



Fırında pişirilen patates kızartmalarında akrilamid oluşumunun optimize edilmiş gauss süreç regresyonu ile modellenmesi

Modeling acrylamide formation in oven-baked French fries using optimized gaussian process regression

Eşref Boğar^{1,*} , Damla Nur Kaya² , Deniz Kaynar³ , Büşra Braho⁴ , Melek Harmancı⁵ 

^{1,2,3,4} Pamukkale Üniversitesi, Biyomedikal Mühendisliği Bölümü, 20160, Denizli Türkiye

⁵ BSH Ev Aletleri Sanayi ve Ticaret AŞ, İstanbul Türkiye

Öz

Yüksek düzeyde akrilamid maruziyeti, genotoksik ve potansiyel olarak kanserojen etkiler göstermekte olup, insan sağlığı açısından ciddi bir risk unsuru olarak değerlendirilmektedir. Bu nedenle, gıda ürünlerinde akrilamid oluşumunun kontrol altına alınması, gıda güvenliği açısından büyük önem taşımaktadır. Bu çalışmada, ev tipi fırında pişirilen patates kızartmalarında pişirme sıcaklığı ve süresinin akrilamid oluşumu üzerindeki etkileri deneysel olarak incelenmiş ve bu parametrelerin akrilamid oluşumu ile ilişkisi modellenmiştir. Farklı pişirme koşullarında ölçülen akrilamid düzeyleri 94.78 µg/kg ile 1070.67 µg/kg arasında değişmiş, sıcaklık ve süredeki artışın akrilamid oluşumunu artırdığı gözlemlenmiştir. Modelleme sürecinde, hiperparametre optimizasyonu oransal–integral–türevsel tabanlı arama algoritmasıyla gerçekleştirilen Gauss süreç regresyon modeli önerilmiştir. Önerilen modelin performansı, çok değişkenli doğrusal, etkileşimli, basit karesel, karesel, Gauss, logaritmik ve üstel regresyon modelleriyle karşılaştırılmıştır. Elde edilen bulgular, önerilen modelin deneysel verileri en yüksek doğrulukla temsil ettiğini ortaya koymuştur. Bu model, kök ortalama kare hata (RMSE) değeri 56.90 ve determinasyon katsayısı (R²) değeri 0.97 ile diğer modellere kıyasla üstün bir performans sergilemiştir. Ayrıca, Avrupa Birliği tarafından belirlenen 500 µg/kg'lık referans değer esas alınarak, sıcaklık ve süre kombinasyonlarına bağlı potansiyel sağlık riski haritalandırılmıştır. Bu çalışma, akrilamid oluşumunu azaltmaya yönelik etkili stratejilerin geliştirilmesine katkı sağlamakta ve gıda güvenliği ile halk sağlığının korunmasına yönelik önemli bilgiler sunmaktadır.

Anahtar kelimeler: Akrilamid, Fırınlanmış patates, Gauss süreç regresyonu, Gıda güvenliği, Halk sağlığı

1 Giriş

Akrilamid, yüksek sıcaklık ve düşük nem koşullarında gerçekleştirilen ısı işlemler sırasında bazı gıdalarda oluşan bir kimyasal bileşiktir [1, 2]. Özellikle kızartma, fırınlama ve kavurma işlemleri sırasında, karbonhidrat bakımından zengin gıdalarda (başta patates, kahve ve tahıl bazlı ürünler) serbest amino asitler ile indirgen şekerler arasında

Abstract

High levels of acrylamide exposure exhibit genotoxic and potentially carcinogenic effects and are considered a serious risk factor for human health. Therefore, controlling acrylamide formation in food products is of great importance for ensuring food safety. In this study, the effects of cooking temperature and time on acrylamide formation in oven-baked French fries were experimentally investigated, and the relationship between these parameters and acrylamide formation was modeled. Acrylamide levels measured under different cooking conditions ranged from 94.78 µg/kg to 1070.67 µg/kg, and it was observed that increases in temperature and time led to higher acrylamide formation. In the modeling process, a Gaussian process regression model, with hyperparameters optimized using a proportional–integral–derivative-based search algorithm, was proposed. The performance of the proposed model was compared with multivariate linear, interaction, simple quadratic, quadratic, Gaussian, logarithmic, and exponential regression models. The findings revealed that the proposed model represented the experimental data with the highest accuracy. This model demonstrated superior performance compared to other models, with a root mean square error (RMSE) value of 56.90 and a coefficient of determination (R²) value of 0.97. Additionally, based on the reference value of 500 µg/kg established by the European Union, the potential health risk was mapped according to the combinations of temperature and time. This study contributes to the development of effective strategies to reduce acrylamide formation and provides important insights into ensuring food safety and protecting public health.

Keywords: Acrylamide, Oven-baked French fries, Gaussian process regression, Food safety, Public health

gerçekleşen Maillard reaksiyonu sonucu meydana gelmektedir [3, 4].

Akrilamid oluşumunun en yaygın ve kabul gören mekanizması, Maillard reaksiyonudur. Bu reaksiyon, özellikle glikoz ve fruktoz gibi indirgen şekerlerle asparajin aminoasidi arasında, düşük su aktivitesi ve yüksek sıcaklık koşullarında gerçekleşmektedir [5]. Maillard reaksiyonu

* Sorumlu yazar / Corresponding author, e-posta / e-mail: ebogar@pau.edu.tr (E. Bogar)

Geliş / Received: 09.05.2025 Kabul / Accepted: 17.06.2025 Yayımlanma / Published: 15.07.2025

doi: 10.28948/ngumuh.1696315

sırasında, asparajın ile indirgen şekerler arasındaki ilk reaksiyon sonucunda Schiff bazı oluşur; bu yapı dekarboksilasyon yoluyla dekarboksile Amadori ürününe dönüşür ve ardından Strecker bozunması ile akrilamid oluşumu gerçekleşir [6, 7]. Ayrıca, lipid, karbonhidrat ve amino asitlerin ayrışması sonucu oluşan akrolein veya akrilik asit yoluyla da akrilamid oluşumu meydana gelebilmektedir [8, 9]. Bunlara ek olarak, malik, laktik ve sitrik asit gibi organik asitlerin su veya karboksil grubunun kaybıyla ve amino asitlerden doğrudan akrilamid oluşabileceği belirtilmektedir [10].

Uluslararası Kanser Araştırmaları Ajansı (IARC), gıdalarda bulunan akrilamidi “İnsanlar İçin Grup 2A Olası Kanserojen” olarak sınıflandırmıştır [11]. Avrupa Komisyonu ise akrilamidi genotoksik ve nörotoksik bir bileşen olarak değerlendirmekte olup, potansiyel bir insan kanserojeni olarak sınıflandırmaktadır [12]. Ayrıca çeşitli çalışmalarda, akrilamide uzun süreli maruziyetin sağlık üzerinde farklı olumsuz etkilerle de ilişkilendirildiği bildirilmiştir [6, 13-16]. Bu nedenle, gıdalarda akrilamid oluşumunun azaltılması, potansiyel sağlık risklerinin önlenmesi ve halk sağlığının korunması açısından büyük önem taşımaktadır.

Literatürde, gıdalarda akrilamid oluşumunu azaltmaya yönelik çeşitli tekniklerle çalışmalar yapılmıştır. Bu teknikler arasında proses koşullarının optimizasyonu [17], haşlama [18, 19], enzimatik işlem [20], maya fermentasyonu [21], ultrason uygulaması [22], darbeleri elektrik alan kullanımı [23], katkı maddesi ilavesi [24], ışınlama [25] ve diğer çeşitli stratejiler [4, 26-30] yer almaktadır. Akrilamid oluşumuna etki eden başlıca faktörler arasında proses koşulları, gıdanın bileşimi, pH seviyesi, su aktivitesi, katkı maddeleri, pişirme yöntemi, ön işleme uygulamaları, hammaddenin yetiştirilme koşulları ve depolama koşulları yer almaktadır [31-34]. Özellikle sıcaklık ve süre gibi proses koşulları, akrilamid oluşumunu etkileyen en önemli faktörlerdir [35, 36]. Bu faktörlerin uygun şekilde ayarlanması, akrilamid oluşumunun engellenmesi veya yavaşlatılması için en temel strateji olup, düşük maliyet, zaman verimliliği ve uygulanabilirlik açısından önemli avantajlar sağlamaktadır.

