



## Detection of Pea and Spinach Adulteration in Pistachio Nuts using a Low-Cost Spectral Sensor

Bezza Türköz<sup>1,a</sup>, Muhammed Mustafa Özçelik<sup>1,b</sup>, Sebahattin Serhat Turgut<sup>1,2,c,\*</sup>

<sup>1</sup>Süleyman Demirel Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Gıda Mühendisliği Bölümü, Isparta/Merkez, Türkiye

<sup>2</sup>Triem Arge ve Teknoloji A.Ş., Göller Bölgesi Teknokenti, Süleyman Demirel Üniversitesi, Isparta/Merkez, Türkiye

\*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 15.04.2024 Accepted : 18.07.2024</p> <p><i>Keywords:</i> Adulteration Chemometric methods PCA Deep learning Artificial Neural Networks</p>	<p>Pistachio is a product frequently used in many desserts, especially baklava. Especially ground pistachios are frequently subjected to adulteration due to their high demand and cost. Green peas and spinach are among the most counterfeited products by being mixed with pistachios due to their organoleptic properties, colour similarity and cheapness. However, when these products are mixed with ground pistachios at certain proportions, rapid and on-site detection of counterfeiting is often not possible by methods such as visual inspection. Therefore, the current study aims to detect the adulteration of green peas and spinach in pistachios using a low-cost spectral sensor technology and chemometric methods. In this context, green pea and spinach samples were mixed with pistachios at concentrations between 5-50% (w/w) in 5% increments. Reflectance spectra of pure pistachios and mixed samples were obtained between 410-940 nm. Deep learning method was used to train a model developed to detect fraud rates in samples. Principal Component Analysis was used for dimension reduction in the data fed to the model, and coefficient of determination (<math>R^2</math>), root mean square error (RMSE), and residual predictive deviation (RPD) statistics were used to test the goodness of fit of the regression problem. For training, validation and test data, <math>R^2</math> was 0.85, 0.83, and 0.80; RMSE was 5.81, 6.13, and 6.71; RPD was 2.55, 2.44, and 2.21, respectively. As a result of the findings, it has been revealed that the low-cost spectral sensor and the developed chemometric method have the potential to be used as a non-destructive, rapid and simple method for determining the adulteration rate of green peas and spinach in pistachios, especially above 10%.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 12(s2): 2206-2215, 2024

## Antep Fıstığında Bezelye ve Ispanak Tağışının Düşük Maliyetli Spektral Sensör Kullanılarak Tespiti

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 15.04.2024 Kabul : 18.07.2024</p> <p><i>Anahtar Kelimeler:</i> Tağış Kemometrik yöntemler PCA Derin öğrenme Yapay Sinir Ağları</p>	<p>Antep fıstığı, başta baklava olmak üzere birçok tatlıda sıkça kullanılan bir üründür. Özellikle öğütülmüş Antep fıstığı, talebin yüksek olması ve yüksek maliyeti nedeniyle sıklıkla tağışe maruz kalmaktadır. Yeşil bezelye ve ıspanak, organoleptik özellikleri, renk benzerliği ve ucuzluğu nedeniyle Antep fıstığı ile karıştırılarak en çok sahtecilik gerçekleştirilen ürünler arasındadır. Ancak bu ürünlerin öğütülmüş Antep fıstığına belirli oranlarda karıştırılması durumunda sahteciliğin hızlı ve yerinde tespiti, gözle muayene gibi yöntemlerle çoğu zaman mümkün olmamaktadır. Bu nedenle mevcut çalışma, Antep fıstığındaki yeşil bezelye ve ıspanak tağışının, düşük maliyetli bir spektral sensör teknolojisi ve kemometrik yöntemler kullanılarak tespitini amaçlamaktadır. Bu kapsamda yeşil bezelye ve ıspanak örnekleri Antep fıstığı ile %5-50 (a/a) arasındaki konsantrasyonlarda %5'lik artışlarla karıştırılmıştır. Saf Antep fıstığı ve karışık numunelerin reflektans spektrumları 410-940 nm arasında elde edilmiştir. Numunelerdeki sahtecilik oranlarının tespiti amacıyla geliştirilen modelin eğitilmesinde derin öğrenme yöntemi kullanılmıştır. Modele beslenen verilerde boyut indirgeme amacıyla Temel Bileşenler Analizinden faydalanılmış olup, regresyon probleminin uyum iyiliğini test etmek amacıyla belirleme katsayısı (<math>R^2</math>), hata kareler ortalamasının karekökü (RMSE) ve artıklık tahminsel sapma (RPD) istatistikleri kullanılmıştır. Sırasıyla eğitim, doğrulama ve test verileri için <math>R^2</math> 0,85, 0,83 ve 0,80; RMSE 5,81, 6,13 ve 6,71; RPD 2,55, 2,44 ve 2,21 olarak tespit edilmiştir. Elde edilen bulgular neticesinde, söz konusu ekonomik spektral sensör ve geliştirilen kemometrik yöntemin Antep fıstığında özellikle %10 üzerindeki yeşil bezelye ve ıspanak tağış oranının belirlenmesi için tahribatsız, hızlı ve kolay bir yöntem olarak kullanıma potansiyeline sahip olduğu ortaya konmuştur.</p>

<sup>a</sup> [y12230119007@ogr.sdu.edu.tr](mailto:y12230119007@ogr.sdu.edu.tr)

<sup>b</sup> <https://orcid.org/0000-0002-4777-8843>

<sup>c</sup> [ozcelik.m.mustafa@gmail.com](mailto:ozcelik.m.mustafa@gmail.com)

<https://orcid.org/0000-0002-1933-1737>

<sup>c</sup> [serhatturgut@sdu.edu.tr](mailto:serhatturgut@sdu.edu.tr)

<https://orcid.org/0000-0002-9968-4750>



## Giriş

Gıda ve Tarım Örgütü (FAO) istatistiklerine göre, 2022 yılında dünyadaki toplam Antep fıstığı üretimi 1 milyon tonun üzerinde olup, ülkemiz yıllık yaklaşık 240 bin ton fıstık üretimi ile listede başı çeken ülkeler arasındadır (FAO, 2022). Antep fıstığı, çerez olarak tüketiminin dışında ülkemizde sucuk, hamur işleri ve tatlılar (özellikle baklava), soslar, çikolata ve dondurma ürünlerinde yaygın olarak kullanılmaktadır. Yaygın kullanılması ve yüksek maliyeti, Antep fıstığını özellikle toz halinde kullanıldığında art niyetli üreticiler tarafından tağşiş uygulanmasını cazip hale getirmektedir (SU, 2020; DHA, 2021). Bu bağlamda, Antep fıstığında gerçekleştirilen tağşişin belirlenmesi, tüketiciyi olumsuz etkileyen gıda sahtekârlığının önlenmesi açısından oldukça önemlidir.

Bezelye ve ıspanak, görsel özelliklerinin benzer olması ve baskın olmayan organoleptik karakteristikleri nedeniyle Antep fıstığında sahtecilik gerçekleştirmek amacıyla en yaygın kullanılan bitkilerdir. Ayrıca bu ürünlerin maliyetlerinin Antep fıstığına kıyasla daha düşük olması, olası sahtecilik uygulamalarını daha çekici hale getirmekte ve gıda ürünlerinde kullanılan Antep fıstığının güvenilirliği konusunda endişelere sebep olmaktadır (Eksi-Kocak ve ark., 2016). Antep fıstığında gerçekleştirilen tağşiş, içerdikleri şeker, yağ ve diğer bileşenler nedeniyle özellikle tatlılarda veya Antep fıstığı ezmesi gibi ürünlerde, basit tat, doku veya görsel muayene ile tespit edilememektedir (Sezer ve ark., 2019).

