

Türkiye'de İklimsel Parametrelerin Tarımsal Üretime Etkisinin Makine Öğrenmesi Yöntemleri ile Analizi: 157 Ürün Üzerinde Kapsamlı Bir Risk Değerlendirmesi (2004-2024)

Analysis of the Impact of Climatic Parameters on Agricultural Production in Türkiye Using Machine Learning Methods: A Comprehensive Risk Assessment on 157 Products (2004-2024)

Banu Bolayır¹ 

Uğur Demirel² 

Öz

Amaç- Küresel iklim değişikliğinin tarımsal üretim üzerindeki etkilerinin artması, iklimsel risklerin ürün bazında değerlendirilmesini önemli hale getirmiştir. Bu çalışmanın amacı, Türkiye’de 2004-2024 döneminde 157 farklı tarım ürününün iklimsel parametrelere karşı duyarlılığını belirlemek, üretim eğilimlerini analiz etmek ve ürün bazlı iklim risk düzeylerini veri madenciliği yöntemleri kullanarak değerlendirmektir.

Yöntem/Metodoloji/Dizayn- Araştırmada, 157 tarım ürününe ait yıllık üretim verileri ile 15 farklı meteorolojik değişkenden oluşan veri seti kullanılmıştır. İklim değişkenlerinin üretim üzerindeki etkileri Random Forest ve Gradient Boosting makine öğrenmesi algoritmaları ile analiz edilmiş, değişken önem dereceleri hesaplanmıştır. Ayrıca, üretim trendleri ile iklimsel duyarlılık göstergelerini bütünleştiren Bileşik Risk Skoru (BRS) geliştirilerek ürünler düşük, orta ve yüksek risk gruplarında sınıflandırılmıştır.

Sonuçlar- Analiz sonuçlarına göre tarımsal üretimi etkileyen en önemli iklim değişkeninin %60,42 önem derecesi ile maksimum sıcaklık ortalamaları olduğu belirlenmiştir. Geliştirilen Bileşik Risk Skoru sonucunda incelenen 157 ürünün %33,7’si (53 ürün) yüksek risk grubunda yer almıştır. Özellikle biralık arpa, karpuz ve hasıl mısır ürünlerinde üretim eğilimleri ile iklimsel göstergeler arasındaki ilişkinin diğer ürünlere göre daha belirgin olduğu tespit edilmiştir.

Katkı/Farklılıklar- Çalışma, makine öğrenmesi algoritmaları ile iklimsel değişkenleri üretim eğilimleriyle bütünleştirerek ürün bazında risk değerlendirmesi yapan bütünsel bir analiz yaklaşımı sunmaktadır. Geliştirilen Bileşik Risk Skoru, tarımsal üretimde iklim kaynaklı risklerin önceliklendirilmesine katkı sağlamakta; elde edilen bulguların iklim değişikliğine uyum politikalarının geliştirilmesi, sürdürülebilir tarımsal planlama ve karar destek süreçlerinde kullanılabilecek veri temelli bir çerçeve sunmaktadır.

Abstract

Purpose- Global climate change increasingly affects agricultural production systems and food supply security. The purpose of this study is to determine the sensitivity of 157 different agricultural products in Türkiye to climatic parameters between 2004 and 2024, analyze their production trends, and evaluate product-based climate risk levels using data mining techniques.

Methodology- The study utilizes a comprehensive dataset consisting of annual production volumes of 157 agricultural products and 15 distinct meteorological

1. Dr. Öğr. Üyesi, Gümüşhane Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Gümüşhane, Türkiye, banubolayir@gumushane.edu.tr, ORCID ID: 0000-0003-3818-1989

2. **Sorumlu Yazar | Corresponding author:** Gümüşhane Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Gümüşhane, Türkiye, udemirel@gumushane.edu.tr, ORCID ID: 0000-0002-4992-5632

variables. The impacts of climatic variables on production were analyzed using Random Forest and Gradient Boosting machine learning algorithms to calculate feature importance levels. Furthermore, a Composite Risk Score (CRS) was developed to integrate production trends with climatic sensitivity indicators, classifying products into low, medium, and high-risk groups.

Findings- The analysis results indicate that the maximum temperature average is the most significant climatic variable affecting agricultural production, with an importance level of 60.42%. Based on the developed Composite Risk Score, 33.7% (53 products) of the 157 examined products were identified in the high-risk category. The relationship between production trends and climatic indicators was found to be more pronounced in specific products such as malting barley, watermelon, and silage maize.

Originality/Value- This study presents an integrated analytical approach for product-based risk assessment by combining machine learning algorithms with climatic variables and production trends. The developed Composite Risk Score contributes to the prioritization of climate-induced risks in agricultural production. The findings provide a data-driven framework for developing climate change adaptation strategies, sustainable agricultural planning, and decision-making processes.

Anahtar Kelimeler Gradient Boosting Bileşik Risk Skoru • İklim Değişikliği • Tarımsal Risk • Üretim Trendi

Keywords Gradient Boosting Composite Risk Score • Climate Change • Agricultural Risk • Production Trend

Atıf | Citation: Bolayır, Banu & Demirel, Uğur (2026). Türkiye’de İklimsel Parametrelerin Tarımsal Üretime Etkisinin Makine Öğrenmesi Yöntemleri ile Analizi: 157 Ürün Üzerinde Kapsamlı Bir Risk Değerlendirmesi (2004-2024). *Bilgi Sosyal Bilimler Dergisi*, 28 (1), 57-80. DOI: 10.54838/bilgisosyal.1987555

Extended Summary

Global climate change, characterized by the disruption of atmospheric thermodynamic structures due to anthropogenic activities, represents a direct and escalating threat to agricultural ecosystems. Owing to its geographical positioning within the Mediterranean Basin, Türkiye stands as one of the most vulnerable regions to rising temperatures, irregular precipitation regimes, and prolonged drought cycles. The intrinsic dependence of agricultural yields on climatic stability transforms this environmental phenomenon from a purely economic concern into a critical matter of national food security. While academic literature has extensively documented the impact of climate on specific staple crops or localized regions, there remains a significant research gap regarding comprehensive, large-scale assessments that integrate diverse product ranges with multivariate climatic data. This study addresses this gap by analyzing a 21-year time series (2004–2024) covering 157 different agricultural products and 15 distinct meteorological parameters, utilizing advanced data mining techniques to identify systemic vulnerabilities within Türkiye’s agricultural landscape.

The research methodology was constructed using secondary data compiled from the Turkish Statistical Institute and the General Directorate of Meteorology. To analyze the complex, non-linear relationships between climatic variables and production volumes, the study employed Random Forest and Gradient Boosting machine learning algorithms. These non-parametric models were selected for their superior ability to handle multi-collinearity and provide precise feature importance rankings. The variables evaluated included temperature extremes, total precipitation, humidity, sunshine duration, wind speed, and soil temperatures at depths ranging from 5 cm to 100 cm. A central contribution of this research is the development of a Composite Risk Score (CRS), which integrates the long-term production trend of each crop with its calculated climatic sensitivity. This integrated approach allows for a more nuanced classification of risk, moving beyond simple yield fluctuations to capture how climate stressors fundamentally drive production decline.

The results of the machine learning analysis indicate that average maximum temperatures are the most significant driver of production instability, accounting for a 60.42% importance level. This finding

suggests that heat-induced stress is a primary catalyst for crop failure and yield degradation in the region. Precipitation and soil temperatures were also identified as critical secondary factors. Through the application of the Composite Risk Score, the 157 examined products were categorized into distinct risk tiers. The analysis revealed that 33.7% of these products (53 crops) currently reside in the high-risk category. This group, which includes malting barley, watermelon, silage maize, and various essential vegetables, exhibits a dual vulnerability: a consistent long-term decrease in production and a high sensitivity to climatic anomalies. Conversely, approximately 23.8% of the products were identified as low risk, demonstrating relative resilience or independence from the current climatic shifts.

The findings conclude that the impact of climate change on Turkish agriculture is not uniform, necessitating a shift from generalized agricultural policies to product-specific and climate-oriented adaptation strategies. The high-risk status of over one-third of the analyzed crops highlights an urgent need for targeted interventions, including the development of drought-tolerant genotypes, the implementation of precision irrigation technologies, and the recalibration of agricultural insurance frameworks based on data-driven risk scores. By providing a macro-level assessment of agricultural vulnerability through the lens of machine learning, this study offers a scientific foundation for sustainable agricultural planning and climate resilience policies in Türkiye. The proposed methodology serves as a scalable model for other regions facing similar climatic threats, emphasizing the importance of integrating big data into national food security agendas.

This study contributes to understanding the impact of social media addiction on individuals' quality of life and helps raise awareness regarding social media use. Future research may explore the dynamics of these relationships in greater detail by focusing on mediating and moderating variables. Instead of making broad negative generalizations about social media use, studies should adopt the uses and gratifications approach to investigate what types of distress individuals seek to escape from in their daily lives through social media and what opportunities they aim to pursue within these platforms. In this context, conducting ethnographic research on the social media habits and motivations of different demographic groups appears to be of particular importance.

1. GİRİŞ

Doğal kaynakların insanlar tarafından bilinçsizce kullanılması ve sera gazlarının artması doğal dengeyi bozarak çok önemli sorunların ortaya çıkmasına neden olmuştur. Sera gazlarının atmosferdeki birikimlerinin çeşitli insan etkinlikleri nedeniyle hızla artması, yerkürenin enerji dengesi üzerinde fazladan bir pozitif ısınım salımları oluşturarak dünya ikliminin değişmesine neden olmuştur (Türkeş, 2012: 1). Daha açık bir ifade ile kloroflorokarbon (CFC) gazı ile diazot monoksit (N_2O), metan (CH_4), karbondioksit (CO_2) gibi sera gazlarındaki artışlar atmosferdeki ozon gazının yoğunluğunu azaltarak küresel ısınmaya ve küresel iklim değişikliğine yol açmıştır. Bu durum 19. yüzyılın ortalarından başlayarak günümüze kadarki geçen sürede küresel ortalama hava sıcaklığını $0.3^{\circ}C$ ile $0.6^{\circ}C$ artırmıştır. Yapılan hesaplamalara göre gelecekte 40 yıl içindeki her 10 yılda $0.1^{\circ}C$ 'den fazla miktarda küresel ısınmanın devam edeceği tahmin edilmektedir (Özmen, 2009: 43).

