

GAZİ

JOURNAL OF ENGINEERING SCIENCES

Predicting Yield and Vegetative Growth in Apples Using Mathematical Modeling Methods

Hamit Armağan^a, Ersin Atay^b

Submitted: 26.11.2023 Revised: 19.12.2023 Accepted: 19.12.2023 doi:10.30855/gmbd.0705S19

ABSTRACT

Keywords: machine learning,
fourier regression,
mathematical modeling

^a Süleyman Demirel Üniversitesi,
Rektörlük, Enformatik Bölümü, 32200
Isparta/TÜRKİYE
Orcid: 0000-0002-8948-1546
e-mail: hamitarmagan@sdu.edu.tr

^b Burdur Mehmet Akif Ersoy Üniversitesi,
Burdur Gıda Tarım ve Hayvancılık Meslek
Yüksekokulu Burdur/TÜRKİYE
Orcid: 0000-0003-0810-3779

*Corresponding author:
hamitarmagan@sdu.edu.tr

This study aims to predict the yield and vegetative growth of 'Golden Reinders' apple trees grafted on M.9 rootstock over the economic lifespan of an orchard (15 years). Mathematical models with high determination coefficients were applied to data collected during the first 7 years following orchard establishment in the "Göller Yöresi" region. Fifteen trees were selected after orchard establishment, and their yield and trunk diameter values were recorded over a 7-year period. Regression models for yield and vegetative growth were developed using data processed with the Matlab program. Results were comparatively evaluated, revealing the power regression model as prominent in determining the year-tree trunk diameter relationship, while the Fourier regression model took precedence in establishing the tree trunk diameter-yield relationship. The study concludes that understanding how yield and vegetative growth evolve throughout the economic lifespan of apple orchards can be effectively achieved through such modeling approaches.

Matematiksel Modelleme Yöntemleri ile Elmada Verim ve Vejetatif Gelişimin Tahmin Edilmesi

ÖZ

Bu çalışmada elma ağaçlarında yüksek belirleme katsayısına sahip matematiksel modellemelerle bahçe tesisini takip eden ilk 7 yıl verisine dayalı olarak bahçenin ekonomik ömrünü (15 yıl) kapsayacak şekilde verim ve vejetatif gelişimin tahmin edilmesi amaçlanmıştır. Göller Yöresi şartlarında yürütülen çalışmada M.9 anaçlı 'Golden Reinders' elma çeşidine ait ağaçlar kullanılmıştır. Bahçe tesisini takiben toplamda 15 ağaç belirlenmiş ve 7 yıl boyunca aynı ağaçların verim ve gövde çapı değerleri belirlenmiştir. Matlab programı yardımıyla toplanan verilere dayalı verim ve vejetatif gelişim regresyon modellemeleri yapılmıştır. Sonuçlar karşılaştırmalı olarak değerlendirilmiş ve yıl-ağaç gövde çapı ilişkisinin belirlenmesinde kuvvet regresyon modeli, ağaç gövde çapı-verim ilişkisinin belirlenmesinde ise fourier regresyon modeli ön plana çıkmıştır. Elma bahçelerinin ekonomik ömrü boyunca verim ve vejetatif gelişim nasıl bir seyir izler sorusunun cevabının ancak bu tarz modellemeler yardımıyla cevaplanabileceği sonucuna varılmıştır.

Anahtar Kelimeler:
makine öğrenmesi,
fourier regresyon,
matematiksel modelleme

1. Giriş (Introduction)

Tarımsal üretimde verimi arttırmaya yönelik çalışmalar hız kesmeden devam etmektedir [1]. Tarımda yapay zekâ modellerinin kullanımı bu çalışmaların en önemlileri arasında yer almaktadır [2]. Yapay zekâ modellerinin temeli matematiksel ve istatistiksel yöntemlerdir [3]. Matematiksel fonksiyon ve algoritmalarla veri kümelerinin modellenmesi ile araştırılan konuya yönelik tahminlerin yapılabilmesine olanak sağlanmaktadır [4], [5].

Regresyon modelleri, girdi ve çıktı değişkenleri arasında matematiksel fonksiyonlar ile sürekli değişkenlere ait yanıtları tahmin eder [6]–[8]. Regresyon yöntemi ile modelleme, bağımlı değişken ile bağımsız değişken arasındaki ilişkinin bir fonksiyon ile temsil edilmesidir [6], [9]. Bu fonksiyonun temel amacı modellenen sistem ile ilgili tanım kümesindeki değerlere bağlı olarak tahminlerin hesaplanmasıdır [6]. Pek çok regresyon modeli bulunmaktadır (doğrusal, doğrusal olmayan, üstel ve logaritmik gibi) [9]–[12]. Birçok durumda, tek girdi değişkeni kullanan doğrusal regresyon, ilişkili modellerde yeterli tahmin gücü sunamayabilir [6]. Bu durum, araştırmacıları, regresyon modeli için girdi olarak aynı anda iki ya da daha fazla değişkenin kullanıldığı çoklu doğrusal olmayan regresyon modeline yöneltmiştir [13]–[15].

