

MAKİNE ÖĞRENME METOTLARININ MANTI KALİTESİNİN BELİRLENMESİNDE KULLANILABİLİRLİĞİ

Serkan ÖRÜCÜ¹ ve Süleyman GÖKMEN²

¹Bilgisayar Programcılığı/Teknik Bilimler Meslek Yüksekokulu, Karamanoğlu Mehmetbey Üniversitesi, Türkiye
²Gıda İşleme Bölümü/Teknik Bilimler Meslek Yüksekokulu, Karamanoğlu Mehmetbey Üniversitesi, Türkiye

*(srknorucu@kmu.edu.tr)

(Geliş Tarihi: 13 Ekim 2023, Kabul Tarihi: 13 Kasım 2023)

(2nd International Conference on Contemporary Academic Research ICCAR 2023, November 4-5, 2023)

ATIF/REFERENCE: Örcü, S. & Gökmen, S. (2023). Makine Öğrenme Metotlarının Manti Kalitesinin Belirlenmesinde Kullanılabilirliği. *International Journal of Advanced Natural Sciences and Engineering Researches*, 7(10), 175-181.

Özet –Geleneksel gıdalardan biri olan ve sevilerek tüketilen mantının, endüstriyel üretimdeki çeşitli süreçlerde karşılaşılabilecek sorunlar nedeniyle kalitesi düşebilmektedir. Kalite kontrolde kullanılan CIE Lab sistemi yani üç nokta yöntemi olarak da bilinen renk sistemine göre mantı üretiminde ürünün kalite düşüşleri belirlenebilmektedir. Bu çalışmada mantı üretiminde ısıl işlem süresine göre oluşturulan mantı veriseti (Mikrodalga seviyesi, L, a, b ve zaman) bazı Makine Öğrenmesi (MÖ) yöntemleri kullanılarak işlenmiştir. Bu işlem sonucunda ise en yüksek f-score'un 87% ile DT (Decision Tree) sınıflandırıcısı ile elde edildiği, bu sonucun ise 73% ile Linear çekirdek kullanılan SVM (Support Vector Machine) ve 71% ile N_neighbours çekirdeği kullanan K-NN (K-Nearest Neighbor) tarafından takip edildiği görülmüştür. Sonuç olarak, MÖ yöntemleri kullanılarak mantı üretim süreçlerinde ürün kalitesi ve güvenilirliğinin arttırılabileceği görülmüştür.

Anahtar Kelimeler – CIE Lab Sistemi, Decision Tree, Gıda İşleme, Gıda Kalitesi, Makine Öğrenmesi, Manti Veriseti

I. GİRİŞ

Mantı, "küçük hamur parçalarının içine farklı baharat türleri, soya proteini ve/veya kıyma ile tatlandırılmış et karışımının konulması, kurutulması ve tüketileceği zaman suda haşlanmasıyla hazırlanan geleneksel bir yiyecek" olarak tanımlanmaktadır [1]. Ayrıca mantının farklı ülkelerde farklı üretim teknikleri bulunmaktadır. Bunlar arasında Kazakistan ve Kırgızistan usulü mantı örnek olarak verilebilir. Kırgızistan usulü mantı üretiminde geleneksel mantı üretim teknolojilerinden farklı olarak mantı harcına kıyma, at kıyması, patates ve kabak gibi

hammadeler eklenmekte, bitkisel yağ ilave edilmekte ve farklı şekillerde pişirilmektedir [1].

Mantı, endüstriyel üretimde ön ısıl işlemden geçirilerek veya kurutulularak piyasaya arz edilmektedir. Ancak mantı taze olarak piyasaya sürüldüğünde kıyma içermesi nedeniyle raf ömrü de kısa olmakta ve gıda zehirlenmeleri açısından riskli gıda grubunda yer almaktadır.

Türkiye'de mantı gibi gıdalardan kaynaklanan gıda zehirlenmelerine sıklıkla rastlanmaktadır [2]. Taze mantının raf ömrünü arttırmak için modifiye atmosfer ve vakum paketlenme gibi uygulamalar yapılmış ancak bu yöntemlerle olumlu sonuçlar

alınmasına rağmen endüstriyel anlamda büyük bir başarı sağlanamamıştır [3].

Mantı taze olarak tüketilmeyecekse, tüketiciye ulaşana kadar tazeliğinin ve besleyici özelliklerinin korunması gerekir. Endüstriyel bir mantı üretim hattında mantılar büyük ölçekli kurutma fırınlarında kurutulduktan sonra ambalajlarda muhafaza edilir.

Mantıya uygulanan ısıl işlem sadece ürünün pastörizasyonunu sağlamakla kalmaz, aynı zamanda üründeki su aktivitesini azaltarak mikrobiyolojik ve biyokimyasal aktivitenin azalmasına da katkıda bulunur. Böylece depolama sırasındaki fiziksel ve kimyasal değişimler en aza indirilebilir.