İklim değişikliği küresel ısınmadan kaynaklanmaktadır. İklim değişikliği, Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi'nde "Küresel atmosferin yapısını değiştiren ve karşılaştırılabilir zaman dilimlerinde gözlemlenen doğal iklim değişkenliğine ek olarak doğrudan veya dolaylı olarak insan faaliyetlerine atfedilen bir iklim değişikliği" olarak ifade edilmiştir (United Nations, 1992: 3). Houghton küresel ısınmayı, "İnsan faaliyetlerinin iklim üzerindeki etkisini, özellikle fosil yakıtların (kömür, petrol ve gaz) yanmasını ve en önemlisi CO_2 olan atmosfere büyük miktarlarda 'sera gazları' emisyonuna neden olan büyük ölçekli ormansızlaşma" olarak ifade etmiştir (Houghton, 2005: 1343). Dolayısıyla iklim değişiklikleri, küresel ısınmadan kaynaklanmaktadır. Küresel ısınma, ekosistem dengesini sarsarak

gıda arz güvenliğinin temelini oluşturan tarımsal üretim süreçlerini doğrudan tehdit etmektedir. 2004-2024 dönemini kapsayan güncel veriler, iklimsel anomalilerin tarımsal verimlilik üzerindeki baskısının kritik eşikleri aştığını ve ürün bazı risklerin sistematik bir artış eğiliminde olduğunu göstermektedir. Tarımsal üretimde sürdürülebilirliğin sağlanması, iklimsel değişimlerin ürün verimi üzerindeki etkilerinin önceden tahmin edilmesine bağlıdır. Türkiye’de iklim değişikliğinin tarımsal verim üzerindeki olası etkilerini nicel olarak değerlendirmek amacıyla simülasyon tabanlı bitki gelişim modelleri yaygın biçimde kullanılmaktadır (Gürkan, 2023; Konukcu vd., 2020). Bu modeller aracılığıyla buğday ve ayçiçeği gibi stratejik ürünlerin gelecekteki verim potansiyelleri üzerine senaryolar geliştirilmektedir.

Küresel ısınmayla birlikte iklim değişikliğinin yol açtığı kuraklık, sıcak hava dalgaları gibi olayların tarımsal üretimde olumsuz değişikliklere neden olacağı beklenmektedir (Tekeli, 2020: 2). Bu olumsuz değişiklikler her geçen yıl artmaktadır. Bu olumsuz değişikliklerden biri olan kuraklık bitkilerin büyümesini engellemekte ve dolayısıyla ürün veriminin azalmasına yol açmaktadır. Ayrıca iklim değişikliği, tarımsal üretimin azalmasına yol açmakta ve gıda güvenliğini tehlikeye sokmaktadır. Bu durumlar, tarım sektöründeki paydaşları da olumsuz olarak etkilemektedir. Küresel ısınma ile ilgili çalışmalar yapan birçok kuruluş, küresel ısınmayı önlemek için tarım, sanayi, ulaşım ve enerji sektörlerinde özellikle fosil yakıt kullanımının azaltılmasına yönelik gereken politika değişikliklerinin yapılmasıyla sera gazı emisyonunun azaltılmasının yaşanılabilir bir dünya için gerekli olduğunu bildirmektedirler (Korkmaz, 2007: 47). İklim değişikliğinin tarım sektörü üzerindeki olumsuz etkisi ekonomik, çevresel ve sosyal sorunlara yol açabilmektedir. Alınacak önlemler, gelecek nesillerin yeryüzünde aynı şartlarda yaşama hakkını koruma altına alarak sürdürülebilir kalkınmaya katkı sağlayacaktır.

Diğer yandan Türkiye, iklim yapısından dolayı özellikle küresel ısınmadan kaynaklı herhangi bir iklim değişikliğinden en fazla etkilenecek ülkelerden biridir. Üstelik Türkiye’nin üç tarafının denizler ile çevrili olması, topografyası ve orografik özellikleri nedeniyle Türkiye’deki farklı bölgeler iklim değişikliğinden farklı şekilde ve farklı derecelerde etkilenecektir (Öztürk, 2002: 58). Sıcaklık artışı ve yağış rejimindeki düzensizlikler, bitki fenolojisini doğrudan etkilemektedir. Bölgesel ölçekte yürütülen çalışmalar, bazı kültür bitkilerinin iklim değişimine uyum ve uygunluk düzeylerinin modellenmesinin, tarımsal adaptasyon stratejilerinin planlanması açısından kritik olduğunu göstermektedir (Şen vd., 2024). Ayrıca, Türkiye genelinde uzun dönemli iklim verileri ile temel tahıl ürünlerinin verimi arasındaki nedensellik ilişkilerinin ekonometrik yöntemlerle incelenmesi, iklimsel değişkenlerin üretim üzerindeki belirleyici rolünü teyit etmektedir (Doğar ve Çiçek, 2025).

Küresel ısınmaya bağlı olarak iklimde meydana gelen sürekli dalgalanmalar ve anomaliler, tarımsal üretim hacminin azalmasına, hatta bazı stratejik ürünlerin üretiminin durma noktasına gelmesine yol açmaktadır. Bu noktadan hareketle çalışmanın amacı; Türkiye’de iklimsel parametrelerdeki değişimlere en duyarlı ürün gruplarını belirlemek ve üretim riski taşıyan tarım ürünlerini makine öğrenmesi tabanlı duyarlılık analizi ile tespit etmektir. Çalışma kapsamında, iklim-üretim ilişkisini nicel olarak ortaya koymak amacıyla özgün bir Bileşik Risk Skoru (BRS) (Composite Risk Score- CRS) geliştirilmiştir. Analizlerde kullanılan veriler; Türkiye İstatistik Kurumu (TÜİK) ve Meteoroloji Genel Müdürlüğü’nün resmi kayıtlarından derlenmiştir (MGM, t.y.; TÜİK, t.y.). Geliştirilen bu modelleme yaklaşımı, üretim hacmi azalan ürünlerin önceden tespit edilerek sürdürülebilir kalkınmanın çevresel, sosyal ve ekonomik unsurlarının korunması açısından stratejik bir önem taşımaktadır. Tarımsal üretim süreçlerinde iklimsel değişkenler ile verim/üretim arasındaki ilişkinin ortaya konulmasında veri madenciliği ve makine

öğrenmesi yöntemlerinin kullanımı giderek yaygınlaşmaktadır.

Çalışma; giriş ve literatür taramasının ardından veri setini ve makine öğrenmesi algoritmalarını tanımlayan yöntem bölümüyle devam etmekte; bulgular iklim göstergelerindeki trendler, değişken önem dereceleri, üretim trendleri ve risk skoru dağılımları çerçevesinde aktarılmakta; ardından gelen tartışma bölümünde elde edilen sonuçlar mevcut literatürle karşılaştırılmakta ve çalışma sonuç ile değerlendirme bölümüyle tamamlanmaktadır.

2. LİTERATÜR İNCELEMESİ

Literatürde, farklı çevresel parametre ölçümleri ile yıllık verim verilerini bir araya getirerek ürün bazlı analizler yapan çalışmalar bulunmaktadır (Marinković vd., 2009). Ayrıca, seçilmiş tarım verileri üzerinde farklı regresyon tekniklerinin karşılaştırıldığı ve verim tahmininde destek vektör regresyonunun güçlü bir referans model olabileceğini gösteren çalışmalar rapor edilmiştir (Ruß, 2009). Tarımsal çıktıları etkileyen çoklu faktörlerin sınıflandırılması ve örüntülerin ortaya çıkarılması için karar ağacı ve kümeleme analizi gibi yöntemlerin kullanıldığı uygulamalar da mevcuttur (Yi-yang ve Nan-ping, 2009). Öte yandan, tarımsal planlama açısından çok sayıda mahsul için doğru verim tahmininin kritik olduğu; bu amaçla çoklu doğrusal regresyon, regresyon ağaçları, yapay sinir ağları, destek vektör regresyonu ve k-en yakın komşu gibi yöntemlerin karşılaştırmalı olarak değerlendirildiği görülmektedir (Gonzalez-Sanchez vd., 2014). Benzer biçimde, mahsul-hava-çevre etkileşimlerinin saha gözlemleri ve sensör verileriyle birlikte ele alındığı, olasılıksal sınıflandırma ve ilişkilendirme kuralı madenciliği gibi yaklaşımların kullanıldığı çalışmalar bulunmaktadır (Tripathy vd., 2014). Tarımsal verimlilik hakkında karar destek üretmeyi hedefleyen, çok boyutlu veri modelleri ve birliktelik kurallarıyla zenginleştirilen analiz çerçeveleri de rapor edilmiştir (Hira ve Deshpande, 2015).

Literatürde iklim faktörleri ile ürün verimi arasındaki ilişkileri görünür kılmak için veri görselleştirme ve sınıflandırma algoritmalarının birlikte kullanıldığı uygulamalar yer almakta; ayrıca çok sayıda ürün ve bölgeyi kapsayan senaryolar altında kümeleme ve regresyon temelli yaklaşımlarla parametre seçimine gidildiği çalışmalar da bulunmaktadır (Gandhi ve Armstrong, 2016; Majumdar vd., 2017). Bu çalışmaların yanı sıra, tarımsal ürün/kalite özelliklerinin veri madenciliğiyle tahmin edildiği, farklı sınıflandırıcıların performanslarının karşılaştırıldığı ve akıllı tarım sistemleri kapsamında çeşitli algoritmaların uygulandığı çalışmalar literatürde geniş bir yelpazede sunulmaktadır (Akçın ve Köse, 2023; Aydılek ve Sandıkçı, 2018; Demir vd., 2018; Macuácuá vd., 2023; Mishra vd., 2018; Muangprathub vd., 2019; Özer vd., 2022; Yadav vd., 2020). Makine öğrenmesi yöntemlerinin tarımsal veri setlerinde doğrusal olmayan ilişkileri yakalamadaki başarısı literatürde geniş biçimde rapor edilmektedir. Örneğin Mimić vd., (2020) meteorolojik parametrelerden türetilen özellikleri (feature engineering) Random Forest regresyon modeliyle birleştirerek mısır verimi üzerinde stres göstergeleri ve çevresel indeksler üretmişler, model açıklanabilirliği üzerinden hangi iklimsel bileşenlerin verim düşüşüne yol açtığını tartışmışlardır (Mimić vd., 2020). Bu tür çalışmalar, makine öğrenmesi çıktılarının yalnızca “tahmin” için değil, iklimsel stres/duyarlılık göstergelerinin türetilmesi için de kullanılabileceğini göstermektedir. Bu araştırmada da benzer biçimde, makine öğrenmesi tabanlı değişken önem analizleri “tahmin performansından” bağımsız olarak, ürünlerin iklim değişkenlerine göre göreceli hassasiyetinin ölçülmesi ve bu bilginin risk indeksleme aşamasına taşınması amacıyla kullanılmıştır.

Mevcut çalışmaların önemli bir bölümünün ürün verimini tahmin etmeye (yield prediction) ve

belirli ürün/bölge odaklı model karşılaştırmalarına yöneldiği; kullanılan yöntemlerin ise çoğunlukla makine öğrenmesi tabanlı regresyon ve sınıflandırma yaklaşımları etrafında toplandığı görülmektedir. Bu eğilim, tarımda veri analitiğinin yaygın kullanım alanlarını ortaya koymakla birlikte, çok sayıda ürünü aynı anda kapsayan ve üretim serilerindeki eksiklikleri dışlamadan değerlendirebilen risk-odaklı çerçevelerin görece sınırlı kaldığına işaret etmektedir. Nitekim Marko vd., (2017), verim öngörüsü temelli bir kurgu üzerinden farklı hava senaryolarını dikkate alarak çeşit seçimine yönelik analitik bir yaklaşım geliştirmişler; tarımsal performansın “risk” boyutunu tahmin çıktıları üzerinden değerlendirmişlerdir (Marko vd., 2017). Literatürdeki çalışmalar incelendiğinde, tarımsal verilerin analizinde geleneksel veri madenciliği tekniklerinin yaygın olarak kullanıldığı görülmektedir. Bu çalışma, söz konusu literatür birikimini temel almakla birlikte, analiz aşamasında karmaşık ve doğrusal olmayan ilişkileri modellemede daha yüksek performans sergileyen makine öğrenmesi algoritmalarından Random Forest ve Gradient Boosting yöntemlerini kullanarak literatüre metodolojik bir derinlik katmaktadır. Ayrıca, bu çalışma ürün bazlı risk önceliklendirmesi sunarak, iklim değişikliğine dirençli tarım politikalarının oluşturulması ve bölge bazlı adaptasyon stratejilerinin geliştirilmesi için veri temelli, kapsamlı bir rehber teşkil etmektedir.