Son yıllarda tarımsal üretimde matematiksel modellere dayalı farklı yapay zeka teknolojilerinin kullanımı verimi artırma ve maliyetleri düşürme konusunda dikkat çekici sonuçlar sağlamıştır [1], [16], [17]. Mevcut tarım teknolojilerine entegre edilen güvenilir modeller; verim artışı, hastalık teşhisi ve sulama etkinliğinin artırılmasında rol oynamaya başlamıştır [3], [18]. Elma bahçeleri özelinde kullanılabilir matematiksel modelleme yöntemlerinin geliştirilmesi ticari bahçelerin daha rekabetçi bir noktaya ulaşabilmesi açısından kritiktir [19]. Böylelikle işlemler yoğun mesai gerektiren faaliyetlerde işgücü gereksinimi planlayabilme ve pazarlama organizasyonlarını daha etkin şekilde gerçekleştirebilme potansiyeline sahip olabilirler [19], [20].

Türkiye’de tarım sektörü, ekonomik büyüklük olarak hizmet ve sanayi sektörlerinin ardından üçüncü sırada gelmektedir (TÜİK, 2023). Son verilere göre Türkiye’de 306 milyar TL bitkisel üretim değeri içerisinde meyve üretiminin payı %28, meyve üretim değeri içerisinde elma üretiminin payı ise %11 olarak gerçekleşmiştir (TÜİK, 2023). İthalat ve ihracat verileri incelendiğinde, Türkiye’nin elmada her zaman ihracat fazlası veren bir ülke olduğu görülmektedir. 2020 yılı itibarı ile Türkiye elma ihracatı (1.52 milyon ton; aynı yıl 4.30 milyon ton olan toplam ülke üretiminin %35.34’ü) ve ihracat-ithalat farkı (1.24 milyon ton) rekor seviyeye ulaşmıştır (TÜİK, 2023). Türkiye tarihte ilk defa 2021 yılında dünya elma üretiminde ABD’nin de önüne geçerek Çin’in ardından dünyada sıralamasında ikinciliğe yükselmiştir (FAOSTAT, 2023).

Elmanın ülke tarımı için büyük öneme sahip olduğu açıktır. Bununla birlikte Türkiye’de hemen hemen tüm tarım sektöründe olduğu gibi elma endüstrisinde de ileri tarım teknolojilerine geçiş süreci oldukça sancılı şekilde devam etmektedir [19], [23], [24]. Nitekim tarım sektörünün modernleşmesi ve yapay zekaya dayalı uygulamaların daha hassas şekilde ele alınması ülke kaynaklarının daha etkin şekilde kullanılabilmesi açısından önem arz etmektedir.

Bu bağlamda çalışmada; elma ağaçlarında yüksek belirleme katsayısına sahip matematiksel modellemelerle bahçe tesisini takip eden ilk 7 yıl verisine dayalı olarak bahçenin ekonomik ömrünü (15 yıl) kapsayacak şekilde verim ve vejetatif gelişimin tahmin edilmesi amaçlanmıştır.


2. Materyal ve Metot (Material and Method)

2.1. Materyal (Material)

Çalışma Göller Yöresi şartlarında yürütülmüştür. Bitkisel materyal olarak 4 × 1 m aralıklarla dikilmiş (250 ağaç/dekar) M.9 anacına aşılı ‘Golden Reinders’ çeşidi elma ağaçları kullanılmıştır. Bahçe Merkezkaç sistemine göre terbiye edilmiştir. Bahçe düzenli aralıklarla damla sulama yöntemiyle sulanmış ve tüm kültürel işlemler lokal koşullara göre gerçekleştirilmiştir. Deneme süresince yörede ilkbahar geç donları ya da dolu gibi herhangi bir olumsuz iklim olayı yaşanmamıştır.