Geleneksel kurutma işlemleri çok yüksek sıcaklıklarda olduğu için mantının oksidasyonu, mantının aşırı ısınması, mantıda yanıkların oluşması veya pişmemiş mantı oluşumu, ürün kayıplarına neden olması ve bu nedenlerle ek işlemlere ihtiyaç duyulması sorunlar arasında yer almaktadır [4]. Ayrıca söz konusu ürünlerin endüstriyel üretiminde kurutma aşamasının maksimum maliyetli ve yüksek enerji tüketimine sahip kurutucularla gerçekleştirildiği bilinmektedir.

Günümüzde gıda kalitesinin ölçeklendirilmesi ve kontrolünde MÖ yöntemlerinin kullanımı yaygınlaşmıştır. Gıda ve makine öğrenmesi alanında yapılan çalışmalar incelendiğinde; Zhang'ın gıda zinciri ve güvenliğinde Destek Vektör Makineleri (DVM) tabanlı bir erken uyarı sistemi geliştirdiği ve sistemlerinden %92 doğruluk elde ettiği [5], Kangune ve ark. geliştirdikleri DVM tabanlı sistem ile üzüm resimleri üzerinden %79,49 doğrulukla üzüm olgunluğunu tespit ettiği [6], DVM tabanlı domates kalite tespit otomasyonu üzerinde çalışan Deulkar ve ark. sistemlerinden %91,66 doğruluk elde ettiği [7], Kanij ve ark. gıdalarda formalin tespiti için K-En Yakın Komşular (K-NN) yöntemini kullanmış ve tespit ve sınıflandırmada %95 doğruluk elde etmiştir [8], Hemamalini ve ark. meyvelerdeki hasarları tespit etmek için geliştirdikleri sistemde Karar Ağacı (DT) kullanarak %68,1, DVM kullanarak %98 ve KNN kullanarak %84 doğruluk elde etmiştir [9], Augustin ve ark. K-NN kullanarak sığır etinin kalitesini belirlemeye yönelik çalışmalarında etin kalitesini %90 doğrulukla bulmuş [10], Özalp ve ark. DT kullanarak şarap kalitesinin belirlenmesi için geliştirdikleri sistemde %77,03 doğruluk elde

etmiş [11], yine aynı alanda çalışan Shaw ve ark. DVM kullanarak %57,29, DT kullanarak %81,96 doğruluk elde etmiş [12], Buzura ve arkadaşları geliştirdikleri taşınabilir spektral analiz sisteminde kahve ve püre kalitesini makine öğrenmesi yöntemleri ile inceleyerek DVM kullanımında %65, K-NN kullanımında %80, DT kullanımında ise %90 doğruluk elde etmişlerdir [13].

Tüm bunlardan yola çıkarak çalışmamızda, oluşturduğumuz mantı veriseti kullanılarak, MÖ yöntemlerinden SVM, K-NN ve DT sınıflandırıcıları kullanılarak, mantıya yönelik mikrodalga kurutma uygulamalarında ürünün renginde zamana bağlı olarak meydana gelen değişimlerin sınıflandırılması amaçlanmıştır.

Yapılan çalışmalarda geleneksel yöntemlerle yapılan üretimde mantının bazı kalitatif özelliklerinin olumsuz etkilendiği ancak mikrodalga ile yapılan kurutma sonrasında mantının kalite özelliklerinin geleneksel yöntemlere göre daha iyi korunduğu bildirilmiştir [4, 14]. Bu nedenle bu çalışmada kullanılan mantıların mikrodalga fırın ile farklı güçlerde kurutulması tercih edilmiştir.

Böylece endüstriyel ölçekte mikrodalga kurutma tekniği ile üretilen mantıların yeterli ısıl işlem görüp görmediği veya ortalama ne kadar ısıl işlem gördüğü ML yöntemleri ve veriseti kullanılarak hızlı bir şekilde tespit edilebilecektir.

II. MATERYAL VE YÖNTEM

A. Mantı ve Mikrodalga Kurutma Özellikleri


Mantı üretimi, Kayseri mantısının coğrafi işaretlerinde tarif edilen; un, su, yumurta ve tuzun belirli oranlarda karıştırılıp yoğrulmasıyla oluşturulan hamurun bir süre dinlendirildikten sonra açılarak belirli parçalara ayrılması ve her bir parçaya eşit miktarda kıyma eklenerek hamurun bükülmesi yöntemine göre yapılmıştır [14]. Deneme amaçlı üretilen kıymalı mantılara ve kurutma işlemine ilişkin bilgiler Tablo 1'de sunulmuştur.