Optimum proses koşullarının belirlenebilmesi için öncelikle süreç değişkenleri ile akrilamid oluşumu arasındaki ilişkinin doğru ve hassas bir şekilde modellenmesi gerekmektedir. Literatürde bu amaçla çeşitli modelleme yaklaşımları önerilmiştir. Bu yaklaşımlar arasında en yaygın kullanılanlardan bazıları, Yanıt Yüzey Yöntemi (Response Surface Methodology, RSM) kapsamında değerlendirilen etkileşimli ve ikinci dereceden (karesel) regresyon modelleridir [17, 19, 37-40]. Ayrıca, Chen vd. [41] sıcaklık ve süre değişkenlerine karşılık akrilamid oluşumunu modellemek amacıyla doğrusal, basit karesel (parabolik), Gauss ve Lorentzian olmak üzere dört farklı çok değişkenli regresyon yöntemini kullanmışlardır. Bu klasik regresyon yaklaşımları, basitlik ve uygulama kolaylıkları nedeniyle yaygın olarak kullanılsa da çoklu parametrelerin karmaşık etkileşimlerini doğru bir şekilde modelleme ve tahmin etme konusunda zaman zaman sınırlamalar gösterebilmektedir [42]. Bu nedenle, Makine Öğrenmesi teknikleri, özellikle

Yapay Sinir Ağları (Artificial Neural Networks, ANN), Destek Vektör Regresyonu (Support Vector Regression, SVR) ve Gauss Süreç Regresyonu (Gaussian Process Regression, GPR) gibi yöntemler, karmaşık etkileşimlerin modellenmesinde daha başarılı sonuçlar verebilmesinden dolayı popülerlik kazanmışlardır [43]. Bu tekniklerin kullanımı, verinin büyüklüğü ve karmaşıklığına bağlı olarak farklı avantajlar sunmaktadır. ANN ve SVR büyük veri setlerinde yüksek modelleme ve tahmin performansı gösterirken, GPR özellikle küçük veri setlerinde sağladığı güçlü performans, esneklik ve belirsizlik modelleme kabiliyetiyle öne çıkmaktadır [44-46].

Literatürdeki bu bulgular ışığında, bu çalışma kapsamında ev tipi fırında pişirilen patates kızartmalarında sıcaklık ve sürenin akrilamid oluşumu üzerindeki etkileri deneysel olarak incelenmiş ve bu faktörler ile akrilamid oluşumu arasındaki ilişki modellenmiştir. Sınırlı sayıda deneysel veri elde edilebildiğinden, modelleme aşamasında GPR yöntemi kullanılmıştır. Bu yönüyle, akrilamid oluşumunun GPR ile modellenmesi literatürde bir ilk olup, çalışmanın yenilikçi yönlerinden biridir. Ayrıca, GPR’de hiperparametre optimizasyonu için genellikle gradyan tabanlı optimizasyon algoritmaları kullanılmaktadır. Ancak, bu algoritmalar başlangıç değerine aşırı bağımlı olması ve yerel optimuma takılma gibi dezavantajlara sahiptir [47, 48]. Bu nedenle, bu çalışmada hiperparametre optimizasyonu için global arama yeteneğine sahip ve birçok meta-sezgisel algoritmaya göre performansı kanıtlanmış PID tabanlı arama algoritması (PID-based search algorithm, PSA) kullanılmıştır. PSA’nın GPR hiperparametrelerinin optimizasyonunda ilk kez uygulanması, çalışmanın bir diğer özgün katkısını oluşturmaktadır. Ek olarak, Avrupa Birliği tarafından belirlenen referans değerler dikkate alınarak sıcaklık ve süre faktörlerine bağlı olarak akrilamid miktarının sağlık açısından haritalandırılması, çalışmanın diğer önemli katkılarından biridir. Bu çalışmanın bulguları; gıda üreticileri, halk sağlığı yetkilileri, tüketiciler ve fırın üreticileri gibi farklı paydaşlara yönelik bilgiler sunmakta ve halk sağlığının korunmasına yönelik stratejilere katkı sağlamaktadır.

2 Materyal ve metod

2.1 Deneysel süreç

Bu çalışmada, pişirme süresi ve sıcaklığı olmak üzere iki bağımsız değişken ele alınmıştır. Her bir değişken için üç farklı seviye belirlenmiş olup, kullanılan değişkenler ve seviyeleri Tablo 1’de verilmiştir.

Tablo 1. Çalışmada kullanılan değişkenler ve seviyeleri

Değişken	Seviye 1	Seviye 2	Seviye 3
Süre (dakika)	20	30	40
Sıcaklık (°C)	180	200	220

Deneysel çalışma, tam faktöriyel deney tasarımı çerçevesinde gerçekleştirilmiştir. Her iki değişkenin üç seviyesinin tüm olası kombinasyonları kullanılarak toplam dokuz farklı deney koşulu oluşturulmuştur. Deneylerde tutarlılığı sağlamak ve standardizasyonu korumak amacıyla, endüstriyel ölçekte üretilmiş dondurulmuş parmak patates

(SuperFresh) kullanılmış ve tüm numuneler aynı üretim partisinden olacak şekilde temin edilmiştir. Ürünün 100 gramındaki besin öğeleri Tablo 2'de sunulmuştur.

Tablo 2. Çalışmada kullanılan ürünün besin öğeleri (100 g için)

Besin öğesi	Miktar (g)
Yağ	3,5
Doymuş yağ	1,5
Karbonhidrat	28
Protein	2,0
Tuz	0,6

Her bir deney koşulunda 500 g patates örneği, 66 L iç hacme sahip, mekanik ısı kontrolü bulunan elektrikli ankastre fırında; sıcak hava modunda, önceden ısıtılmış fırının üçüncü raf seviyesine yerleştirilen ızgara tepsisi üzerinde pişirilmiştir. Pişirme işlemi, üretici kullanım kılavuzunda belirtilen yerleşim ve çalışma koşullarına uygun şekilde gerçekleştirilmiştir. Pişirme işlemleri sırasında patatesler tek katman halinde yerleştirilmiş, ek yağ kullanılmamış ve önceden çözdürme işlemi uygulanmamıştır.

Akrilamid analizleri, Radix/Denise Özel Gıda Kontrol Laboratuvarı'nda gerçekleştirilen hizmet alımı kapsamında, LC-MS/MS yöntemi ile yapılmıştır. Uygulanan analiz prosedürü, Rufián-Henares ve Morales [49] tarafından geliştirilen metoda dayanmaktadır. %95 güven aralığında elde edilen analiz sonuçları doğrultusunda, her bir deney koşuluna karşılık gelen akrilamid değerleri belirlenmiş ve dokuz farklı pişirme koşuluna ait giriş-çıkış veri kümesi oluşturulmuştur.

2.2 Modelleme süreci

Bu bölümde, öncelikle modelleme sürecinde kullanılan Gauss Süreç Regresyonu yöntemi ve hiperparametre optimizasyonunda kullanılan PID tabanlı arama algoritması açıklanmıştır. Daha sonra, önerilen PSA-GPR yaklaşımı ayrıntılı olarak sunulmuştur.

2.2.1 Gauss süreç regresyonu

Gauss Süreç Regresyonu (Gaussian Process Regression, GPR), parametrik olmayan yapısı sayesinde doğrusal olmayan ve karmaşık ilişkileri modellemede yüksek başarı gösteren, güçlü bir makine öğrenmesi yöntemidir [50-53]. Belirli bir fonksiyonel forma ihtiyaç duymadan veriye esnek şekilde uyum sağlayabilmesi ve modelleme sürecinde belirsizlikleri nicel olarak ifade edebilmesi, GPR'yi özellikle küçük örneklem boyutuna sahip, gürültülü ya da eksik veriler içeren sistemler için etkili bir seçenek hâline getirmektedir [54]. Bu avantajları sayesinde GPR; yanıt yüzeyi modelleme [55], dinamik süreçlerin modellenmesi [56], sistem tanılaması [57] ve zaman serisi analizi [58] gibi farklı uygulama alanlarında yaygın olarak kullanılmaktadır.

GPR, gözlemlenen veriler ile bilinmeyen hedef fonksiyon arasındaki ilişkiyi olasılıksal yaklaşımla ifade etmektedir. Bu yöntemde, giriş uzayındaki bir x girdisine karşılık gelen çıktı y , Denklem (1)'de gösterildiği şekilde ifade edilir [59].

$$y = f(x) + \varepsilon \quad (1)$$

Burada $f(x)$ bilinmeyen hedef fonksiyon, $\varepsilon \sim \mathcal{N}(0, \sigma_\varepsilon^2)$ ise sıfır ortalama ve σ_ε^2 varyansa sahip normal dağılmış gözlem gürültüsünü temsil etmektedir.