2.2. Veri toplama (Data collection)

Bahçeden 15 ağaç belirlenerek etiketlenmiş ve bahçe tesisini takip eden ilk 7 yıl verim ve vejetatif gelişim verileri boyunca aynı ağaçlardan toplanmıştır. Hasat zamanında ağaç verimi (kg/ağaç) değerleri kaydedilmiştir. Vejetatif gelişimi belirlemek için ağaç gövde çapı değerleri aşu noktasının 15 cm üzerinden dijital kumpas yardımıyla ölçülmüştür. Elmada ağaçlarında verim ve vejetatif gelişimin tahmin edilmesine ait veri toplama ve modelleme süreçleri şekil 1’de verilmiştir.



Şekil 1. Matematiksel modelleme yöntemleri ile elmada verim ve vejetatif gelişimin tahmin edilmesine ait süreçler
(Processes of estimating yield and vegetative development in apples using mathematical modeling methods)

2.3. Matematiksel modelleme (Mathematical modeling)

Verim ve vejetatif gelişim verileri düzgün dağılım göstermediği için, çalışmada doğrusal olmayan çoklu regresyon teknikleri kullanılmıştır. Verim değerleri genotipe ve çevresel faktörlere bağlı olarak yıllar bazında değiştiği için Ağaç Gövde Çapı-Verim İlişkisinin belirlenmesinde fourier regresyon modeli kullanılmıştır. Yıl-Ağaç Gövde Çapı İlişkisinin belirlenmesinde ise 5 farklı model (polinom regresyon, üstel regresyon, logaritmik regresyon, fourier regresyon ve kuvvet regresyonu) kullanılmıştır. Uygun regresyon modelini belirlemede uzman görüşü temeline dayanan bir uzman sistem yöntemi kullanılmıştır. Uzmanlar, regresyon modellerinin seçimindeki deneyim ve bilgilerini kullanarak analizin doğruluğunu artırmışlardır [3], [4], [6], [7].

Çalışmada denenilen/kullanılan regresyon modelleri aşağıda listelenmiştir. Listede 1, 2, 3, 4 ve 5 numaraları sırasıyla polinom, üstel, logaritmik, fourier ve kuvvet regresyon modellerini temsil etmektedir.

$$f(x) = ax^2 + bx + c \quad (1)$$

$$f(x) = ae^{(bx)} + ce^{(dx)} \quad (2)$$

$$f(x) = a \ln(x) + b \quad (3)$$

$$f(x) = a + b \cos(wx) + c \sin(wx) \quad (4)$$

$$f(x) = ax^b \quad (5)$$

2.3.1. Polinom regresyon (Polynomial regression)

Polinom regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için polinom fonksiyonlarını kullanarak bir regresyon modeli oluşturma yöntemidir. Genel olarak n. dereceden bir polinom regresyon modeli şu şekildedir:

$$y = a_0 + a_1x + a_2x^2 + \dots + a_nx^n \quad (6)$$

Burada $a_0, a_1, a_2, \dots, a_n$ katsayıları modelin öğrenilmiş parametreleridir ve regresyon analizi ve lineer denklem sistemleri ile değerleri hesaplanır. Polinom regresyon uygulanırken, modelin derecesinin seçilmesi

önemlidir. Çünkü düşük dereceli bir model veri setindeki karmaşıklığı yakalayamazken, benzer şekilde yüksek dereceli model de aşırı uyuma yol açabilmektedir.

2.3.2. Üstel regresyon (Exponential regression)

Üstel regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için üstel fonksiyonları kullanarak bir regresyon modeli oluşturma tekniğidir. Genel olarak birinci dereceden bir üstel regresyon modeli şu şekildedir:

$$y = a_0 + a_1 e^{(a_2 x)} \quad (7)$$

Burada a_0 ve a_1 katsayıları modelin öğrenilmiş parametreleridir. x bağımsız, y bağımlı değişken olup e Euler sayısıdır.

2.3.3. Logaritmik regresyon (Logarithmic regression)

Logaritmik regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için logaritmik fonksiyonları kullanan bir regresyon türüdür. Genel olarak logaritmik regresyon modeli şu şekildedir:

$$y = a_0 + a_1 \ln(x) \quad (8)$$

burada a_0 ve a_1 katsayıları modelin öğrenilmiş parametreleridir. x bağımsız, y bağımlı değişken olup "ln" doğal logaritma fonksiyonudur.

2.3.4. Fourier regresyon (Fourier regression)

Fourier regresyonu, bir periyodik fonksiyonu (veri setlerinin periyodik bir grafiğe sahip olması) sinüs ve kosinüs terimlerinin toplamı olarak ifade eden bir regresyon yöntemidir. Genel olarak Fourier regresyon modeli şu şekildedir:

$$f(x) = y = a_0 + \sum_{i=1}^n a_i \cos(iwx) + b_i \sin(iwx) \quad (9)$$

Burada $f(x)$ periyodik fonksiyon ve a_0 , a_n ve b_n Fourier katsayılarıdır.