Tablo1. Mantı ve kurutma bilgileri

Ön Pastörize Mantı Üretimi ve Kurutma Süreci	
İsim	Çiğ Mantı
Kullanılan Kıyma	Dana kıyma, çift çekilmiş but, az yağlı
Mantı Şekli	Paket Tipi
Mantı Boyutları	1.5x1.5x1.5cm
Kullanılan Baharatlar	Tuz, biber, nane
Mantı Ağırlığı	Ortalama 1g
Un Türü	Tip 550 un, ağırlıkça %13.00-13.50 protein, minimum %32 yaş gluten ve %14,5 nem.
Mikrodalga Kurutma İşlemi	Düşük, orta ve yüksek güçlerde
İşlem Sayısı	3 Tekrarlı
Paralellik	5 Paralel

Veri toplama işleminde, mantılar mikrodalgada farklı güçlerde 1 dakika süreyle ısıtılma tabi tutulmuştur. Ürünlerin kuruma süresi %35 nemden %12'ye kadardır. Renk ölçekleyici ile ürünlerin ortalama dakika sayısı (Zaman) ve mikrodalga gücü (Mikrodalga Seviyesi) belirlenmiştir.

Mantının kurutulması, Şekil 1'de gösterildiği gibi bir mutfak mikrodalga fırını kullanılarak gerçekleştirilmiştir.



Şekil 1. Mikrodalga Fırın

Bu mikrodalga fırının teknik özellikleri ise Tablo 2'te sunulmuştur.

Tablo 2. Mikrodalga fırının teknik özellikleri

Özellikler	Tanım	Güç Özellikleri	Tanım
Derinlik (cm)	32.5	Power (W)	700
Genişlik (cm)	45.2	Güç Seviyesi	5
Fırın Hacmi	17 Lt	Zamanlayıcı	Var
Yükseklik (cm)	26.2	Kullanım	Tekli
Izgara	Yok	Kontrol kartı	Mekanik

B. CIE Lab Renk Sistemi

Her bir ısıtılma işleminden sonra, mantıların Parlaklık (L), Sarılık (a) ve Yoğunluk (b) değerlerindeki değişimler elde taşınabilen bir Minoka renk analiz cihazında belirlenmiştir. Bu süreçte kullanılan

matematiksel ölçekleme tabanlı Renk Ölçekleme Sistemi, CIE (Commission Internationale de l'Eclairage) Lab sistemi tarafından oluşturulan bir renk tanımlama sistemidir [15].

Bu sistem üzerinden renkler tanımlanırken insan gözünde bulunan koni şeklindeki ışığı algılayan hücreler temel alınmaktadır. Bu hücreler üç tiptir ve mavi, yeşil ve kırmızı (RGB - Kırmızı, Yeşil ve Mavi) ışıklara duyarlı oldukları bilgisine göre modelleme yapılır. Modelleme sonucunda her renk L, a ve b kısaltmalarıyla üç bileşen (RGB) cinsinden ifade edilir.

CIE Lab renk sisteminde, rengi belirlenecek nesnenin yanı sıra ışık ve gözlemci için de tanımlamalar sağladığından diğer renk tanımlama sistemlerine göre daha kesin ve tekrarlanabilir sonuçlar verir [16]. Renk ve renk farklılıkları genellikle CIE tarafından geliştirilen yöntemle göre enstrümantal olarak değerlendirilir.

Bu ölçüm yönteminde [17];

- L^*/L , ışık geçirgenlik değerleri, 0 (geçirgenlik yok) ve 100 (tam geçirgenlik),
- a^*/a kırmızılık (- $a^*/-a$, yeşillik) ve
- b^*/b sarılık (- $b^*/-b$, mavilik) değerlerini gösterir.

Bu yöntemde L^* : Açıklık-Koyuluk Eksenini Değerini, a^* : Kırmızı-Yeşil Eksenini Değerini, b^* : Sarı-Mavi Eksenini Değerini ifade eder.

C. Mantı Veri Seti

Bir önceki bölümde bahsedilen ölçüm yöntemleri ile mantı üzerinde ölçümler yaparak elde ettiğimiz mantı veri setinin özellikleri Tablo 3'te sunulmuştur.


Tablo 3. Mantı Veri Setinin Karakteristik Özellikleri

ID	Özellik Açıklaması	Veri Türü
1	Mikrodalga Seviyesi	Sayısal
2	Parlaklık	Sayısal
3	Sarılık	Sayısal
4	Yoğunluk	Sayısal
5	Zaman	Sayısal

Veri setinde Mikrodalga seviyesi "Mikrodalga Seviyesi" sütunu altında yer almakta ve bu seviyeler 1-5 arasında değişmektedir, buna bağlı olarak bu mikrodalga seviyelerine maruz kalma süresi veri setinde "Zaman" sütunu altında yer almakta ve bu değer 1-11 dakika zaman aralığında değişmektedir.

