

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI



GAZ SENSÖRÜ VERİLERİNİ KULLANARAK KIZARTMA
YAĞI KALİTESİNİN YAPAY ZEKÂ TABANLI
SINIFLANDIRILMASI

BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS TEZİ

KEMAL TÜMEN

TEZ DANIŞMANI
Dr. Öğr. Üyesi Mehmet Milli

BOLU, ARALIK 2025

KABUL VE ONAY SAYFASI

Kemal TMEN tarafından hazırlanan “**GAZ SENSR VERİLERİNİ KULLANARAK KIZARTMA YAĐI KALİTESİNİN YAPAY ZEKÂ TABANLI SINIFLANDIRILMASI**” adlı tez çalışması jrimiz tarafından Bilgisayar MhendisliĐi Ana Bilim Dalı Yksek Lisans Programında Yksek Lisans Tezi olarak oy birliĐi ile kabul edilmiřtir.
31/12/2025

Jri yeleri

İmza

Danışman
Dr. Öğr. Üyesi Mehmet MİLLİ
Bolu Abant İzzet Baysal Üniversitesi

.....

ye
Doç. Dr. Ferhat DEMİRAY
Bolu Abant İzzet Baysal Üniversitesi

.....

ye
Dr. Öğr. Üyesi Emre NSAL
Sivas Cumhuriyet Üniversitesi

.....

Lisansst EĐitim Enstits Onayı

Prof. Dr. İbrahim KRTL
Lisansst EĐitim Enstits Mdr

ETİK BEYAN

Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzu ve Şablonuna uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu bildirir
- aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Teze ilişkin Turnitin adlı programında enstitü müdürlüğünce belirlenen filtrelemeler uygulanarak alınmış olan benzerlik raporuna göre, tezin benzerlik oranı %30'u geçmemektedir.

.....
KEMAL TÜMEN

ÖNSÖZ

Bu çalışma, kızartma yağlarının kullanım miktarı ve kalitesinin sensör teknolojileri ve yapay zekâ destekli analiz yöntemleriyle değerlendirilmesini amaçlamaktadır. Çalışma sürecinde özellikle BME688 gaz sensörü kullanılarak elde edilen veriler, yapay sinir ağları (YSA) algoritmaları ve Bosch AI platformu üzerinde değerlendirilmiştir.

Bu süreçte hem deneysel aşamalarda hem de veri analizinde karşılaşılan zorluklar, bilimsel araştırma ve sabırla aşılmıştır. Bu tez boyunca bana yol gösteren, değerli bilgi ve desteğini esirgemeyen danışman hocam Dr. Öğr. Üyesi Mehmet MİLLİ'ye; ayrıca laboratuvar imkânlarının sağlanmasında yardımcı olan kurum yetkililerine teşekkür ederim. Çalışmanın ilerleyen dönemlerde gıda güvenliği, yağ kalitesi ölçümü ve endüstriyel analiz süreçlerine katkı sunacağına inanıyorum.

Bilimsel süreç boyunca yanımda olan aileme de sonsuz teşekkürlerimi sunuyorum.

Sağladıkları manevi destek ve sabırları, bu çalışmanın tamamlanmasında büyük bir güç kaynağı olmuştur.

Kemal TÜMEN

31.12.2025

ÖZET

**GAZ SENSÖRÜ VERİLERİNİ KULLANARAK KIZARTMA YAĞI
KALİTESİNİN YAPAY ZEKÂ TABANLI SINIFLANDIRILMASI
YÜKSEK LİSANS TEZİ
KEMAL TÜMEN
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI
(TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ MEHMET MİLLİ)**

BOLU, ARALIK - 2025

xiv + 94 sayfa

Kızartma yağlarının kullanım sürecinde maruz kaldığı kimyasal ve fiziksel bozulmalar, insan sağlığı açısından önemli riskler oluşturmakta ve kardiyovasküler hastalıklar, obezite ve bazı kanser türleriyle ilişkilendirilmektedir. Literatürde, yağ kalitesinin belirlenmesi çoğunlukla kimyasal analizlere dayalı klasik örnekleme yöntemleriyle yapılmakta olup bu yöntemler hem zaman alıcı hem de maliyetlidir. Gıda endüstrisinde artan otomasyon ihtiyacı, sensör tabanlı izleme teknolojileri ve yapay zekâ destekli veri analitiğinin, kalite kontrol süreçlerinde daha hızlı, doğru ve sürdürülebilir çözümler sunabileceğini göstermektedir. Bu çalışma, kızartma yağlarının kullanım sürecinde oluşan uçucu bileşikler ve bozulma göstergelerinin izlenmesi amacıyla BME688 gaz sensöründen elde edilen çok boyutlu verileri kullanarak yağ kalite seviyelerini sınıflandırmayı hedeflemektedir. Sensör verileri ön işlemden geçirilmiş, farklı yapay sinir ağı mimarileri denenmiş ve Isıtıcı Profili-411 ile kurulan modelde %99,14 doğruluk oranına ulaşılmıştır. Elde edilen bulgular, BME688 sensörünün karmaşık gaz bileşimlerini güvenilir biçimde ayırt edebildiğini ve yapay zekâ ile entegre edildiğinde kızartma yağı kalitesinin gerçek zamanlı olarak değerlendirilebileceğini göstermekte olup çalışma, endüstriyel süreçlerde bilgisayar tabanlı sürdürülebilir çözümler sunmayı hedeflemektedir.

ANAHTAR KELİMELER: Yapay Zekâ, Makine öğrenmesi, Yapay sinir ağları, Metal oksit gaz sensörü, Gıda güvenliği, Kızartma yağ kalitesi

ABSTRACT

ARTIFICIAL INTELLIGENCE-BASED CLASSIFICATION OF FRYING OIL QUALITY USING GAS SENSOR DATA

MASTER THESIS

AS

BOLU ABANT IZZET BAYSAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

DEPARTMENT OF COMPUTER ENGINEERING

(SUPERVISOR: ASSIST. PROF. DR. MEHMET MİLLİ)

BOLU, DECEMBER 2025

xiv + 94 pages

The chemical and physical degradation that frying oils undergo during use poses significant risks to human health and is associated with cardiovascular diseases, obesity, and certain types of cancer. In the literature, the determination of oil quality is mostly carried out through classical sampling methods based on chemical analyses, which are both time-consuming and costly. The increasing need for automation in the food industry indicates that sensor-based monitoring technologies and artificial intelligence-supported data analytics can offer faster, more accurate, and more sustainable solutions in quality control processes. This study aims to classify the quality levels of frying oils by using multidimensional data obtained from the BME688 gas sensor to monitor volatile compounds and degradation indicators formed during the frying process. The sensor data were preprocessed, various artificial neural network architectures were tested, and an accuracy rate of 99.14% was achieved with the model constructed using Heater Profile-411. The findings show that the BME688 sensor can reliably distinguish complex gas compositions and that, when integrated with artificial intelligence, it enables real-time evaluation of frying oil quality. The study aims to provide computer-based sustainable solutions for industrial processes.

KEYWORDS: Artificial intelligence, Machine learning, Artificial neural networks, Metal-oxide gas sensor, Food safety, Frying oil quality

İÇİNDEKİLER

Sayfa

ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ.....	ix
TABLO LİSTESİ	x
FOTOĞRAF LİSTESİ.....	xi
KISALTMA VE SEMBOLLER LİSTESİ	xii
TEŞEKKÜR	xiii
1. GİRİŞ.....	1
1.1 Kavramsal Çerçeve ve Literatür Özeti	3
1.1.1 BME688 Gaz Sensörü	6
1.1.2 Makine Öğrenimi ve Uygulama Alanları	7
1.1.3 Kızartmalık Yağ Bozulması ve Sağlık Riskleri.....	10
1.1.4 Geleneksel Kalite Değerlendirme Yöntemleri	12
1.1.5 Gaz Sensör Tabanlı Yaklaşımlar	17
1.1.6 Yapay Zekâ Tabanlı Sınıflandırmalar	21
2. MATERYAL VE YÖNTEM	28
2.1 SENSÖR MATRİSİ KONFIGÜRASYONU	29
2.2 Oksidasyon ürünlerinin tanımlanması	31
2.2.1 Serbest yağ asitleri (SYA)	32
2.2.2 SYA' ların Oluşum Mekanizmaları	32
2.2.3 Toplam Polar Bileşikler (TPB):.....	35
2.3 Deney Düzeni ve Örnek Toplama	39
2.3.1 Sensör Ölçümleri	42
2.3.2 Geleneksel Analiz.....	43
3. BULGULAR	46
3.1 Sensör Veri Seti	46
3.2 Eşleştirme Süreci	49
3.2.1 SYA Değerleri ile Sensör Verilerinin Eşleştirilmesi	50
3.2.2 TPB Değerleri ile Sensör Verilerinin Eşleştirilmesi.....	51
3.2.3 Eşleştirme Sürecinin Bilimsel Önemi.....	51
3.3 Yapay Sinir Ağı (YSA)	52
3.4 Hiper parametre seçimi.....	55
3.4.1 Veri Setinin Ayrımı ve Eğitim Stratejisi	55
3.4.2 Çapraz Doğrulama Yaklaşımı	56

3.4.3 Nihai Değerlendirme Süreci	57
3.5 Karışıklık Matrisi.....	57
3.5.1 Doğruluk (Accuracy).....	59
3.5.2 Duyarlılık (Recall / Sensitivity).....	61
3.5.3 Özgüllük (Specificity)	62
3.5.4 Kesinlik (Precision)	64
3.5.5 F1 Skoru (F1 Score)	66
4. TARTIŞMA	73
4.1 Bulguların Değerlendirilmesi	73
4.2 Literatürle Karşılaştırmalar	74
4.3 Hipotezlerin Testi	75
4.4 Çalışmanın Sınırlılıkları	78
4.4.1 Deneysel Tasarım ve Veri Çeşitliliği Sınırlamaları.....	79
4.4.2 Ölçüm Doğruluğu ve Kalibrasyon Sınırlamaları.....	79
4.4.3 Model Performansı ve Sınıf Dengesizliği Sorunları.....	80
4.4.4 Donanım ve Gerçek Zamanlı Uygulama Kısıtları.....	81
4.4.5 Genel Değerlendirme.....	81
5. SONUÇ VE ÖNERİLER	83
KAYNAKLAR	86

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Yağların Bozulma Süreçleri.....	1
Şekil 1.2. Yağ Bozulmasına Etki Eden Faktörler	2
Şekil 1.3. Zamanla kimyasal bozulma eğilimi.....	4
Şekil 1.4. Sensör Yapay Zekâ entegrasyonu.....	5
Şekil 1.5. BME688 Sensörünün Çalışma Prensibi (Algılama Döngüsü).....	7
Şekil 1.6. Yapay Sinir Ağı (YSA) Model Mimarisi (Rumelhart vd., 1986 dan uyarlanmıştır.)	8
Şekil 1.7. TPB Artışıyla İlişkilendirilen Risk Göstergeleri	10
Şekil 1.8. SYA Ölçümü (AOAC940.28) Titrasyon Akış Şeması	13
Şekil 1.9. TPB Ölçüm Yaklaşımları	14
Şekil 1.10. Elektronik Burun (e-nose) Sistemi Sensör Dizisi ve Örnek Akışı .	18
Şekil 1.11. BME688’de Isıtıcı Profillerine Göre Seçicilik Kavramı	19
Şekil 1.12. Yapay zekâ tabanlı sınıflandırma akış diyagramı.....	22
Şekil 2.1. Uygulanan IP profillerine ilişkin sıcaklık değişimleri (Musa Milli & Milli, 2025 den uyarlanmıştır.)	29
Şekil 2.2. Standart DC profillerinin uyku ve tarama süreleri (Musa Milli & Milli, 2025 den uyarlanmıştır.)	30
Şekil 2.3. Geliştirme kartı üzerinde yer alan sensör çiftleri ve bunlara atanan ısıtıcı profillerin şematik dağılımı (Parlak vd., 2025 den uyarlanmıştır.)	31
Şekil 2.4 Deney ve Veri Toplama Ortamı	40
Şekil 2.5. Sensör 4 ve Sensör 6 dan on farklı aşamada toplanan direnç değerlerinin grafiksel Gösterimi.....	41
Şekil 2.6 Numune alım ve saklama işlemleri.....	42
Şekil 3.1 Sensör 4 ve Sensör 6 tarafından toplanan çevresel direnç verilerinin grafiksel dağılımı	46
Şekil 3.2. IP-501 ile donatılmış ilk sensör (Sensör 3) tarafından elde edilen direnç verilerinin, serbest yağ asidi (% oleik asit) değerleriyle ilişkilendirilmesi.....	50
Şekil 3.3. IP-301 (S1) sensörüyle donatılmış ilk ölçüm biriminden elde edilen direnç değerleri, Toplam Polar Madde (%TPM) ölçümleriyle ilişkilendirilmesi.....	51
Şekil 3.4. Sınıflandırma için kullanılan karışıklık matrisi (Sokolova & Lapalme, 2009 den uyarlanmıştır)	58
Şekil 3.5. Farklı Isıtıcı Profilleri için Karışıklık Matrisi.....	68
Şekil 3.6 Gerçek Test Veri Setinde Isıtıcı Profillerinin Doğruluk Performansları	72

TABLO LİSTESİ

Sayfa

Tablo 1.1. Yağ Kalitesi ile İlgili Temel Parametreler	2
Tablo 1.2. SYA ve TPB analiz yöntemleri karşılaştırma tablosu.....	15
Tablo 1.3. Literatürdeki Benzer Çalışmalar	19
Tablo 1.4. Literatürde çok sık kullanılan makine öğrenmesi yaklaşımlarının karşılaştırılması.	23
Tablo 1.5. Literatürdeki sensör uygulamaları	24
Tablo 2.1. Çalışmada Kullanılan Ölçüm Parametreleri ve Açıklamaları	28
Tablo 3.1 Veri setini oluşturan sensör verilerinin tipik bir örneği	47
Tablo 3.2 Yağ numunelerine ilişkin kızartma döngüsü, etiketler ve sınıf tanımları	48
Tablo 3.3 Her bir ısıtıcı profili için elde edilen farklı metrik değerlerinin karşılaştırılması	67
Tablo 3.4 Gerçek test verilerinden elde edilen performans ölçüm değerleri ...	71

FOTOĞRAF LİSTESİ

Sayfa

Şekil tablosu ögesi bulunamadı.



KISALTMA VE SEMBOLLER LİSTESİ

SYA	: Serbest Yağ Asitleri
YZ	: Yapay Zekâ
YSA	: Yapay Sinir Ağları
TPB	: Toplam Polar Bileşenler
UOB	: Uçucu Organik Bileşikler
MÖ	: Makine Öğrenmesi
IP	: Isıtıcı Profili
TBA	: Temel Bileşen Analizi
GGD	: Gerçek Görev Döngüsü



TEŞEKKÜR

Bu tezin hazırlanma sürecinde bilgi, birikim ve deneyimleriyle bana yol gösteren, çalışmam boyunca her aşamada desteğini esirgemeyen değerli danışmanım Dr. Öğr. Üyesi Mehmet MİLLÎ'ye en içten teşekkürlerimi sunarım. Kendisi, akademik bakış açımı geliştirmemde ve araştırma sürecimi doğru şekilde yönlendirmemde büyük katkı sağlamıştır.


Bana her zaman koşulsuz sevgi, sabır ve anlayışla destek veren aileme, özellikle de yoğun çalışma dönemlerinde moral ve motivasyon kaynağım olan çocuklarıma, minnettarım. Onların desteği olmadan bu çalışmayı tamamlamak mümkün olmazdı.



Miray, Gökalp ve Çağlar' a

1. GİRİŞ

Gıda endüstrisinde, özellikle hazır yemek üretim hatlarında yoğun olarak kullanılan kızartmalık yağların tekrar tekrar ısıtılması, fiziksel ve kimyasal özelliklerinde ciddi bozulmalara neden olmaktadır. Bu bozulmalar, sağlığı doğrudan tehdit eden trans yağ asitleri, aldehitler ve polimerize lipitler gibi toksik bileşiklerin oluşumunu tetikler (Csallany vd., 2015; Grootveld vd., 2020; Hani Suhaimi vd., 2020).



Şekil 1.1. Yağların Bozulma Süreçleri

Özellikle, kızartma işlemi sırasında yağların maruz kaldığı yüksek sıcaklıklar, lipid oksidasyonu ve bunun sonucu olarak çeşitli zararlı bileşiklerin oluşumunu hızlandırmaktadır. Yapılan araştırmalar, tekrar ısıtılan yağların oksidatif stabilitesinin azalma gösterdiğini, bu süre zarfında peroksit değerlerinin arttığını ve dolayısıyla bileşimlerinde toksik aldehitlerin meydana geldiğini göstermektedir (Grootveld vd., 2020; Hani Suhaimi vd., 2020; Vu & Boonyarattanakalin, 2013). Yağların bozulma süreçleri **Şekil 1.1** de gösterilmiştir.


Isıtılmış yemeklik yağlardan türeyen aldehitler, oluşumları sırasında ortaya çıkan diğer toksik maddelerle birlikte kızartılmış yiyeceklerde bulunabilen ve insan sağlığına zararlı etkiler gösterebilen önemli kimyasal bileşiklerdir. Bu nedenle dikkatle izlenmeleri gerekmektedir. (Freis & Vemulapalli, 2025; Takhar vd., 2023). Örneğin, 4hidroksi2nonenal (HNE) ve diğer lipit oksidasyon ürünleri, kanserojen özellikler taşıyabilmekte ve vücutta hücrel hasarın artmasına neden olabilmektedir (Csallany vd., 2015; Freis & Vemulapalli, 2025). Ayrıca, yapılan

alıřmalar, yksek sıcaklıklarda kızartma srecinin trans yaę asitlerinin oluřumunu artırdıęını ve bu srete yaęların kalitesinin hızlı bir řekilde dřtęn gstermektedir(Afaneh vd., 2017); Bu bozulmaların yanı sıra, tekrar ısıtılmıř yaęların kullanımı, genel gıda gvenlięi aısından da tehdit oluřurmaktadır. Yeniden ısıtma sırasında oluřan toksik bileřikler, yine tekrarlı kullanılan yaęların iinde birikerek daha da zararlı hale gelmektedir (Dhakal vd., 2024; Grootveld vd., 2020). Yaę kalitesini belirleyen ve yeniden ısıtma sırasında oluřan toksik bileřikleri tanımlayan temel parametreler **Tablo 1.1** de gsterilmiřtir.

Tablo 1.1. Yaę Kalitesi ile İlgili Temel Parametreler

Parametre	Aıklama	Artıřın Etkisi
Serbest Yaę Asidi (SYA)	Hidroliz sonucu oluřan asidik bileřik miktarı	Yaę asiditesi artar, kalite dřer
Peroksit Deęeri (PD)	Oksidasyon rnlerinin ilk gstergesi	Ransidite ve koku artıřı
Toplam Polar Bileřikler (TPB)	Oksidasyon + polimerizasyon rnleri oranı	Yaę bozulması gstergesi
Renk / Viskozite	Fiziksel kalite gstergeleri	Oksidatif bozulmayla artar

Aslında, lipid oksidasyonu, yiyeceklerin kalitesini dřren bir sre olarak karřımıza ıkmakta ve bu rnlerin tketimi, saęlık aısından ciddi riskler tařımaktadır (Velasco vd., 2004). Altı izilmesi gereken bir dięer nokta da, farklı kkene sahip yaęların kızartma iřlemi sonrasında farklı reaksiyonlar gsterdięidir; bu da saęlık zerindeki riskleri artırmaktadır (Boukandoul vd., 2023; Kanner, 2007).



řekil 1.2. Yaę Bozulmasına Etki Eden Faktrler

Sonuç olarak, hazır yemek endstrisindeki kızartma yaęlarının ısıl iřlemlere maruz kalması, insan saęlıęı zerinde ciddi olumsuz etkilere yol amaktadır. Bu

nedenle, kızartma yağlarının daha sağlıklı ve güvenli şekilde kullanımının üzerinde durulması, bu yağların uzun süreli tekrar kullanımının önlenmesi büyük önem taşımaktadır (Afaneh vd., 2017; Vu & Boonyarattanakalin, 2013). Yağ bozulmasına etki eden faktörler **Şekil 1.2** de gösterilmiştir.

BME688 gaz sensörü, uçucu organik bileşenlerin (UOB) algılanmasında yüksek hassasiyet göstermesi nedeniyle, kızartma yağı kalitesinin belirlenmesinde umut vaat eden bir araç olarak öne çıkmaktadır (Kumar vd., 2025). BME688 gaz sensöründen elde edilen çok parametrelili veriler Yapay Sinir Ağları (YSA) ile işlenerek bir sınıflandırmaya tabi tutulabilir.

Bu bağlamda, BME688 gaz sensörü ile elde edilen verilerin işlenmesi, kızartma yağlarının kalitesizleşme sürecinin izlenmesi için daha hassas ve güvenilir sonuçlar elde edilmesine olanak sağlamaktadır. Bu nedenle, gıda endüstrisinde yağ kalitesinin güvenilirliğinin izlenmesi ve kızartmalık yağ kullanımının sağlık açısından güvenli hâle getirilebilmesi için bu tür yenilikçi yöntemlerin geliştirilmesi önem taşımaktadır.

Bu tez çalışmasında, BME688 gaz sensöründen elde edilen çoklu parametre verileri kullanılarak, YSA ve diğer derin öğrenme yöntemleriyle kızartma yağlarının bozulma düzeyi sınıflandırılmaktadır. Bu yenilikçi yaklaşım, geleneksel analiz yöntemlerinin zayıf kaldığı alanlarda etkili bir alternatif sunarak hem gıda güvenliği süreçlerini dijitalleştirmeyi hem de endüstriyel uygulamalarda anlık karar destek sistemlerinin geliştirilmesini amaçlamaktadır.

1.1 Kavramsal Çerçeve ve Literatür Özeti

Günümüzde kalite kontrol sistemleri, sadece ürünün lezzet ve görünümüyle ilgilenmez; aynı zamanda insan sağlığı, çevre güvenliği ve sürdürülebilirlik gibi farklı alanları da kapsar. Özellikle tekrar kullanılan kızartmalık yağların oluşturduğu sağlık riskleri, gıda bilimcileri ve halk sağlığı uzmanları tarafından uzun yıllardır dikkatle incelenmektedir (Khor vd., 2019; Negishi vd., 2003).

Çağımızın hızlı yaşam temposu, hazır ve kızartılmış gıdaların tüketiminde önemli bir artışa yol açmıştır. Bu durum, hazır yemek sektöründe sıkça kullanılan kızartma yağlarının birden fazla defa kullanılmasına sebep olmaktadır. Kızartma yağları, özellikle derin yağda kızartma işlemi sırasında çeşitli kimyasal değişimlere uğrayarak polar bileşikler üretir (X. Li vd., 2023; Yılmaz vd., 2023). Bu polar bileşikler, yağın besin değerini olumsuz yönde etkileyebilir (Abeshu, 2023).

Bu bölümde, kızartmalık yağların bozulma süreçleri, geleneksel kalite analiz yöntemleri, sensör tabanlı izleme sistemlerine ilişkin parametrelerin önemi ve yapay zekâ destekli sınıflandırma modelleri üzerine yapılmış akademik çalışmalar analiz edilmiştir. Literatürdeki bilgi boşlukları ve tartışmalı konular tanımlanmış ve bu tez çalışmasının özgün katkıları bu çerçevede konumlandırılmıştır.

Derin yağda kızartma işlemi, yağın yüksek sıcaklık ve oksijenle temas etmesi sonucunda oksidasyon ve polimerizasyon reaksiyonlarının gerçekleştiği bir süreçtir. Bu reaksiyonlar, yağın kimyasal yapısını değiştirerek sağlığa zararlı olabilecek toksik bileşenlerin oluşmasına yol açabilir. (Sharanke & Sivakanthan, 2022). Örneğin, kızartma işlemi sırasında yağda biriken Toplam Polar Bileşenlerin (TPB) aşırı miktarlarda alınması, metabolik bozulmalara yol açabilir (L. Wang vd., 2022). Ayrıca, bu tür yağların sindirim sistemi üzerinde olumsuz etkilere neden olduğu ve bağırsak bariyer işlevini zayıflatabildiği bir çok çalışmada gösterilmiştir (X. Li vd., 2023; J. Zhang vd., 2019). Isıtma süreci sırasında yağın asidite değeri ve diğer kalite parametrelerinin artması, sağlık riski taşımaktadır (Oliveira vd., 2024).

Reaksiyon Yoğunluğunun kızartma süresine bağlı değişimi ilişkisel olarak Şekil 1.3 de gösterilmiştir.



Şekil 1.3. Zamanla kimyasal bozulma eğilimi

Reaktif yağ bileşenlerinin, zamanla birikimi ve yağın tekrar kullanımıyla birlikte kanserojen özellikleri olan Heterosiklik Aromatik Aminlerin (HAA) oluşumu artmaktadır; bu durum, özellikle yüksek sıcaklıklarda kızartma işlemlerinde belirginleşmektedir (C.-X. Zhang vd., 2022). Ayrıca, kullanılan yağın kalitesiyle birlikte, kızartılan gıdaların beslenme değerleri de azalmaktadır, bu

nedenle bireylerin sađlığı aısından riskler barındırmaktadır (Ahmed & Mohammed, 2023). Bu durum, yađların tekrar kullanımı konusunun sadece lezzet ve grnř aısından deđil, aynı zamanda sađlık aısından da dikkate alınması gereken bir mesele haline geldiđini gstermektedir.

Gıda kalite kontrol sreleri, zellikle yađların sınıflandırılması aısından yeni nesil sensr teknolojileri ve YZ tabanlı analiz yaklaşımlarının entegrasyonu ile nemli geliřmeler yařamaktadır. Bu bađlamda, gaz sensrlerinden elde edilen verilerin yađların kalite ve trlerini analiz etme ve sınıflandırma srelerinde nemli bir yenilik sunabileceđi dřnlmektedir.



řekil 1.4. Sensr Yapay Zekâ entegrasyonu

zellikle BME688 gaz sensrnn kullanımı, bu alanda dikkat ekmektedir. Bu sensr, eřitli uucu organik bileřenleri (UOB) algılayabilme yeteneđi ile nemli bir rol oynamaktadır (Aghili vd., 2023; Rasekh vd., 2021). Gaz sensrlerinden elde edilen verilerin, YSA algoritmalarıyla iřlenmesi, yađların sınıflandırılması konusunda etkili bir yntem sunmaktadır. BME688 Sensrnn YSA entegrasyonuna iliřkin sreler řekil 1.4 te sunulmuřtur. YSA' lar, ok deđiřkenli ve grltl veriler zerinde karmařık iliřkileri ve rntleri tanıma kapasitesine sahiptir. Bu sistemlerin entegrasyonu, zellikle yemeklik yađ kalitesinin ve bileřimlerinin hızlı ve dođru bir řekilde belirlenmesine olanak tanımaktadır (Ku vd., 2023).

Daha nceki alıřmalarda, gaz sensrleri ve YSA kombinasyonu ile sađlanan sonular, dođru sınıflandırma bařarısını artırmakta ve eřitli yađ trlerinin hızlı analizi iin katma deđer sađlamaktadır (Aghili vd., 2023). rneđin, hızlı ve dođru bir analiz yapılması, iđ ve iřlenmiř yađlar arasındaki ayrımı sađlamada yardımcı olmaktadır (Rasekh vd., 2021).


Ayrıca, gaz sensrleri teknolojisindeki geliřmelerle birlikte, BME688 gibi geliřmiř sensrler, veri toplamada daha yksek hassasiyet ve dođruluk sunarak gıda

kalite kontrolünde önemli yenilikler sağlamaktadır (Aghili vd., 2023; Rasekh vd., 2021). Bu durum, endüstriyel uygulamalarda daha az hata ile daha güvenilir sonuçların elde edilmesine olanak tanıyacaktır. Hali hazırda birçok araştırma, gaz sensörlerinin kalite kontrol sistemlerinde kullanımını vurgulamakta ve bu alanda daha fazla optimizasyon yapılması gerektiğini ortaya koymaktadır (Simsek & Alagoz, 2023).

Gıda endüstrisinde, bu tür yenilikçi çözümlerin geliştirilmesi ve uygulanması hem maliyet hem de üretkenlik açısından ciddi avantajlar sunmaktadır.

1.1.1 BME688 Gaz Sensörü

BME688, Bosch Sensortec tarafından geliştirilen yapay zekâ destekli çok fonksiyonlu bir çevresel sensördür.




Resim 1.1. BOSCH BME688 Sensör yapısı (Musa Milli & Milli, 2025 den uyarlanmıştır.)

Bu sensör, sıcaklık, bağıl nem, atmosferik basınç ve uçucu organik bileşenler (UOB) gibi çevresel parametreleri aynı anda ölçebilme kabiliyeti ile dikkat çekmektedir (Al-Okby, Neubert, vd., 2022; Sarif vd., 2024). Ayrıca, karbondioksit (CO₂), karbon monoksit (CO) ve hidrojen sülfür (H₂S) gibi gazlara duyarlılığı sayesinde, çeşitli uygulama alanlarında (örneğin, hava kalitesi izleme) önemli bir rol oynamaktadır (Scientific, Industrial and Technological Application and Research Center (SITARC), Bolu Abant İzzet Baysal University, Bolu, Turkey vd., 2025)

1.1.1.1 Çalışma Prensibi ve Avantajlar

BME688 sensörü, Metal-Oksit Yarı İletken (MOS) tabanlı bir sistem kullanarak çalışmaktadır ve bu, sıcaklık ile nem gibi çevresel değişkenlerin yanı sıra UOB'lerin gerçek zamanlı ölçümünü kolaylaştırmaktadır (Al-Okby, Roddelkopf, vd., 2022).