GPR kapsamında $f(x)$ fonksiyonu, bir Gaussian süreç (GP) ile modellenir ve bu fonksiyon Denklem (2) şeklinde ifade edilir [60].

$$f(x) \sim GP(m(x), k(x, x')) \quad (2)$$

Burada $m(x)$ ortalama fonksiyonunu, $k(x, x')$ ise iki giriş arasındaki benzerliği tanımlayan çekirdek (kernel) fonksiyonunu ifade eder. Literatürde çeşitli çekirdek fonksiyonları bulunmakla birlikte, kare üstel (squared exponential) fonksiyon, yüksek genelleme yeteneği ve çok çeşitli uygulamalarda gösterdiği başarılı performans nedeniyle en yaygın olarak kullanılan çekirdek fonksiyonlarından biridir [61]. Bu çalışmada da söz konusu avantajları nedeniyle kare üstel çekirdek fonksiyonu tercih edilmiş olup, fonksiyonel ifadesi Denklem (3)'te verilmiştir.

$$k(x, x') = \sigma_f^2 \exp\left(-\frac{\|x - x'\|^2}{2l^2}\right) \quad (3)$$

Bu eşitlikte σ_f^2 sinyal varyansı, l ise karakteristik uzunluk (length-scale) parametresini temsil etmektedir. Bu çekirdek fonksiyonu kullanılarak, $X = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^{n \times d}$ ve bunlara karşılık gelen gözlem çıktıları $y = [y_1, y_2, \dots, y_n]^T \in \mathbb{R}^n$ olmak üzere, kovaryans matrisi $K \in \mathbb{R}^{n \times n}$ Denklem (4) kullanılarak hesaplanır.

$$K_{ij} = k(x_i, x_j), \quad \forall i, j = 1, 2, \dots, n \quad (4)$$

Yeni bir test girdisi $x_* \in \mathbb{R}^d$ verildiğinde, bu girdiye karşılık gelen tahmini çıktı (beklenen değer) $\bar{y}_*$ ve ilgili belirsizlik (varyans) σ_*^2 , sırasıyla Denklem (5) ve Denklem (6)'da tanımlanmıştır [62].

$$\bar{y}_* = k_*^T (K + \sigma_\varepsilon^2 I)^{-1} y \quad (5)$$

$$\sigma_*^2 = k(x_*, x_*) - k_*^T (K + \sigma_\varepsilon^2 I)^{-1} k_* \quad (6)$$

Bu denklemlerde $k_* \in \mathbb{R}^n$, test girdisi ile tüm eğitim verileri arasındaki kovaryansları içeren vektörü temsil etmekte olup, Denklem (7) ile ifade edilir.

$$k_* = [k(x_*, x_1), k(x_*, x_2), \dots, k(x_*, x_n)]^T \quad (7)$$

Modelin performansını belirleyen hiperparametreler olan σ_ε^2 , σ_f^2 ve l doğrudan tahmin doğruluğunu etkilemektedir. Bu nedenle bu hiperparametrelerin optimize edilmesi, modelin güvenilirliği ve genellenebilirliği açısından büyük önem taşımaktadır.

2.2.2 PID tabanlı arama algoritması

PID tabanlı arama algoritması (PID-based search algorithm, PSA), 2023 yılında Gao [63] tarafından

geliştirilen, popülasyon tabanlı bir meta-sezgisel optimizasyon algoritmasıdır. Bu algoritma, artırılmış Oransal-İntegral-Türevsel (Proportional-Integral-Derivative, PID) kontrol stratejisinden esinlenerek tasarlanmıştır. PSA, PID kontrol mekanizmasının hata geri besleme prensibini kullanarak arama sürecini yönlendirir ve global optimum çözümün bulunmasını hedefler. Algoritmanın etkinliği, çeşitli karmaşık test fonksiyonları ve farklı gerçek dünya problemleri üzerinde gerçekleştirilen çalışmalarla doğrulanmıştır [63-69].

Genel olarak PSA, popülasyondaki her bir bireyi/çözümü sistemin ölçülen değeri olarak kabul ederken, önceki iterasyonlarda elde edilen en iyi çözümü ise hedef yani referans değer olarak değerlendirir. PID kontrol mekanizmasının hata geri besleme prensibi doğrultusunda, her bireyin mevcut konumu ile en iyi çözüm arasındaki sapma iteratif olarak düzenlenir. Bu süreç aracılığıyla popülasyonun zamanla global optimuma doğru yönlendirilmesi amaçlanmaktadır. PSA'nın matematiksel modeli aşağıda sunulmaktadır.

PSA optimizasyon sürecine, çözüm uzayı içinde rastgele bir popülasyon üreterek başlar. Bu başlangıç popülasyonu, Denklem (8) kullanılarak oluşturulur [63].

$$X_{ij} = l_j + r(u_j - l_j), \quad \begin{cases} i = 1, 2, \dots, N \\ j = 1, 2, \dots, D \end{cases} \quad (8)$$

Bu denklemde X_{ij} i . bireyin j . boyuttaki konumunu, $r \in (0,1)$ düzgün dağılımlı rastgele bir sayıyı ifade etmektedir. Ayrıca, N popülasyon büyüklüğünü, D problemin boyutunu (değişken sayısını), l_j ve u_j ise sırasıyla j . değişkenin alt ve üst sınırlarını göstermektedir.

Başlangıç popülasyonunun oluşturulmasının ardından, PSA algoritmasında popülasyon güncellemeleri iteratif bir süreç boyunca ($t = 1, 2, \dots, T$) gerçekleştirilir. Burada, T algoritmanın bir giriş parametresi olup maksimum iterasyon sayısını temsil etmektedir. Popülasyon güncellemesi, sistemdeki sapmalara dayalı bir PID düzenleme mekanizması kullanılarak yapılır. Bu bağlamda, t . iterasyondaki PID düzenleyicisinin çıkış değeri ΔU^t Denklem (9) ile hesaplanır [63].

$$\Delta U^t = K_p r_1 [E_0^t - E_1^t] + K_i r_2 E_0^t + K_d r_3 [E_0^t - 2E_1^t + E_2^t] \quad (9)$$

Bu denklemde K_p , K_i ve K_d sırasıyla oransal, integral ve türev katsayılarını temsil etmekte olup kullanıcı tarafından girilmesi gereken PSA'ya özgü parametrelerdir. Ayrıca, r_1 , r_2 ve r_3 eleman değerleri 0 ile 1 arasında olan rastgele oluşturulan vektörlerdir. E_0^t , E_1^t ve E_2^t , t . iterasyondaki sistem sapmalarını ifade etmekte olup, Denklemler (10)-(12) ile iteratif olarak güncellenir.

$$E_0^t = X_*^{t-1} - X^{t-1}, \quad t \geq 1 \quad (10)$$

$$E_1^t = \begin{cases} E_0^t & t = 1 \\ E_0^{t-1} + X_*^t - X_*^{t-1} & t > 1 \end{cases} \quad (11)$$

$$E_2^t = \begin{cases} E_0^t, & t = 1 \\ E_1^{t-1}, & t > 1 \end{cases} \quad (12)$$

Bu denklemlerde X_*^t ve X_*^{t-1} sırasıyla t . ve $(t-1)$. iterasyonlar boyunca elde edilen en iyi çözümleri temsil etmektedir.

Ayrıca, algoritmanın yerel optimuma sıkışmasını önlemek ve keşif yeteneğini artırmak için bu mekanizmaya "sıfır çıkış" adı verilen bir koşullandırma faktörü eklenmiştir. Sıfır çıkış (O^t), Denklem (13) ile hesaplanmaktadır [63]:

$$O^t = \left(\cos \left(1 - \frac{t}{T} \right) + \tau RL \right) E_0^t \quad (13)$$

Burada R elemanları 0 ile 1 arasında düzgün dağılımlı rastgele sayılardan oluşan $N \times D$ boyutunda bir matristir. L ise Levy uçuş fonksiyonunu ifade etmekte olup, Denklem (14) ile tanımlanmaktadır.

$$L = \frac{U\varphi}{|V|^{1/\lambda}}; \quad \varphi = \left[\frac{\Gamma(1 + \lambda \sin(\frac{\pi\lambda}{2}))^{1/\lambda}}{\Gamma(\frac{1+\lambda}{2}) \lambda 2^{\frac{\lambda-1}{2}}} \right] \quad (14)$$

U ve V normal dağılımlı rastgele sayılardan oluşan matrislerdir; $\Gamma(\cdot)$ Gamma fonksiyonunu işaret etmektedir ve λ ise değeri 1.5 olarak ayarlanmış bir sabittir.