2.3.5. Kuvvet regresyonu (Power regression)

Bağımsız değişkenin bir bağımlı değişken üzerinde üstel bir etkiye sahip olduğu durumları modellemek için kullanılan regresyon yöntemidir. Temel kuvvet regresyon modeli;

$$f(x) = ax^b \quad (10)$$

şeklinde, burada a ve b regresyon katsayılarıdır.

3. Sonuçlar ve Tartışma (Results and Discussion)

3.1. Yıl-Ağaç gövde çapı ilişkisi (Year-Tree trunk diameter relationship)

Bu çalışmada, ağaç gövde çapı artışını tahmin etmek amacıyla farklı regresyon modelleri kullanılmış ve bu modellerin performansları karşılaştırılmıştır. Toplamda 15 deneme ağacı için polinom, üstel, logaritmik, kuvvet ve Fourier regresyon modelleri oluşturulmuş, bu modellerin hata ve yaklaşım değerleri Tablo 1'de detaylı olarak sunulmuştur. Ayrıca, her bir deneme ağacının yıllar bazında ölçülen gövde çapı değerleri, regresyon modelleriyle karşılaştırmak amacıyla Şekil 2'de görselleştirilmiştir.

Uzman görüşleri, ilerleyen yıllarda (8-15. yıllar) ağaç gövde çapında azalma olmayacağı sonucuna varmıştır. Bu bağlamda, ağaç gövde çapının ilk 7 yıl artış hızına bağlı olarak kuvvet regresyon fonksiyonunun en uygun model olduğu belirlenmiştir. Farklı regresyon modellerinin etkili bir şekilde kullanılabileceği ve uzman görüşlerinin bu süreçte kritik bir rol oynadığı görülmüştür.

Kuvvet regresyon modelinin 15 ağaç için uygulanmasıyla elde edilen hata ve yaklaşım değerleri aşağıda verilmiştir.

$$\begin{aligned} 0.9623 &\leq \text{RSQUARE} \leq 0.9948 \\ 0.4535 &\leq \text{MAE} \leq 2.5498 \\ 1.2839 &\leq \text{MAPE} \leq 6.2976 \\ 0.55 &\leq \text{RMSE} \leq 2.9655 \end{aligned}$$

Bu sonuçlar, modelin veri setine uyum sağladığı ayrıca verim değerlerini tahmin etmede de güvenilir olduğunu göstermektedir.

Sonuç olarak, bu çalışma, farklı regresyon modellerinin kullanılmasıyla ağaç gövde çapı artışını tahmin etme konusunda kuvvetli bir yöntem sunmaktadır. Uzman görüşleriyle bütünleşmiş regresyon modelleri, ağaç büyümesi stratejileri için değerli bilgiler sağlayabilir. Gelecekteki çalışmalarda daha geniş veri setleri ve uzun vadeli ölçümlerle model performansının daha fazla doğrulanmasını sağlayacaktır.

Tablo 1. Ağaç gövde çapı-Yıl ilişkisinin belirlenmesinde kullanılan regresyon modelleri ile hata ve yaklaşım değerleri (Regression models and error and approximation values used in determining the tree trunk diameter-year relationship)