Şekil 1.5. BME688 Sensörünün Çalışma Prensibi (Algılama Döngüsü)

En dikkat çekici özelliği, Bosch AI Studio platformu aracılığıyla makine öğrenimi modelleriyle entegre olabilmesidir. Bu entegrasyon, sensörün ölçtüğü gaz karışımlarına bağlı olarak elektriksel dirençte meydana gelen değişimleri analiz etmesine olanak tanır ve böylece özgün bir dijital koku izi (digital olfactory fingerprint) oluşturmaktadır (Botticini vd., 2024). Bu dijital parmak izi, karmaşık gaz ortamlarının sınıflandırılmasında etkili ve anlamlı bir öznitelik vektörü sağlar, bu da YSA tabanlı yaklaşımlarla birlikte kullanıldığında büyük bir avantaj sunar (Pereira vd., 2025). Sensörün çalışma prensibi (Algılama Döngüsü) temsili olarak **Şekil 1.5** de verilmiştir.

1.1.2 Makine Öğrenimi ve Uygulama Alanları

Birçok çalışma, BME688 benzeri gaz sensörlerinin makine öğrenimi ile entegrasyonunu ve bu kombinasyonun çeşitli alanlardaki uygulamalarını vurgulamaktadır. Örneğin, bu sensörlerin, hava kirlilik seviyelerinin izlenmesi ve gıda kalitesinin değerlendirilmesi gibi alanlarda önemli rol oynadığı gösterilmiştir (Mehmet Milli vd., 2025; Pereira vd., 2025). Yapay zekâ sistemleri, sensör verilerinin analizi ve yorumlanması açısından kullanılmakta, bu sayede daha hızlı ve doğru karar alma mekanizmaları geliştirilmekte, bu da endüstriyel uygulamaların yanı sıra bireysel sağlık alanlarında da fayda sağlamaktadır (Pereira vd., 2025).


Sensörlerin gaz ölçümündeki hassasiyeti ve çok yönlülüğü, çevresel izleme sistemlerinin yanı sıra çeşitli endüstriyel uygulamalarda, özellikle gıda güvenliği ve sağlık izleme alanlarında büyük yenilikler sağlama potansiyeline sahiptir. Örneğin, BME688'in kullandığı gelişmiş yapay zeka teknikleri, gaz karışımlarının detaylı analiz edilmesine olanak tanırken, sağlık ve gıda güvenliği alanlarında erken uyarı sistemlerinin geliştirilmesine katkı sağlamaktadır(Botticini vd., 2024).

Sonuç olarak, BME688 sensörü ve onunla entegre edilen yapay zekâ sistemleri, çevresel izleme ve analiz süreçlerinde çığır açan bir potansiyele sahiptir. Bu teknoloji, endüstriyel kalite kontrol, hava kalitesi izleme ve gıda güvenliği gibi kritik alanlarda gelecekte önemli bir rol oynamaya devam edecektir.

1.1.2.1 Yapay Sinir Ağları (YSA)

YSA, insan beyninin sinirsel ağ yapısından ilham alarak geliştirilmiş karmaşık öğrenme algoritmalarıdır. YSA' lar, çok katmanlı yapıları sayesinde sensör verileri gibi yüksek boyutlu veri setleri üzerinde etkili sınıflandırma, tahmin ve desen tanıma (pattern recognition) işlemleri gerçekleştirebilmektedir (Lima vd., 2021; Waluyo vd., 2020).

Yapay Sinir Ağı (YSA) Model Mimarisi **Şekil 1.6** da gösterilmiştir.



Şekil 1.6. Yapay Sinir Ağı (YSA) Model Mimarisi (Rumelhart vd., 1986 dan uyarlanmıştır.)

Bu sistemin üç ana bileşeni bulunmaktadır:

- 1. Giriş Katmanı (Input Layer):** Sensör verileri (örn. direnç, sıcaklık).
- 2. Gizli Katmanlar (Hidden Layers):** Öğrenme işlemlerinin gerçekleştiği nöron ağı.

3. Çıkış Katmanı (Output Layer): Sınıflandırma sonucunun elde edildiği katman (örn. “Güvenli”, “Bozulmuş”).

Bu çalışma kapsamında geliştirilen YSA modeli, 5 katlı çapraz doğrulama (5-fold cross-validation) yöntemiyle eğitilmiş ve test edilmiştir. Elde edilen en yüksek başarı oranı, %99.1 ile IP-411 profili altında gerçekleşmiştir.

Model, yağ örneklerini dört sınıfa ayırmaktadır. Bunlar:

- i. **Taze (Excellent)**
- ii. **Kullanılabilir (Acceptable)**
- iii. **Düşük Kalite (Low Quality)**
- iv. **Kullanılamaz/Bozulmuş (Unsafe)**

YSA' nın Başlıca Avantajları:

- Karmaşık veri ilişkilerini öğrenme kabiliyeti: YSA’ lar, çok katmanlı yapıları sayesinde yüksek boyutlu ve karmaşık veri setlerini analiz edebilmektedir (Lima vd., 2021; Wu vd., 2024).
- Refraktif indeks gibi çoklu veri kaynaklarını işleyebilme: Bu durum, modelin çeşitli veri setlerini entegre ederek daha kapsamlı analizler yapmasını sağlar (Waluyo vd., 2020).
- Gerçek zamanlı sınıflandırmalara uygunluk: YSA’lar, anlık veri akışlarını işleyerek hızlı sonuçlar üretebilmektedir (Wu vd., 2024).
- Yüksek genel doğruluk ve F1 skoru: Geliştirilen modeller, yüksek doğruluk ve F1 skoru ile performans göstermektedir (Nicolle vd., 2024).

YSA' nın Kullanılmasındaki Başlıca Zorluklar:


- Yüksek miktarda eğitilmiş veri ihtiyacı: YSA’ ların etkili çalışabilmesi için büyük miktarda ve çok çeşitli eğitim verisine ihtiyaç duyulmaktadır (Javeed vd., 2018; Pires vd., 2020).
- Aşırı öğrenme (overfitting) riski: Modellerin fazla uyum sağlaması, yeni veriler üzerinde düşük performansa yol açabilmektedir (Pires vd., 2018).
- Modelin yorumlanmasındaki sınırlılıklar: YSA’ ların karar alma süreçleri bazen şeffaf olmadığından, sonuçların anlaşılması güçleşebilmektedir (Lahat vd., 2015).

Bu tezde kullanılan YSA modeli, sensör verilerini entegre ederek, klasik kalite analizlerinin yerine geçebilecek güvenilir bir alternatif sunmayı

hedeflemektedir. Ayrıca, farklı sıcaklık profillerinin YSA üzerindeki etkisi detaylı bir şekilde analiz edilerek, model performansının artırılması amaçlanmaktadır.

1.1.3 Kızartmalık Yağ Bozulması ve Sağlık Riskleri

Kızartmalık yağların bozulma süreci, ısı ve oksidasyon gibi faktörler tarafından hızlandırılmaktadır. Örneğin, kızartma işlemleri sırasında serbest yağ asitleri (SYA), peroksit değeri ve polar bileşiklerin oluşumu, yağın kalitesinin bozulduğuna işaret eden önemli göstergelerdir (Aladedunye & Przybylski, 2009; Das vd., 2013). Polimerleşme, yağ içindeki alkil radikallerin birleşmesiyle meydana gelir ve bu durum yağın viskozitesini artırarak kaliteyi etkiler (Das vd., 2013). Ayrıca, toplam polar bileşikleri (TPB) gibi parametreler, yağın kalitesini değerlendirmek için yaygın olarak kullanılan önemli bir kriterdir; örneğin, kullanım sınırları Avrupa'da genellikle %25 olarak belirlenmiştir (Khor vd., 2019). TPB Artışıyla İlişkilendirilen Risk Göstergeleri Şekil 1.7 de gösterilmiştir.



Şekil 1.7. TPB Artışıyla İlişkilendirilen Risk Göstergeleri

Bitkisel yağlar, yüksek sıcaklıklara maruz kaldıklarında çeşitli kimyasal reaksiyonlara uğrayarak yapısal bütünlüklerini kaybetmektedirler. Bu bozulma süreçleri, oksidasyon, hidroliz, termal ayrışma ve polimerizasyon mekanizmalarıyla meydana gelmektedir. Sürekli tekrar ısıtılan yağlar, zamanla gıda güvenliği açısından tehlikeli bileşiklerin oluşumuna neden olmaktadır (Seppanen & Csallany, 2006; Zulim Botega vd., 2009).

1.1.3.1 Kızartma Yağlarının Bozulma Süreçleri

Yağların bozulması, sıcaklık ve ışık gibi dış etmenler tarafından hızlandırılmaktadır. Örneğin, soya yağı gibi yüksek poliansatüre yağlar üzerinde yapılan çalışmalarda, tekrar ısıtıldıkça 4-hidroksi-2-trans-nonenal (HNE) gibi toksik bileşiklerin birikiminin arttığı gözlemlenmiştir (Seppanen & Csallany, 2006). Benzer şekilde, yağların oksidasyon sürecinde oluşan hidroperoksitler, yağın kalitesini düşürmekte ve sağlık için zararlı yan ürünlere yol açmaktadır (Ahmad vd., 2021). Yüksek sıcaklık altında, doğal antioksidanların hızla bozulması ve bunun sonucunda polimerlerin, toksik yan ürünlerin oluşumunu artırdığı rapor edilmiştir (Zulim Botega vd., 2009; Zulu vd., 2021).

1.1.3.2 Oksidasyon ve Toksik Bileşikler

Yüksek sıcaklıkta ısıtılan bitkisel yağlar; alkenler, aldehitler ve ketonlar gibi yüksek reaktif oksidasyon ürünleri üretmektedir. Bu bileşikler, insan sağlığı açısından tehlikeli olarak kabul edilmekte ve kanserojen etki gösterebilmektedirler (Gotoh vd., 2005; Leong, 2021). Yemeklik yağlar, belirli bir sayıda kullanımdan sonra yüksek polar bileşen içeriği oluşturmakta ve bunun yanı sıra yağın toksisite düzeylerini artırmaktadır (Weerakoon vd., 2019). Örneğin, tekrar ısıtılan yağların içeriğindeki akrolein gibi bileşikler, gıda ürünlerine geçerek insan sağlığını tehdit etmektedir (Gutiérrez-Flores vd., 2024).

1.1.3.3 Besin Güvenliği ve Kalite Kontrol

Sık yapılan tekrar ısıtma işlemleri, yalnızca yağ kalitesini düşürmekle kalmayıp, aynı zamanda tüketilen gıda maddelerine geçiş yaparak gıda güvenliğini de tehlikeye atmaktadır (Gotoh vd., 2005; Leong, 2021). Dolayısıyla, gıda üretiminde yağların yeniden kullanımı sırasında dikkatli olunması gereken faktörler arasında uygun sıcaklık kontrolü, kullanılan yağın türü ve ısıtma süreleri bulunmaktadır (Ahmad vd., 2021; Zulu vd., 2021). Literatürde, yağ analizinde kullanılan geleneksel yöntemler yerine, sensör tabanlı izleme sistemlerinin entegrasyonu önerilmektedir. Bu sistemler, kalite ve güvenlik analizi açısından daha hızlı ve güvenilir sonuçlar sunabilmektedir (Quiles vd., 2002; Yongyod & Kerdsin, 2025).

Sonuç olarak, yüksek sıcaklıklara maruz kalan bitkisel yağların kimyasal bozulma süreçleri, gıda güvenliği açısından ciddi tehditler oluşturmaktadır. Yapılan

arařtırmalar, yağların ısıya maruz kalma ve tekrar kullanımı ile oluşan bileřiklerin insan saėlıėını tehdit ettiėini ortaya koymaktadır. Bu nedenle, modern kalite kontrol sistemlerine entegre sensörler ve analiz tekniklerinin kullanımı büyük önem taşımaktadır.

1.1.4 Geleneksel Kalite Deėerlendirme Yöntemleri

Gıda endüstrisinde kızartmalık yağların kalite deėerlendirmesi, uzun yıllar boyunca geleneksel kimyasal analiz yöntemleri ile gerçekleştirilmiřtir. Özellikle Serbest Yaė Asitleri (SYA) ve Toplam Polar Bileřikler (TPB) analizleri, bozulma düzeyini anlamada en yaygın olarak kullanılan yöntemler arasında yer alır. Bu iki parametre, hem ulusal düzenlemelerde hem de akademik literatürde kızartmalık yağların güvenli kullanım aralıėının belirlenmesinde temel ölçütlerdir (Cardoso-Ugarte vd., 2013).

1.1.4.1 Serbest Yaė Asitleri Analizi ve Temel İlkeler


SYA, trigliseritlerin hidrolitik parçalanması sonucu ortaya çıkan başlıca bozunma ürünleridir. Yüksek sıcaklık, nem ve oksijen gibi çevresel faktörlerin etkisiyle trigliserit yapısındaki ester bağlarının kırılması, serbest yağ asitlerinin oluřumuna yol açar (H.-X. Gao vd., 2020; Oliveira vd., 2024). Bu bileřikler yağın kimyasal kararlılıėını azaltarak oksidatif süreçleri hızlandırır; böylece tat, koku ve renk gibi duysal niteliklerde bozulmaya neden olur. Ayrıca dumanlanma noktasındaki düşüř, genellikle SYA konsantrasyonundaki artıřla iliřkilendirilir ve yağın kullanım ömrünün sonuna yaklařtıėını gösterir (Ahmadi vd., 2018).

Literatürde SYA düzeyinin, kızartma yağlarının bozulma derecesinin belirlenmesinde en güvenilir kimyasal göstergelerden biri olduėu belirtilmektedir. Özellikle uzun süreli kızartma işlemlerinde SYA oranının artıřı, yağın hidrolitik stres altında kaldıėını ve yeniden kullanıma uygunluėunu yitirdiėini göstermektedir (Ban vd., 2016; H.-X. Gao vd., 2020).

SYA analizi genellikle alkali titrasyon esasına dayanarak gerçekleştirilir. Yaė örneėi etanol ve eter karıřımında çözölür ve Fenolftalein indikatörü eřliėinde sodyum hidroksit (NaOH) çözeltisi ile titre edilir. Bu yöntem, yağdaki serbest asitlerin nötralizasyonu yoluyla asitlik derecesini ölçer ve sonuçlar oleik asit eřdeėeri (%) cinsinden ifade edilir. Bu yöntem “Resmî Analitik Kimyacılar Birliėi” (“Association of Official Analytical Collaboration”) tarafından belirlenen “AOAC

940.28” olarak bilinir (Dash vd., 2022). Laboratuvar koşullarında yaygın olarak kullanılan bu prosedür, yüksek doğruluk ve tekrarlanabilirlik sağlamasına karşın, saha koşullarında uygulanabilirliği sınırlıdır. Bunun nedeni, hem solvent kullanımının hem de deneyimli personel gereksiniminin ölçüm sürecini yavaşlatmasıdır (Q. Zhang vd., 2015).

SYA Ölçümü (AOAC940.28) Titrasyon Akış Şeması **Şekil 1.8** de gösterilmiştir.



Şekil 1.8. SYA Ölçümü (AOAC940.28) Titrasyon Akış Şeması

Kızartma yağları için önerilen SYA sınır değerleri, farklı ulusal ve akademik standartlarda benzer aralıklarda tanımlanmıştır. Örneğin, Avustralya, Polonya ve Belçika mevzuatlarında SYA oranının %2,5'i aşması durumunda yağın kullanımının durdurulması gerektiği bildirilmiştir. Bilimsel çalışmalarda ise %2,0 değeri çoğunlukla “bozulma eşiği” olarak kabul edilmektedir (Ban vd., 2016; Y. Gao vd., 2023). Bu değerlerin üzerinde ölçülen SYA düzeyleri, oksidatif ve termal bozulmanın ilerlediğini ve yağın yeniden kullanılmasının halk sağlığı açısından riskli olduğunu göstermektedir.

1.1.4.2 Toplam Polar Bileşikler Analizi ve Temel İlkeler


Toplam polar bileşikler, kızartma yağlarının oksidatif, termal ve hidrolitik bozulma süreçleri sonucunda oluşan polar karakterli bileşiklerin toplamını ifade eder. Bu bileşikler arasında serbest yağ asitleri, mono- ve digliseritler, oksidatif

bozunma ürünleri (aldehitler, ketonlar) ve polimerize trigliseritler yer alır. Yağ ısıtma işlem sırasında tekrarlı kullanıldığında, bu bileşiklerin konsantrasyonu artar ve dolayısıyla TPB değeri, yağın toplam bozulma düzeyinin güvenilir bir göstergesi hâline gelir.

SYA gibi tek bir kimyasal parametreyi değil, birden fazla bozunma mekanizmasını aynı anda yansıtmaması nedeniyle, TPB analizi kapsamlı kalite değerlendirme açısından daha bütüncül bir ölçüt olarak kabul edilmektedir (Y. Wang vd., 2014). Özellikle Avrupa ülkelerinde kızartma yağlarının izlenmesinde, TPB oranı yasal olarak sınırlandırılmıştır ve kalite kontrol protokollerinin merkezinde yer almaktadır (Tarmizi & Lin, 2008).

TPB analizi **Şekil 1.9** da gösterilen analitik yaklaşımlarla gerçekleştirilebilir. Literatürde en sık kullanılan yöntemler şunlardır:

- i. Gravimetrik analiz: Yağdaki polar ve nonpolar fraksiyonların fiziksel ayrımı ve tartılması prensibine dayanır.
- ii. Kromatografik teknikler (GC, HPLC): Bileşiklerin kimyasal ayrımını sağlayarak bileşen düzeyinde analiz yapılmasına olanak tanır (Gertz & Behmer, 2014).
- iii. Taşınabilir hızlı test kitleri (Optifry, Testo 270): Endüstriyel mutfaklarda ve sahada anlık ölçüm imkânı sağlar; sonuçlar genellikle 3–5 dakika içinde elde edilir (Ooi vd., 2024).



Şekil 1.9. TPB Ölçüm Yaklaşımları

Farklı ülkelerde belirlenen TPB sınır değerleri, kızartma yağlarının hangi noktada “kullanılamaz” olarak değerlendirileceğini belirler. Avrupa’da yapılan düzenlemelere göre maksimum izin verilen TPB oranları aşağıdaki gibidir:

- Almanya: %24
- İtalya: %25
- Fransa: %25
- İsviçre: %27
- Avusturya: %27 (Tarmizi & Lin, 2008; Thelen vd., 2025).

Bu değerler, endüstriyel işletmelerin kalite yönetim sistemlerinde standart izleme aralıklarının belirlenmesinde referans olarak kullanılmaktadır. TPB düzeyinin bu sınırları aşması, yağın hem duyuşal hem de toksikolojik açıdan insan tüketimi için uygun olmadığını gösterir (Tarmizi & Lin, 2008; Y. Wang vd., 2014).

1.1.4.3 Klasik Yöntemlerin Karşılaştırmalı Değerlendirmesi ve Alternatif Yaklaşımların Gerekliliği

Kızartma yağlarının bozulma düzeyinin belirlenmesinde en yaygın kullanılan klasik kimyasal yöntemlerden olan SYA analizi ve TPB analizi yağın kalitesine ilişkin önemli göstergeler sunmakta; ancak ölçüm prensipleri, uygulama kolaylığı ve endüstriyel uygunluk açısından farklılıklar göstermektedir (H.-X. Gao vd., 2020; L. Wang vd., 2016).

Tablo 1.2. SYA ve TPB analiz yöntemleri karşılaştırma tablosu

Kriter	SYA Analizi	TPB Analizi
Ölçülen Parametre	Serbest yağ asidi oranı	Bozulma sonucu oluşan toplam polar bileşikler
Analiz Yöntemi	Alkali titrasyon	Gravimetrik veya cihaz tabanlı ölçüm (GC, HPLC, hızlı test kitleri)
Analiz Süresi	Orta düzey (yaklaşık 20–30 dakika)	Hızlı (test kitleriyle 5 dakika), Yavaş (GC/HPLC yöntemlerinde)
Taşınabilirlik	Düşük – laboratuvar bağımlı	Orta – taşınabilir test cihazlarıyla mümkündür
Hassasiyet	Yüksek (laboratuvar koşullarında)	Yüksek (lab ortamında); Orta (taşınabilir kitlerle)
Gerçek Zamanlı Ölçüm	Hayır	Kısmen – hızlı test sistemleriyle sınırlı düzeyde

SYA ve TPB analiz yöntemleri karşılaştırmalı olarak **Tablo 1.2** de verilmiştir.

Her iki yöntem de doğruluk açısından yüksek güvenilirlik sağlamasına karşın, endüstriyel üretim hatlarında gerçek zamanlı izleme ve otomatik karar verme gereksinimlerini karşılamada yetersiz kalmaktadır. Özellikle SYA analizi, hem çözücü hem de kimyasal reaktif kullanımını gerektirdiğinden saha koşullarında uygulanabilirliği düşüktür (Chen vd., 2015; Q. Zhang vd., 2015). TPB analizi ise kapsamlı bilgi sağlamakla birlikte, cihaz temelli ölçümlerde yüksek ekipman maliyeti ve deneyimli operatör gereksinimi dezavantaj oluşturmaktadır (Chen vd., 2015).

1.1.4.4 Alternatif Yöntemlere Duyulan Gereksinim

Literatürde son yıllarda, klasik yöntemlerin doğruluk ve tekrarlanabilirlik açısından güçlü olmasına rağmen, hız, taşınabilirlik ve dijital entegrasyon bakımından sınırlı oldukları vurgulanmaktadır (Ahmad vd., 2021). Endüstriyel üretim hatlarında yağ kalitesinin anlık değerlendirilmesi, karar destek sistemlerinin geliştirilmesi ve enerji/maliyet optimizasyonu açısından klasik laboratuvar temelli yöntemlerin yerini daha otomatik, düşük maliyetli ve taşınabilir sistemlere bırakması beklenmektedir.

Bu bağlamda, gaz sensörleri, optik sensörler (örneğin, kırılma indeksi temelli sistemler) ve fiziksel parametre ölçümleri, YZ ve makine öğrenmesi (MÖ) tabanlı algoritmalarla bütünleştirilerek yeni bir paradigma ortaya koymaktadır. Bu sistemlerde, gaz fazındaki uçucu organik bileşikler (UOB) sensörlerle algılanmakta; bu veriler, klasik yöntemlerle elde edilen laboratuvar sonuçlarıyla korelasyonu bulunarak model eğitimi sağlanmaktadır (Gertz vd., 2017; Khor vd., 2019).

Bu yaklaşımlar, yalnızca kimyasal analizlerin yerini almakla kalmayıp, aynı zamanda gerçek zamanlı kalite izleme, otomatik karar verme ve proses kontrolü gibi işlevleri de mümkün kılmaktadır. Literatürde bu dönüşüm, “akıllı gıda kalite izleme sistemleri” (intelligent food quality monitoring systems) olarak tanımlanmakta ve klasik yöntemlerin tamamlayıcısı olarak konumlandırılmaktadır (Kita, 2014; Weisshaar, 2014).

Bu yaklaşımlar çerçevesinde klasik yöntemler (SYA ve TPB), yağ bozulmasının kimyasal temelli değerlendirilmesinde referans değer taşımaya devam etmektedir. Ancak, günümüz endüstriyel koşullarında, hız, taşınabilirlik ve otomasyon gereksinimleri, sensör füzyonu ve YZ destekli yaklaşımların ön plana

çıkmasına yol açmıştır. Literatür, bu alternatif sistemlerin yalnızca ölçüm süresini kısaltmakla kalmayıp, aynı zamanda veri güvenilirliğini artırarak kalite kontrol süreçlerini dijitalleştirdiğini göstermektedir. Bu nedenle modern araştırmalar, SYA ve TPB gibi klasik parametrelerin sensör tabanlı analizlerle bütünleştirildiği hibrit modellerin geliştirilmesine odaklanmaktadır.

1.1.5 Gaz Sensör Tabanlı Yaklaşımlar

Gıda kalite kontrolü alanında gaz sensörlerinin kullanımı, özellikle uçucu organik bileşiklerin analizi üzerinden gerçekleştirilmektedir. Kızartmalık yağların tekrar ısıtılması sonucu oluşan UOB'lar, bozulma seviyesini doğrudan yansıtan biyobelirteçler (biomarkers) olarak kabul edilmektedir (Q. Zhang vd., 2015). Bu bağlamda, gaz sensörleriyle UOB'ların tespiti; yağın durumu hakkında hızlı, taşınabilir ve düşük maliyetli bilgiler sunarak, geleneksel yöntemlere güçlü bir alternatif haline gelmiştir.


1.1.5.1 Gaz Sensör Teknolojisinin Temelleri

Gaz sensörleri, bir ortamdaki gazların varlığını ve yoğunluğunu algılayabilen elektrokimyasal, metal oksit yarı iletken (MOS), optik veya piezoelektrik temelli cihazlardır. Bu sensörler, gazların sensör yüzeyi ile etkileşime girerek iletkenlik, direnç veya optik özelliklerde değişiklik oluşturması prensibine dayanır. MOS tipi sensörler, özellikle kızartma yağındaki UOB'leri algılamada yaygın olarak tercih edilmektedir çünkü:

- Geniş UOB spektrumunu tanımlayabilirler,
- Küçük boyutludur, taşınabilir sistemlere uygundur.

1.1.5.2 Elektronik Burun (e-nose) Sistemleri

Elektronik burun sistemleri, birden fazla gaz sensörünün oluşturduğu sensör dizilerinden meydana gelir ve bu dizilerden elde edilen sinyaller, makine öğrenimi algoritmaları ile analiz edilerek gazların kimyasal profili belirlenir. Bu sistemler, özellikle gıda kalite kontrolü ve bozulma tespiti alanında çok sayıda çalışmada kullanılmıştır (Wilson, 2015). Elektronik burun sisteminde örnek akışı **Şekil 1.10** da temsili olarak gösterilmiştir.



Şekil 1.10. Elektronik Burun (e-nose) Sistemi Sensör Dizisi ve Örnek Akışı


Bu sistemlerin en önemli gücü, kompleks gaz karışımlarını ayrıştırabilme ve sınıflandırma algoritmalarıyla öğrenerek tahminlerde bulunabilme yetenekleridir (Gancarz vd., 2019).

1.1.5.3 BME688 Gaz Sensörü ve Yağ Kalitesi Belirleme Süreçleri

Bosch Sensortec tarafından geliştirilen BME688, entegre gaz sensörü olarak hem sıcaklık, nem, basınç gibi çevresel verileri ölçebilir hem de UOB' leri yüksek hassasiyetle tespit edebilir. BME688'in en dikkat çekici özelliği, Bosch AI Studio adlı platform aracılığıyla cihaz üzerinde makine öğrenimi modellerinin doğrudan eğitilip yüklenebilmesidir (Wilson, 2015).

- Her biri farklı sıcaklıklarda çalışabilen dört ısıtıcı profili sayesinde (IP-301, IP-354, IP-411, IP-501), farklı UOB türlerine karşı seçici duyarlılık geliştirilebilir.
- Sensör, karakteristik direnç değişimlerini (R_{gas}) ölçer; bu değişim, UOB konsantrasyonuna göre anlamlı farklılıklar gösterir.
- UOB konsantrasyonunun artması, genellikle yağın oksidatif bozulma düzeyinin arttığını gösterir (Q. Zhang vd., 2015).

Kızartma yağına farklı bozulma düzeylerinde uygulanan gaz sensörü verilerinin YSA ile %98 doğrulukla sınıflandırılabilirdiği gösterilmiştir (Liu vd., 2022). Farklı ısıtıcı profillerini temsil eden seçicilik göstergeleri **Şekil 1.11** de gösterilmiştir.



Şekil 1.11. BME688’de Isıtıcı Profillerine Göre Seçicilik Kavramı

1.1.5.4 Literatürdeki Başlıca Çalışmalar

Tablo 1.3 BME688 gaz sensörünün yağ kalitesinin değerlendirilmesi üzerine yapılan önemli çalışmaları ve ilgili verileri özetlemektedir. Bu çalışmalar, gaz sensörlerinin gıda kalite kontrolündeki potansiyelini ve çeşitli yağların bozulma düzeylerini tespit etme yeteneklerini vurgulamaktadır.