Denklem (13)'te τ bir ayarlama faktörüdür ve iteratif olarak Denklem (15)'te gösterildiği şekilde hesaplanır.

$$\tau = \left(\frac{\ln(T - t + 2)}{\ln(T)} \right)^2 \quad (15)$$

Son olarak, mevcut popülasyon, ΔU^t ve O^t değerlerine bağlı olarak Denklem (16) kullanılarak güncellenmektedir [63].

$$X^{t+1} = X^t + \eta \Delta U^t + (1 - \eta) O^t \quad (16)$$

Bu denklemde X^{t+1} güncellenmiş popülasyonu temsil etmektedir ve burada ki η vektörü Denklem (17) kullanılarak güncellenir.

$$\eta = r_5 \cos \left(\frac{t}{T} \right) \quad (17)$$

Burada r_5 , elemanları 0 ve 1 aralığında düzgün dağılımlı olan bir satır vektördür. Bu mekanizma sayesinde PSA, iterasyonların erken aşamalarında keşif odaklı çalışırken, ilerleyen aşamalarda daha fazla sömürü odaklı hale gelmektedir.

2.2.3 Önerilen PSA-GPR modeli


Akrilamid oluşumunun modellenmesinde, hiperparametreleri PID tabanlı arama algoritması (PSA) ile optimize edilen Gauss süreç regresyonu (GPR) modeli önerilmiştir. Bu kapsamda geliştirilen model, PSA-GPR olarak adlandırılmıştır. GPR modeli, daha önce ifade edildiği

üzere, σ_e^2 , σ_f^2 ve l olmak üzere üç hiperparametreye sahiptir. Bu hiperparametrelerin uygun biçimde belirlenmesi, modelin genelleme performansı ve tahmin doğruluğu açısından belirleyici bir rol oynamaktadır.

Bu çalışmada, söz konusu hiperparametrelerin optimizasyonu için bir meta-sezgisel algoritma olan PSA kullanılmıştır. Ayrıca, modelin aşırı öğrenme eğilimini azaltmak ve genelleme yeteneğini güvenilir biçimde değerlendirebilmek adına birini dışarıda bırak çapraz doğrulama (Leave-One-Out Cross Validation, LOOCV) stratejisi benimsenmiştir. LOOCV, her bir gözlemi sırasıyla test/doğrulama verisi olarak dışarıda bırakarak, geri kalan veriyle modelin yeniden eğitildiği bir çapraz doğrulama yaklaşımıdır. Özellikle örnek sayısı sınırlı veri kümelerinde, model performansını değerlendirmek için sıkça tercih edilen bir yaklaşımdır [70, 71]. Bu bağlamda, çalışmada kullanılan veri setinin sınırlı örnek sayısına sahip olması nedeniyle, bu

çapraz doğrulama yaklaşımının tercih edildiğini belirtmekte fayda vardır.

Şekil 1’de PSA algoritması kullanılarak GPR modelinin hiperparametrelerinin optimize edildiği sürecin ayrıntılı akış şeması sunulmuştur. Bu süreç, LOOCV stratejisiyle yapılandırılmış GPR modeli ile PSA algoritmasının hiperparametre arama mekanizmasından oluşan iki bileşenden oluşmaktadır. İlk bileşende, GPR modeli LOOCV kapsamında eğitim ve doğrulama adımlarına tabi tutulmaktadır. Her bir döngüde bir gözlem doğrulama amacıyla dışarıda bırakılır, kalan gözlemlerle model eğitilir ve dışarıda bırakılan gözlem üzerinde tahmin hatası (e_i) hesaplanır. Elde edilen tüm hata değerleriyle hata karelerinin ortalamasının karekökü (Root Mean Square Error, RMSE) hesaplanır ve bu RMSE değeri, PSA algoritmasında ilgili aday çözümün uygunluk değeri olarak kullanılır.



Şekil 1. GPR modelinin PSA ile hiperparametre optimizasyonunun akış şeması

İkinci bileşende, PSA algoritması, rastgele oluşturulmuş bir başlangıç popülasyonunun oluşturulmasıyla optimizasyon sürecine başlar. Her bir aday çözüm, GPR modelinin hiperparametreleri olan σ_e^2 , σ_f^2 ve l ile temsil edilmektedir. PSA, her iterasyonda tahmin hatalarına dayalı RMSE'yi minimize etmeye çalışmaktadır. Her iterasyonda uygunluk değerleri yeniden hesaplanarak popülasyon güncellenmekte ve bu süreç, belirlenen durdurma kriteri sağlanana kadar devam etmektedir. Son iterasyonun ardından elde edilen en iyi çözüm, optimum hiperparametre kombinasyonunu temsil eder ve bu parametrelerle nihai GPR modeli oluşturulur. Son aşamada, tüm veri seti ve optimize edilmiş hiperparametreler kullanılarak akrilamid oluşumu modellenir.

3 Bulgular ve tartışma

Çalışma kapsamında farklı pişirme koşullarının akrilamid oluşumu üzerindeki etkileri deneysel olarak değerlendirilmiştir. Elde edilen bulgular, hem sıcaklığın hem de pişirme süresinin artmasının akrilamid seviyelerinde belirgin bir yükselişe neden olduğunu ortaya koymuştur. Özellikle 220°C'de 40 dakika pişirme süresi, en yüksek akrilamid seviyesinin ölçüldüğü koşul olmuştur. Bu sonuçlar, sıcaklık ve sürenin akrilamid oluşumu üzerinde önemli bir etkiye sahip olduğunu ve doğrusal olmayan bir ilişkiyle akrilamid seviyelerinin değiştiğini ortaya koymaktadır. Benzer şekilde, Gökmen vd. [1], Matthäus vd. [35], Tepe ve Kadakal [72], Michalak vd. [73] ve Lu vd. [74] tarafından yapılan çalışmalarda da patates ürünlerinde akrilamid oluşumunun pişirme sıcaklığı ve süresindeki artışa bağlı olarak arttığı rapor edilmiştir. Bu durum, sıcaklığın artmasıyla Maillard reaksiyonunun hızlanması ve ara ürünlerin, özellikle asparajın ile indirgen şekerlerin, daha hızlı reaksiyona girerek akrilamid oluşumunu artırması; pişirme süresinin ise bu reaksiyonların devam etmesine ve akrilamid birikimine olanak sağlamasıyla açıklanabilir [75]. Ayrıca, literatürde akrilamid oluşumunun sıcaklık ve süreye bağlı olarak doğrusal olmayan bir biçimde değiştiği çeşitli çalışmalarda da belirtilmiştir [76-78].

Sıcaklık ve süre faktörlerinin akrilamid oluşumu üzerindeki etkileri, önerilen PSA-GPR modeli kullanılarak modellenmiştir. Bu modelin hiperparametrelerinin belirlenmesinde kullanılan PSA algoritmasında, popülasyon büyüklüğü 50 ve maksimum iterasyon sayısı 1000 olarak belirlenmiştir. Algoritmaya özgü diğer parametreler ise orijinal çalışmada önerilen değerlere dayalı olarak tanımlanmıştır. Önerilen yaklaşımın performansını değerlendirmek amacıyla çok değişkenli doğrusal, etkileşimli, basit karesel, karesel, Gauss, logaritmik ve üstel regresyon modelleriyle karşılaştırmalar yapılmıştır. Bu kapsamda, ölçülen akrilamid değerleri ile modeller tarafından tahmin edilen değerler karşılaştırmalı olarak Şekil 2'de sunulmuştur. Şekildeki siyah düz çizgi (regresyon çizgisi) gözlemlenen ve tahmin edilen değerler arasındaki ideal uyumu temsil ederken, bu çizgilerden sapmalar modelin hata payını yansıtmaktadır. Şekil 2 incelendiğinde, önerilen PSA-GPR modelinin, akrilamid oluşumunu diğer


modellere kıyasla daha yüksek doğrulukla modellediği ve deneysel verileri daha iyi temsil ettiği gözlemlenmektedir.