Gıda ürünlerinde gerçekleştirilmiş olması muhtemel ve hem gıda güvenliği hem de kalite güvencesi için tespiti elzem olan tağşişin belirlenmesine yönelik farklı analitik teknikler bulunmaktadır. Yaygın olarak tercih edilen kromatografik ve spektroskopik metotların yanı sıra, bir takım enzimatik yöntemler ve elektronik burun gibi elektronik sensörlerin kullanımı da bilimsel literatürde kendisine yer bulmaktadır (Anagaw ve ark., 2024). Örneğin genetik ve jeokimyasal DNA parmak izi analizi (Zannella ve ark., 2017), floresan dedektörlü yüksek performanslı sıvı kromatografisi (HPLC) (Campmajó ve ark., 2020), kütle spektroskopisi ile destekli sıvı veya gaz kromatografisi (Kendirici & Onoğur, 2011; Çavuş ve ark., 2018; Suman ve ark., 2021; Campmajó ve ark., 2023), mikrodalga ekstraksiyon destekli ve/veya UV dedektörlü HPLC (Campmajó ve ark., 2019; Kalogiouri ve ark., 2022) gibi ileri analitik yöntemler Antep fıstıklarında tağşiş tespiti amacıyla kendisine bilimsel literatürde yer bulabilmiştir. Söz konusu yöntemlerin hassasiyeti ve doğruluğu oldukça yüksek olmakla birlikte dezavantajları da bulunmaktadır. Bunlar arasında zaman alıcı ve iş gücü yoğun örnek hazırlama yöntemleri olmaları, laboratuvar alanı gereksinimi, eğitilmiş personel ve sarf malzemeleri nedeniyle ekonomik olarak daha az verimli olmaları, sonuçların elde edilmesi için daha uzun süre gerektirmeleri ve yıkıcı (tahribatlı) olmaları yer almaktadır (Lu, 2017). Bu nedenle Antep fıstıklarında bulunan muhtemel tağşişlerin tespiti için hızlı, ekonomik ve basit tespit yöntemlerinin geliştirilmesi büyük önem taşımaktadır.


Gıda ürünlerinde tağşiş tespitinde hızlı ve tahribatsız sonuç üreten spektral sensörlerin kemometrik yöntemlerle birlikte kullanımı son dönemlerde yaygınlaşmaktadır (Edwards ve ark., 2021; Khan ve ark., 2021; Modupalli ve ark., 2021; Nobari Moghaddam ve ark., 2022; Turgut ve

ark., 2024). Benzer şekilde, kuruyemiş ve ürünlerinde sahteciliğin tespiti için çok sayıda çalışma mevcut olmakla birlikte (Teixeira & Sousa, 2019; Vega-Castellote ve ark., 2024), Antep fıstıklarında gerçekleştirilmesi muhtemel sahteciliğin hızlı ve tahribatsız tespitini konu edinen sınırlı sayıda çalışma tespit edilebilmiştir. Örneğin, kemometrik yöntemlerle birlikte FT-MIR ve FT-NIR (Aykas & Menevseoglu, 2021), NIR ve MIR (Temizkan ve ark., 2020; Genis ve ark., 2021), Raman hiperspektral görüntüleme (Eksi-Kocak ve ark., 2016) ve bilgisayar gözü (Çınarer ve ark., 2024) gibi spektral yöntemler, Antep fıstıklarında gerçekleştirilen sahteciliğin tespiti amacıyla denenmiştir. Söz konusu yöntemlerle yüksek doğruluğa sahip tahminler üretilebilmekle birlikte, kullanılan sensör sistemleri genellikle yüksek maliyetlidir ve/veya örneklerin yerinde analizine imkân verecek düzeyde taşınabilir değildir. Bu olumsuzlukların giderilerek, rutin analizlerin sıklaştırılması ve denetleme mekanizmalarının daha yaygın uygulanabilmesi için hem uygun maliyetli hem de gerçek anlamda taşınabilir (cep boyutunda) tağşiş tespit yöntemlerinin geliştirilmesi, gıda kalitesi ve güvenliğinin temini için büyük önem arz etmektedir.

Bu bağlamda mevcut çalışmanın amacı, farklı oranlarda bezelye ve/veya ıspanak karıştırılarak hazırlanan Antep fıstığı örneklerindeki sahtecilik oranlarının herhangi bir örnek hazırlığı olmadan ve tahribatsız bir şekilde belirlenmesi için kullanımı kolay, düşük maliyetli ve taşınabilir bir spektroskopik cihazın (triSens PT-01, Triem Arge ve Teknoloji, Isparta, Türkiye) potansiyelinin değerlendirilmesidir.

## Materyal ve Yöntem

Antep fıstığı örneklerinde gerçekleştirilmesi muhtemel bezelye ve ıspanak ilavesi ile sahteciliğin tespiti amacıyla mevcut çalışma kapsamında gerçekleştirilen örnek hazırlama, spektrum okuma ve veri analizi basamakları aşağıda detaylandırılmış olup, ayrıca özet gösterimi Şekil 1'de sunulmuştur.



Şekil 1 Saf Antep fıstığı ve tağşiş uygulanmış (bezelye ve ıspanak ilaveli) Antep fıstığı numunelerinin tahribatsız tespitine yönelik gerçekleştirilen çalışmanın özet şematik gösterimi  
Figure 1 Schematic representation of the study carried out for the non-destructive detection of pure pistachio and adulterated (pea and spinach added) pistachio samples

### Örnek Hazırlama

Antep fıstığı numuneleri Gaziantep ilinde faaliyet gösteren ulusal bir firmadan temin edilmiş olup, bezelye ve ıspanak örnekleri Isparta'da faaliyet gösteren yerel bir marketten dondurulmuş olarak satın alınmıştır. Ham maddelerin nem miktarı, nem tayin cihazı (DBS 60-3, Kern, Almanya) kullanılarak gravimetrik yöntemle tespit edilmiştir. Bu amaçla numuneler 105°C'de sabit ağırlığa gelinceye kadar kurutulmuş olup, örneklerin nem içeriği "g nem/100 g numune" olarak hesaplanmıştır.

Analiz sonucunda Antep fıstığı numunelerinin nem içeriği %3,85±0,05 bulunmuş olup, yeniden kurutma uygulanmamıştır. Ancak ıspanak ve bezelye numunelerinin nem içeriklerini, Antep fıstığı numunelerinin sahip olduğu nem seviyesine düşürmek amacıyla kurutma işlemi gerçekleştirilmiştir. Kurutma işleminden önce bezelye ve ıspanak numuneleri iki gruba ayrılmıştır. Bir grup doğrudan kurutmaya tabii tutulurken, diğer grup kurutmada işleminden önce 1 dk kaynar su içerisinde bekletilmiştir. Kurutma işlemleri 65°C sıcaklıkta havalı döner kurutucuda (TK-LAB, EKSİS Makine, Isparta, Türkiye) gerçekleştirilmiştir. Kurutma işlemi süresince numunelerin nem miktarı düzenli aralıklarla takip edilerek, nihai nem oranının %3-4 seviyesine erişmesi hedeflenmiştir. Çalışmanın sonraki aşamalarında kullanılmadan önce kurutulan numunelerin oda sıcaklığına kadar soğuması beklenmiştir.

Boz Antep fıstığı, kurutulmuş bezelye ve ıspanak örnekleri bir değirmen (KSPG-4812, Kiwi, Çin Halk Cumhuriyeti) yardımıyla öğütülmüştür. Ardından öğütülmüş örnekler eleme uygulanarak boyutlandırma işlemi gerçekleştirilmiştir. Boyutlandırma eleklerinden geçirilen örnekler, büyüklüklerine göre sırasıyla (i) 2 mm'den büyük, (ii) 1 mm'den büyük, (iii) 0.5 mm'den büyük ve (iv) 0.5 mm'den küçük olmak üzere tanecik boyutuna göre dört farklı sınıfa ayrılmıştır. Boyutlandırılan örnekler içerisinde 1 mm'den büyük tanecik boyutuna sahip örnekler ayrılarak nem geçirme direnci yüksek materyal içerisinde vakum ambalaj uygulanmıştır. Numuneler analizlere kadar vakum ambalaj içerisinde, karanlıkta ve buzdolabı sıcaklığında muhafaza edilmiştir.

Öğütülmüş örnekler spektral ölçümlerden hemen önce farklı oranlarda karıştırılarak okumaya hazır hale getirilmiştir. Bu amaçla ham Antep fıstığı dışında dört farklı örnek grubu oluşturularak olası gıda sahteciliği taklit edilmeye çalışılmıştır. Oluşturulan örnek grupları şöyledir:

(i) Antep fıstığı:bezelye (haşlanmamış) karışımı, (ii) Antep fıstığı:bezelye (haşlanmış) karışımı, (iii) Antep fıstığı:bezelye:ıspanak (haşlanmamış ve 1:1 bezelye:ıspanak karışım oranı) karışımı ve (iv) Antep fıstığı:bezelye:ıspanak (haşlanmış ve 1:1 bezelye:ıspanak karışım oranı) karışımı. Bezelye ve bezelye:ıspanak karışımları (1:1), ham Antep fıstığına %5-50 (a/a) arasında değişen ve %5'lik aralıklarla artan 10 farklı oranda karıştırılmıştır. Hazırlanan karışım oranları Tablo 1'de sunulmuştur.