Veri setimizdeki veriler 277 farklı ölçümden elde edilmiş olup, "Parlaklık", "Sarılık" ve "Yoğunluk" sütunlarında mantının farklı mikrodalga seviyelerine farklı sürelerde maruz bırakılmasıyla elde edilen parlaklık, sarılık ve yoğunluk değerleri yer almaktadır.

Bahsettiğimiz "Parlaklık", "Sarılık" ve "Yoğunluk", "Mikrodalga" ve "Zaman" değerleri Şekil 3'te sunulmuştur.



Şekil 3. SVM yapısı


Şekil 3'te de görüleceği üzere iki farklı sınıf bulunmaktadır. Sınıflandırma işleminde öncelikle iki sınıfı ayıran bir çizgi çizilir ve çizginin +1 ve -1 değerleri arasında kalan gri alana Marjini (1) adı verilir.

$$\hat{y} = \begin{cases} 0 & \text{if } w^T * x + b < 0, \\ 1 & \text{if } w^T * x + b \geq 0 \end{cases} \quad (1)$$

(3)'te w^T ağırlık vektörünü, x girdi vektörünü ve b sapmayı ifade etmektedir. Şekil 3 üzerinden açıklayacak olursak, sınıflandırma sonucunda (3)'ten elde edilen değer 0'dan küçük ise sınıflandırılacak değer mavi noktalara, 0'a eşit veya büyük ise mor noktalara daha yakın olacaktır.

SVM çoklu sınıflandırma için kullanılan birkaç kernel yöntemi vardır [20]. Bu çalışmada ise SVM ile Linear [21], RBF [22], Polynomial [23] ve Multi-Class çekirdekleri [24] kullanılmıştır.

İkinci olarak kullanılan K-NN (K-Nearest Neighbor) parametrik olmayan, basit ve en yaygın kullanılan sınıflandırma yöntemlerinden biridir. Şekil 4'da gösterildiği gibi bu yapıda sınıflandırılacak veriler için en yakın komşular kontrol edilmektedir.

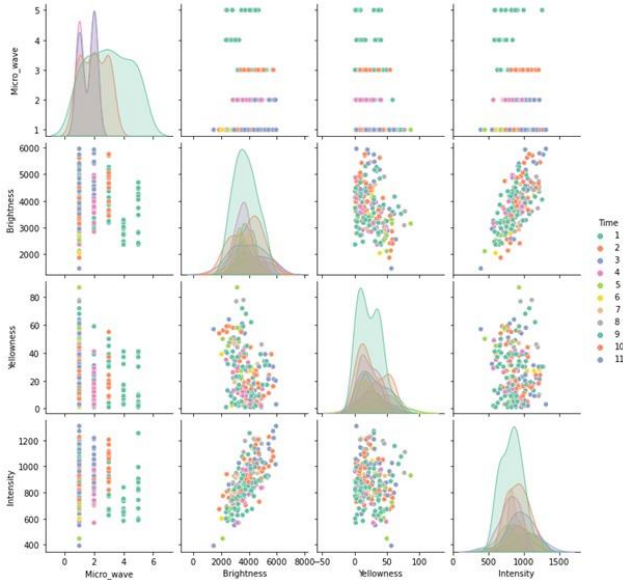


Şekil 4. K-NN Yapısı

Bu işlemde öncelikle bir Öklid mesafesi kullanılarak k değeri belirlenir (2).

$$k_{(m1,n2)} = \sqrt{\sum_{i=1}^n (m_i - n_i)^2} \quad (2)$$

Burada, $m_1=(m_{11},m_{12},\dots,m_{1x})$ ve $n_2=(n_{21},n_{22},\dots,n_{2x})$ işlenecek veri verileri olmak üzere veriler arası mesafe Öklid distance olarak ($n_neighbours$ çekirdeği) hesaplanmıştır.



Şekil 2. Mantının Farklı Mikrodalga Seviyelerine Farklı Sürelerde Maruz Bırakılmasıyla Elde Edilen Parlaklık, Sarılık ve Yoğunluk Değerleri

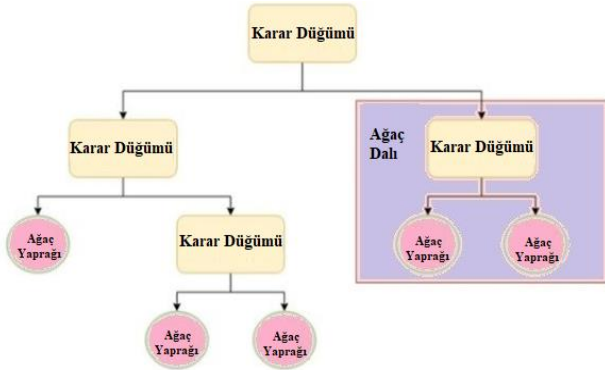
Şekil 2 incelenecek olursa "Parlaklık", "Sarılık" ve "Yoğunluk" ve "Mikrodalga" değerlerindeki değişimler ayrı ayrı görülebilmektedir. Bu şekilde zaman aralığı değişkeni "Zaman" (1-11 dk) renklerle ifade edilerek her bir değerlerin birbiriyle etkileşimi renkli zaman noktaları aracılığıyla gösterilmektedir.