Bu görsel değerlendirmeye ek olarak, modellerin performansına ilişkin kök ortalama kare hata (RMSE) ve belirleme katsayısı (R^2) değerleri Tablo 3'te sunulmuştur. RMSE, modelin tahminlerinde yaptığı hataların ortalama büyüklüğünü ifade ederken; R^2 , bağımlı değişkendeki toplam varyansın ne kadarının modeldeki açıklayıcı değişkenler tarafından açıklandığını göstermektedir [79]. Bir modelin üstün sayılabilmesi için genellikle hataların küçüklüğü (daha düşük RMSE) ve açıklama gücünün yüksekliği (daha yüksek R^2) temel kriterlerdir. Çünkü daha düşük RMSE, modelin tahminlerinin gerçek değerlere daha yakın olduğunu; daha yüksek R^2 ise modelin verideki varyasyonu daha iyi açıkladığını gösterir. Tablo 3'te görüldüğü gibi, önerilen PSA-GPR modeli diğer regresyon modellerine kıyasla hem daha düşük RMSE hem de daha yüksek R^2 değerlerine sahiptir. Bu da modelin hata oranlarının daha düşük ve veri varyansını daha iyi açıkladığı anlamına gelmekte olup, üstün performansını doğrulamaktadır. Ayrıca, bu çalışmanın temelini oluşturan GPR modelinin, literatürde farklı gıda ürünlerine yönelik uygulamalarda da benzer şekilde düşük RMSE ve yüksek R^2 değerleriyle etkili tahmin sonuçları verdiği rapor edilmiştir [80-82]. Bu bulgular, GPR modelinin gıdalla ilişkili regresyon temelli modelleme çalışmalarında güvenilir ve güçlü bir yöntem olduğunu desteklemektedir.


Tablo 3. Modellerin elde ettikleri RMSE ve R^2 değerleri

Model	RMSE	R^2
PSA-GPR	56.9030	0.9748
Doğrusal	130.7603	0.8669
Etkileşimli	98.0406	0.9252
Basit karesel	125.9778	0.8765
Karesel	91.5649	0.9348
Gauss	81.7628	0.9480
Logaritmik	149.9761	0.8250
Üstel	126.4188	0.8756

Karşılaştırmalı sonuçlar doğrultusunda, en yüksek doğruluğu sağlayan PSA-GPR modeline ait sıcaklık ve süre değişimlerine karşılık akrilamid oluşumunun yanıt yüzeyi Şekil 3'te sunulmuştur. Bu üç boyutlu yüzey grafiği, pişirme süresi (dakika) ve sıcaklık (°C) değişimlerine karşılık akrilamid oluşumunu ($\mu\text{g/kg}$) göstermektedir. Grafik üzerinde ayrıca, ölçülen akrilamid seviyeleri siyah işaretleyiciler ile belirtilmiş ve modelin gözlemlerle uyumu görsel olarak da değerlendirilmiştir. Grafik incelendiğinde, sıcaklık ve sürenin artışıyla birlikte akrilamid seviyelerinde belirgin bir artış meydana geldiği gözlemlenmektedir. Özellikle yüksek sıcaklık ve uzun pişirme süresi kombinasyonlarında akrilamid konsantrasyonlarının yüksek seviyelere ulaştığı; buna karşılık, düşük sıcaklık ve kısa pişirme süresi koşullarında ise akrilamid oluşumunun düşük seviyelerde kaldığı görülmektedir.




Şekil 2. Modellerin tahmin ettiği akrilamid değerleri ile deneysel olarak ölçülen akrilamid değerleri arasındaki uyumun karşılaştırması



Şekil 3. PSA-GPR modeline ait sıcaklık ve süre değişimlerine karşılık akrilamid oluşumunun yanıt yüzey grafiği

Avrupa Birliği'nin EU 2017/2158 sayılı regülasyonu kapsamında, patates kızartmaları için 500 µg/kg düzeyinde bir referans seviye tanımlanmıştır [83]. Bu referans değeri temel alarak, akrilamid oluşumuna bağlı potansiyel sağlık risklerini değerlendirmek amacıyla, pişirme sıcaklığı ve süresi değişimlerine göre oluşturulan sağlık riski haritası **Şekil 4**'te sunulmuştur. Bu haritada, açık mavi renkle gösterilen alan, akrilamid seviyelerinin referans değerinin (500 µg/kg) altında kaldığı ve sağlık açısından düşük risk taşıyan pişirme koşullarını ifade etmektedir. Buna karşılık, koyu mavi (lacivert) renkle gösterilen bölge, akrilamid seviyelerinin referans değeri aştığı ve potansiyel sağlık riski oluşturduğu pişirme koşullarını göstermektedir. Grafik incelendiğinde, yüksek sıcaklık ve uzun pişirme süresi kombinasyonlarının riskli bölgeyle ilişkili olduğu; düşük sıcaklık ve kısa pişirme süresi koşullarında ise akrilamid oluşumunun sağlık açısından kabul edilebilir seviyelerde kaldığı belirlenmiştir. Bu harita, güvenli pişirme koşullarının tanımlanmasına, akrilamid maruziyetinin azaltılmasına ve halk sağlığının korunmasına yönelik önemli bilimsel bilgiler sunmaktadır.



Şekil 4. Pişirme sıcaklığı ve süresine göre akrilamid oluşumuna dayalı sağlık riski haritası

4 Sonuçlar

Bu çalışmada, ev tipi fırında pişirilen patates kızartmalarında pişirme sıcaklığı ve süresinin akrilamid oluşumu üzerindeki etkileri incelenmiş ve elde edilen veriler GPR modeli kullanılarak modellenmiştir. Modelin hiperparametreleri, yeni bir meta-sezgisel optimizasyon yöntemi olan PSA aracılığıyla optimize edilmiştir. Optimizasyon sürecinde, modelin aşırı öğrenmesini önlemek ve tahmin performansını artırmak amacıyla LOOCV stratejisi uygulanmıştır. Önerilen PSA-GPR modeli, diğer çok değişkenli regresyon modellerine kıyasla ölçülen akrilamid seviyelerini daha yüksek doğrulukla temsil etmiştir. Bulgular, pişirme sıcaklığı ve süresinin artışıyla akrilamid seviyelerinde anlamlı yükselmeler meydana geldiğini açıkça ortaya koymuştur. Avrupa Birliği tarafından belirlenen referans değerler esas alınarak gerçekleştirilen risk haritalandırması ise, sağlık açısından kritik eşiklerin aşıldığı pişirme koşullarını belirlemede önemli bir araç sunmuştur.

Bu çalışma, ilerleyen araştırma ve geliştirme faaliyetleri için çeşitli olanaklar sunmaktadır. Aşağıda, gelecekteki çalışmalara yönelik potansiyel araştırma yönleri önerilmektedir:

- Bütçe kısıtlamaları nedeniyle sınırlı sayıda deney gerçekleştirilebilmiş olsa da daha geniş bir deneysel tasarımın ve deney tekrarlarının uygulanması, modelin geçerliliğini ve elde edilen sonuçların güvenilirliğini artırabilir. Ayrıca, bağımsız test veri setleri üzerinde doğrulama süreçlerinin gerçekleştirilmesi, modelin tahmin performansının daha kapsamlı bir biçimde değerlendirilmesine katkı sağlayabilir.

- Veri setinin genişletilmesi, yapay sinir ağları, destek vektör regresyonu, karar ağaçları ve XGBoost gibi farklı makine öğrenmesi yöntemlerinin uygulanmasına olanak sağlayabilir. Bu sayede, farklı algoritmaların modelleme performansları karşılaştırılabilir ve en uygun yöntem seçilerek daha yüksek tahmin doğruluğu elde edilebilir.

- Çalışma kapsamında önerilen PSA-GPR modeli, yalnızca akrilamid oluşumunun modellenmesiyle sınırlı kalmayıp, özellikle örneklem sayısı düşük olan deneysel veri setlerinde de esnek biçimde uygulanabilir. Bu yönüyle modelin farklı alanlardaki veri yapıları üzerinde etkili biçimde kullanılması mümkündür.