3. VERİ VE MODEL

3.1 Veri

Bu çalışma, Türkiye tarımsal üretim sisteminin iklim değişkenlerine karşı duyarlılığını ve uzun dönemli kırılganlığını ortaya koymayı amaçlamaktadır. Analiz, 2004–2024 yıllarını kapsayan 21 yıllık dönem için yürütülmüş olup hem tarımsal üretim verileri hem de meteorolojik parametreler birlikte değerlendirilmiştir. Çalışmanın temel metodolojik yaklaşımı, üretim miktarlarındaki değişimi yalnızca gözlemsel trendler üzerinden değil, iklimsel stres faktörleriyle ilişkisi bağlamında ele almaktır. Tarımsal üretim verileri (TÜİK, t.y.), TÜİK tarafından yayımlanan bitkisel üretim istatistiklerinden elde edilmiştir. Analizin zamansal tutarlılığını sağlamak amacıyla, 2004–2024 dönemi boyunca kesintisiz üretim verisine sahip olan 157 ürün çalışma kapsamına dahil edilmiştir. Bu tercih, farklı ürünlerin farklı zaman aralıklarında raporlanmasından kaynaklanabilecek metodolojik sapmaları önlemek ve tüm ürünleri aynı iklimsel koşullar altında karşılaştırabilmek amacıyla yapılmıştır. Meteorolojik veriler (MGM, t.y.), Türkiye geneli yıllık ortalamaları temsil edecek şekilde derlenmiş olup; hava sıcaklıkları (ortalama, minimum ve maksimum), toplam yağış miktarı, buharlaşma, nem, rüzgâr hızı, kar örtülü gün sayısı, dolu yağışlı gün sayısı, güneşlenme süresi ile 5 cm, 10 cm, 20 cm, 50 cm ve 100 cm derinliklerindeki toprak sıcaklıklarını içeren toplam 15 iklimsel değişkenden oluşmaktadır. Tüm meteorolojik değişkenler üretim verileriyle aynı yıllara hizalanmış ve analiz öncesinde sayısal formata dönüştürülerek kontrol edilmiştir.

Analiz sürecinde herhangi bir veri interpolasyonu veya tahmini değer üretimi yapılmamıştır. Eksik yıl içeren ürünler analiz dışında bırakılmış, böylece sonuçların yalnızca gözlemlenmiş veriler üzerinden üretilmesi sağlanmıştır. Üretim miktarları mutlak değerler (ton) üzerinden değerlendirilmiş, logaritmik dönüşüm uygulanmamıştır. Bunun temel nedeni, üretimdeki yönlü değişimin (artış veya azalış) korunmak istenmesidir. Meteorolojik değişkenler arasında çoklu doğrusal bağlantı (multicollinearity) olasılığı göz önünde bulundurulmuş, ancak bu durum klasik doğrusal regresyon yerine ağaç tabanlı makine öğrenmesi yöntemlerinin tercih edilmesiyle metodolojik bir sorun olmaktan çıkarılmıştır. Analiz sürecinde, iklimsel değişkenlerin üretim üzerindeki etkisini belirlemek amacıyla topluluk öğrenme (ensemble learning) disiplinine ait algoritmalar tercih edilmiştir. Bu

yöntemlerin seçilme nedeni, tarımsal üretimdeki çok boyutlu ve doğrusal olmayan yapıyı, geleneksel regresyon modellerine göre daha düşük hata payı ve daha yüksek açıklanabilirlik (feature importance) ile modelleyebilmeleridir (Breiman, 2001; Friedman, 2001).

3.2. Model

İklim değişkenlerinin göreceli etkisinin belirlenmesi

Bu aşamada amaç, meteorolojik değişkenlerin tarımsal üretim miktarıyla ilişkisini doğrusal varsayımlara bağlı kalmadan değerlendirmek ve hangi iklim göstergelerinin daha fazla açıklayıcı sinyal taşıdığını ortaya koymaktır. Veri yapısı “ürün-yıl” düzeyindedir; her gözlem bir ürünün belirli bir yıldaki üretim miktarını (ton) ve aynı yıl için Türkiye geneli meteorolojik değişkenleri içermektedir. Analizde bağımlı değişken olarak üretim miktarı (ton), bağımsız değişkenler olarak ise meteorolojik parametreler kullanılmıştır. Doğrusal olmayan ilişkileri ve değişkenler arası etkileşimleri yakalayabilmek amacıyla iki ağaç tabanlı regresyon algoritması olan Random Forest Regressor ve Gradient Boosting Regressor denenmiştir.

Model performansı, test verisi üzerinde açıklayıcılık katsayısı (R^2) ve Ortalama Mutlak Hata (MAE) ile raporlanmıştır. Performans karşılaştırması “model performansı” sayfasında yer alan değerler üzerinden Tablo 1’de sunulmaktadır.

Tablo 1: Model performans karşılaştırması (test seti)

Model	R^2	MAE
Random Forest	-0.004180	1.182,778
Gradient Boosting	-0.004604	1.188,428


Çalışma kapsamında kurulan makine öğrenmesi modellerinde elde edilen negatif R^2 değerleri- R^2 , bir modelin bağımlı değişkenin varyansını açıklama oranını ifade etmekte olup sıfırın altındaki değerler modelin basit ortalama tahminden daha kötü performans sergilediğine işaret etmektedir- tarımsal üretimin doğasındaki çok boyutlu gürültüyü ve iklim dışı değişkenlerin baskınlığını ortaya koymaktadır. Tarımsal rekolte üzerinde; sulama altyapısı, gübreleme stratejileri, zirai ilaçlama, hükümet destekleri ve ekim alanlarındaki yapısal dönüşümler gibi model dışı bırakılan antropojenik faktörler, üretim varyansının büyük bir kısmını domine etmektedir. Bu doğrultuda kullanılan modeller, doğrudan bir üretim miktarı tahminleme mekanizması olmaktan ziyade, iklimsel değişkenlerin üretim trendleri üzerindeki göreceli hassasiyet ve etki derecelerini saptamak amacıyla bir duyarlılık analizi aracı olarak konumlandırılmıştır. Model tahmin performansının düşük seyretmesi, iklimsel değişkenlerin kendi arasındaki ağırlık hiyerarşisini ve ısı stresinin diğer parametrelere göre olan yüksek önem karakteristiğini (göreceli önem dereceleri) geçersiz kılmamaktadır. Analiz bu yönüyle, doğrudan bir projeksiyon sunmak yerine, iklimsel baskı noktalarını hiyerarşik olarak önceliklendiren bir risk çerçevesi çizmektedir.

Bu sonuçlar, meteorolojik değişkenlerin tek başına (ürün kimliği/ekim alanı/teknoloji/sulama/politika gibi üretimi güçlü biçimde belirleyen faktörler modele dahil edilmeden) üretim miktarını tahmin etme gücünün düşük olduğunu göstermektedir. R^2 değerlerinin sıfırın altında olması, modelin “ortalama tahmin” (baseline) yaklaşımından daha iyi performans üretemediğini ifade eder. Bu nedenle makine öğrenmesi çıktıları bu çalışmada “kesin tahmin modeli” olarak değil,

değişkenlerin görelî bilgi taşıma kapasitesini keşifsel olarak sıralamak amacıyla kullanılmıştır. Model performansı sınırlı olmakla birlikte, Gradient Boosting modeli üzerinden hesaplanan değişken önem dereceleri meteorolojik değişkenler arasında belirgin bir ayrışmaya işaret etmektedir (Tablo 1; Şekil 1). En yüksek önem derecesine sahip değişken maksimum sıcaklık ortalamasıdır (%60,42). Bunu toplam yağış (%11,98) ve 10 cm toprak sıcaklığı (%11,26) izlemektedir. Daha sık toprak sıcaklıkları, güneşlenme süresi ve kar örtülü gün sayısı gibi değişkenler daha düşük fakat ölçülebilir katkılar sunmaktadır. Bu bulgu, Türkiye genelinde üretim değişimlerinin özellikle ısı stresi (maksimum sıcaklık) ve su/toprak-ısı rejimi ekseninde daha belirgin bir iklimsel sinyal taşıdığı şeklinde yorumlanır (Şekil 1).

Tablo 2: İklim önem dereceleri

Değişken	Önem Derecesi
Maksimum sıcaklıkların ortalaması	60.41617
Toplam yağış	11.97896
10 cm toprak sıcaklıkları	11.25626
5 cm toprak sıcaklıkları	3.49206
Günlük güneşlenme süreleri	3.086752
Ortalama kar örtülü günler sayısı	2.433263
Ortalama nem	2.034255
Ortalama buharlaşma	1.422514
Minimum sıcaklıkların ortalaması	1.190208
Ortalama toplam dolulu yağışlı günler sayısı	0.755525
Ortalama sıcaklık	0.50661
50 cm toprak sıcaklıklar	0.477664
100 cm toprak sıcaklıkları	0.394071
20 cm toprak sıcaklıkları	0.38045
Ortalama rüzgâr	0.175234



Şekil 1: Tarımsal üretim üzerinde iklim değişkenlerinin önem derecesi

Üretim trendi analizi

Ürün bazında üretim trendini sayısallaştırmak için her ürünün 2004–2024 dönemindeki yıllık üretim serisi kullanılmış ve üretim miktarının zamanla değişimi basit doğrusal regresyon ile özetlenmiştir. Her ürün için Eşitlik (1)'deki doğrusal model kurulmuştur:

$$P_{i,t} = \alpha_i + \beta_i t + \varepsilon_{i,t} \quad (\text{Eş.1})$$

Burada $P_{i,t}$, i ürünü için t yılındaki üretim miktarı (ton); β_i ise “yıllık trend eğimi”dir (ton/yıl). Pratikte β_i , en küçük kareler yaklaşımı ile (örn. np. polyfit (yıl, ton, 1) gibi) hesaplanmıştır. Trend eğiminin işareti ve büyüklüğü, üretimin uzun vadede artış veya azalış gösterdiğini ifade eder.

Trend analizini daha anlaşılır hale getirmek için ayrıca dönem başı ve dönem sonu üretimleri kullanılarak yüzde değişim Eşitlik (2)'de olduğu gibi hesaplanmıştır:

$$\Delta\%_i = \frac{P_{i, \text{son}} - P_{i, \text{baş}}}{P_{i, \text{baş}}} \times 100 \quad (\text{Eş.2})$$

Bu yüzde değişime göre ürünler artış, stabil, azalış ve ciddi azalış olmak üzere dört kategoride değerlendirilmiştir (Şekil 3). Bu sınıflama, eğim bilgisini tamamlayıcı niteliktedir; çünkü β_i mutlak üretim ölçeğine (ton) duyarlı iken yüzde değişim göreceli değişimi yansıtır. Bununla birlikte yüzde değişim metriğinin, başlangıç yılındaki üretim çok küçükse aşırı büyük yüzdelere yol açabileceği de not edilmelidir (örn. bazı ürünlerde çok yüksek artış yüzdeleri bu nedenle oluşabilir.); bu nedenle yorumlar eğim ve yüzde değişim birlikte ele alınarak yapılmalıdır (FAO, 2023; Lobell ve Burke, 2010).