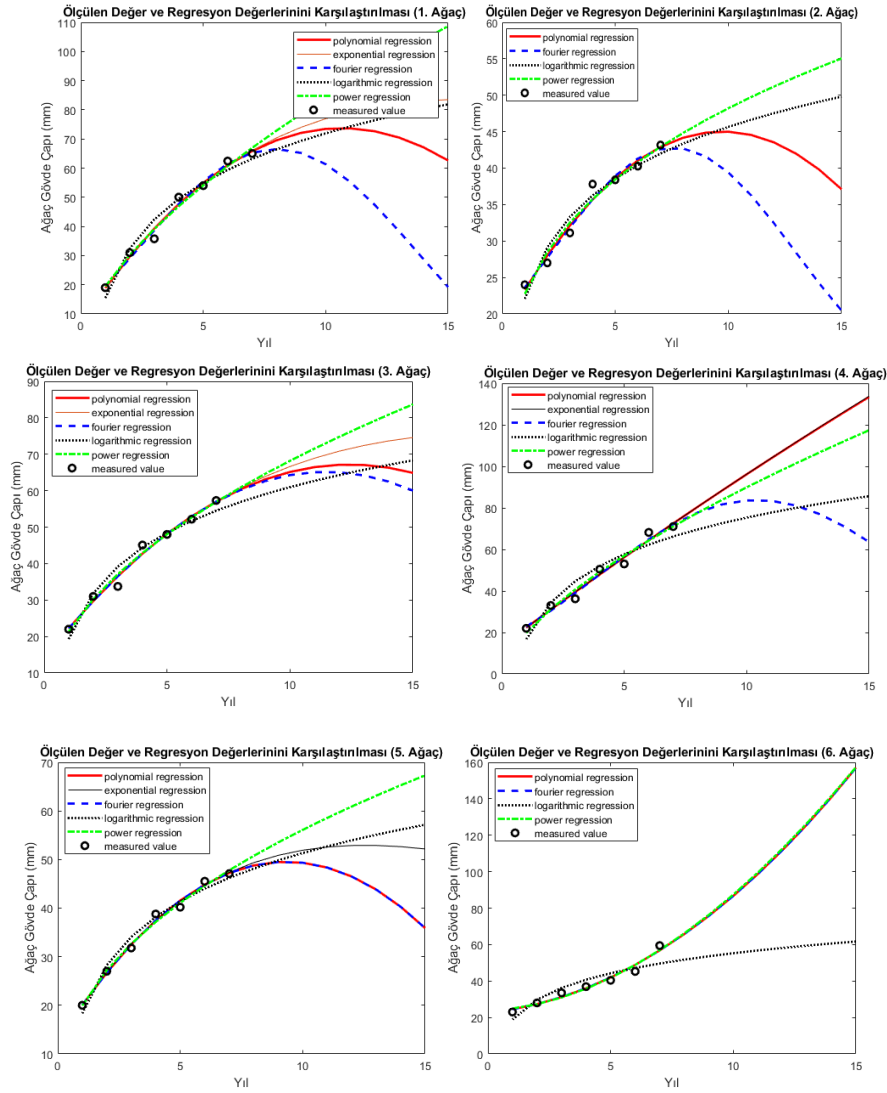
Ağaç No	Regresyon Modeli	R ²	MAE	MAPE	RMSE
1	$f(x) = ax^2 + bx + c$	0.9868	1.5050	3.5305	1.8290
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9862	1.5318	3.5659	1.8638
	$f(x) = \ln(x) + b$	0.9589	2.5755	7.5121	3.2215
	$f(x) = a + b\cos(wx) + c\sin(wx)$	0.9879	1.4926	3.8016	1.7446
	$f(x) = ax^b$	0.9839	1.6346	3.7634	2.0170
2	$f(x) = ax^2 + bx + c$	0.9749	0.8792	2.6753	1.0579
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9722	0.8560	2.3486	1.1143
	$f(x) = \ln(x) + b$	0.9453	1.3322	4.3926	1.5636
	$f(x) = a + b\cos(wx) + c\sin(wx)$	0.9765	0.8736	2.5090	1.0239
	$f(x) = ax^b$	0.9663	1.0160	3.2826	1.2270
3	$f(x) = ax^2 + bx + c$	0.9834	1.1291	2.9987	1.5148
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9834	1.0978	2.9187	1.5166
	$f(x) = \ln(x) + b$	0.9520	1.9099	5.6285	2.5773
	$f(x) = a + b\cos(wx) + c\sin(wx)$	0.9834	1.1493	3.0527	1.5145
	$f(x) = ax^b$	0.9818	1.1340	3.1757	1.5874
4	$f(x) = ax^2 + bx + c$	0.9759	2.3853	5.0768	2.6271
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9759	2.3868	5.0806	2.6272
	$f(x) = \ln(x) + b$	0.9090	4.5606	11.2386	5.1088
	$f(x) = a + b\cos(wx) + c\sin(wx)$	0.9766	2.3904	5.3560	2.5880
	$f(x) = ax^b$	0.9693	2.5498	6.2976	2.9655
5	$f(x) = ax^2 + bx + c$	0.9920	0.6552	1.7531	0.8216
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9920	0.6618	1.7325	0.8235
	$f(x) = \ln(x) + b$	0.9757	1.3420	4.2757	1.4344
	$f(x) = a + b\cos(wx) + c\sin(wx)$	0.9920	0.6552	1.7531	0.8216
	$f(x) = ax^b$	0.9907	0.7532	1.9638	0.8904

Tablo 1. (Devam) Ağaç gövde çapı-Yıl ilişkisinin belirlenmesinde kullanılan regresyon modelleri ile hata ve yaklaşım değerleri
(Regression models and error and approximation values used in determining the tree trunk diameter-year relationship)