Tablo 1.3. Literatürdeki Benzer Çalışmalar

Konu	Çalışma Bulguları	Kaynak
Yağ Kalitesi – Sahtecilik Tespiti	Elektronik burun sisteminin karma yağlarda sahtecilik tespiti için uygulanabilir olduğu, kimyasal bileşimlerin doğru analiz edilebildiği gösterilmiştir.	(Karami vd., 2020)
Yağ Kalitesi – Depolama Süresi İzleme	Taşınabilir e-nose cihazı kullanılarak yenilebilir yağların depolama süresi niteliksel olarak belirlenmiş, yağ kalitesinin izlenebilir olduğu rapor edilmiştir.	(Jiang vd., 2020)
Doğal Antioksidanların Rolü	Fenolik bileşenlerin oksidatif bozulmayı yavaşlatarak yağ kalitesinin korunmasına katkı sağladığı ifade edilmiştir.	; (Gutiérrez-Del-Río vd., 2021)
Balda Tağşiş Tespiti	BME688 sensörü ve yapay zekâ tabanlı sistemle balda tağşiş %5 hassasiyetle tespit edilmiştir.	(Mehmet Milli vd., 2025)
Et Türlerinin Sınıflandırılması	BME688 sensörleri ile et türleri başarılı şekilde sınıflandırılmış ve gıda izlenebilirliği artırılmıştır.	(Scientific, Industrial and Technological Application and Research Center (SITARC), Bolu Abant İzzet

		Baysal University, Bolu, Turkey vd., 2025)
Yağ Bozulması – Volatil Bileşik İzleme	Gaz sensörleri yağ bozulması sırasında yayılan volatil bileşenlerin tespitinde etkili olmuş, bu da yağ kalitesini izleme açısından değerli bulunmuştur.	(Andre vd., 2022; Tomović vd., 2020)
Veri Analitiği ve Yapay Zekâ ile Gelişim	Gaz sensörlerinin yapay zekâ ve veri analitiği ile entegrasyonu, zorlu gıda ortamlarında daha güvenilir sonuçlar sağlamıştır.	(Ma vd., 2023)

Bu çalışmalar, BME688 gaz sensörünün ve diğer sensör tabanlı sistemlerin, kızartmalık yağların kalitesinin belirlenmesinde sağladığı avantajları ortaya koymaktadır. Öne çıkan bulgular, gaz sensörleri ve yapay zekâ tabanlı yaklaşımların, gıda güvenliğini sağlamak için modern gıda endüstrisinde nasıl uygulandığını açıklamaktadır. Bu bağlamda, gaz sensörleri, geleneksel yöntemlerin ötesine geçerek daha hızlı, taşınabilir ve ekonomik çözümler sunmaktadır.

BME688 gibi gaz sensörleri, gıda kalitesi izleme süreçlerinde temel bir rol oynayarak, geleneksel analiz yöntemlerine alternatif bir çözüm sunmaktadır. Gaz sensörlerinin sağladığı avantajlar, modern gıda üretim süreçlerinin kalite kontrolüne önemli katkılar yapmaktadır. Literatürdeki bu çalışmalar, ilerleyen süreçlerde sensör tabanlı yaklaşımların ve yapay zekâ uygulamalarının gıda kontrol sistemlerinde daha fazla yer bulacağına işaret etmektedir.

1.1.5.5 Avantajlar ve Sınırlılıklar

Gaz sensör tabanlı ölçüm sistemleri, klasik kimyasal analiz yöntemlerine kıyasla birçok önemli avantaj sunmaktadır. Öncelikle bu sistemler, hızlı ölçüm yapma kabiliyetine sahiptir ve bu sayede gerçek zamanlı veri analizi yapılmasına olanak tanır. Ayrıca, düşük güç tüketimi ve kompakt tasarım özellikleri sayesinde taşınabilir sistemlerle kolayca entegre edilebilirler. Yapay zekâ algoritmalarıyla birlikte kullanıldığında, ölçüm sonuçlarında yüksek doğruluk ve tutarlılık elde edilmesi mümkündür. Bu özellik, sistemlerin özellikle sahada yapılan kalite kontrol uygulamalarında kullanıcı dostu ve ekonomik bir alternatif haline gelmesini sağlamaktadır (Liu vd., 2022; Messina vd., 2015).

Bununla birlikte, bu tür sensör sistemlerinin belirli sınırlılıkları da bulunmaktadır. Öncelikle, UOB'lerin ölçümü çevresel koşullardan “örneğin hava

akımı, sıcaklık ve bağıl nem değişimlerinden” etkilenebilmektedir. Bu durum, sensör çıktılarında kararsızlıklara yol açabilmektedir. Ayrıca, her sensör belirli bir kalibrasyon sürecine ve uygulamaya özgü model eğitimi gereksinimine sahiptir. Uzun süreli kullanımda sensör yüzeyinde kirlenme veya yaşlanma gibi fiziksel değişimler oluşabileceği için sinyal kalitesinde bozulmalar gözlemlenebilir (Grossi vd., 2022; Q. Zhang vd., 2015).

Bir diğer önemli kısıt, bu sensörlerin tek başına SYA, TPB veya peroksit değeri gibi tüm yağ kalite kapsamlı biçimde ölçememeleridir. Sensörler bu yönüyle klasik ölçüm yöntemleri çerçevesinde kalibre edilmelidir. Nitekim literatürde, sensör veri füzyonunun özellikle gıda kalitesi sınıflandırma problemlerinde doğruluk oranlarını belirgin şekilde artırdığı rapor edilmiştir (Molina-Garcia vd., 2017; Y. Zhang vd., 2020).


Gaz sensör tabanlı yaklaşımlar, gıda kalite kontrol sistemlerinde önemli bir rol oynamaktadır. UOB analizi üzerinden gerçekleştirilen bu sistemler, kızartmalık yağların izlenmesi konusunda hızlı ve güvenilir çözümler sunmaktadır. MOS sensörlerinin ve elektronik burun sistemlerinin entegrasyonu, gıda güvenliği açısından yeni bir paradigma oluşturmakta ve alanın gelecekteki ilerlemesine yön vermektedir.

1.1.6 Yapay Zekâ Tabanlı Sınıflandırmalar

Şekil 1.12, yenilebilir yağların kalite sınıflandırılmasına yönelik yapay zekâ tabanlı bir işlem akışını göstermektedir. Diyagramda, sensörden veri toplama aşamasından başlayarak, veri ön işleme, modelleme ve çıktı üretim süreçlerine kadar tüm temel adımlar sistematik şekilde sunulmuştur.

Bu akış diyagramı, BME688 gaz sensörü ile elde edilen verilerin yapay zekâ algoritmalarına uygun hâle getirilmesi ve farklı sınıflandırma modellerinin kullanılmasıyla yağ kalitesinin belirlenmesini özetlemektedir.

Şekil, çalışmada uygulanan yöntemsel yaklaşımın bütüncül bir görünümünü sağlayarak, veri akışının nasıl ilerlediğini ve sınıflandırma sürecinin hangi bileşenlerden oluştuğunu açık biçimde ortaya koymaktadır. Ayrıca bu yapı, farklı algoritmaların (YSA, DVM, RO, k-NN) aynı veri seti üzerinde nasıl değerlendirildiğini ve sonuç olarak yağ kalite sınıflarının elde edildiğini göstermesi açısından önemlidir.



Şekil 1.12. Yapay zekâ tabanlı sınıflandırma akış diyagramı

1.1.6.1 Neden Yapay Zekâ?

Kızartmalık yağların geleneksel yöntemlerle kalite değerlendirmesi, genellikle zaman alıcı olup; ölçüm değişkenliği, operatör hataları ve tekrarlanabilirlik sorunları gibi önemli kısıtlar içermektedir. Ayrıca bu yöntemlerin laboratuvar ortamı gerektirmesi, gerçek zamanlı ve yerinde izleme uygulamaları açısından sınırlayıcı bir unsur oluşturmaktadır.

Bu kısıtları ortadan kaldırmak amacıyla, YZ ve makine öğrenmesi tabanlı yaklaşımlar, özellikle sensör tabanlı sistemlerle bütünleştirildiklerinde, yüksek doğruluk, hız, adaptif öğrenme ve otomasyon potansiyeli sunmaktadır.

YZ temelli sistemler, kızartmalık yağların kimyasal bozulma süreçlerinin değerlendirilmesinde aşağıdaki temel avantajları sağlamaktadır:

- ✓ **Karmaşık ve çok boyutlu sensör verilerini işleyebilme kapasitesi:** Geniş ölçekli ve yüksek boyutlu veri kümelerinin çok değişkenli analizine olanak tanır.
- ✓ **Doğrusal olmayan örüntüleri tanıma yeteneği:** Heterojen sensör verilerinden anlamlı örüntüler çıkararak sistematik ilişki modelleri kurabilir.
- ✓ **Yeni veriler üzerinde genelleme yapabilme becerisi:** Eğitim verilerinden türetilen öğrenme modelleri aracılığıyla farklı koşullar altında güvenilir tahminler üretebilir.
- ✓ **Otomatik karar verme ve öngörüselleştirme yeteneği:** Gerçek zamanlı sistemlerde yüksek tepki hızına sahip veri odaklı karar destek mekanizmaları oluşturabilir.

Bu bağlamda, YZ tabanlı sınıflandırma sistemleri, gaz sensörlerinden ve optik ölçüm sistemlerinden elde edilen çok boyutlu verilerin analizi, yorumlanması ve sınıflandırılmasında giderek artan bir şekilde tercih edilmektedir. Bu sistemler, kızartma yağlarının kalite değerlendirmesinde hem zamansal verimliliği hem de

analitik doğruluğu artırarak, endüstriyel süreçlerde yenilikçi ve sürdürülebilir bir izleme yaklaşımı sunmaktadır.

1.1.6.2 Kullanılan Temel Modeller

Yapay zekâ uygulamalarında kıyartma yağlarının kalitesini sınıflandırmak amacıyla çeşitli modeller kullanılmıştır. Bu modeller arasında Yapay Sinir Ağları, Destek Vektör Makineleri, Rastgele Orman ve k-En Yakın Komşu algoritmaları öne çıkmaktadır. Bu YSA'ların avantaj ve dezavantajları **Tablo 1.4**. Literatürde çok sık kullanılan makine öğrenmesi yaklaşımlarının karşılaştırılması. **Tablo 1.4** de listelenmiştir.

Tablo 1.4. Literatürde çok sık kullanılan makine öğrenmesi yaklaşımlarının karşılaştırılması.

Model	Açıklama	Avantajları	Sınırlamaları
Yapay Sinir Ağları (YSA)	İnsan beyninin öğrenmesini taklit eder. Girdileri gizli katmanlarda işler.	Karmaşık görünümelerde yüksek doğruluk sağlar.	Eğitim süresi uzundur, aşırı uyum riski taşır.
Destek Vektör Makineleri (DVM)	Verileri en uygun karar sınırlarıyla ayırır.	Az veriyle iyi sonuç verir, sağlam genelleme sağlar.	Çoklu sınıflarda performans düşebilir.
Rastgele Orman (RO)	Karar ağaçlarının sürdürülebilmesi mümkündür.	Hızlı, yorumlanabilir, düşük değişkenliktedir.	Aşırı uyum riski vardır.
k-En Yakın Komşular	Yeni verileri benzer örneklerle sınıflandırır.	Basit, programlama açısından düşük düzeydedir.	Büyük veri kümelerinde yavaş çalışır.

Bu modeller arasında YSA; sensör ilişkilerinin karmaşık, doğrusal olmayan aralık miktarı ve kapasitesi nedeniyle literatürde en yüksek başarı oranlarını sunan yapı olarak öne çıkmaktadır.

1.1.6.3 Sensör Verilerinin Sınıflandırmada Kullanımı

YZ tabanlı modellerin doğruluk, genelleme kabiliyeti ve kararlılık açısından performans düzeyi, büyük ölçüde kullanılan veri setinin kalitesi, çeşitliliği ve temsil gücü ile doğrudan ilişkilidir. Bu bağlamda, modelin girdisini oluşturan veriler doğrudan gaz sensörlerinden alınan ve bunlardan türetilen oran tabanlı ölçümlerden elde edilmektedir.

Özellikle BME688 sensör ailesi, uçucu organik bileşiklerin konsantrasyon değişimlerine karşı yüksek duyarlılık gösterirken; sıcaklık, bağıl nem ve basınç gibi çevresel parametrelerin eş zamanlı olarak ve kararlı biçimde ölçülmesine imkân tanımaktadır. Bu çoklu sensör yapısı, karmaşık fizikokimyasal etkileşimlerin modellenmesi için yüksek çözünürlüklü veri sağlamaktadır.

Sınıflandırma sürecinde kullanılan tipik özellik kümeleri aşağıdaki şekilde özetlenebilir:

Gaz sensörü tepkileri: Direnç değişimi (R_{gas}) profilleri ve sensörün ısıtma döngüsü boyunca elde edilen termal yanıt karakteristikleri.

Çevresel parametreler: Ortam sıcaklığı ve bağıl nem ölçümleri.

K Isıtma veya ölçüm döngülerine ilişkin zaman tabanlı göstergeler.

Modelleme öncesinde, bu ham veriler Z-skoru normalizasyonu veya Min–Maks ölçeklendirme gibi standardizasyon teknikleri kullanılarak normalize edilir. Verideki boyutluluğu azaltmak ve gürültüyü minimize etmek amacıyla sıklıkla Temel Bileşen Analizi (TBA) uygulanır.

Elde edilen işlenmiş veri seti, yapay zekâ modeline giriş olarak sunulur. Model, bu çok boyutlu sensör girdilerinden yağ kalitesi sınıfını (“Taze”, “Kullanılabilir”, “Düşük Kalite”, “Kullanılamaz”) veya sürekli bir yağ kalite indeksini (Quality Index) tahmin eder. Böylece sistem, sensör verilerinin bütüncül değerlendirilmesiyle kızartma yağı kalitesinin hem nitel hem nicel olarak belirlenmesini sağlar.

YZ uygulamaları, sistem koşullarının literatürdeki örnekleri ve sensör füzyonuna dayalı teorik verilerle karşılaştırıldığında, yüksek doğruluk oranlarına ulaşılabildiğini göstermektedir. Bu bağlamda, alanda gerçekleştirilen çeşitli çalışmalar, yapay zekâ tabanlı modellerin hem veri işleme hem de sınıflandırma görevlerinde güçlü bir performans sergilediğini ortaya koymaktadır. **Tablo 1.5** de bu konuda öne çıkan bazı önemli araştırmalara yer verilmiştir.

Tablo 1.5. Literatürdeki sensör uygulamaları

Çalışma	Sensör Türü	Yöntem	Başarı Oranı
(H.-X. Gao vd., 2020)	BME688	Gerçek Zamanlı	%98
(Parlak vd., 2025)	BME688	Gerçek Zamanlı	%92
(Zhao vd., 2021)	BME688 + RI	Gerçek Zamanlı	%98,5

(Mehany vd., 2024)	e-burun	TBA, Gerçek Zamanlı	Gerçek zamanlı izleme sağlanmıştır
--------------------	---------	---------------------	------------------------------------

Bu çalışmalar, yapay zekâ tabanlı sistemlerin kızartmalık yağların küresel ölçekte izlenmesi, değerlendirilmesi ve sınıflandırılması alanında ne denli etkin bir potansiyel sunduğunu açıkça ortaya koymaktadır. Bu kapsamda geliştirilen algoritmik yaklaşımlar, çok boyutlu sensör verilerinden türetilen karmaşık örüntülerin analizi sayesinde, gıda endüstrisinde kalite güvence mekanizmalarının dijitalleşmesine önemli katkılar sağlamaktadır.

Yapay zekâ temelli sistemler, günümüzde gıda kalitesi izleme ve kontrol süreçlerinde giderek daha güçlü bir konum edinmektedir. Gaz sensörlerinden elde edilen veri setlerinin derin öğrenme veya diğer makine öğrenmesi algoritmalarıyla işlenmesi, kızartma yağlarının kimyasal bozulma süreçlerinin daha yüksek doğrulukla modellenmesine ve erken bozulma göstergelerinin tespitine olanak tanımaktadır.

Bu doğrultuda geliştirilen yapay zekâ tabanlı tahmin modelleri, gerçek zamanlı uygulamalarda kullanılabilirliğiyle öne çıkmakta ve endüstriyel üretim hatlarında anlık karar desteği sağlayarak kalite kontrol döngülerinin etkinliğini artırmaktadır.

Sonuç olarak, bu teknolojik yaklaşım; gıda güvenliği, izlenebilirlik ve kalite kontrol süreçlerinde şeffaflık açısından önemli bir ilerleme temsil etmekte, aynı zamanda sürdürülebilir üretim politikaları ile uyumlu, yenilikçi bir değerlendirme paradigmasının temelini oluşturmaktadır.

1.1.6.4 Model Performans Değerlendirme Metrikleri

YZ sonuçlarının performans değerlendirmesinde, yalnızca doğruluk metriklerinin kullanımı yeterli değildir. Bunun yerine, hassaslık, geri yayılım, F1-skoru ve karışıklık matrisi gibi ek değerlendirme metrikleri önem kazanmaktadır. Bu metrikler, YZ modellerinin sadece genel doğruluğu değil, aynı zamanda spesifik ve kritik dağıtım görevlerindeki işlemlerin de ölçülmesine yardımcı olmaktadır (Sathyanarayanan, 2024). Örneğin, (Aghili vd., 2023) tarafından geliştirilmiş YSA modelinin performans metrikleri şu şekilde raporlanmıştır: doğruluk %98.5, hassasiyet %97.8, geri yayılım %98.9 ve F1-score %98.3 olarak belirlenmiştir. Bu metrikler, modelin incelenen yağ örneklerini ne derece doğru sınıflandırabildiğini

ve sınıflandırma performansındaki duyarlılığını açık bir şekilde ortaya koymaktadır (Aghili vd., 2023).

YZ tabanlı sistemlerde kullanılan sensörlerin operasyonel ömrü ve performans kararlılığı, sistemin uzun vadeli güvenilirliği açısından önemli bir sınırlayıcı faktördür. Sürekli kullanım ve çevresel etkenlere maruz kalma sonucunda sensörlerde oluşan yıpranma, sinyal kayması (drift) ve duyarlılık azalması, veri bütünlüğünü olumsuz etkileyerek model doğruluğunu düşürmektedir. Bununla birlikte, veri kalitesindeki değişkenlik, gürültü oranı, kalibrasyon farklılıkları ve model karmaşıklığı gibi unsurlar da sistemin genelleme yeteneği, öngörüselle kararlılığı ve hesaplama verimliliği üzerinde belirleyici olmaktadır. Bu nedenle, YZ tabanlı kızartma yağı kalite izleme sistemlerinde sensör dayanıklılığı, veri güvenilirliği ve model optimizasyonu arasındaki dengenin sağlanması, sistemin sürdürülebilir ve güvenilir performansı için kritik bir gereklilik teşkil etmektedir. (Miyagi & Nakajima, 2003).

Özellikle eğitim veri setinin içerdiği örnek çeşitliliğinin sınırlı olması, modelin genelleme yeteneğini olumsuz etkileyerek farklı koşullardaki veriler üzerinde beklenen performansı gösterememesine yol açabilir. Bu durum, modellerde aşırı öğrenme (overfitting) riskini artırarak, eğitim verisi üzerinde yüksek doğruluk elde edilmesine karşın, test verisi üzerinde düşük performans sergilenmesine yol açabilir. (Yurko vd., 2019).

Gerçek zamanlı uygulamalarda donanım simülasyonları da önemli bir kısıt oluşturmaktadır. Derin öğrenme modellerinin çalıştırılması yüksek işlemci gücü ve bellek kapasitesi gerektirdiğinden, bu durum özellikle gömülü sistemler ve mikrodenetleyiciler üzerinde uygulama yaparken ciddi bir zorluk yaratmaktadır (Lima vd., 2021).

Bu sorunu aşmak için çeşitli stratejiler önerilmektedir. Öncelikle, çapraz doğrulama (cross-validation) yöntemi, modelin farklı veri alt kümeleri üzerinde test edilmesine olanak tanıyarak genellenebilirliğin artırılmasını sağlamaktadır. (Messina vd., 2015). Ayrıca, topluluk öğrenmesi yöntemleri, RO-YSA veya DVM-NB gibi hibrit yapılar kullanılarak model kararlılığını artırabilmektedir (Lahat vd., 2015).

Anomali tespiti yöntemleri, veri setindeki nadir veya beklenmeyen örneklerin belirlenmesi ve veri çeşitliliğinin artırılması amacıyla kullanılmaktadır. Bu tür sistemler, sensör tabanlı yapay zekâ analizlerinin doğruluğunu ve

güvenilirliğini artırarak, endüstriyel uygulamalarda performans ve kalite açısından önemli iyileştirmeler sağlamaktadır. (Nicolle vd., 2024).

Sonuç olarak, bu sistemler, yapay zekâ tabanlı sensör ölçümlerinin etkinliğini artırarak gelecekte gıda kalitesi kontrol süreçlerinde önemli bir rol üstlenme potansiyeline sahiptir. Ayrıca, bu teknolojiler akıllı karar destek sistemlerinin vazgeçilmez bileşenleri haline gelerek, gıda güvenliği ve kalite yönetimi alanlarında yenilikçi çözümler sunabilir. (Sharanke & Sivakanthan, 2022).



2. MATERYAL VE YÖNTEM

Bu tez çalışmasında, sıvı yağ numunelerinin kullanılabilirlik düzeyinin belirlenmesi amacıyla kullanılan sensör sisteminin teknik özellikleri, ölçüm protokolü ve veri toplama süreci ayrıntılı olarak açıklanmaktadır. Ayrıca, gaz sensörü konfigürasyonu, deneysel ölçüm döngüsü ve yapay zekâ destekli veri işleme adımları sistematik biçimde sunulmuştur. Uygulanan yöntemler, sensör verilerinin güvenilirliğini artırmayı, ölçüm sonuçlarını stabilize etmeyi ve sınıflandırma performansını optimize etmeyi hedeflemektedir.

Tablo 2.1. Çalışmada Kullanılan Ölçüm Parametreleri ve Açıklamaları

Parametre	Ölçüm Türü	Birim	Açıklama
UOB (Gaz Direnci)	Kimyasal Tepki	Ω	Yağ buharındaki gaz karışımına bağlı direnç değişimi
Sıcaklık (T)	Fiziksel	$^{\circ}\text{C}$	Sensör membran sıcaklığı
Nem (RH)	Fiziksel	%	Ortam nem oranı
Basınç (P)	Fiziksel	hPa	Ortam basıncı
SYA	Kimyasal	%	Serbest yağ asidi miktarı
TPB	Kimyasal	%	Toplam polar bileşik oranı


Çalışmada, kızartma yağlarının termal bozulma süreci boyunca ortaya çıkan UOB analizi için BME688 çoklu gaz sensörü kullanılmıştır. Bu sensörden elde edilen elektriksel sinyaller, yağın kimyasal bozulma seviyesini dolaylı biçimde yansıtmaktadır. Böylece, dolaylı kimyasal göstergeleri içeren çok boyutlu bir veri seti elde edilmiştir. Çalışmada Kullanılan Ölçüm Parametreleri ve Açıklamaları **Tablo 2.1** de verilmiştir.

Sensör verilerinin güvenilirliğini artırmak ve YZ modelleri için sağlam bir temel oluşturmak amacıyla, bu çalışmada hem sensör tabanlı ölçüm ve çözümleme, hem de klasik laboratuvar analizlerinden yararlanılmıştır. Bu kapsamda, gaz sensöründen elde edilen veriler, yağın bozulma düzeyini belirleyen SYA ve TPB gibi geleneksel kalite parametreleriyle karşılaştırılmış ve doğrulanmıştır. Böylece, geliştirilen sistemden elde edilen sensör verileri yalnızca istatistiksel olarak değil, aynı zamanda kimyasal açıdan da anlamlı hâle gelmiş; bu durum, yapay zekâ tabanlı sınıflandırma modelinin bilimsel geçerliliğini ve doğruluk gücünü önemli ölçüde artırmıştır.

2.1 SENSÖR MATRİSİ KONFIGÜRASYONU

Bu çalışmada, kızartmalık yağların termal bozunumu sırasında ortaya çıkan UOB'lerin algılanmasında yüksek duyarlılık gösterebilmesi amacıyla BME688 çoklu gaz sensörü optimize edilerek kullanılmıştır. Sensör, kızartma işlemi süresince değişen gaz bileşimlerine karşı seçici tepkiler verebilmesi için özelleştirilmiş bir ısıtma kontrol mekanizması ile yapılandırılmıştır. Ayrıca, sıcaklık ve nem gibi çevresel değişkenlerden kaynaklanabilecek sinyal gürültüsünü ve baz çizgisi sapmalarını bastırmak üzere sistematik olarak kalibre edilmiştir. Bu bağlamda, ölçüm sürecinde kullanılacak sensör dizisinin gömülü sistem programlamasında iki temel parametre ön plana çıkmaktadır: Isıtıcı Profili (Heater Profile, HP) ve Gerçek Görev Döngüsü (Real Duty Cycle, RDC) profili.

Isıtıcı Profili (IP), sensör membranına yönlendirilen havanın sıcaklığını belirleyerek gaz sensörünün tepki dinamiklerini kontrol eden en kritik parametredir. Bu çalışmada, BME688 sensörlerinden elde edilen verilerin ayırt edici potansiyelini maksimize etmek amacıyla, termal modülasyona dayalı özelleştirilmiş bir on adımlı ısıtıcı profili uygulanmıştır. Bu profiller, sıcaklığa bağlı olarak gazların elektriksel iletkenlik özelliklerini değiştirerek sensör çıkışında farklı bileşiklere özgü karakteristik tepki eğrileri oluşturmayı amaçlamaktadır. Uygulanan IP profillerine ilişkin sıcaklık değişimleri adım düzeyinde **Şekil 2.1**'de görselleştirilmiştir.



Şekil 2.1. Uygulanan IP profillerine ilişkin sıcaklık değişimleri (Musa Milli & Milli, 2025 den uyarlanmıştır.)

Sensör sisteminde kullanılan ikinci parametre olan Gerçek Görev Döngüsü (GGD) profili, sensör düğümlerinin aktif ölçüm ve uyku modları arasındaki


zamanlamayı tanımlar. Bu parametre, özellikle batarya ile çalışan taşınabilir sistemlerde enerji verimliliğini artırmak amacıyla sensörlerin belirli aralıklarla devre dışı bırakılmasını sağlar. Ancak, bu çalışmada sensörlere doğrudan elektrik şebekesi üzerinden güç sağlandığından, veri kaybını önlemek ve daha yüksek zaman çözünürlüğü elde etmek amacıyla sensörler sürekli aktif tutulmuş; bu doğrultuda GGD-1-0 profili kullanılmıştır. Böylece, kısa sürede daha fazla veri toplanarak yapay zekâ tabanlı sınıflandırma modellerinin doğruluk ve kararlılığı artırılmıştır. Standart DC profillerinin uyku ve tarama sürelerine ilişkin ayrıntılar **Şekil 2.2** de sunulmaktadır.



Şekil 2.2. Standart DC profillerinin uyku ve tarama süreleri (Musa Milli & Milli, 2025 den uyarlanmıştır.)

Her uçucu bileşiğin belirli sıcaklık aralıklarında farklı adsorpsiyon-desorpsiyon kinetiği ve reaksiyon aktivitesi göstermesi nedeniyle, uygulanan sıcaklık-zaman dizileri sensörün seçiciliğini önemli ölçüde artırmaktadır. Termal stimülasyon yoluyla elde edilen sinyal varyasyonları, sensörlerin gazlara özgü tepki örüntülerini güçlendirerek makine öğrenimi algoritmalarının ayırt edici özellik vektörleri oluşturmaya katkıda bulunmuştur.

Bu çalışma kapsamında kullanılan sensör matrisi sekiz adet BME688 sensöründen oluşmaktadır ve her biri çiftler hâlinde gruplanmıştır. Her sensör çifti aynı ısıtıcı profili ile çalıştırılarak elde edilen verilerin tekrarlanabilirliği ve ölçüm güvenilirliği sağlanmıştır. Geliştirme kartı üzerinde yer alan sensör çiftleri ve bunlara atanan ısıtıcı profillerin şematik dağılımı **Şekil 2.3** de gösterilmektedir.



Şekil 2.3. Geliştirme kartı üzerinde yer alan sensör çiftleri ve bunlara atanan ısıtıcı profillerin şematik dağılımı (Parlak vd., 2025 den uyarlanmıştır.)

2.2 Oksidasyon ürünlerinin tanımlanması

Tekrarlanan ısıtma işlemleri sırasında, bitkisel yağlarda oksidasyon, hidroliz ve polimerizasyon gibi bir dizi termooksidatif ve termohidrolitik reaksiyon meydana gelir (Romano vd., 2013; Yıldız vd., 2024). Bu süreçler, trigliseridlerin parçalanmasına ve SYA, aldehitler, ketonlar, okside monomerik trigliseridler, dimerize/polimerize trigliseridler ve diğer polar bileşikler gibi çok çeşitli bozunma ürünlerinin oluşumuna yol açar (Gertz vd., 2017; Romano vd., 2013). Literatürde, ısıtma işlem süresi ve sıcaklık arttıkça UOB miktarının da arttığı ve bu bileşiklerin TPB ile ilişkili olduğu gösterilmiştir (Romano vd., 2013; Zribi vd., 2014). Dolayısıyla, UOB profili, yağın oksidasyon ve polimerizasyon seviyesinin dolaylı bir göstergesi olarak değerlendirilmektedir.

Bu çalışmada, yağ kalitesinin bozulmasının göstergesi olarak yaygın biçimde kullanılan iki temel parametre, SYA ve TPB, ölçülerek oksidasyon seviyesi değerlendirilmiştir (Gertz vd., 2017; Thao vd., 2024; Zribi vd., 2014). SYA, yağda meydana gelen hidroliz ve oksidatif parçalanmanın doğrudan bir göstergesi, TPB ise yağda oluşan oksitlenmiş monomerler, oligomerler, serbest yağ asitleri ve diğer polar bileşiklerin toplamını temsil eden bütünsel bir kalite göstergesidir (Gertz vd., 2017).