D. Makine Öğrenmesi Metotları

Denetimli öğrenme yöntemlerinden biri olan Destek Vektör Makineleri (DVM), karmaşık ancak küçük ve orta ölçekli veri setleri için sınıflandırma problemlerinde kullanılmaktadır [18]. DVM'nin çalışması, Şekil 3'teki iki sınıflı temel örnekte gösterildiği gibi, bir düzlem üzerine yerleştirilen noktaların sınıflandırılabilmesi için bir sınıf ayırma çizgisi çizilmesine dayanmaktadır. Bu örnekte, sınıfları ayıran bu çizgi, her iki sınıfın noktaları için maksimum mesafede olmalıdır [19].

Devamında k-NN sınıflandırıcıda sırasıyla Ball-tree, Kd-tree ve Brute çekirdekleri kullanılarak sınıflandırma işlemi yapılmıştır [25].

Çalışmamızda kullandığımız Makine Öğrenmesi yaklaşımlarından biri olan DT temelde bir iç düğümün özelliği, her bir dalın bir karar kuralını temsil ettiği ve her yaprak düğümünün sonucu temsil ettiği bir yaklaşımdır [26]. Bu özelliğiyle akış şemasına benzeyen DT yapısı Şekil 5’de sunulmuştur.



Şekil 5. Karar Ağacı Yapısı

Şekil 5’de gösterildiği üzere bir DT’de en üstteki düğüm, kök düğüm olarak bilinir. Bu yapıda DT, öznitelik değeri temelinde bölümlenmeyi öğrenir ve ağacı yinelemeli bir şekilde bölümlere ayırır, insan seviyesindeki düşünceleri kolayca taklit eden ve akış şeması diyagramı gibi görselleştirme olanağı sunan DT yapısı bu özellikleriyle çalışmamızda kullanım tercihi olmuştur [27].

Karar ağacında nasıl olacağına yanı sıra hangi özelliğe göre dallanacağını belirlemesi, sistemdeki düzensizliği belirten entropi aracılığıyla yapılır [28]. Entropi kullanılarak, bir verisetinin N_1, N_2, \dots, N_m şeklinde birden fazla sınıftan oluştuğunu Q ’nun sınıf değerlerini gösterdiğini farz edersek, sınıflandırılmak istenilen herhangi bir x verisinin bir sınıfa ait olma olasılığı $R_i = (N_i/Q)$ olur ve sınıflara ait entropi ise (3)’de gösterilmiştir.

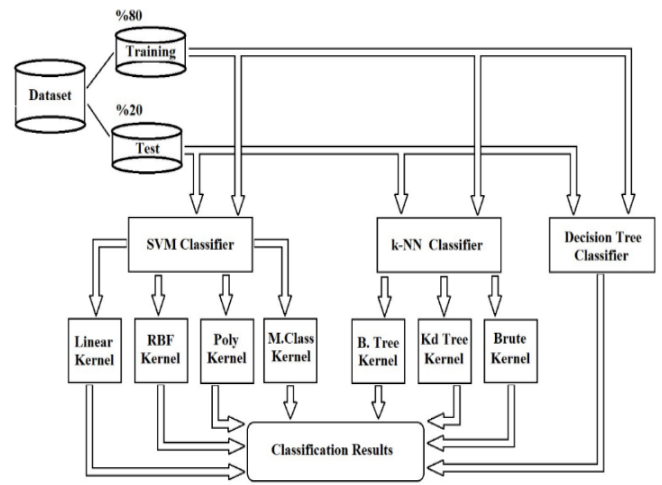
$$Entropy(Q) = - \sum_{i=1}^m R_i \log_2(R_i) \quad (3)$$

E. Sistem kurulumu

Çalışmamızda Python 3.9.7, Pandas 1.3.4 ve Sklearn 1.0.2 kullanılarak, derleme işlemi ise 2.8GHz işlemci, 16 GB Ram ve 8 GB Ekran Kartlı bir bilgisayar kullanılarak yapılmıştır [29]. Programımızda öncelikle Pandas ve Sklearn kütüphaneleri eklenmiş, sonrasında ise verisetimiz tanıtılmıştır.