Tarımsal üretim risk skorlaması

Çalışmada kullanılan tarımsal risk analizi, Hükümetlerarası İklim Değişikliği Paneli (IPCC — Intergovernmental Panel on Climate Change) tarafından geliştirilen ve Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO — Food and Agriculture Organization) tarafından tarımsal sistemlere uyarlanan tehlike (hazard), maruziyet (exposure) ve kırılganlık (vulnerability) etkileşimine dayalı risk çerçevesini temel almaktadır (FAO, 2023; Field, 2012). Bu yaklaşıma göre tarımsal üretim riski, sadece iklimsel bir üç olayın (tehlike) varlığına değil; bu olayın üretim alanlarıyla ne ölçüde çakıştığına (maruziyet) ve ürünün bu değişimlere karşı ne kadar hassas olduğuna (kırılganlık) bağlı olarak şekillenmektedir.

Bu çalışmada risk skoru (R), Eşitlik (3)'deki bileşenlerin bir fonksiyonu olarak modellenmiştir:

$$R = f(H, E, V) \quad (\text{Eş.3})$$

Burada;

- Tehlike (H): Bölgesel meteorolojik verilerdeki ekstrem değişimleri (sıcaklık artış trendi ve yağış rejimindeki sapmalar)
- Maruziyet (E): İlgili ürünün toplam üretim miktarı ve zamansal sürekliliğini
- Kırılganlık (V): Ürünün iklimsel parametrelere (minimum sıcaklık, toplam yağış vb.) olan duyarlılığını ve üretim trendindeki negatif eğimi temsil etmektedir.

Bu metodolojik yaklaşım, ürünlerin sadece geçmişteki üretim kayıplarını değil, aynı zamanda değişen iklim koşulları altındaki göreceli hassasiyetlerini de puanlayarak, geniş ölçekli bir “Tarımsal Risk İndeksi” oluşturulmasına olanak sağlamıştır (FAO, 2023; Field, 2012).

Bu çalışmada “risk”, tek bir faktörden değil; (i) üretimin uzun dönem eğilimi ve (ii) üretimin iklim değişkenleriyle eş-zamanlı ilişkisi birlikte dikkate alınarak ölçülmüştür. Her ürün için üretim ile sıcaklık, üretim ile yağış ve üretim ile minimum sıcaklık arasındaki Pearson korelasyonu olmak üzere üç ayrı korelasyon katsayısı hesaplanmıştır. Bu katsayılar sırasıyla $r_{i,T}$, $r_{i,R}$ ve $r_{i,Tmin}$ ile gösterilsin.

Bileşik Risk Skoru (BRS) Eşitlik (4)’de tanımlanmaktadır:

$$BRS_i = 50 \cdot \left(\frac{-\beta_i}{1000} \right) + 20 \cdot |r_{i,T}| + 15 \cdot |r_{i,R}| + 15 \cdot |r_{i,Tmin}| \quad (\text{Eş. 4})$$

Bu formülde:

$-\beta_i$ terimi, trend negatifse (azalış) riski artırır; trend pozitifse (artış) skoru düşürür.

$|r|$ terimleri, ilişkinin yönünden bağımsız olarak iklim duyarlılığının büyüklüğünü yakalamayı amaçlar.

$\frac{1}{1000}$ ölçeği, β biriminin ton/yıl olmasından kaynaklanan büyüklüğü dengelemek için uygulanmıştır.

BRS hesaplamasında kullanılan ağırlıklandırma ve ölçekleme katsayıları, ürünlerin üretim hacimlerinden kaynaklanan uç değerleri minimize etmek ve farklı tonaj ölçeklerindeki ürünleri ortak bir paydada normalize etmek amacıyla belirlenmiştir. Formüldeki trend eğimi ve korelasyon katsayılarına atanan ağırlıklar (50/20/15/15), uzun dönemli üretim güvenliği perspektifinde trend sürdürülebilirliğine öncelik veren bir uzman kararı yaklaşımını yansıtmaktadır. Bu kurgu, tarımsal risk yönetiminde kullanılan çok kriterli karar verme süreçlerindeki ağırlıklandırma mantığıyla paralel olup, ürünlerin iklimsel kırılganlıklarını üretim hacminden bağımsız bir “nispi risk endeksi” üzerinden okumayı amaçlamaktadır (Hira ve Deshpande, 2015; Majumdar vd., 2017).


Son olarak ürünler BRS dağılımına göre üç eşit gruba ayrılarak düşük, orta ve yüksek risk sınıfları atanmıştır (Ek Tablo 1). Bu sınıflandırma BRS’nin “mutlak risk” değil, ürünler arası göreceli kırılganlık ölçüsü olarak kullanılmasını sağlamaktadır.

4. BULGULAR

4.1. İklim göstergelerinde 2004–2024 eğilimleri

Meteorolojik seri 2004–2024 döneminde Türkiye genelinde belirgin bir ısınma sinyali göstermektedir. Meteoroloji verileri üzerinden (Ek Tablo 2) dönem başı–sonu karşılaştırması yapıldığında ortalama sıcaklık 13.2°C’den 15.3°C’ye yükselerek toplamda +2.1°C, minimum sıcaklık 7.6°C’den 10.0°C’ye yükselerek +2.4°C, maksimum sıcaklık ise 19.2°C’den 21.4°C’ye yükselerek +2.2°C artış göstermiştir. Aynı dönemde toplam yağış 607.4 mm’den 567.0 mm’ye gerileyerek yaklaşık -40.4 mm azalmıştır. Doğrusal eğim yaklaşımıyla ifade edildiğinde sıcaklıklarda 10 yılda yaklaşık 0.76–0.89°C aralığında artış, yağışta ise 10 yılda yaklaşık 30.7 mm azalış eğilimi gözlenmektedir.

Bu bulgu, tarımsal üretim açısından “ısı stresi” ile “su stresi”nin birlikte artabileceği bir iklimsel çerçeveye işaret etmektedir. Şekil 2, sıcaklık serisinin daha net bir artış çizgisi izlerken yağış serisinin daha dalgalı ve kırılgan bir yapıda seyrettiğini görsel olarak desteklemektedir.



Şekil 2: Türkiye geneli sıcaklık ve yağış değişimi (2004-2024)


4.2. İklim değişkenlerinin üretimle ilişkisi ve değişken önemleri

Model performans değerleri (Tablo 1), tarımsal üretimin çok boyutlu yapısını yansıtmaktadır. Elde edilen sonuçlar; üretim hacminin yalnızca meteorolojik parametrelerle değil, aynı zamanda ekim alanı genişliği, sulama altyapısı, teknolojik girdi kullanımı ve tarım politikaları gibi sosyo-ekonomik değişkenlerle de doğrudan ilişkili olduğunu teyit etmektedir. Bu durum, çalışmanın analiz gücünü sınırlamak yerine, iklim-üretim etkileşiminin karmaşıklığını ortaya koyması açısından literatüre katkı sağlamaktadır. Bulgular, iklimin üretim seviyesini tek başına belirleyen bir unsur olmadığını göstermekle birlikte; hangi iklimsel boyutların (özellikle minimum sıcaklıklar ve yağış rejimi) üretim üzerinde daha kritik ve belirleyici sinyaller taşıdığını ayırt etmeyi mümkün kılmaktadır. Bu bağlamda çalışma, iklim değişikliğine karşı en hassas olan kritik eşikleri belirleyerek stratejik bir risk projeksiyonu sunmaktadır.

Bu çerçevede, tarımsal üretim üzerinde iklim değişkenlerinin önem derecesi (Şekil 1) ve iklim önem derecesi (Tablo 2) birlikte incelendiğinde, üretim değişimini açıklamada en baskın iklim değişkeninin maksimum sıcaklık ortalaması olduğu görülmektedir (%60,42). Bu durum, özellikle yaz dönemindeki aşırı sıcakların bitki fizyolojisinde (stomatal kapanma, fotosentez baskılanması, verim ve kalite kaybı) kritik etkiler yaratmasıyla tutarlıdır. Toplam yağışın (%11,98) ve 10 cm toprak sıcaklığının (%11,26) ikinci düzeyde önemli bulunması, su mevcudiyeti ve kök bölgesi ısıl koşullarının üretim üzerinde anlamlı bir sinyal taşıdığına işaret etmektedir. Diğer değişkenlerin önem derecelerinin düşük çıkması, bu çalışmanın ülke geneli yıllık ölçekte kurulmuş olmasının ve ürün bazında heterojen yönetim/alan etkilerinin modele yansıtılamamasının doğal bir sonucudur.

4.3. Üretim trendlerinin genel dağılımı


157 ürünün trend sınıfları Şekil 3'te özetlenmektedir. Sonuçlar, ürünlerin %67,5'inde artış, %9,6'sında azalış, %2,5'inde stabil seyir ve %20,4'ünde ciddi azalış olduğunu göstermektedir. Bu durum, Türkiye tarımında genel üretim kapasitesinin birçok üründe arttığını ancak hatırı sayılır bir ürün kümesinde üretimin sürdürülebilir biçimde gerilediğini göstermektedir.



Şekil 3: 157 ürünün 2004-2024 üretim trendi dağılımı

Buradaki kritik yorum şudur: üretimdeki artışlar, iklimin elverişli hale geldiğini kanıtlamaz; çoğu zaman sulama yatırımları, girdi yoğunlaşması, alan genişlemesi veya çeşit/teknoloji adaptasyonu ile iklimsel baskı telafi edilebilir. Buna karşılık ciddi azalış kümesinin varlığı, belirli ürünlerin iklimsel ve/veya yapısal baskılara karşı daha kırılgan olduğunu ve üretim sisteminin “ürün bazlı” risk yönetimi gerektirdiğini gösterir.

4.4. Üretimi en çok azalan ürünler ve risk ile tutarlılık



Şekil 4: Üretimi en çok azalan 15 ürün (2004-2024)

Şekil 4, 2004–2024 döneminde üretimi en fazla azalan 15 ürünü göstermektedir. Bu ürünler arasında korunga tohumu (-%92,95), tatlı patates (-%92,16), mısır (hasıl) (-%86,10), kuru bakla (insan tüketimi için) (-%80,56) ve acı bakla (insan tüketimi için) (-%79,20) ilk sıralarda yer almaktadır. Listede yem bitkileri ve baklagillerin belirgin biçimde görünmesi, su/ısı stresine duyarlılık ve üretim sistemindeki yapısal değişimlerin (alan kayması, tercih değişimi) birlikte etkili olabileceğine işaret eder.

Bu 15 ürünün tamamının Ek Tablo 1’de “yüksek” risk grubunda yer alması, trend-odaklı bulgular ile bileşik risk yaklaşımının birbirini tutarlı şekilde desteklediğini gösterir: üretimdeki keskin düşüşler, risk skorunu yükselten temel bileşenlerden biridir.