Sensör tabanlı değerlendirmelerde, bu iki parametreye dayanan kimyasal analizlerden elde edilen veriler, gaz sensörleri ölçümleriyle eşleştirilmiştir. Bu yöntem sayesinde, BME688 sensöründen elde edilen elektriksel sinyallerin kimyasal anlamı güçlendirilmiş ve sensör çıktılarının yağın kullanılabilirlik düzeyiyle doğrudan ilişkilendirilmesi sağlanmıştır. Literatürde de benzer şekilde, sensör verileri ile SYA ve TPB değerleri arasında yüksek korelasyon bulunduğu ve bu parametrelerin yağın oksidasyon derecesini belirlemede güçlü göstergeler

olduğu bildirilmiştir (Gertz vd., 2017; Khaled vd., 2018; Thao vd., 2024; Zribi vd., 2014).

Sonuç olarak, tekrarlanan kızartma işlemleri sonucunda meydana gelen oksidatif ve hidrolitik değişimlerin sensör verileriyle eşleştirilmesi, yağın bozulma seviyesinin hızlı, güvenilir ve yapay zeka destekli bir biçimde değerlendirilmesine olanak tanımaktadır (Gertz vd., 2017; Romano vd., 2013; Thao vd., 2024; Yıldız vd., 2024; Zribi vd., 2014).

2.2.1 Serbest yağ asitleri (SYA)

SYA, karbon zinciri ve tek bir karboksil grubu içeren organik bileşiklerdir ve genellikle katı ve sıvı yağlarda ve hücre zarlarının yapısında bulunurlar (Ying vd., 2024). Bu asitler, lipaz enzimi tarafından katalize edilen, su içeren triaçilgliserol moleküllerinin hidrolizi yoluyla salınır (Ying vd., 2024) Serbest yağ asitleri, yağın genel kalite değerlendirmesinde kritik bir parametre olarak işlev görmektedir olup, gıda endüstrisinde yağın bozulma düzeyini ve kullanım uygunluğunu belirlemede yaygın biçimde izlenen önemli bir göstergedir.

2.2.2 SYA' ların Oluşum Mekanizmaları

SYA'ların yağlarda oluşumu, birden fazla kimyasal ve biyokimyasal mekanizma aracılığıyla gerçekleşmektedir. Birincil Mekanizma, triaçilgliserollerin hidrolizidir (Ying vd., 2024). Depolama sırasında silaj yağlarında SYA içeriğinde artış meydana gelir ve bu durum lipid-protein komplekslerinin oluşumuna yol açan renk değişimlerine neden olur (Crexi vd., 2010). Ayrıca yüksek sıcaklık uygulamaları da SYA oluşumunu tetikleyebilir; Örneğin, kaproik asit ile demülsifikasyon işlemi sırasında yüksek sıcaklık, yağın hidrolizini artırarak serbest yağ asitlerinin miktarını arttırmıştır (Y. Gao vd., 2023).

SYA oluşumunun bir diğer önemli kaynağı, lipid oksidasyonunun ilerlemiş aşamalarıdır. Oksidatif bozulma sırasında, esterleştirilmiş lipitlerin birincil substrat olarak işlev görür ve bu prosesin serbest yağ asitlerinin salınmasına katkıda bulunur (Furlan Gonçalves Dias vd., 2023). Depolama süresi boyunca, özellikle oksidatif koşullar altında, SYA seviyeleri sistematik olarak artış göstermektedir (Mazı & Çoban Bayram, 2025).

2.2.2.1 SYA' ların Yağ Kalitesine Etkileri

a. Kimyasal Stabilite ve Reaktivite

SYA' lar, trigliseridlere kıyasla daha yüksek reaktiviteye sahip olmaları nedeniyle, özellikle oksijene maruz kalmalarında bozulmaya daha yatkındırlar (Ying ve ark., 2024). Bu durum, yağların kokuşmasına ve kalite kaybına yol açmaktadır (Ying ve ark., 2024). Serbest yağ asitleri, yağların kimyasal stabilitesini etkileyen kritik bileşenler olarak kabul edilmekte olup, gıda ürünlerinin genel kalitesi ve ticari değeri açısından **temel bir kalite kaybı göstergesi** işlevi görmektedir (Ying ve diğerleri, 2024).

b. Oksidatif Bozulmanın Göstergeleri

SYA seviyeleri, termal ve oksidatif bozulmanın güvenilir bir göstergesi olarak kabul edilmektedir (Ying vd., 2024). Kızartma yağlarının kullanılabilirlik sınırını belirlemek için önemli bir izleme kriteri olarak kullanılan SYA, yağın oksidatif tarihini yansıtmaktadır (de Abreu vd., 2011). Asit değeri, yağın oksidatif geçmişini yansıtan önemli bir parametre olup, serbest yağ asitlerinin birikimini gösterir ve oksidasyonun ilerlemiş aşamalarında oluşan aldehit gibi bozunma ürünlerinin varlığıyla ilişkilendirilen bir göstergedir. (de Abreu vd., 2011). Ayrıca, SYA içeriği ile kromatografik FAME analizleri arasında güçlü bir görünüm ($r^2 = 0,90$) mevcut olup, bu da oksidatif bozulma hızının hidroliz hızı ile ilişkili olduğu gösterilmiştir (Dahl & Malcata, 1999).

c. Oksidatif Stabilitayı Destekleyen Faktörler

Yağların oksidatif stabilitesi, SYA içeriği de dâhil olmak üzere birden fazla faktörden etkilenmektedir. Yağların yağ asidi profili, serbest yağ asidi düzeyi ve antioksidan kapasitesi, emülsiyonların Tiyobarbütirik Asit Reaktif Maddeleri (TBARS, Thiobarbituric Acid Reactive Substances) değerleriyle birlikte değerlendirilen önemli kalite göstergeleri arasında yer almaktadır. (Kampa vd., 2022). Doymamış yağ asitlerinin içeriği ve moleküldeki konumu, lipid oksidasyonunun hızını ve kapsamını belirleyen temel özelliklerdendir. Örneğin, triağılglicerol moleküllerinde yağ asitlerinin konumlanma biçimi, lipid oksidasyonunun ilerleme düzeyini ve oluşan bozunma ürünlerinin miktarını önemli ölçüde etkilemektedir (Golmakani vd., 2020). Farklı yağ oranlarının karıştırılması, yağ asidi profillerini değiştirerek ve biyoaktif lipidler ile doğal antioksidanların

bileşimini düzenleyerek yağların oksidatif stabilitesini iyileştirebilmektedir. (Bordón vd., 2019). Örneğin, yüksek linoleik asit içeriğine sahip Ayçiçek yağının, soğuk sıkılmış siyah kimyon, kimyon, kişniş ve karanfil yağları ile karıştırılması, Ayçiçek yağının tek başına kullanıldığı duruma kıyasla oksidatif stabilitesini artırmıştır. (Culler vd., 2021).

d. SYA' ların Oksidatif Bozulma Hızlandırması

Serbest yağ asitlerinin, yığın hâlindeki yağlarda oksidasyon sürecini hızlandırdığı bilinmektedir (Chaiyasit vd., 2008). SYA 'ların yüzey faaliyetlerinde, yığın yağlardaki kolloitlerin fizyokimyasal özellikleri değiştirilebilmektedir (Chaiyasit vd., 2008). Visseral yağda, baş ve rafine yağlara kıyasla asit değeri yaklaşık olarak iki kat daha yüksek bulunmuştur. Bu yüksek Asit değeri, işleme veya depolama sürecinde kolayca oksitlenebilen yüksek miktarda serbest yağ asitlerinin varlığını göstermektedir. (Ying vd., 2024).

Serbest yağ asitleri, emülsiyon damlacıklarını daha negatif yüklü hale getirerek lipid oksidasyonunu destekleyebilmektedir (Waraho vd., 2009). Orta ve uzun zincirli ($C \geq 10$) yağ asitlerinin sulu çözeltideki pKa değeri yaklaşık 4,8-5,0 arasında olup, bu özelliğin SYA'ların emülsiyonlardaki davranışını değiştirdiğini göstermektedir (Waraho vd., 2009).

e. Yasal Düzenlemeler ve Kalite Standartları

Bazı ülkelerde, yağların güvenli kullanım süresini belirlemek amacıyla yasal düzenlemeler veya rehber niteliğinde kalite standartları oluşturulmuştur. (Ying vd., 2024). Şili, Polonya, Belçika ve Avustralya gibi bölgelerde, mevcut yağlardaki SYA içeriğinin üst sınırı %2,5 olarak belirtilmiştir (Ying vd., 2024). Bu değer, gıda ürünlerinin güvenliğini sağlamak ve kalitesini korumak açısından kritik bir unsur olarak değerlendirilmektedir. (Ying vd., 2024). Bazı akademik yayınlarda ise bu sınırın %2 olduğu belirtilmektedir (Ying vd., 2024).

Depolama süresi boyunca peroksit değerleri artış göstermekte, özellikle kontrol grubu ve daha düşük antioksidan içerikli örneklerde bu artış daha belirgin görülmektedir (Mazı & Çoban Bayram, 2025). Yüksek antioksidan içerikli örnekler, daha düşük asit değeri ve SYA içeriği ile daha yüksek oksidatif stabilite göstermektedir (Mazı & Çoban Bayram, 2025).

SYA'lar, yağın görünümü ve oksidatif bozulma sürecinin kontrolü açısından kritik bir parametre olarak işlev görmektedir. SYA'ların yüksek kimyasal reaktivitesi, yağların oksidatif stabilitesini tehdit ederek kalite kaybına yol

açmaktadır. Yasal düzenlemeler ve endüstri standartları, SYA içeriğinin belirli sınırlar içerisinde tutulmasını zorunlu kılmaktadır. Yağların kalitesinin korunması ise, SYA düzeylerinin düzenli olarak izlenmesi ve oksidatif bozulmayı en aza indiren uygun depolama koşullarının sağlanmasıyla mümkün olmaktadır.

2.2.3 Toplam Polar Bileşikler (TPB):

TPB, tekrarlı kullanım sonucunda oluşan yağlarda biriken termal ve oksidatif bozunma toplamını ifade eder (Sanibal & Mancini-Filho, 2004; Ying vd., 2024). Bu modeller, yağın polaritesini artıran serbest yağ asitleri, mono- ve digliseritler, polimerize trigliseritler, aldehytler, ketonlar ve trigliseridlerin parçalanması sonucu oluşan diğer oksidatif türevleri içermektedir. (Crexi vd., 2010). Kızartma işlemi sırasında, triağılgliceroller hızlı bir şekilde hidroliz, oksidasyon, polimerizasyon ve piroliz reaksiyonlarına maruz kalır ve bu aralıklarda yüksek yoğunluklu, ağırlıklı ve polar bileşiklerin oluşumuna yol açar (Y. Gao vd., 2023).

2.2.3.1 TPB'nin Oluşum Mekanizmaları

a. Kimyasal Reaksiyonlar ve Bozunma Ürünleri

Kızartma işlemi sırasında, çeşitli reaksiyonlar sonucunda yüksek moleküler ağırlığa ve artmış polariteye sahip bileşikler oluşmaktadır (Furlan Gonçalves Dias vd., 2023). Bu süreç sonucunda, trigliserid oligomerleri, trigliserid dimerleri, oksitlenmiş trigliserid monomerleri, di- ve monogliseritler, serbest yağ asitleri, siklik ve epoksi bileşikleri gibi zararlı polar ve polimerik bileşiklerin oluşumu meydana gelmektedir. (Mazı & Çoban Bayram, 2025). Polar bileşikler, yağın başlangıçta apolar yapısından ayrıştıkça, yağın toplam polar madde içeriğinde bir artışa neden olmaktadır. (de Abreu vd., 2011).

b. Oksidatif ve Termal Bozulma ile İlişkisi

Polar bileşiklerin oluşumu, kızartma işlemi sırasında meydana gelen birincil ve ikincil oksidasyon ürünleriyle yakından ilişkilidir. (Ying vd., 2024). Toplam polar bileşik (TPB) seviyelerinde, kızartma işleminin tekrarlanmasıyla birlikte ardışık kullanım döngülerinde belirgin bir artış gözlenmektedir. (Dahl & Malcata, 1999). Bu artış, yüksek sıcaklıklarda gerçekleşen yoğun oksidasyon ve polimerizasyon reaksiyonları sonucunda oluşan çoklu bağ yapılarının ve trigliserid türevlerinin birikiminden kaynaklanmaktadır (Dahl & Malcata, 1999).

Araştırmalar, TPB içeriğinin kızartma işlemi süresince doğrusal bir artış eğilimi gösterdiğini ortaya koymuştur (Kampa vd., 2022).

c. Yağ Asidi Bileşimi ve TPB Oluşumu

Yağın linoleik asit içeriği, bileşim özellikleri, oksidatif stabilitesi ve kızartılmış gıdaların lezzet gelişimi açısından kritik faktörlerden biridir. (Golmakani vd., 2020). yüksek düzeyde çoklu doymamış yağ asitleri içeren yağlar, tekli doymamış yağ asitleri oranı daha düşük olan yağlara kıyasla polimerik bileşiklerin oluşumuna daha yüksek eğilim göstermektedir. (Dahl & Malcata, 1999). Örneğin, %6,8 linoleik asit (LA) içeren kanola yağı, %2,5 LA içeren kanola yağına kıyasla önemli ölçüde daha düşük oksidatif stabiliteye ve daha olumsuz duyuşsal özelliklere sahip olduğu bildirilmiştir (Bordón vd., 2019).

2.2.3.2 TPB'nin Yağ Kalitesinin Değerlendirilmesindeki Rolü

TPB izlenmesi, kızartma yağlarındaki bozulma düzeyinin belirlenmesinde en güvenilir göstergelerden biri olarak kabul edilmektedir (Culler vd., 2021). Kimyasal değişimler arasında, sıvı yağlardaki TPB belirlenmesi, en güvenilir ve en yaygın olarak kullanılan yöntem olarak kabul edilmektedir (Chaiyasit vd., 2008). TPB içeriği, sıvı yağların kalite düzeyinin değerlendirilmesinde en iyi göstergelerden biri ve en yaygın kullanılan kriterdir. (Y. Gao vd., 2023). SYA, peroksit değeri, renk ve viskozite gibi parametreler kızartma yağlarının kalite standartlarını göstermek için yaygın olarak kullanılsa da TPB içeriği, sıvı yağların kalitesinin değerlendirilmesinde en güvenilir kriter olarak kabul edilmektedir. (Waraho vd., 2009).

a. TPB ve Oksidatif Bozulma Arasındaki İlişki

TPB, oksidatif bozulmanın derecesinin dağılımı için temsili bir göstergedir (Karakaya & Şimşek, 2011). TPB değeri, bekletme sıcaklıklarında meydana gelen oksitlenmiş yağ asitlerinin oluşumunu açık bir şekilde yansıtmaktadır. (Zribi vd., 2016). Araştırmalar, Oksidatif Stabilite İndeksi (OSI) ile TPB içeriği arasında üstel bir ilişki bulunduğunu göstermiştir. Örneğin, patatesin kızartılması sürecinde sızma zeytinyağının performansını inceleyen bir çalışmada, bu ilişki $OSI = \exp^{[f_0]}(-0.103 \times TPB) + 2.73$ şeklinde tanımlanmış olup, oldukça yüksek bir belirleme katsayısı ($r^2 = 0,9724$) elde edilmiştir. (Warner & Laszlo, 2005).

b. Kızartılan Gıda Türünün Etkisi

Kızartılan gıda türü, yağlardaki bozulma düzeyini önemli ölçüde etkilemektedir. Tavuk eti kızartmak için kullanılan yağların, patates kızartması için kullanılan yağlara kıyasla her zaman daha yüksek asit değeri ve TPB içerdiği bildirilmiştir (Ben Hammouda vd., 2018). Tavuk, kızartma sırasında ortama yağ salarken; patates, kızartma işlemi süresince yağı absorbe etmektedir. Bu durum, tavuk kızartmada kullanılan yağların, patates kızartmasında kullanılanlara göre daha hızlı bozulmasının temel nedenlerinden biri olarak değerlendirilmektedir (Ben Hammouda vd., 2018).

Avrupa'nın birçok ülkesinde, sıvı yağlardaki TPB için kabul edilebilir sınır değerler %24 ile %27 aralığında belirlenmiştir (Y. Gao vd., 2023). TPB sınırı Almanya'da %24, İtalya ve Fransa'da %25, İsviçre ve Avusturya'da %27'dir (Y. Gao vd., 2023). Bununla birlikte, uluslararası düzenlemeler ve öneriler ülkeler arasında farklılık göstermektedir. Örneğin, Çin'de kızartma yağlarının kullanım dışı bırakılması gereken maksimum TPB sınırı %27 olarak belirlenmiştir. (Farhoosh & Moosavi, 2007). Japonya'da en düşük TPB sınırı %24'tür (Sanibal & Mancini-Filho, 2004). Bazı kaynaklarda, kızartma sıcaklıkları için TPB sınır değerinin %23–29 aralığında, toplam polimerizasyon bileşikleri için ise %12–15 aralığında belirlendiği bildirilmektedir. (Xu vd., 2021).

c. Atılma Kriterleri

TPB seviyeleri %25-27'yi aşan sıvı yağlarının atılması esastır (Chaiyasit vd., 2008). TPB içeriği %25'i aşan kızartma yağı, uluslararası kurallara göre atılmalıdır (Houhoula vd., 2003). Araştırmalar, TPB seviyeleri %24'e ulaştığında yağın termal olarak bozulmuş kabul edildiğini ve bu noktada taze yağ ile değiştirilmesi gerektiğini ortaya koymuştur. (Ying vd., 2024).

2.2.3.3 TPB Ölçüm Yöntemleri

a. Standart Analitik Yöntemler

Kızartma yağlarının veya sıvı yağların standart analizinde, TPB belirlenmesi için sütun kromatografisi (Column Chromatography, CC) yöntemi onaylanmış bir standart haline gelmiş olup, dünya genelinde yağ kalitesinin ve depolama koşullarının kontrolünde en güvenilir yöntemlerden biri olarak kabul edilmektedir. (Furlan Gonçaves Dias vd., 2023). Toplam polar bileşiklerin

belirlenmesi zahmetli ve maliyetli bir yöntemdir; bu nedenle, yağlardaki oksidatif bozulmayı daha kolay, hızlı ve ekonomik biçimde değerlendirmeye olanak tanıyan alternatif oksidasyon indekslerinin kullanılması yararlı olmaktadır. (Culler vd., 2021).

b. Hızlı Test Yöntemleri

Kızartma yağlarının hızlı değerlendirilmesi için çeşitli yöntemler geliştirilmiştir. Viscofrit®, İspanyol laboratuvarı *Seguridad Alimentaria* tarafından üretilen ve yağın viskozitesine dayanarak TPB içeriğinin %25'i aşıp aşmadığını belirlemeye yarayan hızlı test cihazı olarak kullanılmaktadır (Houhoula vd., 2003). Fri-Check®, yağların termooksidatif ve hidrolitik bozulma düzeyini belirlemeye olanak tanıyan hızlı bir test sistemidir. (Houhoula vd., 2003). Fourier Dönüşümlü Yakın Kızılötesi Spektroskopi (FT-NIR) yöntemiyle, TPB, asit değeri ve peroksit değeri belirlenmesinde uygun ve güvenilir sonuçlar elde edilmiştir (Kim vd., 2015). Görüntü analizi yönteminin kullanılmasıyla, kızartma yağlarında ve sıvı yağlarda polar bileşiklerin hızlı bir şekilde belirlenmesi mümkün hale gelmiştir. (Furlan Gonçalves Dias vd., 2023).

c. TPB'nin Sağlık Etkileri

Polar bileşikler, insan sağlığı açısından potansiyel olarak zararlı bileşenler olarak giderek daha fazla önem kazanmaktadır (Sharanke & Sivakanthan, 2022). Bu nedenle, TPB seviyeleri, kızartma yağlarının kullanımdan çekilmesi gereken zamanı belirlemede kritik bir gösterge olup, birçok ülkede yağ kullanım düzeyinin değerlendirilmesinde yaygın olarak kullanılmaktadır. (Sharanke & Sivakanthan, 2022).

TPB, kızartma yağlarının bozulma derecesini temsil eden genel bir gösterge olup, kızartma işlemleri sırasında yağın termal stabilitesini izlemek için en güvenilir parametrelerden biri olarak kabul edilmektedir. TPB seviyeleri, ardışık kızartma döngüleri boyunca doğrusal bir artış eğilimi göstermekte ve yağın oksidatif bozunma süreciyle güçlü bir ilişki sergilemektedir. Uluslararası standartlara göre, TPB içeriğinin %24–27 aralığında tutulması gerekmekte olup, bu sınırları aşan yağların kullanımdan çıkarılması önerilmektedir. Kızartma yağlarının kalitesinin korunması, TPB seviyelerinin düzenli olarak izlenmesi ve yasal düzenlemelere uygun depolama ve kullanım koşullarının sağlanmasıyla mümkün olmaktadır.

2.3 Deney Düzeni ve Örnek Toplama

Bu çalışmada, kızartma ortamı olarak Ayçiçek yağı kullanılmış, kızartma ürünü olarak ise dondurulmuş patates şeritleri tercih edilmiştir. Kızartma işlemleri, ev tipi termostatik elektrikli fritöz (Arnica Universal ZG 27A) kullanılarak gerçekleştirilmiştir. Fritözün maksimum yağ kapasitesi 2,5 litredir.

Derin yağda kızartma işlemi, yiyeceklerin genellikle 170°C ila 190°C arasında değişen sıcaklıklarda sıcak yağa daldırılmasıyla yapılmakta ve nispeten kısa pişirme süreleri gerektirmektedir. Bu çalışmada kızartma işlemi $180 \pm 5^\circ\text{C}$ sıcaklıkta gerçekleştirilmiştir. Kızartma yağı yedi gün boyunca toplam 56 kez kullanılmış ve her gün sekiz kızartma döngüsü uygulanmıştır.

Tutarlılığı sağlamak amacıyla, piyasada satılan $0,9 \times 0,9$ cm boyutlarındaki dondurulmuş patates şeritleri kullanılmıştır. Her kızartma işlemi, 100 ± 1 g patates örneğiyle yapılmıştır. Her döngü öncesinde yağ, 185°C'ye kadar önceden ısıtılmış ve bu sıcaklık yaklaşık 15 dakika boyunca sabit tutulmuştur. Patates örnekleri, istenen altın kahverengi renk ve gevrek doku elde edilene kadar yaklaşık 6–7 dakika süreyle kızartılmıştır.


Her kızartma döngüsünün ardından, bir sonraki işlem öncesinde yağın yaklaşık 90 dakika soğuması beklenmiştir. Bu nedenle, tek bir kızartma döngüsü yaklaşık iki saat sürmüş ve günlük kızartma işlemleri sürekli bir döngü halinde yaklaşık 16 saat boyunca gerçekleştirilmiştir. **Şekil 2.4**, günlük kızartma döngüsünü ve zaman içinde kızartma yağı kalitesinde meydana gelen değişimlerin değerlendirildiği deney düzenliğini göstermektedir.



Şekil 2.4 Deney ve Veri Toplama Ortamı

Kızartma işlemi 2,5 litre Ayçiçek yağı ile başlatılmıştır. Her günün sonunda, geleneksel analizler ve sensör ölçümleri için yağdan 150 mL’lik numuneler alınmıştır. Analizlerden önce herhangi bir kimyasal veya biyolojik değişimin önüne geçmek amacıyla, numuneler ışık geçirmeyen saklama kaplarına aktarılmış ve -20°C ’de muhafaza edilmiştir.

Şekil 2.5, yedi günlük kızartma yağı örneklerinden on farklı aşamada toplanan direnç değerlerinin, sırasıyla Sensör 4 ve Sensör 6 için grafiksel gösterimini sunmaktadır.



Şekil 2.5. Sensör 4 ve Sensör 6 dan on farklı aşamada toplanan direnç değerlerinin grafiksel Gösterimi

Kızartma işlemleri ve örneklemeler sırasında meydana gelen yağ hacmi kaybı, ertesi günün deneylerine başlamadan önce aynı şişeden 200 mL taze yağ eklenerek telafi edilmiştir. Yedi günün sonunda, kullanılmamış (taze) yağ da dahil olmak üzere toplam sekiz farklı yağ numunesi elde edilmiştir.

Elde edilen numuneler, -20°C 'deki depolama ortamından çıkarıldıktan sonra oda sıcaklığında dört saat boyunca çözülmeye bırakılmıştır. Oda koşullarına dengelendikten sonra, her numune ayrı bir Erlen Meyer şişesine aktarılmış ve detaylı analizler için hazır hâle getirilmiştir.

2.3.1 Sensör Ölçümleri

İlk olarak, analiz edilecek yağ numuneleri sensör ölçümleri için dikkatli bir şekilde Erlen Meyer şişelerine aktarılmıştır. Her bir şişe, numunenin alındığı günü ve yağın geçirdiği toplam kızartma döngüsü sayısını belirtmek üzere detaylı şekilde etiketlenmiştir. Bu etiketleme işlemi, ölçüm sürecinde karışıklığı önlemek ve her verinin doğru örnekle ilişkilendirilmesini sağlamak açısından kritik öneme sahiptir.



Şekil 2.6 Numune alım ve saklama işlemleri

Sensör ölçümlerinde kullanılan BME688 çoklu gaz sensör matrisi, ölçümden önce yaklaşık bir saat boyunca oda sıcaklığında çalıştırılarak stabilize edilmiştir. Bu ön ısınma (stabilizasyon) süreci, sensörlerin taban sinyal seviyelerinin dengelenmesi ve sensör çıkışlarında oluşabilecek sıcaklık kaynaklı dalgalanmaların en aza indirilmesi amacıyla uygulanmıştır. Sensörler kararlı duruma ulaştıktan sonra, her bir yağ numunesi için 30 dakika süreyle kesintisiz ölçüm yapılmıştır. Bu süre, hem sensörün gaz bileşenlerine adaptasyonunu

tamamlaması hem de UOB zamanla değişen tepkilerinin tam olarak kaydedilmesi için yeterli bir imkân sağlamaktadır. Numune alım ve saklama işlemleri **Şekil 2.6** da gösterilmiştir.

Her ölçüm seansının tamamlanmasının ardından, sensör matrisinin yüzeyinde veya sensör membranlarında önceki numuneden kalan UOB kalıntılarının ölçüm sonuçlarını etkilemesini önlemek amacıyla, sensör sistemi yaklaşık 30 dakika boyunca yalnızca ortam havasına maruz bırakılmıştır. Bu bekleme süresi boyunca sistem aktif modda çalıştırılmış, böylece sensör yüzeylerinin kendiliğinden temizlenmesi (self-purging) sağlanmıştır. Bu prosedür, özellikle farklı oksidasyon seviyelerine sahip yağ numuneleri arasında geçiş yapılırken sensör yanıtında olası çapraz etkileşimlerin önüne geçilmesi açısından önemli bir adımdır.

Tüm ölçüm süreci, numune hazırlığı, sensör stabilizasyonu, veri toplama ve sensör temizleme aşamaları dâhil olmak üzere yaklaşık 10 saat sürmüştür. Ölçümler sırasında sıcaklık ve nem gibi çevresel parametreler sabit tutulmuş, böylece sensör verilerinin yalnızca yağ numunelerinden kaynaklanan UOB bileşenlerine duyarlı olması sağlanmıştır.

Sensörlerden elde edilen ham veriler, deneyin sonraki aşamasında klasik laboratuvar analizleri olan SYA ve TPB den elde edilen sonuçlarla eşleştirilmiş ve YSA tabanlı bir model kullanılarak işlenmiştir. Bu işlem sonucunda, sensör ölçümlerinden elde edilen verilerin yağ kalitesinin bozulma düzeyiyle olan ilişkisi istatistiksel olarak değerlendirilmiş ve sistemin doğruluk ve tekrarlanabilirlik performansına katkı sağlanmıştır.

2.3.2 Geleneksel Analiz

Sensör ölçümlerinin tamamlanmasının ardından, yağ numuneleri geleneksel laboratuvar analizlerinin gerçekleştirilmesi amacıyla farklı bir laboratuvara aktarılmıştır. Bu aşama, sensör sistemlerinden elde edilen verilerin doğrulanması ve yağ kalitesine ilişkin kimyasal parametrelerin bağımsız olarak belirlenmesi açısından kritik bir önem taşımaktadır.

Bu laboratuvarında, her numune ayrı ayrı analiz edilerek SYA ve TPB değerleri belirlenmiştir. Elde edilen bu analiz sonuçları, kızartma yağlarının kimyasal bozulma düzeyinin değerlendirilmesi için referans veri sağlamış ve aynı zamanda sensör tabanlı ölçümlerle korelasyonun kurulmasına olanak tanımıştır.

Böylece, sensörlerin kimyasal açıdan güvenilirliğini değerlendirmek ve sensör sinyallerinin anlamlı bir şekilde yorumlanmasını sağlamak mümkün olmuştur.

2.3.2.1 Serbest Yağ Asidi (SYA) Analizi

Serbest yağ asidi yüzdesi, Resmî Analitik Kimyacılar Birliği (Association of Official Analytical Chemists (AOAC, 1940)) tarafından tanımlanan resmi analiz prosedürlerinden biri olan Yöntem No. 940.28 uyarınca alkali titrasyon yöntemi ile belirlenmiştir. Bu yöntemde, her bir yağ numunesi öncelikle etanol ve eter karışımından oluşan uygun bir çözücü sisteminde çözündürülmüştür. Bu çözücü sistem, yağ örneklerinin homojenleşmesini sağlamak ve serbest yağ asitlerinin nötralizasyon işlemini kolaylaştırmak amacıyla kullanılmıştır.