Devamında ise veriler test (20%) ve eğitim (80%) verileri olarak 2 kısma ayrılmıştır [30], ayrılan bu verileri, zaman değişkenine göre sınıflandırabilmek için SVM, K-NN ve DT modelleri ile test edilmiştir.

Son olarak, kullanılan sınıflandırma metodlarının kullanılan çekirdeklere göre değerlendirilmesi yapılmıştır. Bu değerlendirme öncelikle, Macro Average ve Weighted Average verilerinin Precision, Recall ve f1-Score değerlerine göre, sonra ise modellerin kullanılan çekirdekle birlikte f-skoru oranlarına göre yapılarak sonuçlarda sunulmuştur. Yapılan işlemlerin özeti Şekil 6’da gösterilmektedir.



Şekil 6. Sınıflandırma Sistemi ile İlgili Yapılan İşlemlerin Özeti

III. BULGULAR

Mantı kurutma işleminde zamana göre yapılan sınıflandırma sonuçları, [31-33]’deki çalışmalarda olduğu gibi, Tablo 4’de kullanılan sınıflandırıcı ve çekirdek yöntemine göre ve Macro Average (Macro Avg.) ile Weighted Average (Weighted Avg.) türlerinden ayrı ayrı sunulmuştur.

Tablo 4. SVM, K-NN ve Decision Tree metodları ve kullanılan çekirdeklere göre sınıflandırma sonuçları.

Classifiers	Kernel Type	Macro Avg			Weighted Avg		
		Precisi on	Recall	f1-Score	Precisi on	Rec all	f1-Score
SVM	RBF	0,18	0,33	0,23	0,29	0,53	0,37
	Poly	0,19	0,33	0,24	0,32	0,56	0,41
	Multiclass	0,47	0,50	0,46	0,76	0,70	0,70
	Linear	0,36	0,40	0,38	0,73	0,74	0,73
K-NN	N_neighbours	0,45	0,45	0,45	0,69	0,72	0,71
	Ball_tree	0,47	0,50	0,46	0,76	0,70	0,70
	Brute	0,19	0,21	0,20	0,41	0,47	0,44
	Kd_tree	0,46	0,48	0,47	0,73	0,72	0,72
Decision Tree	Decision Tree Classifier	0,59	0,62	0,62	0,85	0,85	0,87

Tablo 4’de gösterilen verileri incelersek; SVM metodunda, hem Macro avg türünde hem de Weighted avg türünde en düşük sınıflandırma sonucunun (Precision, Recall ve f1-Score) RBF çekirdeği kullanımıyla (53%), en yüksek f-score’un ise Linear çekirdek kullanımıyla (74%) elde edildiği görülmektedir. K-NN metodu SVM ile karşılaştırıldığında özellikle N_neighbours, Ball_tree ve Kd_tree çekirdekleri kullanımında 70-72% arasında sonuç verdiği görülse bile f-score oranları SVM gibi amaçladığımız oran bandının altında kalmaktadır.

Bunlarla birlikte, Macro Average ve Weigted Average alanlarının ikisinde de en yüksek sınıflandırma f-score’unun DT metodu ile elde edildiği görülmüştür.

IV. SONUÇLAR

Sonuç olarak, en yüksek f-skorun 87% ile yine DT sınıflandırıcısından elde edildiği, bu sonucun ise 73% ile Linear çekirdek kullanılan SVM metodu ve 71% ile N_neighbours çekirdeği kullanan K-NN metotlarının takip ettiği görülmektedir. Sonuç olarak, MÖ yöntemleri kullanılarak mantı üretim süreçlerinde ürün kalitesi ve güvenilirliğinin artırılabilceği görülmüştür.