### Spektrumların Elde Edilmesi ve Verilerin Analizi

Hazırlanan örnekler için spektral reflektans değerleri 410-940 nm arasında ve 18 farklı dalga boyunda elde edilmiştir. Bu amaçla düşük maliyetli ve taşınabilir bir spektral sensör (triSens PT-01, Triem Arge ve Teknoloji, Isparta, Türkiye) kullanılmıştır. Söz konusu sensör tarafımızca geliştirilmiş olup, prototip geliştirme maliyeti yaklaşık 100 Amerikan doları seviyesindedir. Hazırlanan numuneler, Şekil 2'de gösterildiği üzere sensör haznesine doldurularak otomatik olarak sıralı 5 ölçüm alınmış ve bu spektrumların ortalaması (R) geliştirilen yazılım tarafından ilgili örneğe ait tek okuma olarak kaydedilmiştir. Bu şekilde her örnekten 10 okuma gerçekleştirilmiş olup, toplam 410 spektrum elde edilmiştir. Spektrumlar, log(1/R) olarak kaydedilmiştir. Veri setinde bulunan spektrumlar, hammaddelere uygulanan ön işlemlere göre ayrıştırılmadan, tek bir veri seti olarak ele alınarak, veri analizi ve model geliştirme süreçleri işletilmiştir.


Elde edilen spektrumların analizi (veri ön işleme, aykırı verilerin incelenmesi, model geliştirme dahil olmak üzere) Python programlama dilinde (v3.9, Python Software Foundation, ABD) ve ilgili kütüphaneler kullanılarak gerçekleştirilmiştir. Verilerin ön işlenmesi amacıyla MinMax Normalizasyonu kullanılmış olup, spektral veriler -1 ilâ +1 aralığına ölçeklendirilmiştir. Aykırı verilerin tespitinde Shenk & Westerhaus (1993) tarafından önerilen yöntem kullanılmıştır. Bu amaçla MinMax Normalizasyonu gerçekleştirilmiş verilere Temel Bileşenler Analizi (PCA) uygulanmıştır. Ardından toplam varyansın %99'undan fazlasını açıklayabilen ilk 10 temel bileşen skorları kullanılarak her örneğe ait Mahalanobis mesafesi (H) hesaplanmıştır. H istatistiklerinin standart normal dağılım gösterdiği kabul edilmiş olup, kritik değerden ( $p=0.01$ , ortalama + 3 × standart sapma) daha yüksek H değerine sahip olan örnekler olası aykırı değerler olarak ele alınmıştır.

Tablo 1. Hazırlanan karışım oranları

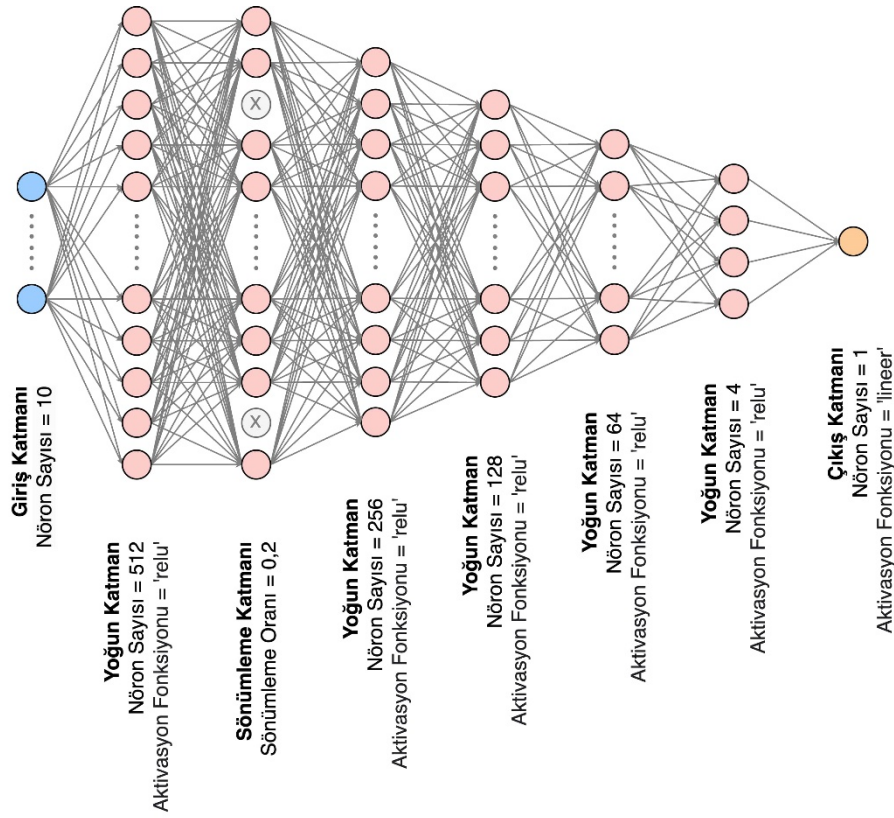
Table 1. Prepared mixture ratios

Hile oranı	Örnek Karışım Oranları				
	Yalnızca B Sahteciliği		B ve I Sahteciliği		
	F	B	F	B	I
%0	1	0	1	0	0
%5	0,95	0,05	9,5	0,025	0,025
%10	0,9	0,1	0,9	0,05	0,05
%15	0,85	0,15	0,85	0,075	0,075
%20	0,8	0,2	0,8	0,1	0,1
%25	0,75	0,25	0,75	0,125	0,125
%30	0,7	0,3	0,7	0,15	0,15
%35	0,65	0,35	0,65	0,175	0,175
%40	0,6	0,4	0,6	0,2	0,2
%45	0,55	0,45	0,55	0,225	0,225
%50	0,5	0,5	0,5	0,25	0,25

- F: Antep fıstığı, B: bezelye, I: ıspanak; - Tabloda sunulan sahtecilik oranları haşlanmamış/haşlanmış bezelye ve ıspanak için ayrı ayrı hazırlanmıştır.



Şekil 2 Örneklerin sensöre aktarılması ve spektrum elde edilmesi  
Figure 2 Transferring the samples to the sensor and obtaining spectra



Şekil 3. Eğitilen derin sıralı öğrenme yapay sinir ağları modeli yapısı  
Figure 3. Structure of the trained deep sequence learning artificial neural networks model

Numunelerdeki sahtecilik oranının belirlenmesi bir regresyon problemi olarak değerlendirilmiştir. Bu amaçla geliştirilecek olan modelin eğitilmesi için derin sıralı öğrenme yapay sinir ağları modeli tercih edilmiştir. İlk olarak MinMax Normalizasyonuna tabi tutulan verilere PCA uygulandıktan sonra ilk 10 temel bileşene ait eksen skorları rastgele ve tabakalama uygulanarak eğitim (%80) ve doğrulama (%20) olmak üzere ikiye ayrılmıştır. Bunlardan eğitim verisi ile model eğitimi sağlanırken, doğrulama verisi yardımıyla kullanılan optimizasyon yöntemi, epok sayısı, her epoktaki iterasyon adedi, öğrenme hızı gibi model hiper parametreleri optimize edilmiştir. Bu esnada model uyum iyiliği istatistiği olarak hata kareler ortalamasının karekökü (*RMSE*) kullanılmıştır.

Eğitilen modelin yapısı Şekil 3'te sunulmuş olup, sırasıyla 10 nöronlu bir giriş katmanı, 512 nöronlu bir yoğun katman, %20 oranında sönümlenme gerçekleştiren bir sönümlenme katmanı, sırasıyla 256-128-64-4 nöronlu oluşan 4 yoğun katman ve tek nöronlu bir çıkış katmanından meydana gelmektedir. Yoğun katmanlarda "relu" aktivasyon fonksiyonu kullanılırken, çıkış katmanında "linear" aktivasyonu fonksiyonu yer almaktadır.

Eğitilen modelin tahmin kabiliyetini değerlendirmek amacıyla eğitim ve doğrulama örnekleri dışında, yeniden ham madde temin edilmesiyle baştan farklı oranlarda karıştırılan örnekler hazırlanarak, toplam 165 adet harici doğrulama (test) verisi elde edilmiştir.

Tüm aşamalarda (eğitim, doğrulama, test) model uyum iyiliğinin değerlendirilmesi amacıyla belirleme katsayısı ( $R^2$ ), hata kareler ortalamasının karekökü ( $RMSE$ ) ve artıklık tahminsel sapma ( $RPD$ ) istatistikleri kullanılmıştır. Bahsi geçen verilerin eşitlikleri aşağıda verilmiştir (Eşitlik 1-2).

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{N}} \quad (1)$$

$$RPD = \frac{SD}{RMSE} \quad (2)$$

Yukarıda sunulan eşitliklerde  $y_i$  ve  $\hat{y}_i$ , gözlemlere ait gerçek ve tahmini değerlerini;  $N$ , gözlem sayısını ve  $SD$ , standart hatayı ifade etmektedir.