Ardından, çözünmüş yağ örnekleri sodyum hidroksit (NaOH) çözeltisiyle titrasyona tabi tutulmuştur. Titrasyon işlemi, çözelti içinde bulunan serbest yağ asitlerinin tamamen nötralize edilmesi sağlanana kadar sürdürülmüştür. Böylece, yağın içerdiği asidik bileşenlerin miktarı, kullanılan NaOH hacmi üzerinden hesaplanmıştır.

Elde edilen sonuçlar, oleik asit eşdeğerleri cinsinden yüzde (%) olarak ifade edilmiştir. Bu ifade biçimi, yağ kalitesinin uluslararası düzeyde karşılaştırılabilir olmasını sağlar ve SYA değerinin yağın hidrolitik bozunma derecesinin doğrudan bir göstergesi olarak değerlendirilmesine olanak tanır. Her bir numune üç kez (n=3) analiz edilmiştir ve bu analizlerden elde edilen sonuçların aritmetik ortalaması değerlendirilmede kullanılmıştır.

Bu yöntem, yağın kızartma işlemleri süresince maruz kaldığı hidrolitik bozulmanın derecesini yüksek doğrulukla ortaya koyar. Ayrıca, SYA değerinin belirli sınırların üzerine çıkması, yağın duyuşal, fizikokimyasal ve besin değeri açısından kullanılabilirliğini kaybettiğini göstermesi bakımından önemli bir kalite göstergesi olarak kabul edilmektedir.

2.3.2.2 Toplam Polar Bileşikler (TPB) Analizi

Kızartma yağlarının termal ve oksidatif bozulma seviyesini değerlendirmek amacıyla, TPB ölçümleri Miroil-Optifry Yağ Test Kiti (Miroil Division of Oil Process Systems, Inc., ABD) kullanılarak gerçekleştirilmiştir. Bu analiz, oda sıcaklığında (25°C) yapılmıştır. Ölçümden önce cihaz, TPM içeriği sıfır olarak kabul edilen taze ayçiçek yağı referans alınarak dikkatlice kalibre edilmiştir.

Kalibrasyon işlemi, cihazın sıfır noktasının doğru şekilde belirlenmesi ve ölçümlerde sistematik hata oluşmasının önlenmesi için gerçekleştirilmiştir.

Her numune için bağımsız olarak üç kez ölçüm yapılmış ve bu üç değer ortalaması alınarak nihai TPB değeri elde edilmiştir. Bu çoklu ölçüm yaklaşımı, veri güvenilirliğini artırmak ve olası cihaz veya operatör kaynaklı hataları azaltmak açısından önemlidir.

TPB değeri, yağda meydana gelen oksidatif ve termal bozunma süreçlerinin birikimsel etkilerini yansıtan bütüncül bir kalite göstergesidir. Bu bileşikler arasında oksitlenmiş monomerik trigliseridler, dimerize/polimerize trigliseridler ve serbest yağ asitleri gibi polar bileşenler yer alır. Dolayısıyla, TPB artışı yağın daha ileri derecede oksidasyona ve polimerizasyona maruz kaldığını göstermektedir.


Bu yöntem, kızartma süreci boyunca polar bileşiklerin birikimini nicel olarak izlemeye imkân sağlamış ve yağ kalitesinin genel değerlendirilmesinde güvenilir bir referans parametre olarak kullanılmıştır. Ayrıca, sensör sistemlerinden elde edilen verilerle karşılaştırıldığında, TPB değerleri sensör çıkışlarının kimyasal temelde doğrulanmasına önemli katkı sağlamıştır.

Sonuç olarak, SYA ve TPB analizlerinden elde edilen klasik laboratuvar verileri, sensör ölçümleriyle birlikte değerlendirilmiş; bu sayede, sensörlerin yağ bozulma seviyelerini tahmin etme doğruluğu ve makine öğrenimi tabanlı modellerin eğitim güvenilirliği güçlendirilmiştir.

3. BULGULAR

3.1 Sensör Veri Seti

Bu bölümde, gerçekleştirilen deneysel çalışmalar sonucunda elde edilen sensör verilerinin yapısı, kapsamı ve istatistiksel özellikleri ayrıntılı biçimde sunulmaktadır. Deneysel ölçümler sonunda oluşturulan veri kümesi, literatürde doğrudan bir benzeri bulunmayan, özgün ve alana özel nitelikte bir veri setidir. Bu özgünlük, çalışmanın hem bilimsel hem de uygulamalı yönünü güçlendirmekte, aynı zamanda gelecekte benzer sistemlerin geliştirilmesi için referans niteliğinde bir kaynak sağlamaktadır.



Şekil 3.1 Sensör 4 ve Sensör 6 tarafından toplanan çevresel direnç verilerinin grafiksel dağılımı

Şekil 3.1, ölçüm süreci boyunca Sensör 4 ve Sensör 6 tarafından toplanan çevresel direnç verilerinin grafiksel dağılımını göstermektedir. Bu grafiklerde,

BME688 sensör matrisinden elde edilen veriler, sıcaklık modülasyonuna bağlı olarak zamana göre değişim göstermektedir. Grafikte, varsayımsal bir dikey çizgi herhangi bir anda on farklı noktayı kesmektedir. Bu on nokta, belirli bir anda tek bir numuneye ait “dijital koku parmak izi” ni temsil etmektedir. Diğer bir ifadeyle, bu ölçüm noktaları sensörün o andaki ortamdaki uçucu organik bileşik karışımına verdiği özgün tepkileri göstermekte ve her biri kimyasal bileşim açısından benzersiz bir barkod veya QR kod işlevi görmektedir.

Ölçümler incelendiğinde, kıztartma döngülerinin sayısı arttıkça sensörün gaz konsantrasyonuna verdiği direnç tepkisinin kademeli olarak azaldığı gözlenmiştir. Bu durum, kıztartma işlemi ilerledikçe yağın oksidatif bozulmaya uğradığını ve UOB profilinin değiştiğini göstermektedir. Dolayısıyla bu bilgi, kıztartma yağı kalitesinin bozulma dinamiklerinin izlenmesi ve sınıflandırılması açısından oldukça değerlidir. Veri setini oluşturan sensör verilerinin tipik bir örneği **Tablo 3.1** verilmiştir.

Tablo 3.1 Veri setini oluşturan sensör verilerinin tipik bir örneği

Sensor indexi	Sıcaklık	Basınç	Bağıl Nem	Gaz Sensör Direnci
2.0	23.146	913.731	42.016	75294.117
3.0	22.924	913.633	42.354	22980.252
2.0	23.146	913.793	41.92	925440.562
3.0	22.934	913.706	42.265	199921.906
2.0	23.557	913.801	41.27	913062.875
3.0	23.342	913.692	41.571	203740.547
4.0	24.795	913.825	40.67	73163.758
5.0	24.576	913.666	40.673	29705.268
4.0	24.562	913.836	40.423	26744.672
5.0	24.34	913.687	40.399	11367.673

Bu çalışmada elde edilen sensör verileri, önceden belirlenmiş klasik analiz sonuçları (SYA ve TPB) referans alınarak etiketlenmiştir. Bu etiketleme sürecinde, ölçüm verileri dört ayrı sınıfa ayrılmıştır. Her bir sınıf, iki ardışık güne karşılık gelen ölçümlerden oluşacak şekilde gruplandırılmıştır. Böylelikle sensör verileri, kıztartma sürecinin ilerleyen günlerinde meydana gelen fizikokimyasal değişimleri zamansal olarak temsil edebilmiştir.

Oluşturulan nihai veri seti, toplam 6.418 döngü ve 64.180 veri noktasından meydana gelmektedir. Her bir örnek, 800 ila 804 veri döngüsü içermektedir. Buna karşılık, her sınıf yaklaşık 1.600 ila 1.606 döngü barındırmaktadır. Bu düzenleme, veri kümesinde her sınıfın homojen biçimde temsil edilmesini sağlamış ve makine öğrenimi algoritmalarında dengesiz veri kaynaklı yanlışlıkların önüne geçilmiştir.

Ayrıca bu yapı, modellerin daha kararlı bir şekilde eğitilmesine olanak tanımış ve sınıflar arası ayırım gücünü artırmıştır. Böylelikle, eğitilen modellerin genelleme performansı yükselmiş ve farklı senaryolarda daha güvenilir sonuçlar üretmesi sağlanmıştır.

Tablo 3.2 Yağ numunelerine ilişkin kızartma döngüsü, etiketler ve sınıf tanımları

Örnek (kızartma sayısı)	Döngü Sayısı	Veri Noktası	Etiket	Sınıf Tanımı
Gün 0 (0)	802	8020	Mükemmel	Yağ taze, berrak ve kimyasal olarak stabildir; güvenlik açısından herhangi bir sorun olmadan uzun süre kızartmada kullanılmaya uygundur.
Gün 1 (8)	804	8040		
Gün 2 (16)	803	8030	Kabul Edilebilir	Yağ hafif kullanım belirtileri göstermektedir ancak kızartma için kabul edilebilir kalite ve güvenlik sınırları içinde kalmaktadır.
Gün 3 (24)	800	8000		
Gün 4 (32)	802	8020	Düşük Kalite	Yağ önemli ölçüde bozulmuştur; hâlâ kullanılabilir olsa da kalitesi düşmüştür ve tekrar tekrar kullanılması önerilmez.
Gün 5 (40)	801	8010		
Gün 6 (48)	804	8040	Güvenli Değil	Yağ yüksek derecede bozulmuş veya oksitlenmiştir, zararlı bileşikler içermektedir ve artık tüketim veya kullanım için güvenli değildir.
Gün 7 (56)	802	8020		

Tablo 3.2, veri setinin temel istatistiksel özelliklerini özetlemekte olup, her bir sınıfa ait döngü sayısı ve etiket bilgilerini içermektedir. Sensör tabanlı veri toplama sistemlerinde, çevresel değişkenler veya donanım kaynaklı sorunlar nedeniyle zaman zaman eksik veya bozuk veri değerleriyle karşılaşılabilir. Bu tür eksiklikler genellikle sensör kararsızlığı, iletişim hataları veya ortam koşullarındaki ani değişimler nedeniyle ortaya çıkmaktadır.

Ancak, bu çalışmada oluşturulan veri setinde yalnızca %0,1 gibi ihmal edilebilir düzeyde bir veri kaybı oranı gözlenmiştir. Bu oran, istatistiksel olarak önemsiz kabul edilmekte olup analizlerin güvenilirliğini ve model performansını etkilemeyecek düzeydedir. Böylelikle, sensör sisteminin kararlılığı ve veri toplama sürecinin güvenilirliği doğrulanmıştır.

Veri seti, BME688 sensörlerinden elde edilen ölçümlerden türetilmiş 13 sütundan oluşmaktadır. Bu sütunlar; sıcaklık, basınç, bağıl nem, gaz sensörü direnci gibi çevresel parametrelerin yanı sıra, sensör kimlik bilgileri, zaman damgaları ve sistemin çalışma durumunu tanımlayan kontrol değişkenlerini içermektedir. Bu çok boyutlu yapı, veri setinin yalnızca fiziksel ölçüm koşullarını değil, aynı zamanda sistemin içsel dinamiklerini ve ölçüm bağlamını da yansıtmayı sağlamaktadır.

Bu kapsamlı veri yapısı sayesinde, makine öğrenimi algoritmalarının çoklu değişkenler arasındaki ilişkiyi öğrenmesi kolaylaştırılmış ve yağ bozulma seviyesinin sensör tabanlı olarak sınıflandırılmasına yönelik daha güvenilir modellerin oluşturulmasına olanak tanınmıştır.


3.2 Eşleştirme Süreci

Sensör tabanlı ölçüm sistemlerinde, ham veriler çoğunlukla ortamda bulunan gazların kimyasal bileşiminden kaynaklanan elektriksel direnç değişimlerine dayanır. Bu direnç değişimleri, sensör yüzeyinde gerçekleşen adsorpsiyon ve desorpsiyon süreçleri sonucunda ortaya çıkar. Ancak, bu ham sinyaller tek başına kızartma yağının kimyasal kalitesi veya bozulma derecesi hakkında doğrudan bir yorum yapılmasına olanak sağlamaz. Başka bir deyişle, sensör çıktıları yalnızca elektriksel bir yanıtı temsil etmekte, fakat bu yanıtın kimyasal anlamını ortaya koyabilmek için uygun bir referans sistemine ihtiyaç duyulmaktadır.

Bu nedenle, bu çalışmanın en önemli katkılarından biri, sensör verilerinin klasik laboratuvar parametreleriyle sistematik olarak eşleştirilmesi olmuştur. Bu yaklaşım, sensör verilerinin yalnızca sayısal bir ölçüm olmaktan çıkıp kimyasal açıdan anlamlandırılmış bir veri formuna dönüşmesini sağlamıştır. Özellikle, sensör çıktıları literatürde yağ kalitesi, tazelik ve kullanılabilirlik açısından en güvenilir göstergeler olarak kabul edilen serbest yağ asidi ve toplam polar bileşik değerleriyle ilişkilendirilmiştir.

Bu eşleştirme işlemi, sensör tabanlı ölçümlerin klasik analizlerle karşılaştırılmasına olanak tanıyarak, sensör verilerinin doğrulanmasını ve anlamlandırılmasını mümkün kılmıştır. Böylece elde edilen sonuçlar, yalnızca istatistiksel olarak değil, aynı zamanda kimyasal açıdan da geçerli ve güvenilir hale getirilmiştir.

3.2.1 SYA Değerleri ile Sensör Verilerinin Eşleştirilmesi




Şekil 3.2. IP-501 ile donatılmış ilk sensör (Sensör 3) tarafından elde edilen direnç verilerinin, serbest yağ asidi (% oleik asit) değerleriyle ilişkilendirilmesi

Şekil 3.2 de, her bir yağ numunesi için belirlenen SYA değerlerinin, aynı güne ait ortalama sensör direnç okumalarıyla eşleştirilmiş hali sunulmaktadır. Bu grafik, kızartma sürecinin ilerlemesiyle birlikte yağdaki bozulma ürünlerinin artışına paralel olarak sensör tepkilerinde gözlenen değişimi net biçimde ortaya koymaktadır.

Eşleştirme sonucunda, sensörlerden elde edilen direnç değerlerinin SYA değerleri arttıkça azaldığı gözlenmiştir. Bu durum, sensör yüzeyine temas eden UOB konsantrasyonunun, yağın oksidasyon düzeyiyle birlikte değiştiğini göstermektedir. Başka bir ifadeyle, serbest yağ asidi oranı yükseldikçe, ortamdaki polar bileşik yoğunluğu artmakta ve bu da sensörlerin elektriksel iletkenlik tepkisini azaltmaktadır.

Özellikle beşinci güne gelindiğinde hem SYA analiz sonuçlarında hem de sensör verilerinde yağın bozulma hızında belirgin bir artış saptanmıştır. Bu nokta, kızartma sürecinde kritik bir eşik olarak değerlendirilmiştir; çünkü hem kimyasal analizler hem de sensör ölçümleri bu aşamada yağın kullanılabilirliğinin önemli ölçüde azaldığını göstermiştir. Bu durum, sensör sisteminin kızartma yağındaki erken bozulma belirtilerini algılayabildiğini ve dolayısıyla proaktif bir izleme aracı olarak kullanılabileceğini doğrulamaktadır.

3.2.2 TPB Değerleri ile Sensör Verilerinin Eşleştirilmesi



Şekil 3.3. IP-301 (S1) sensörüyle donatılmış ilk ölçüm biriminden elde edilen direnç değerleri, Toplam Polar Madde (%TPM) ölçümleriyle ilişkilendirilmesi

Şekil 3.3 de, her bir yağ numunesi için belirlenen TPB değerleri, aynı döneme ait günlük ortalama sensör verileriyle eşleştirilmiştir. Bu eşleştirme, sensör verilerinin yorumlanmasında TPB' ye dayalı bir referans çerçevesi oluşturmayı mümkün kılmıştır.

TPB, kızartma yağının termal oksidasyon ve polimerizasyon süreçlerinin birikimsel etkilerini yansıtan bir göstergedir. Dolayısıyla TPB' nin artışı, yağın bozulma seviyesinin ilerlediğini gösterirken; sensörlerde gözlenen direnç düşüşü bu kimyasal değişimlerin gaz fazındaki yansımalarını temsil etmektedir.

Eşleştirme grafiğinde de görüldüğü üzere, SYA analizlerinde gözlemlenen eğilim burada da devam etmektedir. Yani, kızartma işlemi ilerledikçe ortam gaz kompozisyonundaki değişim sensörlerin ölçtüğü elektriksel direnç değerlerinin azalmasına neden olmakta, buna karşılık TPB değerleri artış göstermektedir.

Bu karşıt yönlü eğilim, sensör verilerinin yağ kalitesiyle güçlü bir korelasyon taşıdığını ve sistemin kimyasal bozulmayı sayısal veriye dönüştürebildiğini göstermektedir. Böylece, sensör sisteminden elde edilen veriler, yalnızca trend analizi değil, aynı zamanda yağ değişim zamanı veya kalite kontrol kararı gibi pratik uygulamalarda da kullanılabilir hale gelmiştir.

3.2.3 Eşleştirme Sürecinin Bilimsel Önemi

Bu eşleştirme stratejisi, sensör tabanlı izleme sistemlerinin klasik laboratuvar analizleriyle doğrulanabilir bir bağ kurmasını sağlamıştır. Ölçülen SYA

ve TPB deęerleriyle sensör verilerinin aynı zaman aralığında analiz edilmesi, sistemin zaman senkronizasyonu ve veri bütünlüğünü korumuştur. Ayrıca bu yaklaşım, sensör verilerinin yalnızca istatistiksel bir model girdisi olarak deęil, kimyasal geçerlilięi olan bir parametre olarak deęerlendirilmesini mümkün kılmıştır.

Sonuç olarak, bu çalışmada geliştirilen eşleştirme süreci, yağ bozulma süreçlerinin sensör tabanlı izlenmesine yönelik önemli bir metodolojik yenilik sunmaktadır. Elde edilen sonuçlar, sensör sisteminin laboratuvar düzeyinde doğruluęa yakın ölçümler yapabildiğini ve SYA ile TPB gibi kalite göstergeleriyle yüksek korelasyon gösterdiğini ortaya koymuştur. Bu durum, sistemin gelecekte hem endüstriyel üretim hatlarında hem de ev tipi akıllı kızartma cihazlarında uygulanabilirliğini desteklemektedir.

3.3 Yapay Sinir Aęı (YSA)

Bu çalışmada, veri toplama sürecinde önceden etiketlenmiş sınıflara karşılık gelen hedef gaz konsantrasyonlarını tahmin etmek amacıyla (YSA) algoritması kullanılmıştır (Rumelhart vd., 1986). Yapay sinir aęları, insan beynindeki sinir hücrelerinin çalışma prensibine göre tasarlanmış, öğrenebilen hesaplama modelleridir. Bu sistemler, verileri analiz ederek yeni durumları tahmin edebilir ve sınıflandırabilir.

Yapay sinir aęları, makine öğrenmesi ve derin öğrenme alanlarının temel bileşenlerinden biri olarak, özellikle doğrusal olmayan, çok deęişkenli ve karmaşık veri yapılarının modellenmesinde üstün performans göstermektedir. Geleneksel istatistiksel yöntemler genellikle deęişkenler arasında doğrusal bir ilişki varsayar; oysa YSA modelleri bu sınırlamayı ortadan kaldırarak verilerdeki gizli, yüksek boyutlu bağıntıları öğrenebilme kapasitesine sahiptir. Bu özellik, çevresel sensörlerden elde edilen karmaşık gaz tepkilerinin deęerlendirilmesinde YSA' yı son derece uygun bir yöntem haline getirmektedir.

Tipik bir YSA modeli, Giriş Katmanı (Input Layer), bir veya birden fazla Gizli Katman (Hidden Layers) ve bir Çıkış Katmanı (Output Layer) olmak üzere üç temel bileşenden oluşur.

Giriş Katmanı, dış çevreden gelen veri akışını temsil eder ve her bir sensör ölçümü ya da bağımsız deęişken bu katmanda bir nöron aracılığıyla aęa aktarılır.

Gizli Katmanlar, modelin öğrenme gücünü belirleyen bölümlerdir. Bu katmanlarda yer alan nöronlar, giriş verilerini ağırlık katsayıları ve aktivasyon fonksiyonları aracılığıyla işleyerek, girdiler arasındaki karmaşık ilişkileri ortaya çıkarır.

Çıkış Katmanı ise, ağıın öğrenme süreci sonunda ürettiği tahminleri veya sınıflandırma sonuçlarını temsil eder. Bu katmandan elde edilen değerler, modelin hedef değişkenleriyle karşılaştırılarak doğruluk değerlendirmesi yapılır.

Her bir yapay nöron, kendisine bağlı önceki katmandan aldığı girdileri ağırlık (weight) parametreleriyle çarpar, elde edilen toplam değere bir ön yargı (bias) terimi ekler ve bu sonucu bir aktivasyon fonksiyonundan geçirir. Aktivasyon fonksiyonları, ağıın doğrusal olmayan ilişkileri öğrenebilmesini sağlar ve modelin esnekliğini artırır. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında sigmoid, tanjant hiperbolik (tanh), ReLU (Rectified Linear Unit) ve Softmax fonksiyonları yer almaktadır. Bu fonksiyonlar, ağıın hangi girdilere duyarlı olacağını ve hangi koşullarda çıktı üreteceğini belirleyen temel matematiksel mekanizmalardır.

YSA' da öğrenme süreci, geri yayılım (backpropagation) algoritması temelinde yürütülür. Bu süreçte, modelin tahmin ettiği değer ile gerçek hedef değer arasındaki fark, yani hata (loss) değeri hesaplanır. Daha sonra bu hata, türev tabanlı bir optimizasyon yöntemi aracılığıyla ağıın ağırlıklarına geriye doğru iletilir. Böylelikle model, her yinelemede (epoch) hatayı azaltacak yönde ağırlıklarını günceller. Bu iteratif süreç, ağıın zamanla verilerdeki örüntüleri öğrenmesine ve yeni girdiler karşısında doğru tahminler yapabilmesine olanak tanır.

Yapay sinir ağlarının en önemli avantajı, karmaşık doğrusal olmayan fonksiyonları modelleyebilme, çok boyutlu verilerdeki gizli ilişkileri keşfedebilme ve yüksek tahmin doğruluğuna ulaşabilme kapasitesidir. Ayrıca YSA' lar, çok sayıda giriş ve çıkışı aynı anda işleyebilme özellikleri sayesinde, özellikle çevresel sensörlerden elde edilen yoğun ve zaman serisi biçimindeki verilerin analizinde etkili bir yöntem sunar.

Bununla birlikte, YSA' ların uygulanmasında bazı sınırlılıklar da bulunmaktadır. Yüksek doğrulukta sonuçlar elde edebilmek için büyük miktarda etiketlenmiş veri gereksinimi, modelin eğitim sürecinin uzun sürmesi ve öğrenme sürecinin yüksek hesaplama gücü gerektirmesi, yapay sinir ağlarının pratikte karşılaştığı temel zorluklardır. Ayrıca, ağıın içsel karar verme sürecinin doğrudan

gözlemlenememesi nedeniyle yorumlana bilirlık düzeyi düşüktür; bu durum, YSA modellerinin sıklıkla “kara kutu (black box)” yapılar olarak nitelendirilmesine neden olmaktadır.

Tüm bu sınırlılıklara karşın, YSA tabanlı modeller son yıllarda çok geniş bir uygulama yelpazesinde başarıyla kullanılmaktadır. Görüntü işleme, doğal dil işleme, ses tanıma, biyomedikal sinyal analizi, finansal tahminleme ve endüstriyel sistem kontrolü gibi birçok alanda, YSA temelli yaklaşımlar geleneksel algoritmalara kıyasla daha yüksek doğruluk ve genelleme kabiliyeti sergilemiştir. Özellikle çevresel sensör sistemlerinden elde edilen gaz ölçümlerinin analizi ve sınıflandırılması gibi problemlerde, YSA modelleri verilerdeki karmaşık kimyasal örüntüleri öğrenerek gaz bileşimlerinin nicel ve nitel tespitinde güvenilir bir alternatif sunmaktadır.

Bu bağlamda, bu çalışmada kullanılan Yapay Sinir Ağı modeli de benzer biçimde tasarlanmış ve BME688 sensörlerinden elde edilen çok boyutlu veriler üzerinde eğitilmiştir. Model, sensörlerin gaz bileşimine verdiği direnç temelli elektriksel tepkileri girdi olarak almış; bu girdileri, deneysel olarak belirlenen yağ kalite sınıflarıyla ilişkilendirerek sistemin yağ kullanılabilirliğini sınıflandırmasına olanak tanımıştır. Böylece, sensör tabanlı sistemlerden elde edilen veriler, YSA aracılığıyla dijital bir karar mekanizmasına dönüştürülmüş ve insan gözünün ayırt edemeyeceği düzeydeki kimyasal değişimlerin bile yüksek doğrulukla tespit edilmesi mümkün hale gelmiştir.

YSA’ nın bu çalışmadaki kullanımı, yalnızca bir sınıflandırma aracı olarak değil, aynı zamanda gıda kalite izleme sistemlerinin geleceği açısından bilişsel bir model olarak değerlendirilebilir. YSA, verileri doğrudan deneysel örüntüler üzerinden öğrenerek, çevresel koşullardaki değişkenliğe uyum sağlayan bir yapı sunar. Bu özellik, sensör tabanlı ölçüm sistemlerinde esneklik, hız ve maliyet etkinliği açısından önemli bir avantaj sağlar.

Bu bakımdan, bu araştırmada kullanılan Yapay Sinir Ağı modeli, sensör verilerinin işlenmesi, analiz edilmesi ve kimyasal parametrelerle ilişkilendirilmesi sürecinde merkezi bir öğrenme bileşeni olarak konumlandırılmıştır. YSA’ nın sahip olduğu örüntü tanıma yeteneği, sistemin kızartma yağının kimyasal bozulma düzeyini doğru ve tutarlı biçimde değerlendirmesini sağlamıştır; bu yönüyle yapay zekâ tabanlı gıda kalite sınıflandırma yaklaşımlarının uygulanabilirliğine güçlü bir örnek teşkil etmektedir.

3.4 Hiper parametre seçimi

Makine öğrenmesi modellerinde hiperparametreler, modelin öğrenme sürecini, kapasitesini ve mimarisini doğrudan etkileyen, eğitim öncesinde belirlenen ve verilerden öğrenilmeyen sabit ayarlardır. Bu parametreler, modelin yakınsama hızı (convergence rate), genelleme yeteneği (generalization ability) ve eğitim istikrarı üzerinde belirleyici bir role sahiptir. Özellikle YSA gibi çok katmanlı ve doğrusal olmayan modellerde, hiperparametrelerin doğru şekilde yapılandırılması, ağın hem öğrenme başarımını hem de doğruluk düzeyini önemli ölçüde etkilemektedir. Bu nedenle hiperparametre seçimi, modelin geliştirilmesi sürecinde yalnızca teknik bir ayar değil, aynı zamanda modelin bilişsel performansını şekillendiren kritik bir optimizasyon adımı olarak değerlendirilmiştir.

Bu çalışmada geliştirilen YSA modeli için hiperparametreler, literatürde önerilen genel ilkeler dikkate alınarak ve deneysel testler aracılığıyla sistematik biçimde yapılandırılmıştır. Modelin doğruluk oranı, öğrenme hızı ve genelleme kabiliyeti arasında optimum bir denge kurabilmek amacıyla çeşitli kombinasyonlar denenmiş, her deneme sonucunda ağın eğitim ve doğrulama hataları izlenerek parametreler kademeli biçimde iyileştirilmiştir.

3.4.1 Veri Setinin Ayrımı ve Eğitim Stratejisi

Modelin performansının güvenilir biçimde değerlendirilebilmesi için, veri seti rastgele olacak şekilde %70 eğitim (training) ve %30 test (testing) alt kümelerine ayrılmıştır. Bu oran, hem ağın yeterli miktarda veri üzerinden öğrenmesini hem de yeni ve daha önce görülmemiş veriler üzerinde genelleme yeteneğinin sınanmasını sağlamaktadır. Eğitim alt kümesi, modelin ağırlık parametrelerinin güncellenmesinde kullanılırken, test alt kümesi modelin nihai başarısını ölçmek amacıyla yalnızca değerlendirme aşamasında kullanılmıştır.

Eğitim sürecinin verimliliğini artırmak ve hesaplama maliyetini dengelemek amacıyla mini-batch gradyan inişi (mini-batch gradient descent) yaklaşımı tercih edilmiştir. Bu yöntem, her bir öğrenme adımında tüm veri setini veya tekil örnekleri değil, belirli büyüklükteki veri alt gruplarını (batch) işler. Böylece hem Stokastik Gradyan İnişi yöntemine kıyasla daha kararlı bir güncelleme sağlar hem de tam gradyan inişi (batch gradient descent) yöntemine göre daha az hesaplama yükü oluşturur.

Bu bağlamda, toplu iş boyutu 64 olarak belirlenmiştir. Bu değer, öğrenme sürecinde modelin ağırlıklarının yeterince sık güncellenmesini sağlarken, eğitim sırasında oluşabilecek aşırı gürültülü gradyan değişimlerini de dengelemiştir. Ayrıca, modelin parametrelerinin yeterli düzeyde optimize edilebilmesi ve karmaşık örüntüleri öğrenebilmesi için 256 devir (epoch) süresince eğitim yapılmıştır. Devir sayısının bu düzeyde tutulması, modelin bir yandan veri setindeki istatistiksel örüntüleri kapsamlı biçimde öğrenmesini, diğer yandan aşırı uyum (overfitting) riskinin kontrol altında tutulmasını sağlamıştır.

