil (*Lens Culinaris* L.) Influenced by Weed Interference. *Journal of Plant Protection Research*, 60(3): 284–295.
- Bali N, Singla A (2022) Emerging Trends in Machine Learning to Predict Crop Yield and Study its Influential Factors: A Survey. *Archives of Computational Methods in Engineering*, 29(1): 95-112.
- Bars T, Uçum İ, Akbay C (2018) ARIMA Modeli ile Türkiye Fındık Üretim Projeksiyonu. *KSÜ Tarım ve Doğa Dergisi*, 21: 154-160.
- Başakın EE, Ekmekcioğlu Ö, Özger M, Çelik A (2020) Dalgacık Bulanık Zaman Serisi Yöntemi ve Gri Tahmin Yöntemi ile Türkiye Buğday Verimi Tahmini. *Türkiye Tarımsal Araştırmalar Dergisi*, 7(3): 246-252.
- Benos E, Tagarakis AC, Dolias G, Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine Learning in Agriculture: A Comprehensive Updated Review. *Sensors*, 21(11): 3758-3813.
- Berk A, Uçum İ (2019) Türkiye'nin Nohut Üretimini ARIMA Modeli ile Tahmini. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(4): 2284-2293.
- Bolat M, Ünüvar Fİ, Dellal İ (2017) Türkiye'de Yemelik Baklagillerin Gelecek Eğilimlerinin Belirlenmesi. *Tarım Ekonomisi Araştırmaları Dergisi*, 3(2): 7-18.
- Boye J, Zare F, Pletch A (2010) Pulse Proteins: Processing, Characterization, Functional Properties and Applications in Food and Feed. *Food Research International*, 43: 413-431.
- Bregaglio S, Fischer K, Ginaldi F, Valeriano T, Giustarini L (2021) The Hades Yield Prediction System—A Case Study on the Turkish Hazelnut Sector. *Frontiers in Plant Science*, 12: 1-14.
- Burucu D. (2021) Ürün Raporu Nohut 2021. Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü, Ankara. <https://arastirma.tarimorman.gov.tr>, (Erişim Tarihi: 25/04/2022).
- Deniz M, Hiç Ö (2022) İklim Değişikliği ve Tarımın Değişen Yüzü: Artan Riskler, Tarımdaki Daralmalar ve Orman Yangınları Sonrası Politika Önerileri. *Biga İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3(1): 12-22.
- Doran İ, Koca, YK, Kılıç T (2009) Olası İklim Değişiminin Diyarbakır Tarımına Etkileri. In V. Ulusal Coğrafya Sempozyumu, Türkiye Coğrafyası Araştırma ve Uygulama Merkezi, Ankara, 369-377.
- Dörtok A, Aksoy, A (2018) Türkiye Buğday Sektörünün Eşanlı Model Yöntemiyle Tahmini. *KSÜ Tarım ve Doğa Dergisi*, 21(4): 580-586.
- Dumlu Gül Z, Tan M (2013) Baklagil Yem Bitkilerinin Silajlık Olarak Kullanılması. Atatürk Üniversitesi Ziraat Fakültesi Dergisi, 44(1): 188-193.
- FAO (2021) The State of Food and Agriculture 2021: Making Agrifood Systems More Resilient to Shocks and Stresses. FAO, Rome. <https://www.fao.org/3/cb4476en/cb4476en.pdf>, (Erişim Tarihi: 20/04/2022)
- Giraka O, Selvaraj VK (2020) Short-Term Prediction of Intersection Turning Volume Using Seasonal ARIMA Model. *Transportation Letters*, 12(7): 483-490
- Gopal PS, Bhargavi R (2019) Performance Evaluation of Best Feature Subsets for Crop Yield Prediction Using Machine Learning Algorithms. *Applied Artificial Intelligence*, 33(7): 621-642.
- Gülaç ZN (2021) Ürün Raporu Mercimek 2021. Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü, Ankara.