- Akrilamid oluşumuna etki eden diğer faktörler dikkate alınarak, akrilamid miktarına ek olarak ürün kalitesiyle ilişkili renk, doku ve duyu özellikler gibi farklı çıkış değişkenleri PSA-GPR modeli kullanılarak modellenilebilir. Bunu takiben, çok amaçlı bir optimizasyon problemi tanımlanarak, PSA algoritması aracılığıyla birden fazla çıkış değişkeni için optimum pişirme koşulları belirlenebilir.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 2209-B Üniversite Öğrencileri Sanayiye Yönelik Araştırma Projeleri Desteği Programı kapsamında desteklenmiştir. Bu destek için TÜBİTAK'a ve sanayi destekçisi olarak katkılarından

dolayı BSH Ev Aletleri Sanayi ve Ticaret A.Ş.'ye teşekkür ederiz. Ayrıca, çalışma sürecinde sağladığı değerli bilgi ve katkılarından dolayı Prof. Dr. Ahmet KOLUMAN'a teşekkür ederiz.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %11

Kaynaklar

- [1] V. Gökmen, T. K. Palazoğlu, and H. Z. Şenyuva, Relation between the acrylamide formation and time–temperature history of surface and core regions of French fries. *Journal of Food Engineering*, 77 (4), 972-976, 2006. <https://doi.org/10.1016/j.jfoodeng.2005.08.030>.
- [2] G. Arusoğlu, Akrilamid oluşumu ve insan sağlığına etkileri. *Akademik Gıda*, 13 (1), 61-71, 2015.
- [3] H. A. Deribew and A. Z. Woldegiorgis, Acrylamide levels in coffee powder, potato chips and French fries in Addis Ababa city of Ethiopia. *Food Control*, 123, 107727, 2021. <https://doi.org/10.1016/j.foodcont.2020.107727>.
- [4] L. Peivasteh-Roudsari, M. Karami, R. Barzegar-Bafrouei, S. Samiee, H. Karami, B. Tajdar-Oranj, V. Mahdavi, A. M. Alizadeh, P. Sadighara, G. O. Conti, and A. Mousavi Khaneghah, Toxicity, metabolism, and mitigation strategies of acrylamide: a comprehensive review. *International Journal of Environmental Health Research*, 34 (1), 1–29, 2022. <https://doi.org/10.1080/09603123.2022.2123907>.
- [5] T. K. Tepe, Patates kızartmada uygulanan farklı işlemlerin akrilamid oluşumu üzerine etkisi. Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2018.
- [6] N. M. Nizamlioğlu ve S. Nas, Gıdalarda Akrilamid Oluşum Mekanizmaları, Gıdaların Akrilamid İçeriği Ve Sağlık Üzerine Etkileri. *Akademik Gıda*, 17 (2), 232-242, 2019. <https://doi.org/10.24323/akademik-gida.613588>.
- [7] N. M. Nizamlioğlu, Kavurma ve depolama koşullarının Bademin bazı fiziksel, kimyasal ve duyuşal özellikleri üzerine etkisi. Doktora Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2015.
- [8] A. Karagöz, Akrilamid ve Gıdalarda Bulunuşu. *TAF Preventive Medicine Bulletin*, 8 (2), 187-192, 2009.
- [9] M. Gölükçü and H. Tokgöz, Gıdalarda akrilamid oluşum mekanizması ve insan sağlığı üzerine etkileri. *Derim*, 22 (1), 41-48, 2005.
- [10] F. Ş. Bayraktar, Isıl işlemin yağ oranı kısmen azaltılmış fındık üzerine etkisinin belirlenmesi. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2014.
- [11] International Agency for Research on Cancer (IARC), Some industrial chemicals. IARC monographs on the evaluation of carcinogenic risks to humans. Vol. 60, 1994, <https://publications.iarc.fr/78>, Accessed 29 April 2025.
- [12] European Commission, Proposal for a Directive of the European Parliament and of the Council Amending Directive 2004/37/EC on the Protection of Workers From the Risks Related to Exposure to Carcinogens or Mutagens at Work. Brussels, 2016.
- [13] V. Matoso, P. Bargi-Souza, F. Ivanski, M. A. Romano, and R. M. Romano, Acrylamide: A review about its toxic effects in the light of Developmental Origin of Health and Disease (DOHaD) concept. *Food Chemistry*, 283, 422-430, 2019. <https://doi.org/10.1016/j.foodchem.2019.01.054>.
- [14] M. Bušová, V. Bencko, K. V. Laktičová, I. Holcátová, and M. Vargová, Risk of exposure to acrylamide. *Central European Journal of Public Health*, 28, 43-46, 2020. <https://doi.org/10.21101/cejph.a6177>.
- [15] M. Fan, X. Xu, W. Lang, W. Wang, X. Wang, A. Xin, F. Zhou, Z. Ding, X. Ye, and B. Zhu, Toxicity, formation, contamination, determination and mitigation of acrylamide in thermally processed plant-based foods and herbal medicines: A review. *Ecotoxicology and Environmental Safety*, 260, 115059, 2023. <https://doi.org/10.1016/j.ecoenv.2023.115059>.
- [16] V. Gokmen and B. A. Mogol, Acrylamide in food. Elsevier, 2023.
- [17] B. Asar, Ev Tipi Fırında Sıcak Hava İle Kızartma İşleminin, Taze Ve Dondurulmuş Parmak Patateslerin Kalite Parametrelerine Etkisinin İncelenmesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2014.
- [18] F. Pedreschi, K. Kaack, K. Granby, and E. Troncoso, Acrylamide reduction under different pre-treatments in French fries. *Journal of Food Engineering*, 79 (4), 1287-1294, 2007. <https://doi.org/10.1016/j.jfoodeng.2006.04.014>.
- [19] F. Mestdagh, T. De Wilde, S. Fraselle, Y. Govaert, W. Ooghe, J. M. Degroodt, R. Verhé, C. V. Peteghem, and B. De Meulenaer, Optimization of the blanching process to reduce acrylamide in fried potatoes. *LWT-Food Science and Technology*, 41 (9), 1648-1654, 2008. <https://doi.org/10.1016/j.lwt.2007.10.007>.
- [20] D. K. Bedade, Y. B. Sutar, and R. S. Singhal, Chitosan coated calcium alginate beads for covalent immobilization of acrylamidase: Process parameters and removal of acrylamide from coffee. *Food Chemistry*, 275, 95-104, 2009. <https://doi.org/10.1016/j.foodchem.2018.09.090>.
- [21] S. Wang, J. Yu, Q. Xin, S. Wang, and L. Copeland, Effects of starch damage and yeast fermentation on acrylamide formation in bread. *Food Control*, 73, 230-236, 2017. <https://doi.org/10.1016/j.foodcont.2016.08.002>.
- [22] A. Antunes-Rohling, S. Ciudad-Hidalgo, J. Mir-Bel, J. Raso, G. Cebrián, and I. Álvarez, Ultrasound as a pretreatment to reduce acrylamide formation in fried potatoes. *Innovative Food Science & Emerging Technologies*, 49, 158-169, 2018. <https://doi.org/10.1016/j.ifset.2018.08.010>.