## Bulgular ve tartışma

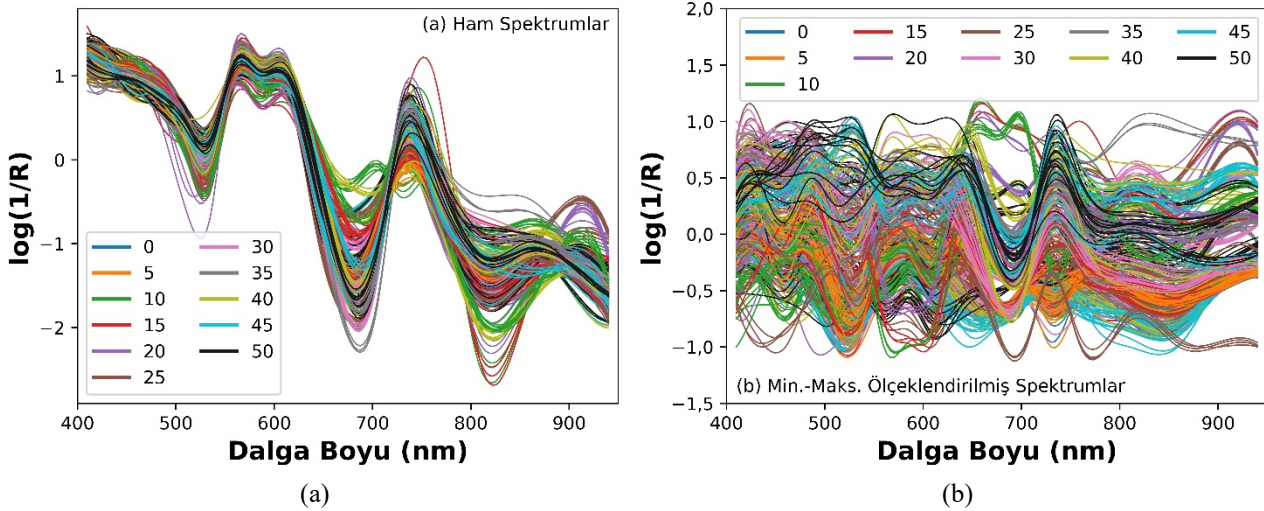
### Spektral Karakterizasyon

Tağşiş uygulanmış ve uygulanmamış Antep fıstığı numunelerine ait 410-940 nm arasındaki 18 dalga boyunda elde edilmiş reflektans spektrumları ( $\log(1/R)$ ), Şekil 4-a'da sunulmuştur. Bilindiği üzere kemometrik yaklaşımlarda verilerin birbirlerinden ayrıştırılması, doğrusallaştırılması ve boyut indirgeme amacıyla PCA sıklıkla uygulanmaktadır (Bro & K. Smilde, 2014). Ancak PCA yöntemi verilerin normal dağılıma sahip olduğu varsayımına dayanmaktadır ve verilerdeki varyans farklılıklarından oldukça etkilenmektedir. Bu nedenle PCA işleminden önce verilerin ölçeklendirilmesi (standardizasyonu veya normalizasyonu) gerekmektedir (Walach ve ark., 2018). Mevcut çalışmada veriler MinMax Normalizasyon işlemi uygulanmış olup, spektrumlar Şekil 4-b'de gösterilmektedir.

Saf fıstık ile tağşiş uygulanmış Antep fıstığı örneklerine ait PCA Skor grafikleri Şekil 5-a'da sunulmuştur. PCA analizi sonuçlarına göre ilk iki temel bileşen (PC1 ve PC2) sırasıyla %58,38 ve %25,67 olmak üzere toplam varyansın yaklaşık %85'ini izah edebilmektedir. Ekski-Kocak ve ark. (2016), tarafından gerçekleştirilen bir çalışmada, farklı Antep fıstığı ve bezelye örnekleri arasında meydana gelen varyasyonları

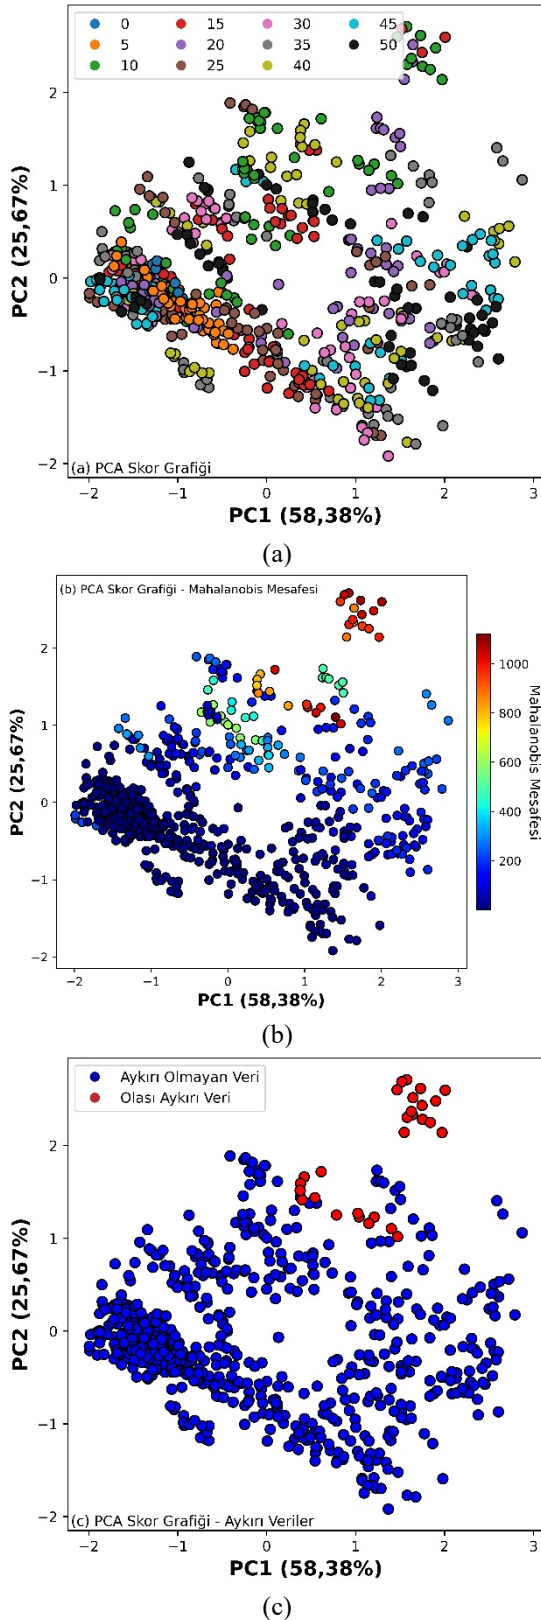
görselleştirmek için PCA yönteminden yararlanılmıştır. Numuneler arasındaki ayırım, tüm spektral aralığı (2703-50000 nm) kapsayacak şekilde gerçekleştirilmiştir. PC1 ile toplam varyansın %95,79'unu açıklanırken, PC2 ile toplam varyansın %3,99'unu açıklanmıştır. Böylece PCA grafiği ile, Antep fıstığı ve yeşil bezelye numuneleri arasında büyük bir mesafe olduğu ve bunun başarılı bir ayırımı göstergesi olduğu rapor edilmektedir. PCA tekniği, veriler arasındaki doğrusal ilişkilerin kuvvetli olması durumunda daha iyi ayırma ortaya koyabilmektedir. Ancak aksi durumda örnekler arasında belirgin gruplaşmalar görülememektedir (Yuille, 2014). Şekil 5-a'da sunulan farklı oranlarda tağşiş içeren örnekler arasında bazı gruplaşmalar olsa dahi, net bir ayırım mevcut değildir. Bu durum söz konusu regresyon probleminin doğrusal olmayan yöntemlerle ele alınması gerektiğini işaret etmektedir. Ayrıca mevcut teknolojiyle 18 farklı dalga boyunda ölçüm sağlayan sensörün, düşük dalga boyu çözünürlüğü ve taradığı dalga boyu aralığının görece dar olması, PCA sonucunda net bir ayırma sağlanamamasının bir diğer nedeni olabilir. Ancak bu özelliklerin zaman içerisinde iyileştirilmesiyle, sensörden elde edilen verinin artırılması, PCA vb. istatistiksel analizlerle daha iyi sonuçlar alınmasına yardımcı olacaktır.