Ağaç No	Regresyon Modeli	R ²	MAE	MAPE	RMSE
6	$f(x) = ax^2 + bx + c$	0.9641	1.8799	4.9186	2.1073
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9908	0.8030	2.6053	1.0636
	$f(x) = a \ln(x) + b$	0.8171	4.0161	10.4852	4.7533
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9641	1.8799	4.9186	2.1073
	$f(x) = ax^b$	0.9623	1.9584	5.2739	2.1594
7	$f(x) = ax^2 + bx + c$	0.9754	1.5918	4.4650	1.8019
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9831	1.1743	2.8240	1.4934
	$f(x) = a \ln(x) + b$	0.9292	2.5823	6.7785	3.0575
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9754	1.5918	4.4650	1.8019
	$f(x) = ax^b$	0.9763	1.5735	4.2983	1.7694
8	$f(x) = ax^2 + bx + c$	0.9770	1.7290	4.7035	1.9932
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9825	1.4424	4.3296	1.7357
	$f(x) = a \ln(x) + b$	0.8904	3.8027	11.7342	4.3471
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9809	1.6444	4.7697	1.8134
	$f(x) = ax^b$	0.9772	1.7121	4.5910	1.9810
9	$f(x) = ax^2 + bx + c$	0.9921	1.1635	2.5264	1.4314
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9921	1.1636	2.5265	1.4314
	$f(x) = a \ln(x) + b$	0.9181	4.1420	9.5639	4.5983
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9930	1.1672	2.7638	1.3437
	$f(x) = ax^b$	0.9921	1.1782	2.5679	1.4308
10	$f(x) = ax^2 + bx + c$	0.9853	1.3605	3.5613	1.6045
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9851	1.3678	3.5529	1.6145
	$f(x) = a \ln(x) + b$	0.9547	2.1610	6.0508	2.8143
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9856	1.3672	3.7119	1.5870
	$f(x) = ax^b$	0.9846	1.3542	3.3932	1.6418
11	$f(x) = ax^2 + bx + c$	0.9767	0.8717	2.5753	1.0819
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9775	0.8063	2.3562	1.0631
	$f(x) = a \ln(x) + b$	0.9757	0.7693	2.2292	1.1066
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9767	0.8716	2.5748	1.0817
	$f(x) = ax^b$	0.9775	0.8044	2.2534	1.0637
12	$f(x) = ax^2 + bx + c$	0.9904	0.9393	2.4680	1.1399
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9905	0.9351	2.3809	1.1348
	$f(x) = a \ln(x) + b$	0.9750	1.4555	3.6824	1.8390
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9904	0.9393	2.4680	1.1399
	$f(x) = ax^b$	0.9909	0.8931	2.1604	1.1078
13	$f(x) = ax^2 + bx + c$	0.9728	1.3347	3.5562	1.7871
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9746	1.3311	3.6253	1.7254
	$f(x) = a \ln(x) + b$	0.9224	2.4450	7.0368	3.0182
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9751	1.2826	3.5166	1.7083
	$f(x) = ax^b$	0.9717	1.3491	3.5306	1.8228

Tablo 1. (Devam) Ağaç gövde çapı-Yıl ilişkisinin belirlenmesinde kullanılan regresyon modelleri ile hata ve yaklaşım değerleri
(Regression models and error and approximation values used in determining the tree trunk diameter-year relationship)

Ağaç No	Regresyon Modeli	R ²	MAE	MAPE	RMSE
14	$f(x) = ax^2 + bx + c$	0.9849	0.8038	2.5344	0.9371
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9959	0.3976	0.9976	0.4899
	$f(x) = a \ln(x) + b$	0.9943	0.4681	1.2420	0.5747
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9849	0.8038	2.5344	0.9371
	$f(x) = ax^b$	0.9948	0.4535	1.2839	0.5500
15	$f(x) = ax^2 + bx + c$	0.9744	1.2980	3.6251	1.4877
	$f(x) = ae^{(bx)} + ce^{(dx)}$	0.9919	0.5555	1.4136	0.8384
	$f(x) = a \ln(x) + b$	0.9884	0.8576	2.1972	1.0006
	$f(x) = a + b \cos(wx) + c \sin(wx)$	0.9744	1.2980	3.6251	1.4877
	$f(x) = ax^b$	0.9885	0.8705	2.2674	0.9973



Şekil 2. Çalışmada kullanılan 15 ağaçta yıllar bazında ölçülen ağaç gövde çapı değerlerinin regresyon modelleriyle karşılaştırılması
(Comparison of tree trunk diameter values measured on a yearly basis in the 15 trees used in the study with regression models)