KAYNAKLAR

- [1] S. Gokmen, M. F. Aydin, A. Kocabas, A. Sayaslan, and A. Caglar, "A Study on Quality Criteria of Commercial Stuffed Pasta (Manti), as Traditional Food," (in English), *International Food Research Journal*, vol. 22, no. 5, 2015/04/20/ 2015. [Online]. Available: [http://www.ifrj.upm.edu.my/22%20\(05\)%202015/\(40\).pdf](http://www.ifrj.upm.edu.my/22%20(05)%202015/(40).pdf).
- [2] S. Karaman, O. Sağdıç, A. Kayacıer, and H. Yetim, "Kayseri Piyasasında Satılan Mantıların Bazı Mikrobiyolojik Özellikleri," ed. VAN: 2. Geleneksel Gıdalar Sempozyumu, 2022, pp. 862-865.
- [3] S. Uzunlu and I. Var, "Effect of Modified Atmosphere Packaging on the Refrigerated Storage of Manti," (in English), *Turkish Journal of Agriculture - Food Science and Technology*, vol. 4, no. 1, pp. 36-40, 2016, doi: 10.24925/turjaf.v4i1.36-40.535.
- [4] S. Gökmen, A. Kocabaş, İ. Savran, A. Sayaslan, M. f. Aydin, and H. Yetim, "Effect of Infrared, Ultraviolet-C Radiations and Vacuum Drying on Certain Chemical and Microbial Characteristics of Stuffed Pasta (Manti)," (in English), *Journal of Agricultural Sciences*, vol. 25, no. 1, pp. 100-107, 2019, doi: 10.15832/ankutbd.539010.
- [5] Y. Zhang, "Food safety risk intelligence early warning based on support vector machine," *Journal of Intelligent & Fuzzy Systems*, vol. 38, pp. 6957-6969, 2020, doi: 10.3233/JIFS-179774.
- [6] K. Kangune, V. Kulkarni, and P. Kosamkar, "Grapes Ripeness Estimation using Convolutional Neural network and Support Vector Machine," in *2019 Global Conference for Advancement in Technology (GCAT)*, 18-20 Oct. 2019 2019, pp. 1-5, doi: 10.1109/GCAT47503.2019.8978341.
- [7] S. S. Deulkar and S. S. Barve, "An Automated Tomato Quality Grading using Clustering based Support Vector Machine," in *2018 3rd International Conference on Communication and Electronics Systems (ICCES)*, 15-16 Oct. 2018 2018, pp. 1128-1133, doi: 10.1109/CESYS.2018.8724084.
- [8] K. Tabassum, A. A. Memi, N. Sultana, A. W. Reza, and S. D. Barman, "Food and Formalin Detector Using Machine Learning Approach," *International Journal of Machine Learning and Computing*, vol. 9, no. 5, 2019.
- [9] V. Hemamalini et al., "Food Quality Inspection and Grading Using Efficient Image Segmentation and Machine Learning-Based System," *Journal of Food Quality*, vol. 2022, p. 5262294, 2022/02/11 2022, doi: 10.1155/2022/5262294.
- [10] S. Agustin and R. Dijaya, "Beef Image Classification using K-Nearest Neighbor Algorithm for Identification Quality and Freshness," *Journal of Physics: Conference Series*, vol. 1179, no. 1, p. 012184, 2019/07/01 2019, doi: 10.1088/1742-6596/1179/1/012184.
- [11] A. E. Ozalp and İ. Askerzade, "A data science study for determining food quality: an application to wine," (in English), *Communications Faculty of Sciences University of Ankara Series A1 Mathematics and Statistics*, vol. 68, no. 1, pp. 762-770, 2019, doi: 10.31801/cfsuasmas.469131.
- [12] B. Shaw, A. K. Suman, and B. Chakraborty, "Wine Quality Analysis Using Machine Learning," in *Emerging Technology in Modelling and Graphics*, Singapore, J. K. Mandal and D. Bhattacharya, Eds., 2020// 2020: Springer Singapore, pp. 239-247.
- [13] L. Buzura, M. L. Budileanu, A. Potarniche, and R. Galatus, "Python based portable system for fast characterisation of foods based on spectral analysis," in *2021 IEEE 27th International Symposium for Design and Technology in Electronic Packaging (SIITME)*, 27-30 Oct. 2021 2021, pp. 275-280, doi: 10.1109/SIITME53254.2021.9663677.
- [14] S. Gokmen, "Effect of far-infrared (FIR) and microwave drying on some properties of stuffed pasta (manti)," (in English), *Advances in Food Sciences*, vol. 41, no. 4, pp. 92-98, 2019. [Online]. Available: <https://www.cabdirect.org/globalhealth/abstract/20203333211>.
- [15] N. Khediri, M. B. Ammar, and M. Kherallah, "Comparison of Image Segmentation using Different Color Spaces," in *2021 IEEE 21st International Conference on Communication Technology (ICCT)*, 13-16 Oct. 2021 2021, pp. 1188-1192, doi: 10.1109/ICCT52962.2021.9658094.
- [16] B. C. K. Ly, E. B. Dyer, J. L. Feig, A. L. Chien, and S. Del Bino, "Research Techniques Made Simple: Cutaneous Colorimetry: A Reliable Technique for Objective Skin Color Measurement," *Journal of Investigative Dermatology*, vol. 140, no. 1, pp. 3-12.e1,