PCA ayrıca, H istatistiği ile birlikte olası aykırı verilerin tespiti için kullanılmıştır. Şekil 5-b'de PCA skor grafiği üzerine işlenmiş olan H istatistikleri ve Şekil 5-c'de olası aykırı veriler sunulmuştur. Numunelerin kümelenebilirliğini görüntülemek için ilk 2 temel bileşen kullanılırken, H istatistiklerinin hesaplanması ve olası aykırı verilerin işaretlenmesinde ilk 10 temel bileşen skorlarından faydalanılmıştır. Çok değişkenli düzlemde H mesafesi, kümenin şekli (kovaryansı) dikkate alınarak her gözlemin veri kümesinin merkezinden uzaklığı şeklinde ifade edilmektedir. Ayrıca bu değer ne kadar büyük olursa, ilgili veri noktasının aykırı değer olma olasılığı o kadar artmaktadır (Holbert, 2022). Mevcut çalışma kapsamında ise ortalama H mesafesine 3 standart sapma eklenmiş değerden daha büyük H mesafesine sahip olan örnekler, olası aykırı veriler olarak etiketlenmiştir. Ancak söz konusu olası aykırı örnekler için değerler incelendiğinde, bunların belirli örnekler için oldukları ve veri setinde korunması gerektiğine kanaat getirilmiştir.



Şekil 4. (a). Saf ve tağşiş uygulanmış Antep fıstığı örneklerinin reflektans spektrumları ve (b). MinMax Normalizasyonu ile ölçeklendirilmiş reflektans spektrumları (Grafik göstergelerinde 0-50 arasında değerler Antep fıstıklarına gerçekleştirilen tağşiş oranlarını temsil etmektedir.)

Figure 4. (a) Reflectance spectra of pure and adulterated pistachio samples, and (b). reflectance spectra scaled with MinMax Normalization (Values between 0-50 in the graphic indicators represent the adulteration ratio of pistachios.)



Şekil 5. (a) PCA skor grafiği (Grafik göstergesinde 0-50 arasında değerler Antep fıstıklarına gerçekleştirilen taşıyıcı oranlarını temsil etmektedir.), (b). Mahalanobis mesafesini gösterir PCA skor grafiği ve (c) olası aykırı değerleri gösterir PCA skor grafiği

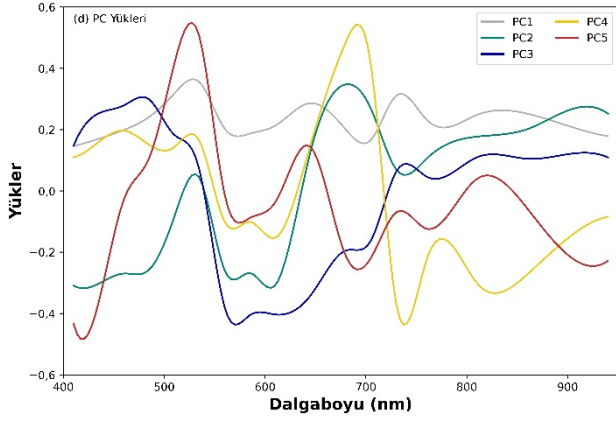
Figure 5. (a) PCA score graph (Values between 0-50 in the graph display represent the adulteration ratios of pistachios.), (b.) PCA score graph showing the Mahalanobis distance and (c) PCA score graph showing possible outliers

PCA ile elde edilen grafiklerin yorumlanması ve eksen skorlarının anlaşılması, az sayıda örnekle çalışılıyor ve örnek gruplarına göre etiketleme mevcut ise daha kolay olabilmektedir. Ancak sınıflar bilinmiyorsa veya beklenmedik kümeler tespit edilirse grafiğin yorumlanması zorlaşabilmektedir (Ivosev ve ark., 2008). Çünkü başlangıç değişkenlerinin doğrusal kombinasyonlarını temsil eden temel bileşen değerleri, ilgili değişkenler için gerçek hayatta sayısal bir anlam taşımamaktadır. Bu nedenle yorumlamak güçtür. Fakat her değişkenin bir temel bileşen üzerindeki yükleri incelenerek, bağımsız değişkenlerin her bir bileşene sağladığı katkı analiz edilebilir. Yükler sayısal açıdan bakıldığında değişkenlerin katsayılarına eşit olup, hangi değişkenlerin bileşenlere en büyük katkıyı sağladığı hakkında bilgi vermektedir. Yüksek mutlak yük değerleri (-1 veya +1'e doğru), değişkenin bileşeni güçlü bir şekilde etkilediğini ve 0'a yakın yük değerleri ise değişkenin bileşen üzerinde zayıf bir etkiye sahip olduğunu göstermektedir. Yükleme işaretinin yönü (- veya + olması), bir değişken ile bir temel bileşenin pozitif veya negatif ilişkisini ifade etmektedir (Taskesen, 2023).


Şekil 6, saf Antep fıstığı ve katkılı numunelerin normalize edilmiş spektrumları üzerinde gerçekleştirilen PCA'dan elde edilen ilk 5 temel bileşen (PC1-5) üzerindeki yüklemeleri göstermektedir. Buna göre, elde edilen spektrumlardaki reflektans değerleri ve PC yüklemelerinin, örneklerde mevcut olan pigmentlere ve O-H, C-H veya N-H fonksiyonel gruplarının gerilme titreşimlerine bağlı olarak ortaya çıktığı söylenebilir. Bu fonksiyonel gruplar, genellikle şekerler ve asitlerin konsantrasyonlarıyla ilişkilendirilmektedir (Cen & He, 2007; Mohammadi-Moghaddam ve ark., 2018). Örneğin, 400-700 nm arasında beliren piklerin, örneklerdeki Antep fıstıklarında var olan pigmentlerle ilişkili olduğu düşünülebilir. Yaklaşık 470 nm civarında beliren pikler karotenoidler ile ilişkilendirilirken, antosiyaninler ise yaklaşık 535-555 nm dalga boyu aralığında birden fazla pik gösterebilmektedir (Mohammadi-Moghaddam ve ark., 2018). Ayrıca yaklaşık 525 ve 660 nm dalga boylarında elde edilen yüklerin, numunenin rengi ile ilişkili olduğu ifade edilebilir (Ghosh ve ark., 2015). Söz konusu dalga boyu aralığında bulunabilen 601, 631 ve 634 nm civarında bulunan piklerin klorofil-b, 651 ve 696 nm dalga boyu seviyesinde bulunan yüklerin ise klorofil-a kaynaklı olduğu bilinmektedir (Mohammadi-Moghaddam ve ark., 2018). Meulebroeck & Thienpont (2006) ve Kavdir ve ark. (2007), 660 ve 680 nm dalga boyunda elde edilen reflektansların, örneklerde var olan klorofil ile ilişkilendirilebileceğini daha önce rapor etmişlerdir. Ayrıca NIR bölgesinde, 750 ve 925 nm civarında PC1-5'te görülen pikler, sırasıyla C-H'nin dördüncü aşırı ton ve üçüncü aşırı ton ile ilişkilendirilebilir. N-H'nin üçüncü aşırı tonunun 790, 820 ve 840 nm civarında reflektans gösterdiği bilinmektedir. 860 nm, 922 nm ve 940 nm'ye kadar olan piklerin ise aromatik gruplardaki CH bağından, C-H'nin üçüncü aşırı tonundan ve su moleküllerinden kaynaklanabileceği bilinmektedir (Cen & He, 2007; Mohammadi-Moghaddam ve ark., 2018).

Mevcut çalışmada ölçülen spektrum aralığının dışında kalmakla birlikte ilgili literatürde 1209, 1724, 1761, 2309 ve 2350 nm dalga boylarına elde edilen değerlerin yağ asitleri veya yağ içeriği (Fox & Cruickshank, 2005), 1690, 1728 ve 1780 nm civarında karbonhidratların C-H

bağlarının gerilme titreşim noktası (Kelly ve ark., 2006), 2148 nm civarındaki değerlerin proteinler ve 1458 nm civarındaki değerlerin O-H aşırı ton bağıyla ilişkili olabileceği yapılan farklı çalışmalarda belirtilmiştir (Sundaram ve ark., 2009).