Şekil 2. (Devam) Çalışmada kullanılan 15 ağaçta yıllar bazında ölçülen ağaç gövde çapı değerlerinin regresyon modelleriyle karşılaştırılması
(Comparison of tree trunk diameter values measured on a yearly basis in the 15 trees used in the study with regression models)

3.2. Ağaç gövde çapı-verim ilişkisi (Tree trunk diameter-yield relationship)

Bu çalışmanın sonuçları, ağaç gövde çapı ile verim arasındaki ilişkiyi anlamak ve gelecekteki verim değerlerini tahmin etmek için etkili bir model geliştirmek adına önemli bilgiler sunmaktadır. Fourier regresyon modeli, ağaç verim değerlerindeki periyodik desenleri başarıyla tanımlayarak (Şekil 3-A, 3-B), Rsquare değeri 0.9890 ve rmse değeri 7.9125 ile oldukça yüksek bir doğruluk sağlamıştır. Bu sonuçlar, modelin gözlemlenen veri setine iyi uymakla birlikte verim değerlerini tahmin etmede de güvenilir olduğunu göstermektedir.

Araştırmanın temel bulgularından biri, Fourier regresyonunun ağaçların verimini etkileyen karmaşık faktörleri periyodik değişimlerle birleştirebilme yeteneğidir. Bu, ağaç verimini etkileyen genotip ve çevresel faktörlerin karmaşıklığını anlama ve modelleme açısından önemli olabilmektedir. Bu regresyon modeli, ağaçların gövde çapı ile verim arasındaki ilişkiyi daha iyi anlamak ve bu ilişkiyi gelecekteki verim tahminleri için kullanmak isteyen araştırmacılara güçlü bir araç sağlamaktadır.

Sonuçlar, elde edilen ağaç gövde çapı-verim regresyon modelinin genotip ve çevresel faktörlere bağlı olarak ağaç verimini tahmin etme konusunda güçlü bir araç olduğunu göstermektedir. Bu, tarım endüstrisinde, verim artışını planlamak ve yönetmek adına önemli bir bilgi kaynağı olabilir.



Şekil 3. (a) Ağaç gövde çapı-verim regresyon fonksiyonu (b) Ağaç gövde çapı-verim-yıl ilişkisi
(a) Tree trunk diameter-yield regression function (b) Tree trunk diameter-yield-year relationship)

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] T. Ayoub Shaikh, T. Rasool, and F. Rasheed Lone, "Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming," *Comput. Electron. Agric.*, vol. 198, p. 107119, Jul. 2022, doi: 10.1016/J.COMPAG.2022.107119.
- [2] M. Pathan, N. Patel, H. Yagnik, and M. Shah, "Artificial cognition for applications in smart agriculture: A comprehensive review," *Artif. Intell. Agric.*, vol. 4, pp. 81–95, Jan. 2020, doi: 10.1016/J.AIIA.2020.06.001.
- [3] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine Learning in Agriculture: A Review," *Sensors 2018*, Vol. 18, Page 2674, vol. 18, no. 8, p. 2674, Aug. 2018, doi: 10.3390/S18082674.
- [4] T. U. Rehman, M. S. Mahmud, Y. K. Chang, J. Jin, and J. Shin, "Current and future applications of statistical machine learning algorithms for agricultural machine vision systems," *Comput. Electron. Agric.*, vol. 156, pp. 585–605, Jan. 2019, doi: 10.1016/J.COMPAG.2018.12.006.
- [5] I. Keramatlou, M. Sharifani, H. Sabouri, M. Alizadeh, and B. Kamkar, "A simple linear model for leaf area estimation in Persian walnut (*Juglans regia* L.)," *Sci. Hortic. (Amsterdam)*, vol. 184, pp. 36–39, Mar. 2015, doi: 10.1016/j.scienta.2014.12.017.
- [6] P. Freund, R. J. and Wilson, W. J., Sa, *Regression analysis: Statistical Modeling of a response variable* (2nd ed). California, USA, Elsevier.
- [7] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, pp. 70–90, Apr.

2018, doi: 10.1016/J.COMPAG.2018.02.016.

[8] S. Chen et al., "Rapid estimation of leaf nitrogen content in apple-trees based on canopy hyperspectral reflectance using multivariate methods," *Infrared Phys. Technol.*, vol. 111, p. 103542, Dec. 2020, doi: 10.1016/J.INFRARED.2020.103542.