- <https://arastirma.tarimorman.gov.tr>, (Erişim Tarihi: 25/04/2022)
- Halepmollası R (2016) Alt Sekans Profil Haritaları Kullanılarak Protein Katlanması Tanıma. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Jeong JH, Resop JP, Mueller ND, Fleisher DH, Yun K, Butler EE, . . . , Kim SH (2016) Random Forests for Global and Regional Crop Yield Predictions. *PLoS One*, 11(6): e0156571.
- Kaya Y, Polat N (2021) Bitki İndeksleri Kullanarak Buğday Bittisinin Rekolte Tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(1): 99-110.
- Kaynar O, Yüksek G, Demirkoparan F (2016) Genetik Algoritma ile Eğitilmiş Destek Vektör Regresyon Kullanılarak Türkiye'nin Elektrik Tüketim Tahmini. *İktisat Fakültesi Mecmuası*, 66(2): 45-60.
- Kün E, Çiftçi CY, Birsin M, Ülger AC, Karahan S, Zencirci N, . . . , Atak M (2005) Tahıl ve Yemelik Dane Baklagiller Üretimi. In *Türkiye Tarım Mühendisliği VI. Teknik Kongresi Bildiriler*, TMMOB Ziraat Mühendisleri Odası, Ankara, 367-407.
- Lin AY, Zhang M, Selpi S (2018) Using Scaling Methods to Improve Support Vector Regression's Performance for Travel Time and Traffic Volume Predictions. In: Rojas I, Pomares H, Valenzuela O (eds), *Time Series Analysis and Forecasting. ITISE 2017 Contributions to Statistics*, Springer, Cham, 115-127.
- Lischeid G, Webber H, Sommer M, Nendel C, Ewert F (2022). *Machine Learning in Crop Yield Modelling: A Powerful Tool, But No Surrogate For Science. Agricultural and Forest Meteorology*, 312: 108698.
- Liu Y, Miller E, Habib KN (2021) Detecting Transportation Modes Using Smartphone Data and GIS Information: Evaluating Alternative Algorithms for an Integrated Smartphone-Based Travel Diary Imputation. *Transportation Letters*, 1-11.
- Matloff N (2017) *Statistical Regression and Classification - From Linear Models to Machine Learning*, CRC Press, Boca Raton, FL.
- Murphy KP (2012) *Machine Learning - A Probabilistic Perspective*, The MIT Press, Cambridge, MA.
- Müller AC, Guido S (2016) *Introduction to Machine Learning with Python - A Guide for Data Scientists*. O'Reilly Media, Inc. Sebastopol, CA.
- Myttenaere A. de, Golden B, Le Grand B, Rossi F (2016) Mean Absolute Percentage Error for Regression Models. *Neurocomputing*, 192: 38-48.
- Özçelik A, Özer OO (2006) Koyck Modeliyle Türkiye'de Buğday Üretimi ve Fiyatı İlişkisinin Analizi. *Tarım Bilimleri Dergisi*, 12(4): 333-339.
- Pant J, Pant RP, Singh MK, Singh DP, Pant H (2021) Analysis of Agricultural Crop Yield Prediction Using Statistical Techniques of Machine Learning. *Materials Today: Proceedings*, 46: 10922-10926.
- Paper D (2020) *Hands-on Scikit-Learn for Machine Learning Applications - Data Science Fundamentals with Python*. Apress. Logan, UT.
- Pastor-Cavada E, Juan R, Pastor JE, Alaiz M, Vioque J (2011) Nutritional Characteristics of Seed Proteins in 15 Lathyrus Species (Fabaceae) from Southern Spain. *LWT - Food Science and Technology*, 44: 1059-1064.
- Pekşen E, Artık C (2005) Antibesinsel Maddeler ve Yemelik Tane Baklagillerin Besleyici Değerleri. *Anadolu Tarım Bilimleri Dergisi*, 20(2): 110-120.
- Rokach L, Maimon O (2015) *Data Mining with Decision Trees: Theory and Applications*. World Scientific Publishing Co. Pte. Ltd. Singapore.
- Sarker A, Erskine W, Singh M (2003) Regression Models for Lentil Seed and Straw Yields in Near East. *Agricultural and Forest Meteorology*, 116: 61-72.
- SBB (2019) 11. Kalkınma Planı (2019-2023). Strateji ve Bütçe Başkanlığı, Ankara. <https://www.sbb.gov.tr>, (Erişim Tarihi: 05/05/2022).
- Sherasia PL, Garg MR, Bhandari BM (2018) Pulses and Their By-Products as Animal Feed. *United Nations. Rome*.
- Singh P, Virmani S (1996) Modeling Growth and Yield of Chickpea (*Cicer Arietinum L.*). *Field Crops Research*, 46: 41-59.
- Soltani A, Ghassemi-Golezani K, Khooie F, Moghaddam M (1999) A Simple Model for Chickpea Growth and Yield. *Field Crops Research*, 62: 213-224.
- Suzan U, Gürgülü H (2019) Küresel Isınma ve İklim Değişikliği ile Meydana Gelen Kuraklık ve Kuraklığın Tarıma Etkileri. In: Yılmaz, FI (eds), *ERASMUS Symposium*, Asos Yayınevi, Elazığ, 49-62.
- Şahin G (2016) 2016 Uluslararası Bakliyat Yılı Hasebiyle Türkiye'de Mercimek. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 20(4): 1665-1696.
- Şimşek O, Mermer A, Yıldız H, Özyayın K A, Çakmak B, (2007) Agrometshell Modeli Kullanılarak Türkiye'de Buğdayın Verim Tahmini. *Tarım Bilimleri Dergisi*, 13(3): 299-307.
- Ton A, Karaköy T, Anlarsal AE (2014) Türkiye'de Yemelik Tane Baklagiller Üretiminin Sorunları ve Çözüm Önerileri. *Türk Tarım-Gıda Bilim ve Teknoloji Dergisi*, 2(4): 175-180.

Tunca E, Köksal ES (2021) Sentinel 2 Uydu Görüntülerinden Bitki Türlerinin Makine Öğrenmesi ile Belirlenmesi. ÇOMÜ Ziraat Fakültesi Dergisi, 9(1): 189-200.

Uğuz S (2021) Makine Öğrenmesi - Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zeka Ekolü. Nobel Akademik Yayıncılık. Ankara.

Vanli Ö, Ahmad I, Ustundag BB (2020) Area Estimation and Yield Forecasting of Wheat in Southeastern Turkey

Using a Machine Learning Approach. Journal of the Indian Society of Remote Sensing, 48(12): 1757-1766.

Varjovi MH, Talu MF (2016) Kayısı için Otomatik Rekolte Tahmin Sistemi. In International Conference on Artificial Intelligence and Data Processing, Inonu University, Malatya, 1-5.