- [23] J. Genovese, S. Tappi, W. Luo, U. Tylewicz, S. Marzocchi, S. Marziali, S. Romani, L. Ragni, and P. Rocculi, Important factors to consider for acrylamide mitigation in potato crisps using pulsed electric fields. *Innovative Food Science & Emerging Technologies*, 55, 18-26, 2019. <https://doi.org/10.1016/j.ifset.2019.05.008>.
- [24] Y. Narita and K. Inouye, Decrease in the acrylamide content in canned coffee by heat treatment with the addition of cysteine. *Journal of Agricultural and Food Chemistry*, 62 (50), 12218-12222, 2014. <https://doi.org/10.1021/jf5035288>.
- [25] M. Z. Mulla, V. R. Bharadwaj, U. S. Annapure, P. S. Variyar, A. Sharma, and R. S. Singhal, Acrylamide content in fried chips prepared from irradiated and non-irradiated stored potatoes. *Food Chemistry*, 127 (4), 1668-1672, 2011. <https://doi.org/10.1016/j.foodchem.2011.02.034>.
- [26] A. A. Maan, M. A. Anjum, M. K. I. Khan, A. Nazir, F. Saeed, M. Afzaal, and R. M. Aadil, Acrylamide Formation and Different Mitigation Strategies during Food Processing – A Review. *Food Reviews International*, 38 (1), 70-87, 2022. <https://doi.org/10.1080/87559129.2020.1719505>.
- [27] X. Zhang, M. Zhang, and B. Adhikari, Recent developments in frying technologies applied to fresh foods. *Trends in Food Science & Technology*, 98, 68-81, 2020. <https://doi.org/10.1016/j.tifs.2020.02.007>.
- [28] C. Rannou, D. Laroque, E. Renault, C. Prost, and T. Sérot, Mitigation strategies of acrylamide, furans, heterocyclic amines and browning during the Maillard reaction in foods. *Food Research International*, 90, 154-176, 2016. <https://doi.org/10.1016/j.foodres.2016.10.037>.
- [29] R. Pandiselvam, Ö. Süfer, Z. T. Özaslan, N. A. N. Gowda, M. K. Pulivarthi, A. P. R. Charles, B. Ramesh, S. Ramniwas, S. Rustagi, Z. Jafari, and G. Jeevarathinam, Acrylamide in food products: Formation, technological strategies for mitigation, and future outlook. *Food Frontiers*, 5 (3), 1063-1095, 2024. <https://doi.org/10.1002/fft2.368>.
- [30] L. Rifai and F. A. Saleh, A review on acrylamide in food: Occurrence, toxicity, and mitigation strategies. *International Journal of Toxicology*, 39 (2), 93-102, 2020. <https://doi.org/10.1177/1091581820902>.
- [31] M. A. Adimas, B. D. Abera, Z. T. Adimas, H. W. Woldemariam, and M. A. Delele, Traditional food processing and Acrylamide formation: A review. *Heliyon*, 10 (9), e30258, 2024. <https://doi.org/10.1016/j.heliyon.2024.e30258>.
- [32] I. Govindaraju, M. Sana, I. Chakraborty, M. H. Rahman, R. Biswas, and N. Mazumder, Dietary Acrylamide: A Detailed Review on Formation, Detection, Mitigation, and Its Health Impacts. *Foods*, 13 (4), 556, 2024. <https://doi.org/10.3390/foods13040556>.
- [33] V. Gökmen and H. Z. Şenyuva, Acrylamide formation is prevented by divalent cations during the Maillard reaction. *Food Chemistry*, 103 (1), 196-203, 2007. <https://doi.org/10.1016/j.foodchem.2006.08.011>.
- [34] G. Mutlu, S. Uğur ve B. Şimşek, Farklı tatlandırıcılar ve kaymak kullanımı ile üretilen Höşmerim tatlısının akrilamid içeriği ve bazı özellikleri. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 14 (2), 588-596, 2025. <https://doi.org/10.28948/ngumuh.1587053>.
- [35] B. Matthäus, N. U. Haase, and K. Vosmann, Factors affecting the concentration of acrylamide during deep-fat frying of potatoes. *European Journal of Lipid Science and Technology*, 106 (11), 793-801, 2004. <https://doi.org/10.1002/ejlt.200400992>.
- [36] F. Pedreschi, P. Moyano, K. Kaack, and K. Granby, Color changes and acrylamide formation in fried potato slices. *Food Research International*, 38 (1), 1-9, 2005. <https://doi.org/10.1016/j.foodres.2004.07.002>.
- [37] D. M. H. Farah and A. H. Zaibunnisa, Optimization of cocoa beans roasting process using Response Surface Methodology based on concentration of pyrazine and acrylamide. *International Food Research Journal*, 19 (4), 2012.
- [38] O. Lasekan and K. Abbas, Investigation of the roasting conditions with minimal acrylamide generation in tropical almond (*Terminalia catappa*) nuts by response surface methodology. *Food Chemistry*, 125 (2), 713-718, 2011. <https://doi.org/10.1016/j.foodchem.2010.09.073>.
- [39] E. Akwagiobe, M. Ekpenyong, A. Asitok, A. Amenaghawon, D. Ubi, E. Ikharria, H. Kusuma, and S. Antai, Strain improvement, artificial intelligence optimization, and sensitivity analysis of asparaginase-mediated acrylamide reduction in sweet potato chips. *Journal of Food Science and Technology*, 60 (9), 2358-2369, 2023. <https://doi.org/10.1007/s13197-023-05757-5>.
- [40] H. Liu, X. Li, and Y. Yuan, Mitigation effect of sodium alginate on acrylamide formation in fried potato chips system based on response surface methodology. *Journal of Food Science*, 85 (8), 2615-2621, 2020. <https://doi.org/10.1111/1750-3841.15343>.
- [41] M. J. Chen, H. T. Hsu, C. L. Lin, and W. Y. Ju, A statistical regression model for the estimation of acrylamide concentrations in French fries for excess lifetime cancer risk assessment. *Food and Chemical Toxicology*, 50 (10), 3867-3876, 2012. <https://doi.org/10.1016/j.fct.2012.07.010>.
- [42] Y. Zhang and Y. Wu, Introducing Machine Learning Models to Response Surface Methodologies. *IntechOpen*, 2021.
- [43] E. Alpaydin, Introduction to machine learning. MIT press, 2020.
- [44] X. Liu, G. Sun, R. Ju, J. Li, Z. Li, Y. Jiang, K. Zhao, Y. Zhang, Y. Jing, and G. Yang, Prediction of load-bearing capacity of FRP-steel composite tubed concrete columns: Using explainable machine learning model with limited data. *Structures*, 71,

- 10789, 2025. <https://doi.org/10.1016/j.istruc.2024.107890>.
- [45] Q. Chen and C. Yang, Hybrid algorithm for multi-objective optimization design of parallel manipulators. *Applied Mathematical Modelling*, 98, 245-265, 2021. <https://doi.org/10.1016/j.apm.2021.05.009>.
- [46] F. Zhu, C. Xu, and G. Dui, Particle swarm hybridize with Gaussian process regression for displacement prediction. 2010 IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA), 522-525, Changsha, China, 2010. <https://doi.org/10.1109/BICTA.2010.5645179>.
- [47] B. K. Isamura and P. L. Popelier, Metaheuristic optimisation of Gaussian process regression model hyperparameters: Insights from FEREBUS. *Artificial Intelligence Chemistry*, 1 (2), 100021, 2023. <https://doi.org/10.1016/j.aichem.2023.100021>.
- [48] L. Kang, R. S. Chen, N. Xiong, Y. C. Chen, Y. X. Hu and C. M. Chen, Selecting hyper-parameters of Gaussian process regression based on non-inertial particle swarm optimization in Internet of Things. *IEEE Access*, 7, 59504-59513, 2019. <https://doi.org/10.1109/ACCESS.2019.2913757>.
- [49] J. A. Rufián-Henares and F. J. Morales, Determination of acrylamide in potato chips by a reversed-phase LC-MS method based on a stable isotope dilution assay. *Food Chemistry*, 97 (3), 555-562, 2006. <https://doi.org/10.1016/j.foodchem.2005.06.007>.
- [50] J. Q. Shi and T. Choi, Gaussian process regression analysis for functional data. CRC press, 2011.
- [51] T. Hai, A. Basem, A. A. Alizadeh, K. Sharma, D. J. Jasim, H. Rajab, M. Ahmed, M. Kassim, N. S. S. Singh, and H. Maleki, Optimizing Gaussian process regression (GPR) hyperparameters with three metaheuristic algorithms for viscosity prediction of suspensions containing microencapsulated PCMs. *Scientific Reports*, 14 (1), 20271, 2024. <https://doi.org/10.1038/s41598-024-71027-9>.
- [52] F. Gisperm, R. Klausser, M. Elshazly, J. Kopp, E. P. Brichtová, and O. Spadiut, Bayesian Optimization in Bioprocess Engineering—Where Do We Stand Today?. *Biotechnology and Bioengineering*, 2025. <https://doi.org/10.1002/bit.28960>.
- [53] M. A. Ulaş, Gauss Süreç Regresyonu ve Destek Vektör Makineleri Kullanılarak Değerlendirilen Kendiliğinden Yerleşen Beton Davranışının Deneysel Veri İle Doğrulanması. *Firat Üniversitesi Mühendislik Bilimleri Dergisi*, 35 (1), 379-388, 2023. <https://doi.org/10.35234/fumbd.1237839>.
- [54] M. Ehteram, A. N. Ahmed, Z. Sheikh Khozani, and A. El-Shafie, Convolutional neural network-support vector machine model-gaussian process regression: a new machine model for predicting monthly and daily rainfall. *Water Resources Management*, 37 (9), 3631-3655, 2023. <https://doi.org/10.1007/s11269-023-03519-8>.
- [55] J. Yuan, K. Wang, T. Yu, and M. Fang, Reliable multi-objective optimization of high-speed WEDM process based on Gaussian process regression. *International Journal of Machine Tools and Manufacture*, 48 (1), 47-60, 2008. <https://doi.org/10.1016/j.ijmachtools.2007.07.011>.
- [56] B. Likar and J. Kocijan, Predictive control of a gas-liquid separation plant based on a Gaussian process model. *Computers & Chemical Engineering*, 31 (3), 142-152, 2007. <https://doi.org/10.1016/j.compchemeng.2006.05.011>.
- [57] L. L. T. Chan, Y. Liu, and J. Chen, Nonlinear System Identification with Selective Recursive Gaussian Process Models. *Industrial & Engineering Chemistry Research*, 52 (51), 18276-18286, 2013. <https://doi.org/10.1021/ie4031538>.
- [58] T. Gil-Díaz and M. Trumm, Gaussian process regression as a powerful tool for analysing time series in environmental geochemistry. *Ecological Informatics*, 84, 102877, 2024. <https://doi.org/10.1016/j.ecoinf.2024.102877>.
- [59] O. Ozbayram, A. Olivier, and L. Graham-Brady, Heteroscedastic Gaussian Process Regression for material structure-property relationship modeling. *Computer Methods in Applied Mechanics and Engineering*, 431, 117326, 2024. <https://doi.org/10.1016/j.cma.2024.117326>.
- [60] N. Gültekin ve A. Doğan, Kohezyonlu zeminlerde net limit basınç ve deformasyon modülünün makine öğrenimi temelli modeller kullanılarak tahmin edilmesi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 11 (4), 1025-1033, 2022. <https://doi.org/10.28948/ngumuh.1155568>.
- [61] C. E. Rasmussen, Gaussian Processes in Machine Learning. *Advanced Lectures on Machine Learning, ML 2003, Lecture Notes in Computer Science*, 3176. Springer, Berlin, Heidelberg, 2003. https://doi.org/10.1007/978-3-540-28650-9_4.
- [62] A. Kumar, S. Patil, A. Kovacevic, and S. A. Ponnusami, Performance prediction and Bayesian optimization of screw compressors using Gaussian Process Regression. *Engineering Applications of Artificial Intelligence*, 133, 108270, 2024. <https://doi.org/10.1016/j.engappai.2024.108270>.
- [63] Y. Gao, PID-based search algorithm: A novel metaheuristic algorithm based on PID algorithm. *Expert Systems with Applications*, 232, 120886, 2023. <https://doi.org/10.1016/j.eswa.2023.120886>.
- [64] M. A. Azad, A. Sarwar, M. Tariq, F. I. Bakhsh, S. Ahmad, A. S. N. Mohamed, and M. R. Islam, Global maximum power point tracking for photovoltaic systems under partial and complex shading conditions using a PID based search algorithm (PSA). *IET Renewable Power Generation*, 19 (1), e70005, 2025. <https://doi.org/10.1049/rpg2.70005>.
- [65] W. Jiang, H. Han, D. Feng, L. Qian, Q. Wang, and X. G. Xia, Energy-efficient and Accuracy-aware DNN Inference with IoT Device-edge Collaboration. *IEEE Transactions on Services Computing*, 1-14, 2025. <https://doi.org/10.1109/TSC.2025.3536311>.