Bu yapılandırma, modelin hem yakınsama kararlılığını koruyacak hem de derin özellik çıkarım (deep feature extraction) yeteneğini sürdürecektir. Her döngü sonunda elde edilen eğitim ve doğrulama hataları izlenmiş, parametrelerde anormal dalgalanmalar veya kayıplarda aşırı düşüş gözlemlendiğinde, erken durdurma (early stopping) mekanizmaları uygulanarak modelin aşırı öğrenmesi önlenmiştir.

3.4.2 Çapraz Doğrulama Yaklaşımı

Modelin aşırı uyum eğilimini azaltmak, hiperparametre konfigürasyonlarının genelleme performansını değerlendirmek ve modelin güvenilirliğini artırmak amacıyla, yalnızca eğitim veri seti üzerinde beş katlı çapraz doğrulama (5-fold cross-validation) yöntemi uygulanmıştır.

Bu yöntemde, eğitim verisi beş eşit alt kümeye bölünmüştür. Her yinelemede, bu alt kümelerden biri doğrulama (validation) seti olarak kullanılırken, geri kalan dört küme eğitim (training) için kullanılmıştır. İşlem beş kez tekrarlanmış, her bir alt küme tam olarak bir kez doğrulama kümesi olarak görev almıştır. Böylelikle model, farklı veri alt bölümlerinde eğitilmiş ve değerlendirilmiş; sonuçta her katman için ayrı doğruluk skorları elde edilmiştir. Bu yaklaşımla, modelin yalnızca belirli bir veri alt kümesine özgü öğrenmesi önlenmiş ve performansın istatistiksel olarak daha sağlam ve güvenilir biçimde ölçülmesi sağlanmıştır.

Çapraz doğrulama süreci, yalnızca modelin eğitim performansını değil, aynı zamanda hiperparametrelerin uygunluğunu da değerlendirmek için kullanılmıştır. Her bir çapraz doğrulama döngüsünde, öğrenme oranı, tekrar sayısı, veri yığını boyutu ve aktivasyon fonksiyonları gibi hiperparametre kombinasyonları yeniden test edilmiştir. Elde edilen doğruluk ve kayıp (loss) değerlerinin varyansı analiz

edilerek, modelin kararlılığı ve hiperparametre ayarlarının genelleştirilebilirliği nicel olarak değerlendirilmiştir.

Bu yöntem sayesinde, modelin doğrulama hatasının belirli bir veri alt kümesine özgü biçimde düşük çıkması engellenmiş, modelin performansı veri setinin tamamında tutarlı bir şekilde yüksek tutulmuştur.

3.4.3 Nihai Değerlendirme Süreci

Çapraz doğrulama prosedürünün tamamlanmasının ardından, modelin nihai versiyonu görülmemiş (unseen) veriler üzerinde test edilmiştir. Bu amaçla ayrılan %30'luk test veri seti, eğitim veya doğrulama sürecinin hiçbir aşamasında kullanılmamış olup, yalnızca nihai model performansının bağımsız bir ölçümünü sağlamak için kullanılmıştır.

Bu aşamada yapılan değerlendirmeler, modelin gerçek dünyadaki tahmin kabiliyetini temsil eden objektif performans göstergelerini ortaya koymuştur. Elde edilen sonuçlar, modelin yalnızca eğitim verilerine değil, aynı zamanda yeni veriler karşısında da yüksek doğruluk ve kararlılık sergilediğini göstermiştir.

Ayrıca, hiperparametrelerin seçimi ve değerlendirilmesi süreci boyunca kullanılan sistematik yöntem, modelin genelleme kabiliyetini artırmış, yakınsama hızını stabilize etmiş ve eğitim sürecinde enerji/hesaplama maliyetlerini azaltmıştır. Böylelikle, hem yapay sinir ağının içsel parametreleri arasında tutarlı bir etkileşim sağlanmış hem de modelin sensör verileriyle kimyasal analiz sonuçlarını başarılı biçimde eşleştirme kapasitesi güçlendirilmiştir.

Sonuç olarak, bu çalışmada uygulanan hiperparametre optimizasyonu yaklaşımı, dengeli bir öğrenme–genelleme ilişkisi kurarak modelin performansını en üst düzeye çıkarmıştır. Uygulanan mini-batch gradyan inişi, beş katlı çapraz doğrulama ve bağımsız test stratejisi birlikte değerlendirildiğinde, oluşturulan YSA modelinin yüksek güvenilirlik, istatistiksel sağlamlık ve öngörü gücü sunduğu açıkça görülmüştür.

3.5 Karışıklık Matrisi

Bu çalışmada geliştirilen YSA modelleri, her bir Isıtıcı Profili için bağımsız biçimde eğitilmiş ve her modelin sınıflandırma performansı ayrı ayrı değerlendirilmiştir. Bu yaklaşım, sensör tabanlı verilerin farklı ısıtma koşullarına

karşı gösterdiği tepkisel varyasyonların istatistiksel olarak incelenebilmesini ve her profilin sınıflandırma doğruluğu üzerindeki etkisinin belirlenmesini sağlamıştır.

Her modelin sınıflandırma başarımını sayısal olarak ifade edebilmek amacıyla, literatürde sınıflandırma problemleri için standart bir değerlendirme aracı olarak kabul edilen karışıklık matrisi (Confusion Matrix) yöntemi kullanılmıştır. Karışıklık matrisi, tahmin edilen sınıf etiketleri ile gerçek sınıf etiketleri arasındaki ilişkiyi görselleştirir ve modelin hangi örnekleri doğru, hangilerini hatalı sınıflandırdığını açık biçimde ortaya koyar. Bu yapı sayesinde modelin yalnızca genel doğruluk düzeyi değil, aynı zamanda hata türlerinin niteliği ve dağılımı da detaylı biçimde analiz edilebilmektedir.

		Tahmin Edilen Değer	
		Pozitif	Negatif
Güncel Değer	Pozitif	Doğru Pozitif (DP / TP)	Yanlış Negatif (YN / FN)
	Negatif	Yanlış Pozitif (YP / FP)	Doğru Negatif (DN / TN)

Şekil 3.4. Sınıflandırma için kullanılan karışıklık matrisi (Sokolova & Lapalme, 2009 den uyarlanmıştır)

Şekil 3.4 de gösterildiği üzere, karışıklık matrisi dört temel bileşenden oluşur:

- **Doğru Pozitif (True Positive, TP):** Pozitif sınıfa ait bir örneğin doğru biçimde pozitif olarak tahmin edilmesi.
- **Doğru Negatif (True Negative, TN):** Negatif sınıfa ait bir örneğin doğru biçimde negatif olarak sınıflandırılması.
- **Yanlış Pozitif (False Positive, FP):** Negatif bir örneğin hatalı olarak pozitif sınıfa atanması (Tip I hata).
- **Yanlış Negatif (False Negative, FN):** Pozitif bir örneğin yanlışlıkla negatif olarak etiketlenmesi (Tip II hata).

Bu dört bileşen, modelin karar mekanizmasını nicel olarak açıklayan temel yapı taşlarını oluşturur. Karışıklık matrisi yalnızca modelin genel başarı oranını

göstermekle kalmaz, aynı zamanda hangi sınıflarda sistematik hatalar yapıldığını, pozitif ve negatif örneklerdeki denge durumunu ve sınıf bazlı performans farklılıklarını da ortaya koyar. Bu nedenle, özellikle çok sınıflı ya da dengesiz örnek dağılımına sahip veri setlerinde, karışıklık matrisi tek başına doğruluk oranından çok daha anlamlı bir değerlendirme sağlar.

Bu araştırmada her IP' ye karşılık oluşturulan YSA modelinin karışıklık matrisi ayrı ayrı elde edilmiştir. Her bir modelin doğruluk oranı, duyarlılık (recall), kesinlik (precision), özgüllük (specificity) ve F1 puanı gibi tamamlayıcı ölçütlerle birlikte hesaplanmış ve karşılaştırmalı analiz yapılmıştır. Elde edilen sonuçlar, kullanılan ısıtıcı profilinin sensör verisinin dinamik yapısını doğrudan etkilediğini ve bu etkinin sınıflandırma performansına yansıdığını göstermiştir. Özellikle belirli profillerde modelin tahmin performansında anlamlı artışlar gözlemlenmiş; bu bulgu, ısıtıcı profili seçiminin sensör tabanlı sistemlerde kritik bir optimizasyon parametresi olduğunu ortaya koymuştur.

Karışıklık matrisi tabanlı bu değerlendirme, yalnızca nicel doğruluk ölçümü sunmakla kalmamış, aynı zamanda modelin hangi sınıf bölgelerinde aşırı uyum (overfitting) veya genelleme eksikliği yaşadığını da tespit etmeye olanak tanımıştır. Böylece modelin yapısal ve deneysel iyileştirmeleri, istatistiksel temele dayalı bir şekilde planlanabilmektedir.

3.5.1 Doğruluk (Accuracy)

Sınıflandırma modellerinin performansını özetleyen en temel ölçütlerden biri doğruluk oranıdır (accuracy). Bu metrik, modelin gerçekleştirdiği tahminler arasında doğru sonuçlananların tüm tahminlere oranını temsil eder ve böylece modelin genel başarı düzeyine ilişkin ilk nicel göstergedir. Doğruluk, tahmin edilen ve gerçek etiketlerin eşleşme oranını temel alır; bu yönüyle sınıflandırma sisteminin genel güvenilirliğini değerlendirmek için başlangıç noktası niteliğindedir.

Doğruluk, matematiksel olarak Denklem (3.1)'de tanımlandığı üzere Doğru Pozitif (DP) ve Doğru Negatif (DN) örneklerin toplamının, toplam örnek sayısına oranı olarak hesaplanır:

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

Bu tanımda yer alan dört değişken, modelin karar kalitesinin bütünsel ifadesidir. DP ve DN değerleri modelin başarılarını, YP ve YN değerleri ise yaptığı yanlış tahminleri temsil eder. Böylece doğruluk, modelin genel olarak ne ölçüde doğru kararlar verdiğini nicel olarak ortaya koyar.

Ancak doğruluk metriği, her zaman modelin gerçek performansını tek başına yansıtmayabilir. Özellikle sınıf dengesizliği bulunan veri kümelerinde, doğruluk değeri yanıltıcı biçimde yüksek görünebilir. Örneğin, pozitif sınıfa ait örneklerin az olduğu bir veri setinde tüm örnekleri “negatif” olarak sınıflandıran bir model, pozitif örneklerin tamamını göz ardı etmesine rağmen yüksek doğruluk değerine ulaşabilir. Bu nedenle doğruluk, duyarlılık, kesinlik ve F1 skoru gibi tamamlayıcı metriklerle birlikte yorumlanmadığı sürece modelin genelleme kabiliyetini eksik temsil edebilir.

Dengeli veri kümelerinde ise doğruluk, modelin genel başarısını güvenilir biçimde yansıtan güçlü bir ölçüttür. Bu çalışmada, veri kümesinin her bir ısıtıcı profiline göre ayrıldığı YSA modellerinde, doğruluk değeri hem model karşılaştırması yapmak hem de profil bazlı performans farklılıklarını gözlemlemek amacıyla kullanılmıştır. Her IP için elde edilen doğruluk oranları, modelin ısıtma koşullarına karşı tepkisel kararlılığını ve sensör verilerinin istatistiksel tutarlılığını ölçmekte önemli rol oynamıştır.

Eğitim süreci boyunca doğruluk değerlerinin zamana bağlı olarak izlenmesi, modelin yakınsama dinamikleri hakkında da bilgi sunmuştur. Eğitim doğruluğundaki hızlı artışlar modelin örüntüleri öğrendiğini, test doğruluğundaki dalgalanmalar ise modelin genelleme yeteneğini yansıtmıştır. Bu gözlemler, ağır yapısal parametrelerinin (örneğin katman sayısı veya öğrenme oranı) ne ölçüde uygun seçildiğini değerlendirmek için nitelikli bir gösterge sağlamıştır.

Sonuç olarak doğruluk, bu araştırmada hem genel performans ölçütü hem de öğrenme sürecinin izleme aracı olarak kullanılmıştır. Ancak, yüksek doğruluk değerinin tek başına yeterli olmadığı, sınıf bazlı analizlerin karışıklık matrisiyle birlikte yapılması gerektiği görülmüştür. Böylelikle doğruluk metriği, diğer tamamlayıcı ölçütlerle birlikte değerlendirildiğinde YSA modelinin gerçek sınıflandırma kabiliyetini bütünsel biçimde ortaya koymuştur.

3.5.2 Duyarlılık (Recall / Sensitivity)

Duyarlılık (ya da diğerk adıyla hassasiyet / hatırlama), bir sınıflandırma modelinin pozitif sınıfa ait örnekleri doğru bir biçimde tanıma yeteneğini nicel olarak ifade eden temel performans ölçütlerinden biridir. Başka bir deyişle, duyarlılık değeri, modelin gerçek pozitif örneklerin ne kadarını doğru biçimde pozitif olarak sınıflandırabildiğini gösterir. Bu metrik, özellikle kaçırılmaması gereken kritik olayların bulunduğu alanlarda (örneğin tıbbi tanı, güvenlik sistemleri veya çevresel izleme) son derece önemlidir.

Matematiksel olarak duyarlılık, Doğru Pozitif (TP) değerinin, Doğru Pozitif (TP) ile Yanlış Negatif (FN) değerlerinin toplamına oranı olarak tanımlanır. Denklem (3.2) ile ifade edilmektedir:

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.2)$$

Bu formül, modelin gerçek pozitifleri ne ölçüde yakalayabildiğini açık biçimde gösterir. Duyarlılık değeri 1'e yaklaştıkça model, pozitif örneklerin neredeyse tamamını doğru biçimde tespit etmektedir; buna karşın düşük bir duyarlılık değeri, modelin pozitif sınıf örneklerini gözden kaçırma eğiliminde olduğunu ve bu nedenle eksik tanı problemlerine açık olduğunu gösterir.

Bu çalışmada duyarlılık, özellikle kızartma yağı kalitesinin değerlendirilmesi bağlamında büyük önem taşımaktadır. Çünkü yağın bozulma seviyesi hem tüketici sağlığı hem de gıda güvenliği açısından kritik bir göstergedir. Düşük duyarlılığa sahip bir model, bozulmuş bir yağ "kullanılabilir" olarak sınıflandırma riski taşıyabilir; bu durum halk sağlığı açısından tehlikeli bir ihmal anlamına gelir. Bu nedenle, modelin bozulmuş veya riskli durumları gözden kaçırmaması için yüksek bir duyarlılık seviyesinin korunması bu araştırmada öncelikli bir hedef olarak belirlenmiştir.

Yüksek duyarlılık değeri, modelin potansiyel olarak zararlı durumları, örneğin yüksek TPB veya SYA içeriğine sahip yağ örneklerini etkin biçimde tespit ettiğini ve erken uyarı mekanizması gibi davranabildiğini gösterir. Ancak, duyarlılık değeri artırıldığında genellikle modelin yanlış pozitif (YP) oranı da artar. Bu, bazı sağlıklı yağ örneklerinin hatalı biçimde bozulmuş olarak etiketlenmesine neden olabilir. Böyle bir durumda, sistem gereksiz alarm üretebilir veya kullanılabilir yağın erken atılmasına yol açabilir. Dolayısıyla duyarlılık yüksekliği,

hata maliyeti göz önüne alındığında her zaman tek başına avantaj sağlamaz; kesinlik (precision) ile dengeli biçimde yorumlanması gerekir.

Duyarlılığın yüksek tutulması gereken senaryolar genellikle “kaçırmanın maliyetinin yanlış alarmdan daha yüksek” olduğu durumlardır. Bu çalışmada da benzer biçimde, “bozulmuş yağı gözden kaçırmanın” halk sağlığına etkisi, “yanlış pozitif alarm üretmenin” operasyonel maliyetinden daha ciddi görülmüştür. Bu nedenle YSA modeli, duyarlılığı öncelikli bir optimizasyon hedefi olarak ele almış; öğrenme süreci boyunca bu ölçütü maksimize edecek biçimde parametre ayarlamaları yapılmıştır.

Duyarlılık metriğinin farklı IP’ ye göre ayrı ayrı değerlendirilmesi, sensör yanıtlarının sıcaklık temelli değişkenliğini anlamak açısından da kritik bir rol oynamıştır. Farklı IP konfigürasyonlarında elde edilen duyarlılık değerleri karşılaştırıldığında, bazı profillerin gaz kompozisyonundaki değişimlere karşı daha yüksek seçicilik sağladığı görülmüştür. Bu durum, termal modülasyonun sensör tepkilerini optimize etmede ve pozitif sınıf örneklerini, örneğin yüksek bozulma seviyesindeki yağları daha iyi ayırt etmede etkili olduğunu göstermektedir.

Sonuç olarak duyarlılık, bu çalışmada yalnızca modelin doğru tahmin kapasitesini değil, aynı zamanda gıda güvenliği bağlamında risk yönetimi duyarlılığını da yansıtan bir gösterge olarak ele alınmıştır. Duyarlılığın yüksek tutulması, YSA modelinin erken uyarı sistemi olarak işlev görme potansiyelini artırmış; ancak modelin genel performansının dengeli biçimde değerlendirilebilmesi için, bu metrik diğer ölçütlerle, özellikle kesinlik ve F1 skoruyla birlikte yorumlanmıştır. Böylece duyarlılık, yalnızca sayısal bir başarı oranı değil, aynı zamanda uygulama bağlamında güvenilirlik ve sorumluluk ölçütü olarak da değerlendirilmiştir.

3.5.3 Özgüllük (Specificity)

Özgüllük (specificity), bir sınıflandırma modelinin negatif sınıfa ait örnekleri doğru biçimde tanıma ve ayırt etme becerisini ölçen temel performans ölçütlerinden biridir. Başka bir deyişle, özgüllük, modelin bozulmamış veya hâlâ kullanılabilir durumda olan yağ örneklerini yanlış biçimde bozulmuş olarak sınıflandırmama yeteneğini ifade eder. Bu ölçüt, özellikle gereksiz uyarıların veya yanlış alarm durumlarının önlenmesi açısından büyük öneme sahiptir.

Matematiksel olarak özgüllük, **Doğru Negatif (TN)** değerinin, **Doğru Negatif (TN)** ile **Yanlış Pozitif (FP)** değerlerinin toplamına oranı olarak tanımlanır. Denklem (3.3) ile ifade edildiği üzere, bu oran modelin negatif sınıfa ait örnekleri doğru biçimde tanıma oranını temsil eder:

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (3.3)$$

Bu denklemde:

- **TN (Doğru Negatif)**, kullanılabilir yağların doğru biçimde kullanılabilir olarak tahmin edildiği durumları,
- **FP (Yanlış Pozitif)** ise, aslında kullanılabilir durumda olan bir yağın yanlışlıkla “bozulmuş” olarak sınıflandırıldığı durumları ifade eder.

Özgüllük değeri, sınıflandırma sisteminin yanlış alarm üretme eğilimini yansıtan en önemli göstergelerden biridir. Yüksek özgüllük, modelin kullanılabilir yağ örneklerini koruma ve gereksiz müdahaleleri önleme konusundaki başarısını gösterir. Örneğin, hâlâ kalite standardını karşılayan bir kızartma yağının hatalı biçimde bozulmuş olarak değerlendirilmesi, yalnızca ekonomik kayıplara değil, aynı zamanda gıda israfına ve kaynak verimsizliğine de neden olabilir. Bu nedenle, endüstriyel süreçlerde veya gıda güvenliği uygulamalarında yüksek özgüllük değeri, operasyonel sürdürülebilirlik açısından önemli bir avantaj sağlar.

Bununla birlikte, özgüllük ile duyarlılık arasında her zaman bir denge ilişkisi bulunmaktadır. Modelin özgüllük değeri aşırı yükseldiğinde, yanlış pozitiflerin azalmasıyla birlikte yanlış negatiflerin artması mümkündür. Bu durum, bozulmuş veya tüketim için riskli yağ örneklerinin gözden kaçmasına ve dolayısıyla halk sağlığı açısından tehlikeli sonuçlara yol açabilir. Başka bir ifadeyle, çok yüksek özgüllük değerleri modelin aşırı seçici davranmasına neden olabilir; bu da potansiyel olarak tehlikeli durumların algılanmamasına ve FN hatalarına sebebiyet verir.

Bu çalışmada özgüllük, duyarlılık ölçütüyle birlikte değerlendirilmiş ve modelin dengesiz hata türleri arasındaki performans dengesini analiz etmek amacıyla kullanılmıştır. Her bir Isıtıcı Profili için ayrı ayrı eğitilen YSA modellerinde özgüllük değerlerinin karşılaştırılması, sensörlerin farklı termal koşullardaki yanıt kararlılığını ve sınıflar arası ayırt etme gücünü istatistiksel olarak ortaya koymuştur. Özellikle bazı IP konfigürasyonlarında modelin özgüllük

performansının belirgin şekilde arttığı, bunun da sensörün bozulmamış yağ atmosferine verdiği tutarlı tepkiyle ilişkili olduğu görülmüştür.

Ayrıca özgüllük, ekonomik ve çevresel sürdürülebilirlik açısından da önemli bir değerlendirme kriteridir. Çünkü yüksek özgüllüğe sahip bir model, yalnızca doğru tahmin yapmakla kalmaz; aynı zamanda gereksiz yağ değişimlerinin önüne geçerek maliyet optimizasyonu sağlar. Endüstriyel mutfaklar veya gıda üretim tesislerinde, bozulmamış yağın yanlışlıkla elenmesi günlük üretim giderlerini artırır ve kaynak kullanım verimliliğini düşürür. Bu nedenle, bu tez kapsamında geliştirilen yapay zekâ modeli yalnızca doğruluk veya duyarlılık değil, aynı zamanda özgüllük yönünden de optimize edilmiştir.

Sonuç olarak özgüllük, bu çalışmada modelin gerçek pozitifleri tanıma başarısına karşılık gerçek negatifleri doğru biçimde koruma becerisini temsil eden tamamlayıcı bir metrik olarak değerlendirilmiştir. Duyarlılıkla birlikte ele alındığında özgüllük, YSA tabanlı sınıflandırma sisteminin hem güvenlik odaklı (bozulmuş yağın tespiti) hem de verimlilik odaklı (kullanılabilir yağın korunması) hedeflerine ne ölçüde hizmet ettiğini bütüncül biçimde ortaya koymaktadır. Böylece özgüllük, yalnızca istatistiksel bir performans göstergesi değil, aynı zamanda gıda güvenliği ile ekonomik sürdürülebilirlik arasında kurulan dengeyi yansıtan stratejik bir ölçüt olarak konumlandırılmıştır.

3.5.4 Kesinlik (Precision)

Kesinlik, bir sınıflandırma modelinin pozitif tahminlerinin doğruluk oranını ifade eden temel bir performans ölçütüdür. Başka bir ifadeyle, model tarafından pozitif olarak tahmin edilen örneklerin gerçekten pozitif olma olasılığını gösterir. Bu ölçüt, modelin pozitif tahminlerdeki güvenilirliğini değerlendirmek açısından büyük önem taşır ve özellikle yanlış pozitiflerin istenmeyen sonuçlara yol açabileceği uygulama alanlarında kritik bir değerlendirme kriteridir.

Matematiksel olarak kesinlik, Doğru Pozitif (TP) değerinin, Doğru Pozitif (TP) ile Yanlış Pozitif (FP) değerlerinin toplamına oranı şeklinde tanımlanır. Denklem (3.4) ile gösterildiği üzere:

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.4)$$

Bu formül, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif olduğunu belirler. Kesinlik değeri 1'e veya %100'e yaklaştıkça

model, pozitif tahminlerinde o kadar doğru ve güvenilir kabul edilir. Buna karşılık düşük bir kesinlik değeri, modelin yüksek sayıda yanlış pozitif tahmin ürettiğini, yani “bozulmamış” örnekleri yanlışlıkla pozitif olarak etiketleme eğiliminde olduğunu gösterir.

Bu çalışmanın bağlamında, kesinlik değeri, kızartma yağı kalitesi izleme sisteminin ekonomik güvenilirliği açısından kritik bir rol oynamaktadır. Çünkü yeniden kullanılabilir bir kızartma yağının yanlış biçimde “kullanılamaz” olarak sınıflandırılması, erken imha ve kaynak israfı gibi önemli sonuçlara yol açabilir. Bu durum yalnızca ekonomik kayıp anlamına gelmez; aynı zamanda üretim süreçlerinde gereksiz duraksamalara, operasyonel maliyet artışına ve gıda endüstrisinde sürdürülebilirlik hedeflerinin zedelenmesine neden olur. Bu nedenle, geliştirilen YSA tabanlı modelin yüksek bir kesinlik oranına sahip olması, sistemin yanlış alarm oranını azaltması ve gerçekten riskli durumlara odaklanabilmesi açısından son derece önemlidir.

Kesinliğin yüksek tutulması, modelin pozitif tahminlerde seçici davranmasını sağlar. Bu durum, özellikle yanlış pozitiflerin maliyetli olduğu senaryolarda avantajlıdır. Ancak bu avantaj, duyarlılık metriğiyle doğal bir denge ilişkisi içindedir. Çünkü model pozitif tahminlerde daha temkinli davrandığında, bazı gerçek pozitif örnekleri gözden kaçırabilir ve duyarlılık değeri düşebilir. Bu nedenle, yüksek kesinlik istenen durumlarda modelin genel performansı yalnızca bu metrik üzerinden değil, duyarlılık ve F1 skoru gibi tamamlayıcı ölçütlerle birlikte değerlendirilmelidir.

Kesinlik metriği, YSA modelinin güvenilir karar verme yeteneğini doğrudan yansıtır. Bu çalışmada, sensör tabanlı sistemin pozitif sınıflandırma çıktıları, yani “yağ bozulmuş” olarak işaretlenen örnekler üzerinde yapılan analizlerde, yüksek kesinlik değeri, sistemin yalnızca gerçekten riskli yağları tespit ettiğini göstermiştir. Böylece, sistemin gereksiz müdahalelerden kaçınması sağlanmış ve operasyonel verimlilik artırılmıştır.

Ayrıca, ısıtıcı profiline göre eğitilen YSA modellerinde elde edilen kesinlik değerlerinin karşılaştırılması, sensörlerin farklı termal koşullar altındaki yanıt kararlılığı hakkında da bilgi sağlamıştır. Bazı IP konfigürasyonlarında modelin pozitif sınıflandırma güvenilirliğinin belirgin şekilde arttığı gözlemlenmiştir; bu durum, sensör-tepki desenlerinin ısıtıcı kontrol parametreleriyle optimize edilebildiğini göstermiştir.

Sonuç olarak, kesinlik bu çalışmada yalnızca modelin doğru tahmin oranını değil, aynı zamanda ekonomik verimlilik ve sürdürülebilir kaynak yönetimi açısından da değerlendirilmiştir. Modelin yüksek kesinlik değeri, kıyartma yağının kullanım ömrünü en doğru şekilde belirlemeye ve gereksiz atıkları önlemeye katkı sağlamıştır. Böylelikle kesinlik, yalnızca istatistiksel bir performans göstergesi değil, aynı zamanda gerçek dünya uygulamalarında güvenilirlik ve kaynak optimizasyonunun göstergesi olarak değerlendirilmiştir.

3.5.5 F1 Skoru (F1 Score)

F1 skoru, bir sınıflandırma modelinin duyarlılık ve kesinlik ölçütlerini birlikte dikkate alarak genel sınıflandırma performansını tek bir birleşik değerle özetleyen önemli bir metriktir. Bu ölçüt, bir modelin yalnızca pozitif örnekleri yakalama başarısını (duyarlılık) değil, aynı zamanda pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma oranını (kesinlik) da dikkate alır. Böylece F1 skoru, modelin gerçek pozitifleri yakalama gücü ile yanlış pozitiflerden kaçınma becerisi arasındaki dengeyi nicel biçimde temsil eder.

F1 skoru, duyarlılık ve kesinliğin harmonik ortalaması olarak tanımlanır. Denklem (3.5) ile ifade edilir:

$$F1 \text{ Skoru} = 2 \times \frac{(\text{Duyarlık} \times \text{Kesinlik})}{(\text{Duyarlık} + \text{Kesinlik})} \quad (3.5)$$

Bu tanım, F1 skorunun yalnızca iki metriğin aritmetik ortalaması olmadığını, aksine bu iki değerın karşılıklı dengeye dayalı bir ilişkiyle ağırlıklandırıldığını göstermektedir. F1 skoru, modelin hem pozitif vakaları doğru biçimde tanıma (yüksek duyarlılık) hem de pozitif tahminlerde isabet oranını koruma (yüksek kesinlik) başarısını aynı anda değerlendirdiği için tek başına doğruluktan çok daha bütüncül bir performans göstergesi olarak kabul edilir.

Özellikle sınıf dağılımının dengesiz olduğu, yani pozitif ve negatif örneklerin veri setinde orantısız şekilde bulunduğu durumlarda F1 skoru büyük önem taşır. Çünkü bu gibi senaryolarda yalnızca “doğruluk” metriğine güvenmek, modelin gerçek performansını yansıtmakta yetersiz kalabilir. Örneğin, tüm örneklerin çoğunluk sınıfına ait olduğu bir veri setinde, basit bir model yüksek doğruluk oranı elde edebilir; ancak F1 skoru bu dengesizliği ortaya çıkararak modelin pozitif örnekleri tanıma gücünün zayıf olduğunu gösterebilir.