4.5. Risk skorlarının dağılımı ve iklim duyarlılığı örüntüsü

Ek Tablo 1’de risk grupları dengeli biçimde oluşmuştur: yüksek risk 53 ürün, orta risk 52 ürün, düşük risk 52 ürün en yüksek risk skorları arpa (biralık), karpuz ve mısır (hasıl) gibi ürünlerde gözlenmektedir. Bu ürünlerde risk skorunun yükselmesinde, üretim trend eğimlerinin belirgin negatif olması ve üretimin sıcaklık/minimum sıcaklık ile negatif ilişkiler göstermesi etkili olmuştur.

Gruplar arası örüntü daha net görülebilsin diye risk gruplarının ortalama korelasyonları karşılaştırıldığında güçlü bir ayrışma ortaya çıkar: yüksek risk grubunda üretim–sıcaklık korelasyonu ortalama olarak negatiftir (ortalama ≈ -0.21), üretim–yağış korelasyonu ise pozitifdir (ortalama $\approx +0.13$). Bu, yüksek riskli ürünlerde sıcaklık artışının üretimi baskıladığını, yağışın ise üretimi destekleyen bir faktör olarak öne çıktığını işaret etmektedir. Düşük risk grubunda ise üretim–sıcaklık korelasyonunun pozitif, üretim–yağış korelasyonunun negatif ortalamaya sahip olması (sırasıyla $\approx +0.56$ ve ≈ -0.24), üretimi artan ürünlerde ısınma trendiyle paralel büyüme ve teknolojik/altyapısal uyumun rolünü ortaya koymaktadır. Bu sonuç, “iklim etkisi tüm ürünlerde aynı yönde değildir; bazı ürünlerde iklimsel baskı üretimi düşürürken bazı ürünlerde adaptasyon ve yapısal uyum etkileri üretimi artırabilir” şeklinde yorumlanmalıdır.

5. TARTIŞMA

Bu çalışmada elde edilen bulgular, Türkiye tarım-iklim ilişkisine dair mevcut literatürle hem örtüşen hem de özgün katkılar sunan sonuçlar içermektedir.

Maksimum sıcaklığın %60,42’lik değişken önem derecesiyle en baskın iklimsel belirleyici olarak öne çıkması, iklim değişikliğinin tarımsal üretim üzerindeki etkilerini ele alan uluslararası literatürle büyük ölçüde uyum içindedir. Lobell ve Burke (2010), küresel ölçekte sıcaklık artışlarının tahıl verimlerinde belirgin azalışlara yol açtığını ve sıcaklığın yağışa kıyasla daha tutarlı bir negatif sinyal taşıdığını göstermiştir. Porter vd. (2014), IPCC AR5 sentezinde, iklim değişikliğinin özellikle düşük enlemlerdeki (low-latitudes) tahıl üretimini doğrudan tehdit ettiğini ve adaptasyon önlemleri alınmadığı takdirde sıcaklık artışlarının stratejik ürün verimlerinde ciddi oranlarda kayıplara yol açacağını ortaya koymuştur. Porter vd. (2014)’e göre, 2030-2049 dönemi için yapılan projeksiyonların önemli bir kısmı ciddi verim kayıplarına işaret etmekte; her on yıllık ısınma periyodunun küresel verimlilik artışını yaklaşık %1 oranında baskılayacağı öngörülmektedir. Türkiye özelinde Doğar ve Çiçek (2025) ile Konukcu vd. (2020), sıcaklık artışlarının buğday ve arpa verimlerini olumsuz etkilediğini ve bu etkinin yağış değişkenliğinden daha belirleyici olduğunu saptamıştır. Çalışmamızdaki maksimum sıcaklık bulgusu bu çalışmalarla tutarlı biçimde örtüşmektedir.

Yağışın (%11,98) ve 10 cm toprak sıcaklığının (%11,26) ikinci sırada önemli bulunması, su stresi ve kök bölgesi ısı koşullarının üretim üzerindeki sinyal taşıma kapasitesini doğrular niteliktedir. Bu bulgu, Gürkan (2023) ve Hira ve Deshpande (2015) tarafından da vurgulanan toprak-su-iklim etkileşiminin tarımsal modelleme çalışmalarında göz ardı edilmemesi gerektiği argümanı ile uyumludur.

Model performansı açısından elde edilen negatif R^2 değerleri (Random Forest: -0,004180; Gradient Boosting: -0,004604), makine öğrenmesi tabanlı çalışmalarda sıkça karşılaşılan bir durumu

yansıtmaktadır: ulusal ölçekte ve yıllık frekansta kurulan modeller, ekim alanı, sulama altyapısı ve tarım politikaları gibi kritik kontrol değişkenlerini kapsayamadığından meteorolojik değişkenlerle tek başına üretimi tahmin etmekte yetersiz kalmaktadır. Gonzalez-Sanchez vd. (2014), büyük ölçekli tahıl verimi tahminlerinde benzer sınırlamaları raporlamış; meteorolojik değişkenlerin yeterli bağlamsal değişkenler olmadan model performansını sınırladığını vurgulamıştır. Bu nedenle çalışmamızdaki ML modelleri, tahminsel değil keşifsel sinyal sıralaması aracı olarak kullanılmış; negatif R^2 değerleri metodolojik bir başarısızlık olarak değil, tarımsal üretimin çok belirleyicili yapısının doğal bir yansıması olarak yorumlanmaktadır.

Ürün bazlı üretim trendleri incelendiğinde, 157 ürünün yaklaşık %30'unda sistematik bir üretim gerilemesi gözlemlenmiştir. Bu heterojen durum, Majumdar vd. (2017) tarafından vurgulanan; tarımsal verilerin karmaşıklığı ve farklı ürün gruplarının iklimsel değişkenlere (sıcaklık ve yağış) verdiği özgün yanıtların analiz edilmesi gerekliliği ile metodolojik olarak örtüşmektedir. Majumdar vd. (2017), büyük veri setlerinin analiz edilmesinin ürün bazlı özgün duyarlılıkları ortaya çıkararak tarımsal sistemleri iklim değişikliğine karşı daha dirençli (resilient) hale getirdiğini belirtmektedir. Çalışmamızda kullanılan BRS yaklaşımı, bu metodolojik vizyonu Türkiye'deki 157 ürün özelinde somutlaştırarak, farklı ürün gruplarının iklimsel anomalilere verdiği heterojen yanıtları (bazı ürünlerde artış, bazılarında sistemik azalış) başarılı bir şekilde tasnif etmiştir.

Bu çalışmanın literatüre özgün katkısı şu iki noktada toplanmaktadır: (i) Türkiye'de 157 ürünü kapsayan böylesine geniş ölçekli bir makine öğrenmesi tabanlı risk sınıflandırmasının daha önce yapılmamış olması ve (ii) üretim trendi ile iklim duyarlılığını bütünleştiren BRS yaklaşımının, kaynakların veri temelli dağıtılmasına imkân tanıyan özgün bir risk endeksi sunmasıdır. Bununla birlikte, bu metodolojik sınırlılıkların (tek model, ton bazlı bağımlı değişken, ulusal meteoroloji ortalamaları) olası iyileştirme yollarını da içeren bir çerçevede açıkça tartışılması, çalışmanın bilimsel güvenilirliğini artırmaktadır.

6. SONUÇ VE DEĞERLENDİRME

Bu çalışma, Türkiye'nin zengin tarımsal ürün deseninin iklim değişikliği karşısındaki kırılganlığını 2004-2024 dönemini kapsayan 21 yıllık bir perspektifle ve makine öğrenmesi tabanlı analitik modellerle ortaya koymuştur. Elde edilen bulgular, Türkiye tarımının iklimsel parametrelere karşı homojen bir tepki vermediğini, aksine ürün bazlı derin farklılıklar barındırdığını göstermektedir. Makine öğrenmesi modellerinden elde edilen değişken önem dereceleri, Türkiye genelinde tarımsal üretimi belirleyen en baskın iklimsel faktörün yağış miktarından ziyade “maksimum sıcaklık” ortalamalarındaki artış olduğunu kanıtlamıştır. %60,42 gibi yüksek bir açıklayıcılık oranına sahip olan bu bulgu, tarımsal planlamada sadece klasik kuraklık yönetimine değil, ısı stresine dayanıklı çeşitlerin geliştirilmesine ve fenolojik dönemlerin sıcaklık artışına göre yeniden takvimlenmesine odaklanılması gerektiğini bilimsel bir temele dayandırmaktadır.

Çalışma kapsamında analiz edilen 157 ürünün üretim trendleri incelendiğinde, Türkiye tarımında genel üretim kapasitesinin birçok üründe artış eğiliminde olduğu, ancak yaklaşık %30'luk bir ürün grubunda sistematik ve sürdürülebilir bir gerileme yaşandığı saptanmıştır. Üretim artışı gösteren ürünlerdeki başarının, iklimsel baskının teknoloji kullanımı, sulama yatırımları ve girdi yoğunlaşmasıyla telafi edilmesinden kaynaklandığı düşünülmektedir. Buna karşılık, özellikle yem bitkileri ve bazı baklagillerde gözlenen keskin azalış trendleri, bu ürün gruplarının iklimsel ve yapısal risklere karşı daha savunmasız olduğunu ortaya koymaktadır. Geliştirilen özgün BRS, ürünleri sadece

üretim miktarlarındaki değişimle değil, aynı zamanda iklimsel değişkenlerle olan eş-zamanlı korelasyonlarıyla birlikte değerlendirilerek literatüre yeni bir metodolojik çerçeve sunmuştur.

Yapılan risk sınıflandırması sonucunda, incelenen ürünlerin üçte birinin “yüksek risk” grubunda yer alması, tarımsal gıda arz güvenliği açısından stratejik bir uyarı niteliği taşımaktadır. Arpa (biralık), karpuz ve mısır (hasıl) gibi ürünlerde gözlenen yüksek risk skorları, bu ürünlerin hem üretim trendindeki negatif eğilimden hem de sıcaklık anomalilerine karşı gösterdikleri yüksek duyarlılıktan kaynaklanmaktadır. Bu bağlamda, tarımsal destekleme politikalarının ve tarım sigortası primlerinin, bu çalışmada sunulan risk skorları gibi veri temelli modellerle entegre edilmesi, kaynakların daha etkin dağıtılmasını sağlayacaktır.

Bu çalışmanın bazı metodolojik sınırlılıklarının bilimsel dürüstlük açısından paylaşılması gerekmektedir. Birincisi, fenolojik özellikleri ve iklim istekleri bakımından birbirinden belirgin biçimde farklılaşan 157 ürün, tek bir makine öğrenmesi modeli içinde analiz edilmiştir. Bu yaklaşım, ulusal ölçekte genel sinyal sıralamasına imkân tanımakla birlikte, ürün bazlı iklim duyarlılıklarını tam olarak ortaya koyamamaktadır. İkincisi, bağımlı değişken olarak toplam üretim (ton) tercih edilmiştir; iklim etkisini ekim alanı ve altyapısal faktörlerden arındırmak için birim alan verimi (kg/ha) kullanımı daha uygun olmakla birlikte bu verinin 157 ürün için 21 yıllık eksiksiz serisi mevcut değildir. Üçüncüsü, meteorolojik veriler yıllık Türkiye ortalaması biçiminde kullanılmış olup ürünlerin kritik fenolojik dönemleri ve bölgesel iklim farklılıkları kapsam dışında kalmıştır. Dördüncüsü, BRS formülündeki ölçekleme ve ağırlıklandırma parametreleri uzman kararına dayalı normatif bir yapıyı yansıtmakta; ağırlıkların ampirik olarak doğrulanması gelecek çalışmalara bırakılmaktadır. Bu sınırlılıklar, elde edilen bulguların ürün bazında kesin nedensellik iddiaları olarak değil; keşifsel ve gösterge niteliğinde bulgular olarak yorumlanmasını gerektirmektedir. Gelecek çalışmalarda bölge ve ürün grubu bazlı modeller, fenoloji-dönemi meteoroloji verileri ve birim alan verimi serileri kullanılarak bu sınırlılıkların aşılması önerilmektedir.