- [66] Z. You, Y. Bian, Y. Zhang, and L. Chen, An intelligent optimization algorithm with novel fitness function for high-performance PMSM FOC. *Alexandria Engineering Journal*, 115, 286–296, 2025. <https://doi.org/10.1016/j.aej.2024.12.029>.
- [67] F. Li, D. Wang, N. Zhang, R. Zheng and Y. Zhu, Autocalibration for MEMS triaxial accelerometer based on a PID-based search algorithm. 2024 6th International Conference on Intelligent Control, Measurement and Signal Processing (ICMSP), pp. 470-473, Xi'an, China, 2024. <https://doi.org/10.1109/ICMSP64464.2024.10866298>.
- [68] E. Bouguenna, B. Lekouaghet, and M. Haddad, Improved Fractional $PI^{\alpha}D^{\beta}$ Controller for AVR System via a New Optimization Algorithm. 2nd International Conference on Electrical Engineering and Automatic Control (ICEEAC), 1-6, Algeria, 2024. <https://doi.org/10.1109/ICEEAC61226.2024.10576215>.
- [69] S. Tang, Z. Chai, X. Wang, H. Chang, and X. Guo, Adaptive impedance control method for manipulator based on radial basis function. *Industrial Robot*, 2024. <https://doi.org/10.1108/IR-07-2024-0327>.
- [70] B. Ghogh and M. Crowley, The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial. *arXiv preprint arXiv:1905.12787*, 2019. <https://doi.org/10.48550/arXiv.1905.12787>.
- [71] Y. A. Üncü, T. Danişman, and H. Özdoğan, Predicting (n, 3n) nuclear reaction cross-sections using XGBoost and Leave-One-Out Cross-Validation. *Applied Radiation and Isotopes*, 219, 111714, 2025. <https://doi.org/10.1016/j.apradiso.2025.111714>.
- [72] T. K. Tepe and Ç. Kadakal, Temperature and slice size dependences of acrylamide in potato fries. *Journal of Food Processing and Preservation*, 43 (12), e14270, 2019. <https://doi.org/10.1111/jfpp.14270>.
- [73] J. Michalak, E. Gujska, and J. Klepacka, The Effect of Domestic Preparation of Some Potato Products on Acrylamide Content. *Plant Foods for Human Nutrition*, 66, 307-312, 2011. <https://doi.org/10.1007/s11130-011-0252-2>.
- [74] R. Lu, Z. Yang, H. Song, Y. Zhang, S. Zheng, Y. Chen, and N. Zhou, The aroma-active compound, acrylamide and ascorbic acid contents of pan-fried potato slices cooked by different temperature and time. *Journal of Food Processing and Preservation*, 40 (2), 183-191, 2016. <https://doi.org/10.1111/jfpp.12595>.
- [75] L. El Hosry, V. Elias, V. Chamoun, M. Halawi, P. Cayot, A. Nehme, and E. Bou-Maroun, Maillard Reaction: Mechanism, Influencing Parameters, Advantages, Disadvantages, and Food Industrial Applications: A Review. *Foods*, 14 (11), 1881, 2025. <https://doi.org/10.3390/foods14111881>.
- [76] A. Serpen and V. Gökmen, Modeling of acrylamide formation and browning ratio in potato chips by artificial neural network. *Molecular Nutrition & Food Research*, 51 (4), 383-389, 2007. <https://doi.org/10.1002/mnfr.200600121>.
- [77] S. Romani, M. Bacchiocca, P. Rocculi, and M. Dalla Rosa, Effect of frying time on acrylamide content and quality aspects of French fries. *European Food Research and Technology*, 226, 555-560, 2008. <https://doi.org/10.1007/s00217-007-0570-7>.
- [78] M. G. Corradini and M. Peleg, Linear and non-linear kinetics in the synthesis and degradation of acrylamide in foods and model systems. *Critical Reviews in Food Science and Nutrition*, 46 (6), 489-517, 2006. <https://doi.org/10.1080/10408390600758280>.
- [79] D. Chicco, M. J. Warrens, and G. Jurman, The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623, 2021. <https://doi.org/10.7717/peerj-cs.623>.
- [80] P. Chaurasia, K. Younis, O. S. Qadri, G. Srivastava, and K. Osama, Comparison of Gaussian process regression, artificial neural network, and response surface methodology modeling approaches for predicting drying time of mosambi (Citrus limetta) peel. *Journal of Food Process Engineering*, 42 (2), e12966, 2019. <https://doi.org/10.1111/jfpe.12966>.
- [81] X. Chen, J. Xue, X. Chen, X. Zhao, S. Ali, and G. Huang, Gaussian process regression for prediction and confidence analysis of fruit traits by near-infrared spectroscopy. *Food Quality and Safety*, 7, fyac068, 2023. <https://doi.org/10.1093/fqsafe/fyac068>.
- [82] R. R. Pullanagari and M. Li, Uncertainty assessment for firmness and total soluble solids of sweet cherries using hyperspectral imaging and multivariate statistics. *Journal of Food Engineering*, 289, 110177, 2021. <https://doi.org/10.1016/j.jfoodeng.2020.110177>.
- [83] European Commission, Commission Regulation (EU) 2017/2158 establishing mitigation measures and benchmark levels for the reduction of the presence of acrylamide in food. *Official Journal of the European Union*, L304, 24–44, 2017, <http://data.europa.eu/eli/reg/2017/2158/oj>, Accessed 08 May 2025.