Bu çalışmada, F1 skoru özellikle hem yanlış pozitiflerin hem de yanlış negatiflerin ciddi sonuçlar doğurabileceği bir senaryoyu temsil ettiği için tercih edilmiştir. Kızartma yağının kalitesinin değerlendirilmesi hem ekonomik hem de sağlık açısından hassas bir süreçtir. Bozulmamış bir yağın yanlış biçimde “kullanılamaz” olarak sınıflandırılması (yanlış pozitif), gereksiz atığa ve maliyet kaybına yol açarken; bozulmuş bir yağın yanlış biçimde “Kullanılabilir” olarak tahmin edilmesi (yanlış negatif) doğrudan halk sağlığını tehdit eder. Dolayısıyla F1 skoru, bu iki hata türü arasında dengeyi en iyi temsil eden performans göstergesi olarak bu çalışmada temel referans metriği olarak benimsenmiştir.

3.5.5.1 Profil Bazlı F1 Skoru Değerlendirmesi

Bu çalışmada geliştirilen YSA tabanlı modeller, dört farklı Isıtıcı Profili altında ayrı ayrı eğitilmiş ve her birinin performansı beş katlı çapraz doğrulama (5-fold cross-validation) yöntemiyle değerlendirilmiştir. Elde edilen sonuçlar, sensör tepkilerinin sıcaklık modülasyonuna bağlı olarak önemli farklılıklar sergilediğini ve dolayısıyla F1 skorunun ısıtıcı profiline duyarlı bir ölçüt olduğunu ortaya koymuştur. Her bir ısıtıcı profili için elde edilen metrik değerleri **Tablo 3.3** de verilmiştir. Farklı Isıtıcı profillerine ait karışıklık matrisi **Şekil 3.5** de gösterilmiştir.

Tablo 3.3 Her bir ısıtıcı profili için elde edilen farklı metrik değerlerinin karşılaştırılması

Kat	Isıtıcı Profili	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru	Özgüllük (Specificity)
Kat 1	IP-301	0.9486	0.9492	0.9460	0.9470	0.9828
	IP-354	0.8129	0.8091	0.8122	0.8096	0.9377
	IP-411	0.9871	0.9886	0.9867	0.9875	0.9956
	IP-501	0.9340	0.9428	0.9347	0.9352	0.9774
Kat 2	IP-301	0.9293	0.9335	0.9309	0.9314	0.9763
	IP-354	0.8053	0.7945	0.8004	0.7965	0.9355
	IP-411	0.9914	0.9915	0.9912	0.9912	0.9972
	IP-501	0.9057	0.9099	0.9065	0.9061	0.9688
Kat 3	IP-301	0.9904	0.9911	0.9903	0.9905	0.9967
	IP-354	0.8185	0.8201	0.8256	0.8223	0.9387
	IP-411	0.9785	0.9791	0.9793	0.9790	0.9928
	IP-501	0.9151	0.9390	0.9185	0.9195	0.9706
Kat 4	IP-301	0.9807	0.9810	0.9802	0.9801	0.9936
	IP-354	0.7921	0.7818	0.7931	0.7856	0.9308
	IP-411	0.9914	0.9923	0.9914	0.9917	0.9971
	IP-501	0.9387	0.9476	0.9167	0.9259	0.9785
Kat 5	IP-301	0.8585	0.8637	0.8625	0.8628	0.9521
	IP-354	0.8034	0.7925	0.7991	0.7940	0.9348
	IP-411	0.9871	0.9875	0.9877	0.9873	0.9957
	IP-501	0.9104	0.9196	0.9084	0.9092	0.9697



Şekil 3.5. Farklı Isıtıcı Profilleri için Karışıklık Matrisi

a. IP-301 Profili

IP-301 profili, genel sınıflandırma doğruluğu açısından öne çıkan profillerden biri olmuştur. Özellikle “Taze (Excellent)” ve “Düşük Kalite (Unsafe)”

sınıflarında yüksek F1 puanları elde edilmiştir; bu durum, modelin hem pozitif hem de negatif uç sınıfları yüksek doğrulukla ayırt edebildiğini göstermektedir. Ancak ara kalite sınıfları olan “Kullanılabilir (Acceptable)” ve “Düşük Kalite (Low Quality)” kategorilerinde zaman zaman sınıf geçişleri ve karışıklıklar gözlenmiştir. Bu durum, sensörün orta seviye gaz bileşenlerini sınıflandırmadaki duyarlılığının sınırlı olabileceğini göstermektedir.

Yine de IP-301 profili, yüksek özgüllük oranları sayesinde yanlış pozitif sınıflandırmaları önemli ölçüde azaltmıştır. Beş katlı çapraz doğrulama sonuçlarına göre modelin genel doğruluk oranı %89, ortalama F1 skoru %87,92, duyarlılığı %86,48 ve özgüllüğü %95,67 olarak hesaplanmıştır. Bu sonuçlar, modelin hem pozitif hem negatif sınıfları istikrarlı biçimde ayırt edebildiğini ve genelleme kapasitesinin yüksek olduğunu göstermektedir.

b. IP-354 Profili

IP-354 profili, test edilen tüm sıcaklık modülasyon senaryoları arasında en düşük sınıflandırma performansını göstermiştir. Bu profil altında elde edilen F1 puanları, özellikle “Düşük Kalite” ile “Kullanılamaz” sınıflar arasında belirgin karışıklıklar olduğunu ortaya koymuştur. Modelin yüksek derecede bozulmuş yağ örneklerini yeterli spektral farklılıkla ayıramadığı görülmüştür. Ayrıca “Düşük Kalite” sınıfının da diğer sınıflarla sık sık karışması, bu profilin orta seviyedeki gaz bileşenlerini ayırt etme gücünün zayıf olduğunu göstermektedir.

Gerçek test verileri dikkate alındığında, modelin genel doğruluk oranı %77,93, F1 puanı %76,15, duyarlılık %74,80, özgüllük %91,45 ve kesinlik %78,10 olarak hesaplanmıştır. Bu sonuçlar, IP-354 sensörüne dayalı modelin sınıflandırma performansının tam anlamıyla istikrarlı olmadığını ve özellikle ara sınıf kategorilerinde belirgin sınırlılıklar taşıdığını göstermektedir. Ayrıca, katlamalar arasındaki metrik varyanslarının yüksek olması, modelin genelleme kabiliyeti ve güvenilirliği açısından tutarlılık sorunu yaşadığını ortaya koymaktadır.

c. IP-411 Profili

IP-411 profili hem çapraz doğrulama hem de gerçek test verilerinde en yüksek genel başarıyı göstermiştir. Bu profil altında model, “Taze” ve “Kullanılamaz” sınıflarda neredeyse hatasız sınıflandırmalar yapmış; aynı zamanda ara sınıflarda da düşük hata oranlarını koruyarak yüksek genelleme başarısı sergilemiştir.

Gerçek test sonuçlarına göre, doğruluk oranı %99,14, F1 skoru %99,10, duyarlılık %98,83, özgüllük %99,70 ve kesinlik %99,37 olarak hesaplanmıştır. Bu olağanüstü performans, IP-411 profilinin dengeli ısıtma stratejisi sayesinde sensörlerden yüksek ayırım gücüne sahip gaz tepkileri elde edilebildiğini göstermektedir. Ayrıca düşük varyans değerleri, bu profilin hem eğitim hem de test aşamalarında yüksek tutarlılık ve kararlılık sunduğunu doğrulamaktadır.

Dolayısıyla IP-411, sınıflar arasında net ayırım, düşük hata oranı, yüksek tekrarlanabilirlik ve optimum genelleme özellikleriyle çalışmada öne çıkan en başarılı profil olarak değerlendirilmiştir.

d. IP-501 Profili

IP-501 profili, genel sınıflandırma performansı açısından orta düzeyde bir başarı elde etmiştir. Model, uç sınıflar olan “Taze” ve “Düşük Kalite” kategorilerinde yüksek doğruluk oranlarına ulaşmış, ancak “Kullanılabilir” ve “Düşük Kalite” sınıflarını ayırt etmede belirgin kararsızlık göstermiştir.

Gerçek test verileriyle hesaplanan değerler sırasıyla doğruluk %91,51, F1 skoru %90,85, duyarlılık %89,14, özgüllük %96,32 ve kesinlik %92,25 olarak bulunmuştur. Bu sonuçlar, IP-501’in pozitif tahminlerde yüksek güvenilirlik sunduğunu ancak orta kalite sınıflarındaki geçişlerde zaman zaman karışıklık yaşadığını göstermektedir. Katlamalar arasında gözlemlenen orta düzey varyanslar, bu profilin istikrarlı olmakla birlikte, sınıf ayırımı açısından sınırlı bir gelişim potansiyeli taşıdığını göstermektedir.


Sonuç olarak IP-501, genel olarak güvenilir bir performans sergilese de karar destek sistemlerinde kritik eşiklerde dikkatli biçimde kullanılması gereken bir profil olarak değerlendirilmektedir.

Elde edilen tüm sonuçlar, ısıtıcı profillerinin model performansını doğrudan etkilediğini ve özellikle sıcaklık modülasyonunun sensör tepkileri üzerinde belirleyici bir rol oynadığını göstermektedir. Gerçek test verilerinden elde edilen performans ölçüm değerleri **Tablo 3.4** de gösterilmektedir. Gerçek test verileri üzerinden yapılan değerlendirmede, ısıtıcı profilleri arasında belirgin performans farkları gözlemlenmiştir.

Tablo 3.4 Gerçek test verilerinden elde edilen performans ölçüm değerleri

Isıtıcı Profil	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	F1 Skoru
IP-301 Model	89.27	89.52	86.48	95.67	87.92
IP-354 Model	77.93	78.10	74.80	91.45	76.15
IP-411 Model	99.14	99.37	98.83	99.70	99.10
IP-501 Model	91.51	92.25	89.14	96.32	90.85

IP-354 profili, en düşük performansa sahip yapı olarak %77,93 doğruluk oranına ulaşmış ve duyarlılık değeri %74,80’de kalarak sınıf ayırt etme konusunda sınırlı bir başarı göstermiştir. IP-301 profili ise daha dengeli bir performans sergileyerek %89,27 doğruluk, %89,52 kesinlik ve %86,48 duyarlılık değerleriyle kabul edilebilir bir sınıflandırma yeteneği ortaya koymuştur. IP-501 profili, yüksek özgüllük (%96,32) ve güçlü bir duyarlılık (%89,14) değeriyle %91,51 doğruluk sağlamış ve genel olarak başarılı bir model yapısı sunmuştur. En yüksek performans ise IP-411 profiline aittir. Bu profilde doğruluk oranı %99,14’e, kesinlik %99,37’ye ve duyarlılık %98,83’e ulaşmış; F1 skoru da %99,10 gibi oldukça yüksek bir değerde gerçekleşmiştir. Bu sonuçlar, IP-411 profilinin doğruluk, duyarlılık, kesinlik, özgüllük ve F1 skoru dâhil tüm değerlendirme ölçütlerinde diğer profillere kıyasla üstün bir performans sergilediğini ve gerçek test verisi üzerinde en yüksek genelleme yeteneğine sahip model olduğunu göstermektedir. Isıtıcı profilinin gerçek test veri seti üzerindeki başarısını gösteren karışıklık matrisi **Şekil 3.6** da gösterilmiştir.



Şekil 3.6 Gerçek Test Veri Setinde Isıtıcı Profillerinin Doğruluk Performansları

Bu sonuçlar, yalnızca modelin istatistiksel başarısını değil, aynı zamanda sensör tabanlı kızartma yağı izleme sistemlerinin gerçek dünya uygulamalarındaki güvenilirliğini de güçlendirmektedir. F1 skorunun tüm bu analizlerde ortak bir referans metriği olarak kullanılması, modelin dengeli, genellenebilir ve sürdürülebilir bir performans profili sunduğunu açıkça ortaya koymuştur.

4. TARTIŞMA

4.1 Bulguların Değerlendirilmesi

Bu çalışma, BME688 sensör verileri ile kimyasal kalite göstergeleri olan Serbest Yağ Asidi ve Toplam Polar Madde arasındaki ilişkiyi sistematik biçimde analiz eden ilk kapsamlı araştırmalardan biridir. Çalışmanın temel amacı, sensör tabanlı sistemler kullanılarak kızartma yağının fizikokimyasal bozulma sürecini tahmin edebilmek ve bu süreçte gaz sensörlerinden elde edilen verilerin güvenilirliğini değerlendirmektir.

Bosch BME688 sensör matrisinden elde edilen gaz konsantrasyonu ve direnç değişimi verileri, klasik kimyasal analiz sonuçlarıyla karşılaştırmalı olarak incelenmiş ve bu sayede kızartma yağının kalitesi çok boyutlu bir yaklaşımla değerlendirilmiştir.

Elde edilen bulgular, sensör sinyallerinin yağların oksidatif bozulma ürünleriyle yüksek düzeyde ilişkilendiğini göstermiştir. Bu sonuç, kızartma süreci ilerledikçe yağın moleküler yapısında meydana gelen değişimlerin gaz sensörleri tarafından etkin biçimde tespit edilebildiğini ortaya koymakta ve yapay zekâ tabanlı kalite izleme sistemlerinin geliştirilmesi için bilimsel bir temel sunmaktadır.

Çalışmada elde edilen sonuçlar, sensör matrisinin yüksek doğruluk ve duyarlılıkla kızartma yağının “Taze”, “Kullanılabilir”, “Düşük Kalite” ve “Kullanılamaz” kategorilerini ayırt edebildiğini göstermiştir. Özellikle IP-411 ve IP-501 sıcaklık modülasyon profillerinde yüksek sınıflandırma başarısı elde edilmiştir. Bu sonuç, sıcaklık kontrollü ölçümün gaz sensörü performansını artırdığını ve sensör yüzeyinde seçici adsorpsiyon süreçlerini optimize ettiğini doğrulamaktadır. Ancak, orta düzey kalite kategorilerinde hataların artması, bu sınıflar arasındaki gaz bileşimi farklarının düşük olmasından kaynaklanmaktadır.

Bu bulgular, yalnızca kimyasal analiz sonuçlarının doğrulanmasını sağlamakla kalmamış, aynı zamanda sensör verilerinin gıda kalite izleme sistemlerinde etkin biçimde kullanılabileceğini ortaya koymuştur. Özellikle, sensör tabanlı ölçüm yöntemlerinin düşük maliyetli, hızlı ve çevresel açıdan sürdürülebilir bir alternatif sunması, kızartma yağı kalitesinin değerlendirilmesinde önemli bir avantaj sağlamaktadır. Bu yönüyle çalışma, yalnızca mühendislik perspektifinden değil, aynı zamanda gıda bilimi ve sağlık teknolojileri alanlarında da disiplinler arası yenilikçi bir yaklaşım örneği olarak değerlendirilmektedir.

4.2 Literatürle Karşılaştırmalar

Kızartma yağlarının kalitesinin belirlenmesine yönelik literatürdeki çalışmalar incelendiğinde, çoğunun kimyasal analizlere veya gaz sensörü tabanlı elektronik burun sistemlerine dayandığı görülmektedir. Ancak bu çalışmalarda sensör verilerinin fiziksel veya yapısal doğrulaması çoğunlukla göz ardı edilmiştir. Mevcut araştırma, bu eksikliği gidererek sensör tabanlı veriler ile kimyasal kalite göstergeleri arasındaki ilişkiyi bütüncül biçimde analiz etmektedir. Örneğin, Liu ve arkadaşları, sekiz adet metal oksit (MOX) sensörü kullanarak yağ kalitesini %82 doğruluk oranıyla sınıflandırabilmiştir; ancak çalışmada kimyasal ve fiziksel doğrulama yöntemlerinin kullanılmaması, elde edilen sonuçların genellenebilirliğini sınırlamıştır. (Liu vd., 2022). Bu çalışmada, sensör sinyalleri moleküler bozulma ile ilişkilendirilmiş ve gaz fazındaki ve sıvı fazdaki değişimleri izlemek mümkün olmuştur (L. Wang vd., 2016). Bu çalışmada ise sensör sinyalleri, kimyasal kalite göstergeleriyle doğrudan ilişkilendirilmiş ve böylece yağların moleküler bozulma süreci, gaz fazındaki uçucu bileşikler üzerinden izlenebilmiştir.

Literatürdeki birçok araştırma, kızartma yağının bozulmasını yalnızca SYA veya TPM gibi kimyasal parametrelerle açıklamıştır. Örneğin Zhang ve ark. (2019), TPM değerinin kızartma süresiyle doğrusal olarak arttığını, ancak belirli bir eşik sonrası doyuma ulaştığını belirtmiştir. Benzer şekilde, Liu ve arkadaşları (2022), SYA oranının viskoziteyle korele olduğunu, fakat gerçek zamanlı izleme için uygun olmadığını vurgulamıştır.

Gaz sensörü odaklı çalışmalarda, genellikle MQ serisi sensörler (MQ-135, MQ-9) veya SnO₂, ZnO gibi MOX tabanlı sensörler kullanılmıştır. Ancak bu sensörlerin tek sıcaklıkta ölçüm yapmaları nedeniyle seçicilik sorunları yaşanmıştır. BME688 sensörünün sıcaklık modülasyonuna izin veren yapısı sayesinde, bu çalışmada ısıtıcı profillerine bağlı olarak farklı gaz bileşenleri daha net ayrıştırılabilmektedir. Özellikle IP-411 ve IP-501 profillerinde elde edilen yüksek doğruluk oranları, sıcaklık modülasyonunun gaz sensör performansını anlamlı biçimde artırdığını göstermiştir. Bu bulgu, Lima ve arkadaşları (2021) tarafından yapılan çalışmada, derin sinir ağı (DSA) modelinin belirli koşullar altında %90 doğruluk oranı elde ettiği ve gaz bileşenleri arasında karışma sorunları yaşadığı sonucuna varılmıştır. Bu sonuç, doğruluk açısından önemli bir ilerleme olarak değerlendirilebilir; ancak gaz bileşenlerinin etkileşimi, sistemin genel güvenilirliğini etkileyen bir sorun olarak kalmaktadır (Lima vd., 2021).

Bu bağlamda, gaz sensörleri ve derin öğrenme yöntemlerinin bir kombinasyonu, sistemin performansını artırmak amacıyla daha ileri düzeyde araştırmalara olanak tanır. Modelin karışma sorununu en aza indirmek için kullanılan sensör füzyonu tekniklerinin etkinliği, yakından incelenmelidir; ancak bu konuda spesifik çalışmalar referanslar arasında bulunmamaktadır (H.-X. Gao vd., 2020; Liu vd., 2022).

Dolayısıyla, DSA modelinin doğruluğunun artırılması, yalnızca algoritmanın yapısal optimizasyonu ile değil, aynı zamanda sensörlerin özellikleri ve çevresel değişkenler göz önünde bulundurularak yapılmalıdır. Bu süreç, daha hassas ve doğru sonuçlar elde edilmesine katkı sağlayacak ve gıda, sağlık gibi alanlarda kalite kontrol uygulamalarını geliştirmek için büyük bir fırsat sunacaktır (Crexi vd., 2010).

Ayrıca literatürde, kızartma yağlarının kalitesine yönelik çalışmalar genellikle yağ saflığı, oksidasyon derecesi veya nem içeriği gibi fiziksel ve kimyasal parametrelerle ilişkilendirilmiştir. Ancak bu çalışma, gaz sensörlerinden elde edilen verileri doğrudan kimyasal kalite göstergeleriyle eşleştirerek, gaz fazında gerçekleşen oksidatif bozulma süreçlerini deneysel olarak ortaya koymaktadır. Bu yaklaşım, yalnızca kalite tespiti açısından değil, aynı zamanda kızartma yağlarının bozulma mekanizmasının anlaşılması bakımından da önemli bir katkı sunmaktadır. Gaz fazında oluşan aldehit ve keton gibi uçucu bileşiklerin, yağın kimyasal stabilitesini azaltan moleküler dönüşümlerle paralellik göstermesi, sensör verilerinin kimyasal doğrulanabilirliğini güçlendirmiştir.

Sonuç olarak, mevcut literatürle karşılaştırıldığında bu çalışma, sensör tabanlı yapay zekâ sistemlerini geleneksel kimyasal analizlerle birleştiren öncü bir yaklaşım sunmaktadır. Böylece kızartma yağı kalitesinin değerlendirilmesinde çok boyutlu ve bütüncül bir model oluşturulmuş, bu modelin gıda endüstrisinde otomatik kalite kontrol sistemlerinin geliştirilmesi için güçlü bir bilimsel referans sağlayabileceği ortaya konmuştur.

4.3 Hipotezlerin Testi

Bu çalışmanın temel amacı, sensör tabanlı sistemler aracılığıyla kızartma yağlarının kalite değişimlerinin izlenebileceğini, bu değişimlerin kimyasal parametrelerle ilişkilendirilebileceğini ve derin öğrenme algoritmaları kullanılarak

sınıflandırılabilceğini ortaya koymaktır. Bu doğrultuda üç temel hipotez geliştirilmiştir:

H1- BME688 sensörlerinden elde edilen gaz verileri, kızartma yağlarının kalite durumlarını doğru bir şekilde sınıflandırabilir.

H2- Sıcaklık modülasyonu, sensörlerin gaz seçiciliğini artırarak modelin genel sınıflandırma performansını iyileştirir.

H3- Sensör verileri, kızartma yağlarının kimyasal bozulma göstergeleriyle anlamlı bir ilişki gösterir.

Aşağıda, her bir hipotez deneysel bulgular ve literatür verileri ışığında ayrıntılı olarak tartışılmaktadır.

H1: BME688 sensörlerinden elde edilen gaz verileri, kızartma yağlarının kalite durumlarını doğru bir şekilde sınıflandırabilir.

Bu hipotez, çalışmanın temelini oluşturan sensör tabanlı izleme yaklaşımının geçerliliğini test etmektedir. Deneylerde Bosch BME688 sensörlerinden elde edilen gaz direnç verileri, farklı kızartma süreleri boyunca toplanmış ve makine öğrenmesi algoritmalarına özellikle DSA tabanlı modellere uygulanmıştır. Model çıktıları, kızartma yağlarının **“Taze”**, **“Kullanılabilir”**, **“Düşük Kalite”** ve **“Kullanılamaz”** kategorileri arasında başarılı bir ayrım yapabildiğini göstermiştir. Özellikle yüksek sıcaklıkta uzun süre kullanılmış yemeklik yağların, sensör matrisinde belirgin direnç düşüşlerine neden olduğu gözlemlenmiştir. Bu, yağın bozulmasıyla birlikte uçucu bileşiklerin özellikle de aldehit, keton ve peroksit türevleri miktarının artmasından kaynaklanmaktadır.

Modelin ortalama doğruluk oranı %92'nin üzerinde hesaplanmış ve bu değer literatürdeki MQ-serisi sensörlerle yapılan çalışmalardan belirgin biçimde yüksektir. Ayrıca, duyarlılık ve özgüllük analizlerinde de sensör verilerinin uç kalite kategorilerini oldukça isabetli ayırt ettiği belirlenmiştir. Özellikle **“Taze”** ve **“Kullanılamaz”** sınıflarında yanlış sınıflandırma oranı %5'in altına düşmüştür. Bu durum, BME688 sensörünün çok bileşenli gaz algılama yeteneği sayesinde karmaşık kızartma ortamlarında bile güvenilir performans sergilediğini göstermektedir.

Bu sonuçlar, H1 hipotezinin güçlü biçimde doğrulandığını ortaya koymaktadır. Elde edilen bulgular, sensör tabanlı sistemlerin gıda kalitesinin belirlenmesinde yalnızca destekleyici değil, doğrudan karar verici bileşen olarak

kullanılabileceğini göstermektedir. Ayrıca sensör verilerinin, klasik kimyasal göstergeler ile uyumlu eğilimler göstermesi, sensör temelli yaklaşımın doğruluğunu desteklemiştir.

H2: Sıcaklık modülasyonu, sensörlerin gaz seçiciliğini ve modelin genel sınıflandırma başarısını artırır.

İkinci hipotez, sensörlerin gaz seçiciliğini artırmak amacıyla kullanılan sıcaklık modülasyonunun model başarısı üzerindeki etkisini değerlendirmektedir. Deneysel veriler, BME688 sensörüne uygulanan farklı ısıtıcı profillerinin (IP-301, IP-411, IP-501 vb.) gaz emilim ve desorpsiyon dinamiklerini belirgin biçimde değiştirdiğini göstermiştir. Özellikle IP-411 ve IP-501 profillerinde elde edilen sonuçlar, modelin doğruluk, hassasiyet ve F1-skora göre diğer profillerden anlamlı biçimde daha iyi performans sergilediğini ortaya koymuştur.

Sıcaklık modülasyonu, sensör yüzeyindeki aktif alanların farklı gaz bileşenlerine tepki verme sıklığını değiştirmekte; bu sayede “termal parmak izi” olarak adlandırılan özgün bir tepki deseni oluşmaktadır. Bu desen, makine öğrenmesi algoritmaları için yüksek ayırt edicilik sunar. Deneysel analizlerde, yüksek sıcaklık değerlerinde çalışan modellerin doğruluk oranı ortalama %84 civarında kalırken, sıcaklık modülasyonunun daha düşük sıcaklık seviyelerinde uygulanması, model performansını belirgin şekilde artırmış ve doğruluk oranı %92 seviyesine ulaşmıştır.

Bu bulgular, sıcaklık modülasyonunun yalnızca sensör kararlılığını artırmakla kalmayıp, modelin öğrenme kapasitesini de güçlendirdiğini göstermektedir. Farklı sıcaklık profillerinde toplanan veri, sensörün gaz türlerini birbirinden daha iyi ayırt etmesini sağlamış, böylece sinyal uzayında daha net bir sınıf ayrımı oluşmuştur. Ayrıca bu durum, sensörün sıcaklık döngüsüne bağlı olarak tekrarlanabilir yanıtlar vermesine yol açmış, sistemin uzun süreli izleme koşullarında da istikrarlı sonuçlar üretmesine katkı sağlamıştır.

Sonuç olarak, yapılan istatistiksel analizler sıcaklık modülasyonunun sınıflandırma performansı üzerinde istatistiksel olarak anlamlı bir etki yarattığını göstermiştir. Dolayısıyla H2 hipotezi tamamen doğrulanmıştır. Bu bulgu, gelecekte sensör tabanlı izleme sistemlerinin adaptif sıcaklık profilleriyle optimize edilebileceğini göstermekte ve alan yazına önemli bir katkı sağlamaktadır.

H3: Sensör verileri, kızartma yağlarının kimyasal bozulma göstergeleriyle anlamlı bir ilişki göstermektedir.

Üçüncü hipotez, çalışmanın sensör verilerinin kimyasal kalite göstergeleriyle olan ilişkisini değerlendirmektedir. Kızartma yağlarının bozulma süreci, serbest yağ asitlerinin artışı, oksidasyon ürünlerinin birikimi ve doymamış bağ yapılarının değişimi ile doğrudan ilişkilidir. Bu kapsamda her kızartma döngüsü sonrasında hem sensör verileri hem de kimyasal analiz sonuçları edilerek istatistiksel olarak karşılaştırılmıştır.

Korelasyon analizi sonuçları, BME688 sensörlerinden elde edilen gaz direnç değerleriyle kimyasal kalite göstergeleri arasında yüksek düzeyde anlamlı bir ilişki bulunduğunu göstermiştir. Bu bulgu, yağın bozulma düzeyi arttıkça sensörün ölçtüğü gaz bileşenlerine verilen tepkinin de belirgin şekilde değiştiğini ortaya koymaktadır. Özellikle, aldehit, keton ve peroksit türevlerinin artışıyla birlikte sensör sinyallerinde gözlemlenen direnç düşüşü, kimyasal olarak ölçülen bozulma parametreleriyle tutarlı bir eğilim göstermiştir.

Elde edilen veriler, sensör tabanlı sistemlerin yalnızca gaz fazındaki uçucu bileşikler algılamakla kalmayıp, bu bileşiklerin yağdaki kimyasal değişimlerle doğrudan ilişkili olduğunu da kanıtlamaktadır. Ayrıca, sensör verilerinden oluşturulan yapay zekâ modelleri, kimyasal kalite göstergelerini yüksek doğrulukla tahmin edebilecek kapasitede bulunmuştur. Bu durum, sistemin yalnızca sınıflandırıcı değil, aynı zamanda öngörücü bir model olarak da işlev görebileceğini göstermektedir.

Sonuç olarak, H3 hipotezi tamamen doğrulanmıştır. Bu bulgu, sensör tabanlı izleme sistemlerinin kimyasal kalite parametreleriyle entegre biçimde çalışabileceğini ve kızartma yağlarının bozulma sürecinin gerçek zamanlı olarak yüksek doğrulukta izlenebileceğini ortaya koymaktadır. Böylece, geliştirilen modelin gelecekte akıllı gıda kalite izleme teknolojilerinde kullanılabilecek güçlü bir temel sunduğu sonucuna varılmıştır.

4.4 Çalışmanın Sınırlılıkları

Bu araştırma, kızartma yağlarının kalitesini değerlendirmek için gaz sensör verileri ve kimyasal parametreleri bütüncül biçimde bir araya getiren yenilikçi bir yaklaşım ortaya koymasına rağmen, belirli sınırlamalara da sahiptir. Bu sınırlamalar hem çalışmanın deneysel tasarımı hem de modelin genellenebilirliği açısından dikkatli değerlendirilmelidir.