Politika önerileri açısından değerlendirildiğinde, bu çalışmanın bulguları birkaç kritik yönlendirme sunmaktadır: (i) Tarımsal destekleme politikalarında yüksek risk skoruna sahip ürün gruplarına öncelik verilmesi; (ii) Tarım sigortası primlerinin iklim duyarlılığı skorlarıyla entegre edilmesi; (iii) Yem bitkileri ve baklagiller başta olmak üzere ciddi üretim kaybı gözlenen ürünler için bölge bazlı adaptasyon eylem planlarının hazırlanması; (iv) Ulusal tarım iklim bilgi sistemlerinin güçlendirilerek ürün-bölge-sezon bazlı meteorolojik izleme kapasitesinin artırılması.

||Beyan ve Açıklamalar/Disclosure Statements ||

Beyan	Bu çalışmanın yazarı, Bilgi Dergisi’nce beyan edilen araştırma ve yayın etiği ilkelerine uyduğunu beyan etmektedir
Çıkar Çatışması	Yazar çıkar çatışması bildirmemiştir.
Finansal destek	Yazar bu çalışma için finansal destek almadığını beyan etmiştir.
Disclosure	The author confirms that his work complies with the principles of research and publication ethics announced by Bilgi
Conflict of Interest	The author has no conflict of interest to declare
Grant Support	The author declared that this study has received no financial support

Kaynakça

- Akçın, H., ve Köse, R. T. (2023). Tarım arazilerinde değişime neden olan parametrelerin Google Earth Engine veri madenciliği ve WebCBS uygulaması ile değerlendirilmesi. *Journal of the Institute of Science and Technology*, 13(2): 1363-1376. <https://doi.org/10.21597/jist.1192622>
- Aydilek, İ., ve Sandıkçı, Y. (2018). Tarımsal veri analizlerinin veri madenciliği ile yapılması. *Harran Üniversitesi Mühendislik Dergisi*, 3(2): 1-7. <https://izlik.org/JA67SL94FB>
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1): 5-32. <https://doi.org/10.1023/A:1010933404324>
- Demir, B., Gürbüz, F., Eski, İ., ve Kuş, Z. A. (2018). Meyve renk özelliklerini tahmin etmek için veri madenciliği yaklaşımı. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 49(1): 37-43. <https://izlik.org/JA24UR29PK>
- Doğar, D., ve Çiçek, A. (2025). Türkiye’de İklim Verileri ile Buğday ve Arpa Verimi Arasındaki Nedensellik İlişkisinin Toda-Yamamoto Testi ile Belirlenmesi. *Tekirdağ Ziraat Fakültesi Dergisi*, 22(2): 411-427. <https://doi.org/10.33462/jotaf.1483052>
- FAO. (2023). The impact of disasters on agriculture and food security 2023. FAO. <https://doi.org/10.4060/cc7900en>
- Field, C. B. (2012). Managing the risks of extreme events and disasters to advance climate change adaptation: Special report of the intergovernmental panel on climate change. Cambridge University Press.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5): 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Gandhi, N., ve Armstrong, L. J. (2016). Rice crop yield forecasting of tropical wet and dry climatic zone of India using data mining techniques. 2016 IEEE International Conference on Advances in Computer Applications (ICACA), 357-363. <https://doi.org/10.1109/ICACA.2016.7887981>
- Gonzalez-Sanchez, A., Frausto-Solis, J., ve Ojeda-Bustamante, W. (2014). Predictive ability of machine learning methods for massive crop yield prediction. *Spanish Journal of Agricultural Research*, 12(2): 313-328. <https://doi.org/10.5424/sjar/2014122-4439>
- Gürkan, H. (2023). Evaluation of the Impacts of Climate Change on Sunflower with Aquacrop Model. *Tekirdağ Ziraat Fakültesi Dergisi*, 20(4): 933-947. <https://doi.org/10.33462/jotaf.1240401>
- Hira, S., ve Deshpande, P. S. (2015). Data analysis using multidimensional modeling, statistical analysis and data mining on agriculture parameters. *Procedia Computer Science*, 54: 431-439. <https://doi.org/10.1016/j.procs.2015.06.050>
- Houghton, J. (2005). Global warming. *Reports on Progress in Physics*, 68(6), 1343-1403. <https://doi.org/10.1088/0034-4885/68/6/R02>
- Konukcu, F., Deveci, H., ve Altürk, B. (2020). Trakya Bölgesi’nde İklim Değişikliğinin Buğday Verimine Etkisinin AquaCrop ve WOFOST Modeller ile Tahmin Edilmesi. *Tekirdağ Ziraat Fakültesi Dergisi*, 17(1): 77-96. <https://doi.org/10.33462/jotaf.593883>

- Korkmaz, K. (2007). Küresel ısınma ve tarımsal uygulamalara etkisi. *Alatarım Dergisi*, 6(2): 43-49.
https://arastirma.tarimorman.gov.tr/alata/Belgeler/alatarim/alatarim012_2007_12.pdf#page=46
- Lobell, D. B., ve Burke, M. B. (2010). On the use of statistical models to predict crop yield responses to climate change. *Agricultural and Forest Meteorology*, 150(11): 1443–1452.
<https://doi.org/10.1016/j.agrformet.2010.07.008>
- Macuácuá, J. C., Centeno, J. A. S., ve Amisse, C. (2023). Data mining approach for dry bean seeds classification. *Smart Agricultural Technology*, 5: 100240.
<https://doi.org/10.1016/j.atech.2023.100240>
- Majumdar, J., Naraseeyappa, S., ve Ankalaki, S. (2017). Analysis of agriculture data using data mining techniques: Application of big data. *Journal of Big Data*, 4(1): 20.
<https://doi.org/10.1186/s40537-017-0077-4>
- Marinković, B., Crnobarac, J., Brdar, S., Antić, B., Jaćimović, G., ve Crnojević, V. (2009). Data mining approach for predictive modeling of agricultural yield data. *Proc. First Int Workshop on Sensing Technologies in Agriculture, Forestry and Environment (BioSense09)*, Novi Sad, Serbia, 1-5.
- Marko, O., Brdar, S., Panić, M., Šašić, I., Despotović, D., Knežević, M., ve Crnojević, V. (2017). Portfolio optimization for seed selection in diverse weather scenarios. *PloS One*, 12(9): e0184198. <https://doi.org/10.1371/journal.pone.0184198>
- MGM. (t.y.). Meteorolojik Parametrelerin Türkiye Analizi. Resmi İklim İstatistikleri. <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=parametrelerinTürkiyeAnalizi> (Erişim Tarihi: 01.03.2026)
- Mimić, G., Brdar, S., Brkić, M., Panić, M., Marko, O., ve Crnojević, V. (2020). Engineering meteorological features to select stress tolerant hybrids in maize. *Scientific Reports*, 10(1): 3421. <https://doi.org/10.1038/s41598-020-60366-y>
- Mishra, S., Paygude, P., Chaudhary, S., ve Idate, S. (2018). Use of data mining in crop yield prediction. *2018 2nd International Conference on Inventive Systems and Control (ICISC)*, 796-802. <https://doi.org/10.1109/ICISC.2018.8398908>
- Muangprathub, J., Boonnam, N., Kajornkasirat, S., Lekbangpong, N., Wanichsombat, A., ve Nillaor, P. (2019). IoT and agriculture data analysis for smart farm. *Computers and Electronics in Agriculture*, 156: 467-474. <https://doi.org/10.1016/j.compag.2018.12.011>
- Özer, B., Kuş, S., ve Yıldız, O. (2022). Veri madenciliği yöntemleri ile tarımsal veri analizi: Bir akıllı tarım sistemi önerisi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(4): 1417-1429. <https://doi.org/10.21923/jesd.1081814>
- Özmen, M. T. (2009). Sera gazı-küresel ısınma ve Kyoto Protokolü. *İMO Dergisi*, 453(1): 42-46.
- Öztürk, K. (2002). Küresel iklim değişikliği ve Türkiye'ye olası etkileri. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 22(1). <https://izlik.org/JA74YE23AW>
- Porter, J. R., Xie, L., Challinor, A. J., Cochrane, K., Howden, S. M., Iqbal, M. M., Lobell, D. B., ve Travasso, M. I. (2014). Food security and food production systems. In C. B. Field vd. (Eds.), *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and*

- Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change (ss. 485–533). Cambridge University Press.
- Ruß, G. (2009). Data mining of agricultural yield data: A comparison of regression models. Perner, P. (Ed.), In *Advances in Data Mining. Applications and Theoretical Aspects* (5633: 24-37). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-03067-3_3
- Şen, A., Deveci, H., ve Konukcu, F. (2024). Trakya Bölgesi'nde Üretilen Bazı Kültür Bitkilerinin İklim Değişimine Uyumunun Modellenmesi. *Tekirdağ Ziraat Fakültesi Dergisi*, 21(2): 501-516. <https://doi.org/10.33462/jotaf.1312707>
- Tekeli, İ. (2020). İklim değişikliğinin tarıma etkileri stratejiler ve politikalar. İklim Değişikliğinin Ülkemizdeki Önemli Tarım Ürünlerinin Uygunluk Alanları Üzerine Etkilerini Belirliyoruz, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, E-Bülten, 7. (Erişim Linki: https://www.tarimorman.gov.tr/TAGEM/Belgeler/E_BULTEN/ebu%CC%88lten_Temmuz_2020.pdf)
- Tripathy, A. K., Adinarayana, J., Vijayalakshmi, K., Merchant, S. N., Desai, U. B., Ninomiya, S., Hirafuji, M., ve Kiura, T. (2014). Knowledge discovery and leaf spot dynamics of groundnut crop through wireless sensor network and data mining techniques. *Computers and Electronics in Agriculture*, 107: 104-114. <https://doi.org/10.1016/j.compag.2014.05.009>
- TÜİK. (t.y.). Bitkisel Üretim İstatistikleri. <https://biruni.tuik.gov.tr/medas/?kn=92&locale=tr> (Erişim Tarihi: 02.03.2026)
- Türkeş, M. (2012). Türkiye'de gözlenen ve öngörülen iklim değişikliği, kuraklık ve çölleşme. *Ankara Üniversitesi Çevre Bilimleri Dergisi*, 4(2), 1-32. https://doi.org/10.1501/Csaum_00000000063
- United Nations. (1992). United Nations Framework Convention on Climate Change (UNFCCC). (Erişim Linki: <https://unfccc.int/resource/docs/convkp/conveng.pdf>)
- Yadav, S. A., Sahoo, B. M., Sharma, S., ve Das, L. (2020). An analysis of data mining techniques to analyze the effect of weather on agriculture. 2020 International Conference on Intelligent Engineering and Management (ICIEM), 29-32. <https://doi.org/10.1109/ICIEM48762.2020.9160110>
- Yi-yang, G., ve Nan-ping, R. (2009). Data mining and analysis of our agriculture based on the decision tree. 2009 ISECS International Colloquium on Computing, Communication, Control, and Management, 134-138. <https://doi.org/10.1109/CCCM.2009.5267962>