- 2020/01/01/ 2020, doi: <https://doi.org/10.1016/j.jid.2019.11.003>.
- [17] A. S. R. M. Sinaga, "Color-based Segmentation of Batik Using the L^*a^*b Color Space," *Sinkron : jurnal dan penelitian teknik informatika*, vol. 3, no. 2, pp. 175-179, 03/20 2019, doi: 10.33395/sinkron.v3i2.10102.
- [18] I. Ahmad, M. Basher, M. J. Iqbal, and A. Rahim, "Performance Comparison of Support Vector Machine, Random Forest, and Extreme Learning Machine for Intrusion Detection," *IEEE Access*, vol. 6, pp. 33789-33795, 2018, doi: 10.1109/ACCESS.2018.2841987.
- [19] R. E. Caraka, Y. Lee, R. C. Chen, and T. Toharudin, "Using Hierarchical Likelihood Towards Support Vector Machine: Theory and Its Application," *IEEE Access*, vol. 8, pp. 194795-194807, 2020, doi: 10.1109/ACCESS.2020.3033796.
- [20] A. Tharwat, "Parameter investigation of support vector machine classifier with kernel functions," *Knowledge and Information Systems*, vol. 61, no. 3, pp. 1269-1302, 2019/12/01 2019, doi: 10.1007/s10115-019-01335-4.
- [21] I. Burman and S. Som, "Predicting Students Academic Performance Using Support Vector Machine," in 2019 Amity International Conference on Artificial Intelligence (AICAI), 4-6 Feb. 2019 2019, pp. 756-759, doi: 10.1109/AICAI.2019.8701260.
- [22] W. C. Leong, R. O. Kelani, and Z. Ahmad, "Prediction of air pollution index (API) using support vector machine (SVM)," *Journal of Environmental Chemical Engineering*, vol. 8, no. 3, p. 103208, 2020/06/01/ 2020, doi: <https://doi.org/10.1016/j.jece.2019.103208>.
- [23] H. Chen, C. Zhang, N. Jia, I. Duncan, S. Yang, and Y. Yang, "A machine learning model for predicting the minimum miscibility pressure of CO₂ and crude oil system based on a support vector machine algorithm approach," *Fuel*, vol. 290, p. 120048, 2021/04/15/ 2021, doi: <https://doi.org/10.1016/j.fuel.2020.120048>.
- [24] Z. Zhang, Z. Xu, J. Tan, and H. Zou, "Multi-class support vector machine based on the minimization of class variance," *Neural Processing Letters*, vol. 53, no. 1, pp. 517-533, 2021/02/01 2021, doi: 10.1007/s11063-020-10393-7.
- [25] M. T. García-Ordás, C. Benavides, J. A. Benítez-Andrades, H. Alaiz-Moretón, and I. García-Rodríguez, "Diabetes detection using deep learning techniques with oversampling and feature augmentation," *Computer Methods and Programs in Biomedicine*, vol. 202, p. 105968, 2021/04/01/ 2021, doi: <https://doi.org/10.1016/j.cmpb.2021.105968>.
- [26] E. D. van Asselt, M. Y. Noordam, M. G. Pikkemaat, and F. O. Dorgelo, "Risk-based monitoring of chemical substances in food: Prioritization by decision trees," *Food Control*, vol. 93, pp. 112-120, 2018/11/01/ 2018, doi: <https://doi.org/10.1016/j.foodcont.2018.06.001>.
- [27] V. Jain and A. Yadav, "Analysis of Performance of Machine Learning Algorithms in Detection of Flowers," in 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), 4-6 Feb. 2021 2021, pp. 706-709, doi: 10.1109/ICICV50876.2021.9388599.
- [28] Z. Wang, C. Cao, and Y. Zhu, "Entropy and Confidence-Based Undersampling Boosting Random Forests for Imbalanced Problems," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, no. 12, pp. 5178-5191, 2020, doi: 10.1109/TNNLS.2020.2964585.
- [29] M. Selek, F. Başçiftçi, and S. Örucü, "Designing medical expert system based on logical reduced rule for basic malaria diagnosis from malaria signs and symptoms," *World Journal of Engineering*, vol. 14, no. 3, pp. 227-230, 2017, doi: 10.1108/WJE-10-2016-0112.
- [30] B. Geyik and M. Kara, "Severity Prediction with Machine Learning Methods," in 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), 26-28 June 2020 2020, pp. 1-7, doi: 10.1109/HORA49412.2020.9152601.
- [31] P. Caroline Cynthia and S. Thomas George, "An Outlier Detection Approach on Credit Card Fraud Detection Using Machine Learning: A Comparative Analysis on Supervised and Unsupervised Learning," in *Intelligence in Big Data Technologies—Beyond the Hype*, Singapore, J. D. Peter, S. L. Fernandes, and A. H. Alavi, Eds., 2021// 2021: Springer Singapore, pp. 125-135.
- [32] C. Liu, "Drought Level Prediction with Deep Learning," in *Computing and Data Science*, Singapore, W. Cao, A. Ozcan, H. Xie, and B. Guan, Eds., 2021// 2021: Springer Singapore, pp. 53-65.
- [33] A. Karlekar and A. Seal, "SoyNet: Soybean leaf diseases classification," *Computers and Electronics in Agriculture*, vol. 172, p. 105342, 2020/05/01/ 2020, doi: <https://doi.org/10.1016/j.compag.2020.105342>.