Şekil 6 Temel bileşen yükleme grafiği  
Figure 6 Principal component loading chart



Şekil 7. Tağşiş uygulanmış ve uygulanmamış Antep fıstığı örneklerindeki hile oranları için gerçek değerler ile model tahminlerinin karşılaştırılması

Figure 7. Comparison of actual values and model predictions for adulteration ratios in adulterated and unadulterated pistachio samples

### Derin Öğrenme Modeli

Öğütülmüş Antep fıstığı örneklerindeki tağşiş düzeyinin tespiti bir regresyon problemi olarak ele alınmış olup, bu amaçla derin sıralı öğrenme yapay sinir ağı modeli eğitilmiştir. Eğitim esnasında daha önce de belirtildiği üzere farklı model yapıları ve hiper parametre kombinasyonları test edilmiştir. Hem eğitim hem de doğrulama veri seti için en iyi model uyum iyiliği istatistikleri  $10^{-5}$  öğrenme hızı ile Adam optimize edici ve epok adım sayısı 20 olan 1000 epokluk bir eğitim sonucunda elde edilmiştir. Model eğitimi esnasında aşırı ve yetersiz öğrenme sorunları olmamasına özen gösterilmiştir. Söz konusu modelin uyum iyiliği, tahmin ve

test sonuçları Şekil 7'de sunulmuştur. Buna göre öğütülmüş Antep fıstığı örneklerindeki tağşiş içeriğinin tahmin edilmesi amacıyla eğitilen derin öğrenme modeline ait uyum istatistikleri  $R^2_{\text{eğitim}}=0,85$  ve  $RMSE_{\text{eğitim}}=5,81$ , doğrulama istatistikleri ise  $R^2_{\text{doğrulama}}=0,83$  ve  $RMSE_{\text{doğrulama}}=6,13$  olarak hesaplanmıştır. Ayrıca test için yeni ham maddeler temin edilerek, baştan hazırlanan örneklerde model performansı değerlendirilmiştir. Sonuç olarak test istatistikleri  $R^2_{\text{test}}=0,80$  ve  $RMSE_{\text{test}}=6,71$  olarak tespit edilmiştir. Elde edilen sonuçlar geliştirilen modelin çok yüksek tahmin doğruluğuna sahip olmamakla birlikte, kullanıma amacı uyarınca tatmin edici doğrulukta tahminler üretebileceğine işaret etmektedir.

$R^2$  ve  $RMSE$  haricinde  $RPD$  istatistiği de kemometrik modellerinin performansı ve uygulamada kullanılabilirliği hakkında önemli fikir veren oldukça anlamlı ve dikkat çekici bir metriktir. Geliştirilen modellere ait  $RPD$  değerleri eğitim, doğrulama ve test verileri için sırasıyla  $RPD_{\text{eğitim}}=2,55$ ,  $RPD_{\text{doğrulama}}=2,44$  ve  $RPD_{\text{test}}=2,21$  olarak hesaplanmıştır. Literatürde farklı kaynaklarda  $RPD$  değeri hakkında çeşitli yaklaşımlar bulunmaktadır. Örneğin, Williams (2001) ve Bellon-Maurel ve ark. (2010),  $RPD$  değerinin 2'den büyük olmasının, modelin uygulamada kullanılabilir ve stabil tahmin kabiliyetine sahip olduğunu belirttiğini ifade etmektedir. Kısaca, böyle bir model, ilgili referans değişkenini doğru bir şekilde tahmin etmek için kullanılabilir.  $RPD$  değerinin 1,4-2 arasında olması, modelin tarama amacıyla kullanılabilirliğini ve geliştirilebileceğini ifade ederken,  $RPD$  değerinin 1,4'ten küçük olması durumunda modelin güvenilir olarak kabul edildiği belirtilmektedir. Ancak Williams ve ark. (1993),  $RPD$  değerinin 10'dan büyük olmasının mükemmel tahmin kabiliyetine işaret ettiğini (referans kimyasal metotlarla eş değer veya daha iyi), 5-10 arası  $RPD$  değerlerinin kalite kontrol amaçlı kullanılabilir bir modele işaret ettiğini, 2,5'ten büyük  $RPD$  değerlerine sahip modellerin tarama amaçlı kullanılabilirliğini ve 1  $RPD$  değerine sahip bir modelin ise kullanılamaz olduğunu belirtmiştir. Ayrıca, bu sayısal aralıkların istatistiksel bir temele dayanmaması nedeniyle,  $RPD$  değerinin mevcut verinin dağılımı ve modelin kullanım amacına göre değerlendirilmesi gerektiği, dolayısıyla düşük  $RPD$  değerine sahip modellerin de güvenilir sonuçlar almak üzere kullanılabilirliği yine Bellon-Maurel ve ark. (2010) tarafından not edilmiştir. Tüm bu bilgiler ışığında ve eğitilen modele ait diğer istatistikler birlikte değerlendirildiğinde, çalışmada eğitilen ve 2  $RPD$  değerinin üzerinde tahmin üretebilen modelin, referans bir analiz güvenilirliğinde olmamakla birlikte, analiz edilen ürün hakkında genel bir kanyaya ulaşmak amacıyla ve özellikle saha taramalarında kullanılabilirliği görülmektedir.

Her ne kadar geliştirilen model,  $RPD$  değerleri ve diğer model metrikleri incelendiğinde kabul edilebilir performans sergilemiş olsa da bazı olumsuzlukları da mevcuttur. Örneğin, model tahminlerinin, özellikle gerçekleştirilen hile oranı %10 ve üzerinde ise daha güvenilir olduğu söylenebilir. Çünkü, saf Antep fıstığı örneklerinde sahtecilik oranı %0 olması gerekirken, %5 seviyesinin biraz altında tespit edilmiştir ve bu, gerçek yaşam uygulamalarında yanıltıcı sonuçlar üretebilir. Böyle bir durumda, %5 seviyesinde sahtecilik olan örnekler saf Antep fıstığı olarak veya saf Antep fıstığı numuneleri düşük miktarda tağşiş gerçekleştirilmiş olarak

değerlendirilebilir. Bu nedenle mevcut sensör teknolojisi, Antep fıstığı numunelerinde gerçekleştirilmiş olması muhtemel sahtecilikleri analitik doğrulukla belirlemek amacıyla değil, özellikle hızlı ve ekonomik bir tarama gerektiren saha denetimlerinde ilk tetkik amacıyla değerlendirilebilir. Cihazın oldukça küçük boyutu nedeniyle kolayca taşınabilir olması da buna imkân tanımaktadır. Böylece geliştirilen teknoloji sayesinde üretim alanında, anında ve tahribatsız olarak taranan örneklerde tağşiş olup olmadığı hakkında genel bir kanı elde edilip, kabaca %10'dan daha yüksek miktarda tağşiş tespit edilen örnekler şüpheli olarak etiketlenip, kesin sonuç elde etmek amacıyla referans laboratuvarlara gönderilebilir. Öte yandan T.C. Tarım ve Orman Bakanlığı tarafından 2019 yılında yayımlanan kamuoyu duyurusunda Antep fıstığında sahtecilik yapan bir işletmenin, yaklaşık %40 düzeylerinde sahtecilik gerçekleştirdiği görülebilmektedir (TOB, 2019). Bu da potansiyel tağşişlerin daha büyük kârlar elde etmek amacıyla, %1-10 gibi düşük düzeylerde yapılmasının pek olası olmadığını düşündürmektedir.

Mevcut çalışma dışında ilgili literatürde Antep fıstığında uygulanması muhtemel sahteciliklerin kemometrik yöntemlerle belirlenmesini konu alan az sayıda çalışmaya rastlanmıştır. Bu çalışmalardan bir tanesi Antep fıstıklarına yeşil bezelye ve ıspanak karıştırılmasını ele almıştır. NIR sensör teknolojilerinden faydalanan çalışmada, fıstık örneklerinin kantitatif analizini iki farklı En Küçük Kısmî Kareler Regresyonu (PLSR) modeli kullanarak başarılı (bezelye için doğrulama değerleri;  $R^2=0,99$ ,  $RMSE=7,87$  ve ıspanak için  $R^2=0,99$ ,  $RMSE=4,69$ ) bir şekilde gerçekleştirmiştir (Geniş ve ark., 2021). Bir başka çalışmada Antep fıstığına bezelye ve yer fıstığı karıştırılmasının belirlenmesi için Raman hiper spektral görüntüleme kullanılmıştır. Elde edilen veriler PCA ve PLSR yöntemleri ile işlenerek yüksek tahmin başarısı ( $R^2=0,99$ ,  $RMSE=0,05$ ) elde edilmiştir (Eksi-Kocak ve ark., 2016). Aykas ve Menevseoglu (2021), tarafından gerçekleştirilen bir çalışmada, Antep fıstığı örneklerinde yer fıstığı ve bezelye tağşişini belirlemede FT-NIR ve FT-MIR spektroskopisi kullanılmıştır. Modelleme için PLS, PCA ve SIMCA (Yumuşak Bağımsız Sınıf Analoji Modellemesi) yöntemlerinden yararlanılmıştır. SIMCA, PCA uygulandıktan sonra her sınıf için bir güven bölgesine dayanan danışmanlı örüntü tanıma tekniklerinden birisidir (De Maesschalck ve ark., 1999). Spektral karmaşıklık nedeniyle anlamlı bilgi elde etmek için kullanılmaktadır. FT-NIR ve FT-MIR spektrometreleri birbirleri ile karşılaştırıldığında minimum örnekler arası sınıfsal mesafe değerleri (ICD) sırasıyla 13,6 ve 3,5 olarak hesaplanmıştır. FT-NIR'da ICD değerinin daha yüksek olduğu tespit edilmiştir. NIR ve MIR referans değerleri ile tahmin edilen değerler arasındaki farkı tespit etmek için standart tahmin hatası (SEP) değeri kullanılmış olup, yer fıstığı ve bezelye için FT-MIR modellerinde SEP değerleri sırasıyla %2,48 ve %2,51 olarak, FT-NIR modellerinde ise SEP değerleri sırasıyla %1,85 ve %0,7 olarak tespit edilmiştir. Bu şekilde saf ve katkılı numuneler arasında farklı kümelenmeler elde edilebilmiştir. En başarılı ayrıştırmanın FT-NIR spektroskopisi ile sağlandığı bildirilmiştir. Bir diğer çalışmada ise Antep fıstığında bezelye tağşişinin tespiti NIR ve MIR spektroskopisi kullanarak test edilmiştir. Örneklerdeki yeşil bezelye