Ek Tablo 1: Tüm Ürünler İçin Risk Skorları

Ürün	Risk Skoru	Trend Eğimi	Yüzde Değişim	Sıcaklık Korelasyon	Yağış Korelasyon	Minimum Sıcaklık Korelasyon	Risk Grubu
Arpa (Biralık)	1342.026	-26313.4	-66.6667	-0.65163	0.228609	-0.65964	Yüksek
Karpuz	1341.463	-26408.2	-16.3922	-0.52653	0.193852	-0.50773	Yüksek
Mısır (Hasıl)	940.5134	-18285.1	-86.0982	-0.68594	0.112782	-0.72329	Yüksek
Sofralık Üzüm, Çekirdekli	444.1534	-8618.1	-6.05627	-0.25417	0.314148	-0.23019	Yüksek
Kavun	428.7674	-8227.21	-15.4857	-0.47189	-0.04681	-0.48446	Yüksek
Pırasa	334.6877	-6204.45	-48.7197	-0.59843	0.214832	-0.61826	Yüksek
Hayvan Pancarı	332.5324	-6089.71	-76.1894	-0.68181	0.242485	-0.71823	Yüksek
Mercimek, Kuru (Kırmızı)	276.0808	-5305.11	-15.625	-0.23033	0.183571	-0.231	Yüksek
Soğan (Taze)	242.0268	-4310.94	-47.7372	-0.64256	0.22486	-0.68374	Yüksek
Patlıcan	189.045	-3514.48	-8.11067	-0.35319	-0.00513	-0.41203	Yüksek
Şaraplık Üzümler	170.9301	-3214.48	2.902162	-0.26628	0.049701	-0.27566	Yüksek
Lahana (Kara Yaprak)	138.0317	-2131.7	-50.3284	-0.75247	0.319741	-0.77341	Yüksek
Fasulye, Taze	125.5256	-2191.77	-12.8761	-0.33709	0.326987	-0.28603	Yüksek
Tatlı Patates	122.7281	-1946.85	-92.16	-0.56341	0.36658	-0.57458	Yüksek
Kurutmalık Üzüm, Çekirdekli	112.8875	-2087.83	-9.41343	-0.07363	0.464531	0.003703	Yüksek
Burçak (Yeşilot)	90.27425	-1618.84	166.0556	-0.07722	0.414954	-0.10423	Yüksek
Portakal (Yafa)	85.14764	-1195.64	-40.6243	-0.51298	0.511881	-0.4952	Yüksek
Pamuk, Çırcırlanmış (Lifli)	64.95433	-1176.59	-11.3276	-0.17313	-0.06124	-0.11624	Yüksek
Tütün, İşlenmemiş	63.83024	-1000.52	-29.5976	-0.26373	-0.24786	-0.32077	Yüksek
Zerdali	62.65759	-831.839	-28.6667	-0.51569	0.147323	-0.56946	Yüksek
Bakla, Kuru (İnsan Tüketimi İçin)	57.46532	-657.09	-80.555	-0.60012	0.198098	-0.64247	Yüksek
Mürdümük	55.52927	-746.597	-68.6889	-0.48395	-0.02764	-0.54039	Yüksek
Bakla, Kuru (Yemlik)	44.07925	-394.461	-73.09	-0.55158	0.323974	-0.56434	Yüksek
Bamya	43.74914	-494.091	-34.5302	-0.47658	0.102598	-0.5316	Yüksek
Burçak (Dane)	41.39222	-545.826	-20.88	-0.21382	0.406099	-0.24886	Yüksek
Bakla, Taze	41.21652	-516.868	-32.4714	-0.40132	-0.04826	-0.44152	Yüksek
Susam Tohumu	39.08009	-399.801	-37.2217	-0.44518	0.196702	-0.48239	Yüksek
Çavdar	38.31865	-583.065	-4.81481	-0.06717	0.510935	0.010537	Yüksek
Darı	32.34899	-174.283	-46.0857	-0.56557	0.218135	-0.60343	Yüksek
Turp (Bayır)	31.36912	-283.99	-37.1756	-0.44036	0.084741	-0.47276	Yüksek
İğde	30.40928	-45.0143	-22.2857	-0.6599	0.330427	-0.66694	Yüksek

Börülce, Kuru	28.69582	-81.439	-43.5652	-0.57126	0.280161	-0.59975	Yüksek
Haşhaş Tohumu	28.65687	-350.144	-52.6026	-0.16583	0.429869	-0.09233	Yüksek
Acı Bakla (İnsan Tüketimi İçin)	27.86175	-17.9649	-79.2	-0.62697	0.338406	-0.6232	Yüksek
Muşmula	23.11963	49.36883	28.33333	0.579966	-0.34016	0.592419	Yüksek
Kaplıca	22.51638	-244.938	-72.2235	-0.23161	0.139375	-0.23644	Yüksek
Haşhaş Kapsülü (Haşhaş Kellesi)	22.26558	-252.658	-60.3953	-0.13333	0.408502	-0.0559	Yüksek
Sorgum	22.15804	-14.3805	-72.5714	-0.44633	0.35485	-0.4793	Yüksek
Kenevir Tohumu	22.08154	14.07013	1753.333	0.533011	-0.29109	0.517231	Yüksek
Kuşkonmaz	21.70776	83.1	19791.67	0.605328	-0.3168	0.600285	Yüksek
Anason, İşlenmemiş	20.74788	-160.425	-53.6182	-0.23273	0.325436	-0.21271	Yüksek
Yer Elması	20.63422	64.31688	2310	0.6449	0.016737	0.7134	Yüksek
Lahana (Brüksel)	17.57426	97.41039	132.5263	0.556976	-0.15802	0.595663	Yüksek
Üçgül (Yeşilot)	17.07401	-64.5221	6000	-0.29611	0.256547	-0.27184	Yüksek
Pazı	16.2924	123.7727	19.4	0.546112	-0.22155	0.549034	Yüksek
Kereviz (Sap)	14.05088	-28.3247	-44.7059	-0.25854	-0.18218	-0.3154	Yüksek
Ahududu	14.0382	283.1688	224.5909	0.670421	-0.27571	0.710166	Yüksek
Yenidünya (Malta Eriği)	13.79471	261.2468	62.75676	0.637498	-0.27825	0.662219	Yüksek
Buy (Çemen Otu)	12.58712	40.25455	35.2	0.277463	-0.33306	0.270312	Yüksek
Marul (Göbekli)	12.30213	-193.131	12.771	0.08	0.015489	0.054216	Yüksek
Korunga Tohumu	12.22006	-95.2766	-92.95	0.065009	0.403607	-0.0068	Yüksek
Kenevir, Lif	11.17583	11.05325	102.6667	0.296397	-0.12656	0.26014	Yüksek
Börülce, Taze	9.93697	-26.961	-12.1154	-0.19215	0.191311	-0.12509	Yüksek
Yonca Tohumu	9.468503	-78.1545	-33.4286	0.093725	0.241949	0.003802	Orta
Mandalina (King)	8.945553	9.162338	26.02	0.074888	0.418463	0.108597	Orta
Bezelye, Kuru	8.759199	-43.7221	52.94286	-0.14326	0.086482	-0.16071	Orta
Turunç	6.886029	5.581818	43.04	0.131368	-0.23531	0.067207	Orta
Kuş Yemi	5.910704	361.6221	1046.786	0.510477	-0.4259	0.492919	Orta
Kimyon, İşlenmemiş	5.801764	118.0312	13.45333	0.21787	0.224353	0.265374	Orta
Şalgam	4.933647	-11.2584	205.4	-0.06617	-0.13818	-0.06498	Orta
Şerbetçiotu Kozalağı	4.772894	-6.21169	-31	-0.07229	0.147782	-0.05332	Orta
İspanak	1.956681	35.38571	11.36901	0.039465	-0.17226	0.023517	Orta
Kızılıçık	1.369954	29.93506	-20.8	-0.01096	0.166843	0.009658	Orta
Tere	1.328209	503.5961	631.5333	0.616862	-0.28653	0.658187	Orta
Enginar	1.060527	361.1403	26.92333	0.337961	-0.45882	0.365067	Orta
Dereotu	-1.26094	605.2571	903.2	0.70309	-0.27468	0.721325	Orta
Semizotu	-2.04549	482.1818	619.65	0.528837	-0.21725	0.548541	Orta
Kereviz (Kök)	-2.52224	527.5442	75.77576	0.5311	-0.34616	0.53604	Orta
Keçiboynuzu (Harnup)	-2.7036	555.4364	78.57143	0.573057	-0.32263	0.584509	Orta
Kırmızı Pancar	-9.88373	602.474	388.1	0.469524	-0.23301	0.490294	Orta
Mercimek, Kuru (Yeşil)	-17.3917	573.0325	18.33333	0.254755	-0.16742	0.243574	Orta
Nane	-21.7519	977.9403	304.9538	0.627295	-0.32438	0.648907	Orta
Dut	-25.0616	788.039	49.04	0.387803	-0.0134	0.425551	Orta
Acur	-28.279	1133.318	112.2727	0.679098	-0.28969	0.697309	Orta
Kekik, İşlenmemiş	-28.4627	1025.04	160.1857	0.512221	-0.28666	0.549669	Orta