[9] J. K. Basak et al., "Regression Analysis to Estimate Morphology Parameters of Pepper Plant in a Controlled Greenhouse System," *J. Biosyst. Eng.*, vol. 44, no. 2, pp. 57–68, Jun. 2019, doi: 10.1007/S42853-019-00014-0/FIGURES/11.

[10] I. Boldina and P. G. Beninger, "Strengthening statistical usage in marine ecology: linear regression," *J. Exp. Mar. Bio. Ecol.*, vol. 474, pp. 81–91, Jan. 2016, doi: 10.1016/j.jembe.2015.09.010.

[11] V. Strijov and G. W. Weber, "Nonlinear regression model generation using hyperparameter optimization," *Comput. Math. with Appl.*, vol. 60, no. 4, pp. 981–988, Aug. 2010, doi: 10.1016/J.CAMWA.2010.03.021.

[12] N. Panigrahi and B. S. Das, "Evaluation of regression algorithms for estimating leaf area index and canopy water content from water stressed rice canopy reflectance," *Inf. Process. Agric.*, vol. 8, no. 2, pp. 284–298, 2021, doi: 10.1016/j.inpa.2020.06.002.

[13] X. Ye, S. Abe, and S. Zhang, "Estimation and mapping of nitrogen content in apple trees at leaf and canopy levels using hyperspectral imaging," *Precis. Agric.*, vol. 21, no. 1, pp. 198–225, Feb. 2020, doi: 10.1007/S11119-019-09661-X/FIGURES/15.

[14] H. Armağan, "Color Based Segmentation with k-Means Clustering Algorithm and Numerical Analysis of the Effect of Color Spaces on Image Quantities.," *El-Cezeri*, vol. 9, no. 4, pp. 1506–1517, Dec. 2022, doi: 10.31202/ECJSE.1141148.

[15] H. Armağan, E. Atay, X. Crété, P.-E. Lauri, M. Ersoy, and O. Oral, "Deep Learning-Based Prediction Model of Fruit Growth Dynamics in Apple," *In Smart Applications with Advanced Machine Learning and Human-Centred Problem Design*, Cham: Springer International Publishing, 2023, pp. 367–373.

[16] M. Altalak, M. A. Uddin, A. Alajmi, and A. Rizg, "Smart Agriculture Applications Using Deep Learning Technologies: A Survey," *Appl. Sci.*, vol. 12, no. 12, Jun. 2022, doi: 10.3390/app12125919.

[17] J. G. A. Barbedo, "Detection of nutrition deficiencies in plants using proximal images and machine learning: A review," *Comput. Electron. Agric.*, vol. 162, pp. 482–492, Jul. 2019, doi: 10.1016/J.COMPAG.2019.04.035.

[18] M. S. Suchithra and M. L. Pai, "Improving the prediction accuracy of soil nutrient classification by optimizing extreme learning machine parameters," *Inf. Process. Agric.*, vol. 7, no. 1, pp. 72–82, Mar. 2020, doi: 10.1016/J.INPA.2019.05.003.

[19] E. Atay, X. Crété, D. Loubet, and P. E. Lauri, "Diurnal and Seasonal Growth Responses of Apple Trees to Water-Deficit Stress," *Erwerbs-Obstbau*, vol. 65, pp. 1–6, 2022, doi: 10.1007/s10341-022-00689-4.

[20] S. Huang, X. Fan, L. Sun, Y. Shen, and X. Suo, "Research on Classification Method of Maize Seed Defect Based on Machine Vision," *J. Sensors*, vol. 2019, 2019, doi: 10.1155/2019/2716975.

[21] "TÜİK,2023." [Online]. Available: <https://data.tuik.gov.tr/Kategori/GetKategori?p=Tarim-111> [Accessed Nov. 26, 2023].

[22] "FAOSTAT." [Online]. Available: <https://www.fao.org/faostat/en/#data> [Accessed Nov. 26, 2023].

[23] E. Atay, B. Hucbourg, A. Drevet, and P. É. Lauri, "Effects of preharvest deficit irrigation treatments in combination with reduced nitrogen fertilization on orchard performance of nectarine with emphasis on postharvest diseases and pruning weights," *Acta Sci. Pol. Hortorum Cultus*, vol. 18, no. 1, pp. 207–217, 2019, doi: 10.24326/asphc.2019.1.21.

[24] E. Atay and F. Koyuncu, "Branch induction via prolepsis in apple nursery trees," *Acta Hort.*, vol. 1139, pp. 439–444, 2016, doi: 10.17660/ActaHortic.2016.1139.76.

* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICALAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license