oranının nicel tahminleri PLSR kullanılarak gerçekleştirilmiştir. NIR ve MIR kullanılan durumlar için sırasıyla 5,7 ve 1,6 RPD elde edilmiştir. Özetle en iyi tahmin kabiliyetine sahip modelin PLSR ve NIR (1216-2500 nm) kullanarak elde edildiği rapor edilmiştir (Temizkan ve ark., 2020).

Literatürde bulunan yayınlarda kullanılan birçok farklı cihaz ile yüksek tahmin başarıları elde edilmesine rağmen, bu cihazların yüksek maliyetleri nedeniyle uygulamada rutin olarak kullanılmaları ve özellikle küçük işletmeler tarafından temin edilmeleri oldukça zordur. Buna karşın mevcut çalışmada kullanılan cihazın daha dar bir dalga boyu aralığında tarama gerçekleştirmesine ve dalga boyu çözünürlüğünün düşük olmasına rağmen, çok düşük maliyeti saha taramalarında kullanılabilecek düzeyde tahmin kabiliyeti ve bir cebe sığabilecek kadar küçük boyutu sayesinde kazandığı yüksek taşınabilirliği dikkate alındığında, uygulamada ilk tetkik ve ürün hakkında fikir vermesi için rutin analizlerde kullanılma potansiyeline sahip olduğu ifade edilebilir. Fakat ölçüm alınan örneklerin kimyasal yapısı hakkında daha çok bilgi edinebilmek ve kalibrasyon modeli performansını geliştirebilmek için hem mevcut spektral çözünürlüğün artırılması hem de taranan dalga boyu aralığının genişletilmesinin fayda sağlayacağına inanılmaktadır. Ancak hiç şüphesiz ki bu durum, beraberinde cihaz maliyetinin de artmasına yol açacaktır.

## Sonuç

Bu çalışmada düşük maliyetli ve küçük boyutlu bir spektral sensör ve kemometrik yöntemler kullanılarak, Antep fıstığında bezelye ve bezelye/ıspanak tağşişinin hızlı ve tahribatsız bir biçimde tespit edilme olanağı incelenmiştir. Bu amaçla saf Antep fıstığı ile bezelye ve/veya ıspanak karıştırılarak hazırlanan numunelerin reflektans spektrumları geliştirilen spektroskopik sensör kullanılarak 410-940 nm arasında elde edilmiştir. Çalışmada eğitilen derin öğrenme modeli eğitim, doğrulama ve test verileri için kabul edilebilir bir performans sergilemiştir. Ancak, özellikle %10 ve üzeri konsantrasyonlarda uygulanması olası tağşiş tespit etmede daha başarılı olduğu ortaya konmuştur. Bu nedenle, mevcut sensör teknolojisi ve eğitilen modeli analitik hassasiyette tahminler üretmek için değil, rutin saha taramalarında ürün hakkında genel bir kanı elde etmek amacıyla kullanmanın faydalı olacağı kanısına ulaşılmıştır. Özetle, elde edilen verilerin ışığında; geliştirilen taşınabilir spektral sensörün Antep fıstığında tağşişin tespiti ve saf Antep fıstığı kullanımının doğrulanması için uygulanabilecek ekonomik, hızlı bir teknik olduğu ve farklı gıda ürünlerinin kalite tespiti uygulamalarında da kullanım potansiyeline sahip olduğu, ancak daha hassas tahminler elde etmek amacıyla hem spektral çözünürlüğün hem de taranan dalga boyu aralığının geliştirilebileceği ifade edilebilir.

## Kaynaklar

Anagaw, Y. K., Ayenew, W., Limenh, L. W., Geremew, D. T., Worku, M. C., Tessema, T. A., Simegn, W. & Mitku, M. L. (2024). Food adulteration: Causes, risks, and detection techniques—review. *SAGE Open Medicine*, 12, 20503121241250184. <https://doi.org/10.1177/20503121241250184>.