Nohut, Kuru	-28.8683	734.4506	-7.25806	0.224516	0.00164	0.222623	Orta
Bal Kabağı	-36.0304	1086.326	31.21389	0.468566	-0.06498	0.529326	Orta
Sarımsak (Taze)	-36.7653	1148.391	103.48	0.459004	-0.30749	0.457454	Orta
Portakal (Washington)	-39.4712	985.9779	4.072653	0.06	0.467004	0.108176	Orta
Kestane	-41.4717	1344.199	51.63265	0.613746	-0.24704	0.650517	Orta
Pamuk, Çırçırılanmamış (Kütlü)	-46.0162	1027.488	-8.63808	-0.15433	-0.06806	-0.08338	Orta
Barbunya, Taze	-49.6812	1246.29	24.76667	0.330341	0.00648	0.395283	Orta
Mandalina (Klemantin)	-64.3838	1631.105	11.992	0.46748	-0.0054	0.516064	Orta
Roka	-66.0925	1828.403	1753.833	0.592302	-0.28469	0.614084	Orta
Biber (Dolmalık)	-66.9905	1668.762	12.33787	0.385497	-0.19343	0.389079	Orta
Avokado	-70.2883	1838.747	16025	0.509417	-0.24274	0.521312	Orta
Aspir Tohumu	-71.4343	1686.816	19233.33	0.330022	0.033153	0.387249	Orta
Elma (Amasya)	-85.7204	1846.164	31.78833	0.140318	0.101442	0.150653	Orta
Vişne	-90.0433	2249.292	49.78261	0.619543	0.047017	0.621679	Orta
Bezelye, Taze	-91.0253	2191.634	139.1155	0.456772	-0.11545	0.512614	Orta
Turp (Kırmızı)	-106.84	2546.073	10.086	0.425906	-0.3617	0.434668	Orta
Kabak (Çerezlik)	-110.419	2795.856	575.1524	0.705824	-0.27895	0.738193	Orta
Mantar (Kültür)	-113.207	2845.578	402.2667	0.666804	-0.35662	0.692423	Orta
Arpa (Diğer)	-114.44	2360.675	-3.7037	-0.10723	-0.01434	-0.08229	Orta
Sofralık Üzüm, Çekirdeksiz	-131.139	2686.639	4.18975	-0.05565	0.132893	0.00578	Orta
Marul (İceberg)	-137.777	3295.016	656.5133	0.649878	-0.23801	0.693757	Orta
Sarımsak (Kuru)	-143.858	3383.94	48.80952	0.566735	-0.34595	0.587693	Orta
Maydanoz	-159.649	3734.638	168.334	0.648166	-0.27814	0.663163	Orta
Pamuk Çekirdeği (Çiğit)	-161.532	3285.129	-5.6142	-0.07823	-0.07656	-0.00075	Orta
Durum Buğdayı	-168.731	3454.545	-12	-0.11029	0.029284	-0.0901	Orta
Greyfurt (Altıntop)	-191.422	4109.519	11.11111	0.346242	0.073093	0.402196	Orta
Fasulye, Kuru	-203.243	4454.274	11.6	0.443644	-0.24805	0.458454	Orta
Kivi	-205.668	4671.166	2206.225	0.648917	-0.31206	0.682102	Orta
Trabzon Hurması (Cennet Elması)	-214.211	4810.232	738.7294	0.634368	-0.26032	0.647242	Orta
İncir (Yaş)	-258.146	5596.545	36.36364	0.51617	-0.19069	0.566497	Orta
Marul (Kıvırcık)	-260.668	5714.535	62.85741	0.552618	-0.3745	0.559288	Düşük
Kanola veya Kolza Tohumu	-270.691	5842.475	2148.889	0.565667	0.053193	0.621416	Düşük
Brokoli	-272.94	6043.094	1927.108	0.685667	-0.32677	0.70665	Düşük
Ayva	-282.449	6193.953	153.9825	0.63021	-0.31406	0.662214	Düşük
Kurutmalık Üzüm, Çekirdeksiz	-290.148	5859.936	7.306136	0.020539	-0.08494	0.077568	Düşük
Kamabahar	-327.785	7124.69	137.6836	0.702186	-0.2202	0.740204	Düşük
Lahana (Kırmızı)	-339.803	7320.325	93.41429	0.613069	-0.27323	0.656865	Düşük
Yulaf	-341.62	7243.578	41.81818	0.461591	-0.27562	0.479524	Düşük
Erik	-343.557	7400.869	79.04762	0.614246	-0.30631	0.640426	Düşük
Ayçiçeği Tohumu (Çerezlik)	-356.075	7596.851	240	0.598436	-0.15158	0.634981	Düşük
Soya Fasulyesi	-358.429	7628.109	260	0.537575	-0.2369	0.578103	Düşük
Badem	-374.147	8024.973	440.5405	0.621746	-0.33508	0.642698	Düşük

Yerfıstığı, Kabuklu	-379.1	8165.8	208.495	0.68441	-0.33873	0.694738	Düşük
Lahana (Beyaz)	-424.866	8961.555	32.0714	0.532944	-0.28687	0.549986	Düşük
Fındık	-452.879	9399.33	104.8571	0.311212	-0.42096	0.30326	Düşük
Şam Fıstığı (Antep Fıstığı)	-456.353	9668.686	1176.667	0.636516	-0.29876	0.657961	Düşük
Elma (Granny Smith)	-462.579	9800.56	738.212	0.654687	-0.26096	0.696035	Düşük
Ceviz	-539.005	11328.05	238.0952	0.64863	-0.30485	0.656819	Düşük
Nektarin	-563.702	11829.68	863.2946	0.664431	-0.29332	0.672928	Düşük
Triticale	-616.483	12855.67	258.9474	0.605384	-0.32488	0.621332	Düşük
Biber (Sivri)	-637.449	13119.54	31.42113	0.441296	-0.14726	0.499535	Düşük
Biber, Kuru, İşlenmemiş	-651.348	13553.97	1054.29	0.722391	-0.02584	0.767672	Düşük
Armut	-659.446	13769.35	97.03125	0.700503	-0.26399	0.736757	Düşük
Buğday, Durum Buğdayı Hariç	-700.535	14200	2.5	-0.21119	0.224833	-0.12458	Düşük
Havuç	-703.227	14497.03	103.6884	0.554968	-0.12117	0.58052	Düşük
Sofralık Zeytinler	-754.941	15409.35	191.5795	0.293984	-0.32717	0.315915	Düşük
Diğer Portakallar	-812.861	16721.35	119.41	0.604856	-0.10921	0.631379	Düşük
Çay Yaprakları	-825.57	17084.74	31.2248	0.756957	-0.11126	0.79059	Düşük
Kabak (Sakız)	-858.811	17712.3	97.4613	0.616845	-0.32864	0.635823	Düşük
Şeftali	-974.065	20050.79	145.5588	0.656655	-0.33518	0.687588	Düşük
Çeltik	-983.446	20150.71	107.9592	0.597248	-0.15646	0.653206	Düşük
Elma (Golden)	-1049.86	21471.76	52.31779	0.554436	-0.27121	0.571245	Düşük
Kayısı	-1063.94	21577.92	296.5625	0.290378	-0.31344	0.296689	Düşük
Kiraz	-1208.55	24724.15	196.5306	0.676536	-0.23703	0.704659	Düşük
Elma (Starking)	-1241.82	25232.93	55.93924	0.437242	-0.30797	0.430993	Düşük
Çilek	-1241.9	25378.26	291.1316	0.635015	-0.2884	0.665851	Düşük
Mandalina (Satsuma)	-1397.67	28430.18	88.6205	0.587041	-0.18066	0.625754	Düşük
Soğan (Kuru)	-1552.23	31441.95	29.01961	0.404264	-0.39737	0.388337	Düşük
Nar	-1735.04	35268.95	863.5959	0.67272	-0.28587	0.711206	Düşük
Yağlık Zeytinler (Zeytinyağı Üretimi İçin)	-1827.3	36818.78	115.3068	0.266213	-0.24901	0.305275	Düşük
Muz, Plantain Ve Benzerleri	-2093.67	42415.37	573.0769	0.619783	-0.34274	0.63732	Düşük
Mandalina (Diğer)	-2594.83	52415.21	501.6963	0.629371	-0.24726	0.642331	Düşük
Biber (Salçalık, Kapyra)	-2740.1	55384.73	215.6351	0.692171	-0.31409	0.705247	Düşük
Limon ve Misket Limonu	-2842.85	57345.42	188.3333	0.614056	-0.18617	0.623274	Düşük
Diğer Elmalar	-3410.4	68790.35	688.0545	0.686239	-0.31334	0.713119	Düşük
Ayçiçeği Tohumu (Yağlık)	-3695.5	74436.59	131.875	0.603748	-0.29879	0.651855	Düşük
Patates (Tatlı Patates Hariç)	-3822.38	76878.76	44.65409	0.54153	-0.16728	0.547655	Düşük
Korunga (Yeşilot)	-4502.67	90469.67	444.0111	0.515121	-0.12595	0.574446	Düşük
Mısır	-12381.7	248159.7	170	0.607297	-0.29831	0.643562	Düşük
Şeker Pancarı	-21177.8	424045.4	65.81762	0.607297	-0.20627	0.614736	Düşük
Yonca (Yeşilot)	-51454.9	1029613	654.0917	0.623531	-0.21517	0.67403	Düşük
Mısır (Slaj)	-59367	1187914	338.3049	0.668257	-0.31598	0.70464	Düşük

Ek Tablo 2: Meteorolojik veriler (2004-2024)

Yıllar	5 Cm Toprak Sıcaklıkları	10 Cm Toprak Sıcaklıkları	20 Cm Toprak Sıcaklıkları	50 Cm Toprak Sıcaklıkları	100 Cm Toprak Sıcaklıkları	Toplam Yağış	Ortalama Sıcaklık	Ortalama Buharlaşma	Ortalama Rüzgâr	Ortalama Nem	Ortalama Kar Örtülü Günler Sayısı	Ortalama Toplam Dolulu Yağışlı Günler Sayısı	Minimum Sıcaklıkların Ortalaması	Maksimum Sıcaklıkların Ortalaması	Günlük Güneşlenme Süreleri
2004	16,1	16	15,8	15,6	15,5	607,4	13,2	6	2	62,2	36	0,549	7,6	19,2	6,9
2005	16	15,9	15,7	15,6	15,5	637,2	13,3	5,9	1,9	63,2	25,4	0,896	7,9	19,2	6,7
2006	16,2	16,1	15,9	15,7	15,6	607,4	13,3	6,2	1,9	63,6	31,3	0,903	7,9	19,3	6,8
2007	16,4	16,2	16	15,8	15,7	596,7	13,8	6,6	2	61,3	25,9	0,993	8,2	19,8	6,8
2008	16,8	16,2	15,8	15,7	15,7	463,1	13,6	6,4	2	61	31,9	0,986	8	19,7	6,9
2009	16,9	16,4	15,9	15,7	15,6	793,8	13,7	6	1,9	63,8	19,5	2,069	8,4	19,5	6,5
2010	18,1	17,6	17,1	16,8	16,6	703	15,1	6	1,9	62,9	12,7	1,806	9,7	20,1	6,5
2011	16,8	15,8	15,3	15,3	15,5	642,2	12,8	6	2	63,1	20,2	1,84	7,6	18,7	6,7
2012	16,7	16,5	16,3	15,9	15,7	695,2	13,8	6,2	2	62,1	39,9	1,507	8,5	19,7	6,8
2013	16,7	16,6	16,5	16,3	16	547	13,8	6,1	1,9	59,6	23,8	1,611	8,3	19,9	6,8
2014	17,1	17	15,5	15,3	15,2	641,6	14,5	5,6	1,9	62,6	11,2	1,576	9,3	20,5	6,5
2015	16,6	16,5	16,4	16,1	15,9	637,8	13,8	5,7	1,9	62,4	25,5	1,542	8,6	19,8	6,5
2016	16,5	16,6	16,6	16,3	16,1	605,7	14	5,9	2	61,1	29,5	1,667	8,5	20,2	6,6
2017	16	16	15,9	15,7	15,5	553,4	13,7	6,1	1,9	61,5	25,8	1,208	8,3	20	6,5
2018	17,1	17,1	17,1	16,7	16,5	639,2	15,1	5,9	1,9	64,4	9,4	1,563	10	21,1	6,1
2019	16,3	16,4	16,4	16,1	15,8	639,7	14,4	6,1	1,9	63,4	17,6	1,236	9,1	20,4	6,6
2020	16,4	15,9	15,9	15,9	15,8	507,6	14,6	6,2	1,9	61,6	39,4	1,521	9,2	20,7	6
2021	16,3	16,4	16,4	16,2	16,1	579,7	14,5	6,5	1,9	60,6	18,1	2,686	9,1	20,7	6,5
2022	16,1	16,3	16,2	15,9	15,7	530,1	14,1	6	1,9	62,2	45,7	2,09	8,9	20,1	6,5
2023	16,2	16,1	16,3	16,1	16	624,9	14,8	5,6	1,9	63,9	12,5	2,22	9,5	20,8	6,4
2024	16,9	16,2	17	16,7	16,6	567	15,3	6	1,9	62,6	11,7	2,245	10	21,4	6,7