- Aykas, D. P. & Menevseoglu, A. (2021). A rapid method to detect green pea and peanut adulteration in pistachio by using portable FT-MIR and FT-NIR spectroscopy combined with chemometrics. *Food Control*, 121. <https://doi.org/10.1016/j.foodcont.2020.107670>.
- Bellon-Maurel, V., Fernandez-Ahumada, E., Palagos, B., Roger, J.-M. & McBratney, A. (2010). Critical review of chemometric indicators commonly used for assessing the quality of the prediction of soil attributes by NIR spectroscopy. *TrAC Trends in Analytical Chemistry*, 29(9), 1073-1081. <https://doi.org/10.1016/j.trac.2010.05.006>.
- Bro, R. & K. Smilde, A. (2014). Principal component analysis. *Analytical Methods*, 6(9), 2812-2831. <https://doi.org/10.1039/C3AY41907J>.
- Campmajó, G., Navarro, G. J., Núñez, N., Puignou, L., Saurina, J. & Núñez, O. (2019). Non-targeted HPLC-UV fingerprinting as chemical descriptors for the classification and authentication of nuts by multivariate chemometric methods. *Sensors*, 19(6), 1388. <https://doi.org/10.3390/s19061388>.
- Campmajó, G., Saez-Vigo, R., Saurina, J. & Núñez, O. (2020). High-performance liquid chromatography with fluorescence detection fingerprinting combined with chemometrics for nut classification and the detection and quantitation of almond-based product adulterations. *Food Control*, 114, 107265. <https://doi.org/10.1016/j.foodcont.2020.107265>.
- Campmajó, G., Saurina, J. & Núñez, O. (2023). Liquid chromatography coupled to high-resolution mass spectrometry for nut classification and marker identification. *Food Control*, 152, 109834. <https://doi.org/10.1016/j.foodcont.2023.109834>.
- Cen, H. & He, Y. (2007). Theory and application of near infrared reflectance spectroscopy in determination of food quality. *Trends in Food Science & Technology*, 18(2), 72-83. <https://doi.org/10.1016/j.tifs.2006.09.003>.
- Çavuş, F., Us, M. F. & Güzelsoy, N. A. (2018). Assessing Pistachio Nut (*Pistacia vera* L.) Adulteration with Green Pea (*Pisum sativum* L.) by Untargeted Liquid Chromatography-(quadrupole-time of flight)-Mass Spectrometry Method and Chemometrics. *Gıda ve Yem Bilimi Teknolojisi Dergisi*, (19), 34-41.
- Çinarer, G., Doğan, N., Kılıç, K. & Doğan, C. (2024). Rapid detection of adulteration in pistachio based on deep learning methodologies and affordable system. *Multimedia Tools and Applications*, 83(5), 14797-14820. <https://doi.org/10.1007/s11042-023-16172-5>.
- De Maesschalck, R., Candolfi, A., Massart, D. L. & Heuerding, S. (1999). Decision criteria for soft independent modelling of class analogy applied to near infrared data. *Chemometrics and Intelligent Laboratory Systems*, 47(1), 65-77. [https://doi.org/10.1016/S0169-7439\(98\)00159-2](https://doi.org/10.1016/S0169-7439(98)00159-2).
- DHA (2021). *Baklavada "iç" hilesi! Ceviz yerine çekirdek, Antep fıstığı yerine...*, CNN TÜRK. <https://www.cnnturk.com/yasam/baklavada-ic-hilesi-ceviz-yerine-cekirdek-antep-fistigi-yerine>.
- Edwards, K., Manley, M., Hoffman, L. C. & Williams, P. J. (2021). Non-destructive spectroscopic and imaging techniques for the detection of processed meat fraud. *Foods*, 10(2), 448. <https://doi.org/10.3390/foods10020448>.
- Eksi-Kocak, H., Menten-Yilmaz, O. & Boyaci, I. H. (2016). Detection of green pea adulteration in pistachio nut granules by using Raman hyperspectral imaging. *European Food Research and Technology*, 242(2), 271-277. <https://doi.org/10.1007/s00217-015-2538-3>.
- FAO (2022). *FAOSTAT*. <https://www.fao.org/faostat/en/#data/QCL>.
- Fox, G. & Cruickshank, A. (2005). Near infrared reflectance as a rapid and inexpensive surrogate measure for fatty acid composition and oil content of peanuts (*Arachis Hypogaea* L.). *Journal of Near Infrared Spectroscopy*, 13(5), 287-291.
- Genis, H. E., Durna, S. & Boyaci, I. H. (2021). Determination of green pea and spinach adulteration in pistachio nuts using NIR spectroscopy. *LWT*, 136. <https://doi.org/10.1016/j.lwt.2020.110008>.
- Ghosh, S., Domínguez, T. R. C., Diezma, B., Lleó, L., Barreiro, P., Lacarra, T. G. & Roger, J.-M. (2015). VIS/NIR spectral signature for the identification of peanut contamination of powder foods.
- Holbert, C. (2022). Outlier identification using mahalanobis distance. *Charles Holbert*. [https://www.cfholbert.com/blog/outlier\\_mahalanobis\\_distance/](https://www.cfholbert.com/blog/outlier_mahalanobis_distance/).
- Ivosev, G., Burton, L. & Bonner, R. (2008). Dimensionality reduction and visualization in principal component analysis. *Analytical Chemistry*, 80(13), 4933-4944. <https://doi.org/10.1021/ac800110w>.
- Kalogiouri, N. P., Mitsikaris, P. D., Papadopoulos, A. N. & Samanidou, V. F. (2022). Microwave-assisted extraction coupled to HPLC-UV combined with chemometrics for the determination of bioactive compounds in pistachio nuts and the guarantee of quality and authenticity. *Molecules*, 27(4), 1435. <https://doi.org/10.3390/molecules27041435>.
- Kavdir, I., Lu, R., Ariana, D. & Ngouajio, M. (2007). Visible and near-infrared spectroscopy for nondestructive quality assessment of pickling cucumbers. *Postharvest Biology and Technology*, 44(2), 165-174. <https://doi.org/10.1016/j.postharvbio.2006.09.002>.
- Kelly, J. D., Petisco, C. & Downey, G. (2006). Potential of near infrared transmittance spectroscopy to detect adulteration of irish honey by beet invert syrup and high fructose corn syrup. *Journal of Near Infrared Spectroscopy*, 14(2), 139-146.
- Kendirci, P. & Onoğur, T. A. (2011). Investigation of volatile compounds and characterization of flavor profiles of fresh pistachio nuts (*Pistacia vera* L.). *International Journal of Food Properties*, 14(2), 319-330. <https://doi.org/10.1080/10942910903177830>.
- Khan, S., Xiaobo, Z., Ilyas, M., Rahman, K. U., Khan, R. D., Shahid, K., Ahmad, A., Akbar, H., Ahmad, T., Irfan, M., Zafar, Z., Iqbal, A. Z., Boateng, R. A., Maqbool, B., Harlioglu, M. M. & Jamil, M. (2021). Fraud food and food spoilage detection by non-destructive technologies. *Annals of the Romanian Society for Cell Biology*, 25(7), 1389-1405.
- Lu, X., (2017). Sensing Techniques for Food Safety and Quality Control. *Royal Society of Chemistry*.
- Meulebroeck, W. & Thienpont, H. (2006). Optical detection techniques for laser sorting machines. *Optical Sensing II*, 358-369.
- Modupalli, N., Naik, M., Sunil, C. K. & Natarajan, V. (2021). Emerging non-destructive methods for quality and safety monitoring of spices. *Trends in Food Science & Technology*, 108, 133-147. <https://doi.org/10.1016/j.tifs.2020.12.021>.
- Mohammadi-Moghaddam, T., Razavi, S. M. A., Sazgarnia, A. & Taghizadeh, M. (2018). Predicting the moisture content and textural characteristics of roasted pistachio kernels using Vis/NIR reflectance spectroscopy and PLSR analysis. *Journal of Food Measurement and Characterization*, 12(1), 346-355. <https://doi.org/10.1007/s11694-017-9646-7>.
- Nobari Moghaddam, H., Tamiji, Z., Akbari Lakeh, M., Khoshayand, M. R. & Haji Mahmoodi, M. (2022). Multivariate analysis of food fraud: A review of NIR based instruments in tandem with chemometrics. *Journal of Food Composition and Analysis*, 107, 104343. <https://doi.org/10.1016/j.jfca.2021.104343>.
- Sezer, B., Apaydin, H., Bilge, G. & Boyaci, I. H. (2019). Detection of *Pistacia vera* adulteration by using laser induced breakdown spectroscopy. *Journal of the Science of Food and Agriculture*, 99(5), 2236-2242. <https://doi.org/10.1002/jsfa.9418>.
- Shenk, J. S. & Westerhaus, M. O. (1993). *Analysis of agriculture and food products by near infrared reflectance spectroscopy*.

- SU (2020). *Gıda sahtekarları açıklandı! Dana diye domuz, Antep fıstığı diye yer fıstığı satmışlar.* <https://www.sozcu.com.tr/canonicalUrl>.
- Suman, M., Cavanna, D., Sammarco, G., Lambertini, F. & Loffi, C. (2021). Fighting food frauds exploiting chromatography-mass spectrometry technologies: Scenario comparison between solutions in scientific literature and real approaches in place in industrial facilities. *TrAC Trends in Analytical Chemistry*, 142, 116305. <https://doi.org/10.1016/j.trac.2021.116305>.
- Sundaram, J., Kandala, C. V. & Butts, C. L. (2009). Application of near infrared spectroscopy to peanut grading and quality analysis: overview. *Sensing and Instrumentation for Food Quality and Safety*, 3(3), 156-164. <https://doi.org/10.1007/s11694-009-9081-5>.
- Taskesen, E. (2023). What are PCA loadings and how to effectively use Biplots?. *Towards Data Science*. <https://towardsdatascience.com/what-are-pca-loadings-and-biplots-9a7897f2e559>.
- Teixeira, A. M. & Sousa, C. (2019). A review on the application of vibrational spectroscopy to the chemistry of nuts. *Food Chemistry*, 277, 713-724. <https://doi.org/10.1016/j.foodchem.2018.11.030>.
- Temizkan, R., Dogan, M. A., Atakan, O., Nazım, B. A. & Ayvaz, H. (2020). Rapid detection of green pea adulteration in ground pistachio nuts using near and mid-infrared spectroscopy.
- TOB (2019). Kamuoyu duyurusu, Tarım ve Orman Bakanlığı. [https://www.dunya.com/storage/old/uploads/content/kamuyu- duyurusu-tarim11pdf\\_NgT9T.pdf](https://www.dunya.com/storage/old/uploads/content/kamuyu- duyurusu-tarim11pdf_NgT9T.pdf).
- Turgut, S. S., Bilge, G., Entrenas, J. A. & Pérez-Marín, D. (2024). Significant roles of smart sensors in the modern agriculture and food industry, In A. Hassoun, (Eds.), *Food Industry 4.0* (pp. 133-170). <https://doi.org/10.1016/B978-0-443-15516-1.00008-6>.
- Vega-Castellote, M., Sánchez, M.-T., Torres-Rodríguez, I., Entrenas, J.-A. & Pérez-Marín, D. (2024). NIR sensing technologies for the detection of fraud in nuts and nut products: A review, *Foods*, 13(11), 1612. <https://doi.org/10.3390/foods13111612>.
- Walach, J., Filzmoser, P. & Hron, K. (2018). Data normalization and scaling: Consequences for the analysis in omics sciences, *Comprehensive Analytical Chemistry* (pp. 165-196). <https://doi.org/10.1016/bs.coac.2018.06.004>.
- Williams, P. (2001). Implementation of near-infrared technology. *Near-infrared technology in the agricultural and food industries*. <https://cir.nii.ac.jp/crid/1572543025338730368>.
- Williams, P. C. & Sobering, D. C. (1993). Comparison of commercial near infrared transmittance and reflectance instruments for analysis of whole grains and seeds. *Journal of Near Infrared Spectroscopy*, 1(1), 25-32. <https://doi.org/10.1255/jnirs.3>.
- Yuille, A. (2014). Lecture 10. PCA, SVD and Fisher Linear Discriminant.
- Zannella, C., Carucci, F., Aversano, R., Prohaska, T., Vingiani, S., Carputo, D. & Adamo, P. (2017). Genetic and geochemical signatures to prevent frauds and counterfeit of high-quality asparagus and pistachio. *Food Chemistry*, 237, 545-552. <https://doi.org/10.1016/j.foodchem.2017.05.158>.