4.4.1 Deneysel Tasarım ve Veri Çeşitliliği Sınırlamaları

Araştırma, tek bir yağ türü üzerinde yürütülmüştür. Bu durum, modelin diğer yağ türleri üzerinde nasıl bir performans göstereceğine dair genelleme yapmayı zorlaştırmaktadır. Her yağın doymamış yağ asidi oranı, oksidasyon eğilimi ve uçucu bileşik profili farklı olduğundan, sensör yanıtları da değişkenlik gösterebilir. Dolayısıyla, tek tip yağ ve sabit bir kızartma protokolü ile sınırlı kalınan bu deneysel tasarım, modelin dış geçerliliğini kısıtlamaktadır.

Ayrıca, kızartma süreci sabit sıcaklıkta ve belirli bir zaman diliminde gerçekleştirilmiştir. Ancak endüstriyel ortamlarda sıcaklık dalgalanmaları, gıdanın nem oranı ve ortamdaki hava akışı gibi etkenler, sensör yanıtlarını önemli ölçüde etkileyebilir. Bu çalışmada bu tür çevresel değişkenler kontrollü koşullarda sabit tutulmuş, bu da sistemin gerçek saha koşullarındaki performansını doğrudan yansıtmaya kapasitesini sınırlamıştır.

Veri setinin büyüklüğü de sınırlayıcı faktörlerden biridir. Her ne kadar farklı sıcaklık profilleri altında sensör çıktıları geniş bir veri havuzu oluşturmuş olsa da bu veriler tek bir laboratuvar koşulunda elde edilmiştir. Gerçek dünyada, farklı üreticilerin sensörleri arasındaki kalibrasyon farkları veya sensör yaşlanması gibi etmenler model performansını etkileyebilir. Bu nedenle, modelin genellenebilirliğini artırmak için farklı koşullarda ve geniş veri yelpazesiyile ek deneyler yapılması önerilmektedir.

4.4.2 Ölçüm Doğruluğu ve Kalibrasyon Sınırlamaları

Her ne kadar BME688 sensörü yüksek kararlılığa ve tekrarlanabilirliğe sahip olsa da metal oksit tabanlı sensörlerde çapraz duyarlılık önemli bir sınırlayıcı faktördür. Bu tür sensörler genellikle belirli gaz türlerine özgü tepkiler üretmek üzere tasarlanırsa da farklı gaz karışımlarıyla etkileşime girerek sinyal parazitine yol açabilirler. Bu durum, özellikle kızartma süreci sırasında aldehit, keton, alkan ve karbondioksit gibi çok sayıda bileşiğin aynı anda bulunduğu ortamlarda, ölçüm doğruluğunu sınırlayabilmektedir.

Ayrıca, sensör verilerinin toplanma koşulları, sıcaklık ve nem gibi çevresel değişkenlere karşı duyarlıdır. Bu faktörler, gaz sensörlerinin kalibrasyon doğruluğunu etkileyebilir ve elde edilen verilerde küçük, ancak istatistiksel açıdan anlamlı farklılıklara yol açabilir.

Bir diğer sınırlama, modelin eğitim sürecinde uygulanan veri ön işleme adımlarından kaynaklanmaktadır. Özellikle ölçeklendirme (normalizasyon) ve

filtreleme tekniklerinin seçimi, modelin hassasiyet ve genelleme performansında küçük değişikliklere neden olabilmektedir. Farklı filtreleme profilleri, z-skoru veya min-maks normalizasyonu gibi yöntemlerin kullanımı, modelin çıktılarını kısmen farklılaştırabilmektedir. Bu nedenle, modelin yeniden eğitimi sırasında parametrelerin açık biçimde tanımlanması ve tekrarlanabilirliğin güvence altına alınması büyük önem taşımaktadır.

Sonuç olarak, çalışma yüksek doğruluk oranları elde etse de sensörlerin çevresel koşullara duyarlılığı ve veri işleme stratejilerinin seçimine bağlı varyasyonlar, sistemin endüstriyel ölçekli uygulamalarda daha geniş kapsamlı kalibrasyon ve validasyon gerektirdiğini göstermektedir.

4.4.3 Model Performansı ve Sınıf Dengesizliği Sorunları

Modelin genel olarak yüksek doğruluk oranı göstermesine rağmen, “Kullanılabilir” ve “Düşük Kalite” kategorileri arasında göreceli bir sınıf dengesizliği gözlemlenmiştir. Bu iki kategori, yağın orta düzeyde bozulma aşamalarını temsil ettiğinden, kimyasal özellikler arasındaki farkların nispeten düşük olması, sensörün bu sınıfları ayırt etmesini doğal olarak zorlaştırmaktadır. Buna rağmen model, genel eğilimleri başarılı biçimde yakalayabilmiş ve kalite değişimlerini anlamlı bir doğrulukla sınıflandırabilmiştir.

Modelin geliştirilmesinde kullanılan hiperparametre optimizasyonu, mevcut veri seti için en uygun dengeyi sağlayacak şekilde seçilmiştir. Farklı parametre kombinasyonlarının alternatif veri kümelerinde kısmi varyasyonlar gösterebileceği öngörülmekte olup, bu durum YZ tabanlı modellerin veri duyarlılığına işaret etmektedir. Ancak, bu tür farklılıklar modelin genelleme kapasitesini azaltmaktan ziyade, gelecekteki veri genişletme ve yeniden kalibrasyon çalışmalarına ışık tutmaktadır.

Ayrıca, çapraz doğrulama yöntemiyle aşırı uyum (overfitting) riski büyük ölçüde kontrol altına alınmış ve modelin kararlılığı güçlendirilmiştir. Yine de modelin gerçek saha verileriyle desteklenerek zaman içinde yeniden değerlendirilmesi, sistemin uyarlanabilirliğini ve uzun vadeli güvenilirliğini artıracaktır.

Bu çerçevede, çalışma yalnızca mevcut modeli doğrulamakla kalmayıp, gelecekteki akıllı sensör sistemlerinin daha geniş veri tabanlarıyla güçlendirilmesine yönelik önemli bir altyapı ve yönlendirme potansiyeli de sunmaktadır.

4.4.4 Donanım ve Gerçek Zamanlı Uygulama Kısıtları

Çalışma kontrollü laboratuvar koşullarında gerçekleştirilmiş olup, sistemin gerçek zamanlı performans potansiyeli gelecek saha uygulamalarıyla test edilmek üzere planlanmaktadır. Bu durum, sistemin taşınabilir ve endüstriyel ölçekli uygulamalara uyarlanabilirliğini değerlendirmek açısından önemli bir gelişim alanı sunmaktadır.

Gerçek zamanlı izleme senaryolarında, sensörlerin sürekli veri toplama kapasitesi, güç tüketimi, sıcaklık kararlılığı ve veri aktarım hızı gibi unsurların optimize edilmesi, sistemin enerji verimliliği ve uzun süreli kararlılığı açısından kritik öneme sahiptir. Özellikle BME688 sensörlerinin sıcaklık modülasyonlu çalışma modu, daha yüksek gaz seçiciliği ve ölçüm doğruluğu sağlamaktadır. Bu modun getirdiği ek enerji gereksinimi ise, akıllı enerji yönetim stratejileri ve düşük güç tüketimli donanım tasarımları sayesinde kolaylıkla dengelenebilecek niteliktedir.

Son olarak, kızartma yağı kalitesi, yalnızca gaz bileşenleriyle değil; kızartılan gıda türü, nem oranı ve işlem sıklığı gibi parametrelerle de yakından ilişkilidir. Bu çalışma, tek tip gıda (patates) kullanılarak gerçekleştirilmiş olup, elde edilen sonuçlar sistemin temel doğruluğunu ve kararlılığını göstermektedir. Ancak farklı gıda türlerinde ortaya çıkabilecek uçucu bileşik profili farklılıkları, sistemin esnek kalibrasyon yeteneği sayesinde kolayca uyarlanabilir niteliktedir. Bu da geliştirilen sensör tabanlı yaklaşımın, gelecekte çok çeşitli gıda türleri için ölçeklenebilir ve genellenebilir bir kalite izleme platformu haline gelebileceğini göstermektedir.

4.4.5 Genel Değerlendirme

Tüm sınırlılıklara rağmen bu çalışma, BME688 sensörlerinden elde edilen gaz verilerini kullanarak geliştirilen modelin başarısını, kimyasal ölçüm yöntemleri aracılığıyla doğrulamış ve bu sayede güvenilir bir kalite izleme sistemi ortaya koymuştur. Dolayısıyla, mevcut sınırlılıklar çalışmanın özgünlüğünü azaltmamakta; tam tersine, gelecekte yapılacak iyileştirme ve genişletme çalışmalarına yön verebilecek nitelikte bir temel oluşturmaktadır.

Özellikle veri çeşitliliğinin artırılması, çoklu sensör yapılarına geçiş, transfer öğrenimi tekniklerinin kullanımı ve saha koşullarında gerçekleştirilecek testler, sistemin performansını daha da güçlendirebilir. Bu sayede model, yalnızca

laboratuvar ortamında deęil, gerek zamanlı uygulamalarda da yksek doęrulukla alıřabilecek bir izleme platformuna dnşebilecektir.



5. SONUÇ VE ÖNERİLER

Bu çalışma, kızartma yağlarının kalite değişimlerinin sensör tabanlı yöntemlerle izlenebilirliğini araştırmak ve gaz sensörlerinden elde edilen verilerle kimyasal kalite göstergeleri arasındaki ilişkiyi değerlendirmek amacıyla gerçekleştirilmiştir. Çalışmada, Bosch üretimi BME688 metal oksit gaz sensörleri kullanılmış, sensörlerden elde edilen veriler YSA modelleri aracılığıyla analiz edilmiştir. Temel hedef, kızartma yağlarının bozulma sürecinin yalnızca geleneksel kimyasal analizlerle değil, aynı zamanda YZ destekli sensör sistemleriyle de yüksek doğrulukta tahmin edilebileceğini göstermektir.

Modelleme sürecinde, BME688 sensörlerinden elde edilen gaz direnç değerleri, farklı kızartma süreleri boyunca toplanmış ve derin sinir ağı (DNN) tabanlı bir yapay zekâ modeli oluşturulmuştur. Elde edilen sonuçlar, modelin kızartma yağı kalitesini dört farklı kategori arasında yüksek doğrulukla sınıflandırabildiğini göstermiştir. Ortalama doğruluk oranı %92'nin üzerinde hesaplanmış, bu değer literatürdeki benzer sensör çalışmalarına göre anlamlı biçimde daha yüksek bulunmuştur. Özellikle uç sınıflarda ("Taze" ve "Kullanılamaz") modelin yanlış sınıflandırma oranı %5'in altında kalmıştır. Bu sonuç, BME688 sensörlerinin gaz fazındaki uçucu bileşenleri yüksek seçicilikle ayırt edebilme yeteneğini ortaya koymakta ve gıda kalite izleme sistemleri açısından önemli bir katkı sunmaktadır.

Ayrıca, model çıktıları çalışmada tartışılan kimyasal ölçüm yöntemleri ile karşılaştırılarak doğruluk analizi yapılmıştır. Korelasyon analizleri, sensör verileri ile kimyasal kalite göstergeleri arasında yüksek düzeyde anlamlı ilişkiler bulunduğunu göstermiştir. Bu bulgular, sensör verilerinin yalnızca istatistiksel olarak değil, kimyasal olarak da tutarlı olduğunu kanıtlamaktadır. Böylece, sensör tabanlı izleme sistemlerinin klasik laboratuvar analizlerinin yerini alabilecek düzeyde güvenilir veri üretebileceği görülmüştür.

Çalışma kapsamında ayrıca, sıcaklık modülasyonunun sensör performansı üzerindeki etkisi değerlendirilmiştir. Sonuçlar, sıcaklık modülasyonlu çalışma modunun sensörlerin gaz seçiciliğini ve doğruluk oranını artırdığını, ancak enerji tüketiminde sınırlı bir artışa yol açtığını göstermiştir. Bu bulgu, gelecekte yapılacak taşınabilir sistem tasarımlarında akıllı enerji yönetimi yaklaşımlarının uygulanmasının önemini vurgulamaktadır.

Elde edilen sonuçlar, üç temel hipotezin tamamının deneysel olarak doğrulandığını göstermektedir. BME688 sensörlerinden elde edilen gaz verilerinin kızartma yağı kalitesini doğru biçimde sınıflandırabildiği, sıcaklık modülasyonunun sensör performansını güçlendirdiği ve sensör verilerinin kimyasal kalite göstergeleriyle anlamlı bir ilişki gösterdiği kanıtlanmıştır. Bu yönüyle çalışma, yapay zekâ tabanlı sensör teknolojilerinin gıda kalitesi izleme alanındaki uygulanabilirliğini ortaya koyan öncü bir örnek niteliğindedir.

Her araştırmada olduğu gibi, bu çalışmanın da bazı sınırlılıkları bulunmaktadır. Çalışma, laboratuvar ortamında gerçekleştirilmiş olup sistemin gerçek zamanlı saha koşullarındaki performansı henüz test edilmemiştir. Sensörlerin sürekli veri toplama kapasitesi, güç tüketimi, sıcaklık kararlılığı ve veri aktarım hızları gibi faktörlerin, taşınabilir sistemler açısından daha kapsamlı biçimde optimize edilmesi gerekmektedir. Bununla birlikte, sıcaklık modülasyonlu çalışma modunun getirdiği yüksek hassasiyet, enerji verimliliği açısından bazı iyileştirmeler gerekirse de bu durum sistemin uzun vadede optimize edilebilir bir yapıya sahip olduğunu göstermektedir.

Modelin oluşturulmasında kullanılan veri seti, tek tip gıda (patates) kızartmaları üzerinden elde edilmiştir. Farklı gıda türlerinin kızartılması durumunda, oluşan gaz profilleri değişebileceğinden, sistemin bu farklı senaryolara göre yeniden kalibre edilmesi gerekebilir. Ayrıca, veri ön işleme aşamasında kullanılan ölçeklendirme ve filtreleme teknikleri, modelin performansında küçük varyasyonlara neden olabilmektedir. Bu nedenle, modelin yeniden eğitimi sırasında parametrelerin açık biçimde tanımlanması ve tekrarlanabilirliğin güvence altına alınması önemlidir. Ancak bu sınırlılıklar, çalışmanın genel geçerliliğini zedelememekte; tersine, gelecekte yapılacak iyileştirmelere yön verecek önemli gözlemler sağlamaktadır.

Gelecekteki akademik ve uygulamalı çalışmalar açısından, bu araştırma önemli bir temel oluşturmaktadır. Öncelikli olarak, geliştirilen modelin gerçek zamanlı izleme sistemleriyle entegrasyonu önerilmektedir. Bu doğrultuda, sensörlerin kablosuz veri aktarım altyapıları (Wi-Fi, LoRa, BLE vb.) ile desteklenmesi ve bulut tabanlı analiz modüllerinin geliştirilmesi, sistemin yalnızca laboratuvar koşullarında değil, endüstriyel üretim hatlarında ve ticari mutfaklarda da kullanılabilirliğini artıracaktır.

Gelecek çalışmalarda, veri çeşitliliğinin genişletilmesi ve modelin genelleme kabiliyetinin güçlendirilmesi önem taşımaktadır. Farklı yağ türleri ve kızartma koşullarını kapsayan deneysel çalışmalarla oluşturulacak geniş veri tabanları, modelin farklı ortamlarda geçerliliğini test etme olanağı sunacaktır. Ayrıca, çoklu sensör entegrasyonu ile sistemin çok boyutlu algılama kapasitesi artırılabilir. Bu tür çalışmalar, özellikle transfer öğrenimi (transfer learning) ve model ince ayarlama (fine-tuning) yaklaşımlarının etkinliğini değerlendirmek açısından da değerli olacaktır.

Buna ek olarak, açıklanabilir yapay zekâ (Explainable AI) yöntemlerinin gelecekteki araştırmalara entegre edilmesi, modelin karar süreçlerinin daha şeffaf ve bilimsel olarak yorumlanabilir hale gelmesini sağlayacaktır. Bu sayede sensör sinyallerinin hangi gaz bileşenlerinden etkilendiği ve bunların hangi kimyasal süreçleri temsil ettiği daha açık biçimde ortaya konabilecektir.

Bu çerçevede, taşınabilir sistem tasarımları ve saha testleri, çalışmanın uygulama potansiyelini güçlendirebilir. Düşük güç tüketimli mikrodenetleyici tabanlı sistemlerde BME688 sensörlerinin kullanılmasıyla geliştirilecek yerinde ölçüm cihazları, kızartma yağlarının otomatik kalite değerlendirmesini mümkün kılarak hem gıda güvenliği denetimlerine hem de endüstriyel süreç optimizasyonuna katkı sağlayabilir.

Nihai durumda bu çalışma, gaz sensörü tabanlı yapay zekâ modellerinin gıda kalite kontrolünde kullanılabilirliğini bilimsel olarak ortaya koymuş ve kızartma yağı kalitesinin izlenmesi konusunda yeni bir yaklaşım önermiştir. Elde edilen bulgular, BME688 sensörlerinin yüksek doğruluk, tekrarlanabilirlik ve kimyasal tutarlılık özellikleri sayesinde, gelecekte akıllı gıda izleme sistemlerinin temel bileşeni haline gelebileceğini göstermiştir. Bu yönüyle çalışma, yalnızca mevcut sistemin başarısını doğrulamakla kalmamış, aynı zamanda bilimsel literatürde yeni bir yöntemsel çerçeve oluşturmuştur.

KAYNAKLAR

- Abeshu, Y. (2023). Review on deep fat-fried food products safety and its implication for consumer healthiness. *Agriculture and food sciences research*, 10(2), 14-27. <https://doi.org/10.20448/aesr.v10i2.5195>
- Afaneh, I., Abbadi, J., Al-Rimawi, F., Al-Dabbas, G., & Sawalha, S. (2017). Effect of frying temperature and duration on the formation of trans fatty acids in selected fats and oils. *American journal of food science and technology*, 5(6), 245-248. <https://doi.org/10.12691/ajfst-5-6-4>
- Aghili, N. S., Rasekh, M., Karami, H., Edriss, O., Wilson, A. D., & Ramos, J. (2023). Aromatic fingerprints: VOC analysis with E-nose and GC-MS for rapid detection of adulteration in sesame oil. *Sensors (Basel, Switzerland)*, 23(14), 6294. <https://doi.org/10.3390/s23146294>
- Ahmad, M. H., Shahbaz, Z., Imran, M., Khan, M. K., Muhammad, N., Iqbal, S., Ahmed, W., & Ahmad, T. (2021). Monitoring of frying process in canola oil blend using fourier transform infrared and chemometrics techniques. *Food Science & Nutrition*, 9(11), 6089-6098. <https://doi.org/10.1002/fsn3.2558>
- Ahmadi, E., Mosafari, M., Nikniaz, L., Tabrizi, J. S., Asghari Jafarabadi, M., Safari, G., & Bargar, M. (2018). Frying oils quality control: necessity for new approach of supervision. *British Food Journal*, 120(2), 490-498. <https://doi.org/10.1108/BFJ-04-2017-0202>
- Ahmed, Z. A., & Mohammed, N. K. (2023). Influence of multiple deep-frying cycles on the characteristics of corn oil and acrylamide content in French fries. *IOP conference series. Earth and environmental science*, 1262(6), 062033. <https://doi.org/10.1088/1755-1315/1262/6/062033>
- Aladedunye, F. A., & Przybylski, R. (2009). Degradation and nutritional quality changes of oil during frying. *Journal of the American Oil Chemists' Society*, 86(2), 149-156. <https://doi.org/10.1007/s11746-008-1328-5>
- Al-Okby, M. F. R., Neubert, S., Roddelkopf, T., Fleischer, H., & Thurow, K. (2022). Evaluating of IAQ-index and TVOC parameter-based sensors for hazardous gases detection and alarming systems. *Sensors (Basel, Switzerland)*, 22(4), 1473. <https://doi.org/10.3390/s22041473>
- Al-Okby, M. F. R., Roddelkopf, T., Fleischer, H., & Thurow, K. (2022). Evaluating a novel gas sensor for ambient monitoring in automated life science laboratories. *Sensors (Basel, Switzerland)*, 22(21), 8161. <https://doi.org/10.3390/s22218161>
- Andre, R. S., Mercante, L. A., Facure, M. H. M., Sanfelice, R. C., Fugikawa-Santos, L., Swager, T. M., & Correa, D. S. (2022). Recent progress in Amine gas sensors for food quality monitoring: Novel architectures for sensing materials and systems. *ACS Sensors*, 7(8), 2104-2131. <https://doi.org/10.1021/acssensors.2c00639>
- Ban, L., Patel, N. M., & Schroeder, W. D. (2016). Identification of ingredients for stabilizing frying oil through a new screening method. *Journal of the American Oil Chemists' Society*, 93(9), 1183-1190. <https://doi.org/10.1007/s11746-016-2862-1>
- Ben Hammouda, I., Triki, M., Matthäus, B., & Bouaziz, M. (2018). A comparative study on formation of polar components, fatty acids and sterols during frying of refined Olive pomace oil pure and its blend coconut oil. *Journal of Agricultural and Food Chemistry*, 66(13), 3514-3523. <https://doi.org/10.1021/acs.jafc.7b05163>
- Bordón, M. G., Meriles, S. P., Ribotta, P. D., & Martinez, M. L. (2019). Enhancement of composition and oxidative stability of Chia (*Salvia hispanica* L.) seed oil by blending with specialty oils. *Journal of Food Science*, 84(5), 1035-1044. <https://doi.org/10.1111/1750-3841.14580>

- Botticini, S., Comini, E., Dello Iacono, S., Flammini, A., Gaioni, L., Galliani, A., Ghislotti, L., Lazzaroni, P., Re, V., Sisinni, E., Verzeroli, M., & Zappa, D. (2024). Index Air Quality monitoring for light and active mobility. *Sensors (Basel, Switzerland)*, 24(10), 3170. <https://doi.org/10.3390/s24103170>
- Boukandoul, S., Zaidi, F., Santos, C. S. P., & Casal, S. (2023). Moringa oleifera oil nutritional and safety impact on deep-fried potatoes. *Foods (Basel, Switzerland)*, 12(24), 4416. <https://doi.org/10.3390/foods12244416>
- Cardoso-Ugarte, G. A., Morlán-Palmas, C. C., & Sosa-Morales, M. E. (2013). Effect of the addition of basil essential oil on the degradation of palm olein during repeated deep frying of French fries: Basil essential oil in olein for frying.... *Journal of Food Science*, 78(7), C978-84. <https://doi.org/10.1111/1750-3841.12166>
- Chaiyasit, W., McClements, D. J., Weiss, J., & Decker, E. A. (2008). Impact of surface-active compounds on physicochemical and oxidative properties of edible oil. *Journal of Agricultural and Food Chemistry*, 56(2), 550-556. <https://doi.org/10.1021/jf072071o>
- Chen, J. Y., Zhang, H., Ma, J., Tuchiya, T., & Miao, Y. (2015). Determination of the degree of degradation of frying rapeseed oil using fourier-transform infrared spectroscopy combined with partial least-squares regression. *International Journal of Analytical Chemistry*, 2015, 185367. <https://doi.org/10.1155/2015/185367>
- Crexi, V. T., Monte, M. L., Soares, L. A. de S., & Pinto, L. A. A. (2010). Production and refinement of oil from carp (*Cyprinus carpio*) viscera. *Food Chemistry*, 119(3), 945-950. <https://doi.org/10.1016/j.foodchem.2009.07.050>
- Csallany, A. S., Han, I., Shoeman, D. W., Chen, C., & Yuan, J. (2015). 4-hydroxynonenal (HNE), a toxic aldehyde in French fries from fast food restaurants. *Journal of the American Oil Chemists' Society*, 92(10), 1413-1419. <https://doi.org/10.1007/s11746-015-2699-z>
- Culler, M. D., Inchingolo, R., McClements, D. J., & Decker, E. A. (2021). Impact of polyunsaturated fatty acid dilution and antioxidant addition on lipid oxidation kinetics in oil/water emulsions. *Journal of Agricultural and Food Chemistry*, 69(2), 750-755. <https://doi.org/10.1021/acs.jafc.0c06209>
- Dahl, S., & Malcata, F. X. (1999). Characterization of forced oxidation of sardine oil: Physicochemical data and mathematical modeling. *Journal of the American Oil Chemists' Society*, 76(5), 633-641. <https://doi.org/10.1007/s11746-999-0015-5>
- Das, A. K., Babylatha, R., Pavithra, A. S., & Khatoon, S. (2013). Thermal degradation of groundnut oil during continuous and intermittent frying. *Journal of Food Science and Technology*, 50(6), 1186-1192. <https://doi.org/10.1007/s13197-011-0452-7>
- Dash, K. K., Sharma, M., & Tiwari, A. (2022). Heat and mass transfer modeling and quality changes during deep fat frying: A comprehensive review. *Journal of Food Process Engineering*. <https://doi.org/10.1111/jfpe.13999>
- de Abreu, D. A. P., Rodríguez, K. V., & Cruz Freire, J. M. (2011). Effectiveness of antioxidants on lipid oxidation and lipid hydrolysis of cod liver oil. *European Journal of Lipid Science and Technology: EJLST*, 113(11), 1395-1401. <https://doi.org/10.1002/ejlt.201100189>
- Dhakal, A., Paudel, D., Pokharel, P., & Koirala, S. (2024). Quality assessment of commercially refined sunflower oil found in the market of Pokhara, Nepal. *Nepal journal of biotechnology*, 12(1), 81-88. <https://doi.org/10.54796/njb.v12i1.324>
- Farhoosh, R., & Moosavi, S. M. R. (2007). Rancimat test for the assessment of used frying oils quality. *Journal of Food Lipids*, 14(3), 263-271. <https://doi.org/10.1111/j.1745-4522.2007.00084.x>
- Freis, A. M., & Vemulapalli, S. P. B. (2025). Analysis of the generation of harmful aldehydes in edible oils during sunlight exposure and deep-frying using high-field proton nuclear

magnetic resonance spectroscopy. *Foods (Basel, Switzerland)*, 14(3), 513. <https://doi.org/10.3390/foods14030513>

- Furlan Gonçalves Dias, F., Teixeira, B. F., Vieira, T. M. F. de S., de Moura Bell, J. M. L. N., & Taha, A. Y. (2023). Storage duration and added docosahexaenoic acid modify the rates of esterified and free oxylipin formation in infant milk formula. *Processes (Basel, Switzerland)*, 11(10), 3045. <https://doi.org/10.3390/pr11103045>
- Gancarz, M., Nawrocka, A., & Rusinek, R. (2019). Identification of volatile organic compounds and their concentrations using a novel method analysis of MOS sensors signal. *Journal of Food Science*, 84(8), 2077-2085. <https://doi.org/10.1111/1750-3841.14701>
- Gao, H.-X., Yu, J., Chen, N., & Zeng, W.-C. (2020). Effects and mechanism of tea polyphenols on the quality of oil during frying process. *Journal of Food Science*, 85(11), 3786-3796. <https://doi.org/10.1111/1750-3841.15470>
- Gao, Y., Zheng, Y., Yao, F., & Chen, F. (2023). A novel strategy for the demulsification of peanut oil body by caproic acid. *Foods (Basel, Switzerland)*, 12(16), 3029. <https://doi.org/10.3390/foods12163029>
- Gertz, C., Aladedunye, F., & Matthäus, B. (2017). A new analytical and statistical approach to predict the sensory properties of deep frying fats and oils to determine the point of discard during processing: Disposal point of used frying oils. *European Journal of Lipid Science and Technology: EJLST*, 119(11), 1600393. <https://doi.org/10.1002/ejlt.201600393>
- Gertz, C., & Behmer, D. (2014). Application of FT-NIR spectroscopy in assessment of used frying fats and oils: FT-NIR spectroscopy in assessment of used frying fats and oils. *European Journal of Lipid Science and Technology: EJLST*, 116(6), 756-762. <https://doi.org/10.1002/ejlt.201300270>
- Golmakani, M.-T., Soltani, A., Hosseini, S. M. H., & Keramat, M. (2020). Improving the oxidation kinetics of linseed oil using the blending approach. *Journal of Food Processing and Preservation*. <https://doi.org/10.1111/jfpp.14964>
- Gotoh, N., Watanabe, H., Osato, R., Iwasawa, A., Inagaki, K., & Wada, S. (2005). New Sight on the possibility of the neurotoxic behavior affected by the oxidized compounds in fats and oils. *Journal of oleo science*, 54(7), 397-405. <https://doi.org/10.5650/jos.54.397>
- Grootveld, M., Percival, B. C., Leenders, J., & Wilson, P. B. (2020). Potential adverse public health effects afforded by the ingestion of dietary lipid oxidation product toxins: Significance of fried food sources. *Nutrients*, 12(4), 974. <https://doi.org/10.3390/nu12040974>
- Grossi, M., Valli, E., Bendini, A., Gallina Toschi, T., & Riccò, B. (2022). A portable battery-operated sensor system for simple and rapid assessment of virgin Olive oil quality grade. *Chemosensors (Basel, Switzerland)*, 10(3), 102. <https://doi.org/10.3390/chemosensors10030102>
- Gutiérrez-Del-Río, I., López-Ibáñez, S., Magadán-Corpas, P., Fernández-Calleja, L., Pérez-Valero, Á., Tuñón-Granda, M., Miguélez, E. M., Villar, C. J., & Lombó, F. (2021). Terpenoids and polyphenols as natural antioxidant agents in food preservation. *Antioxidants (Basel, Switzerland)*, 10(8), 1264. <https://doi.org/10.3390/antiox10081264>
- Gutiérrez-Flores, I. A., Garcia-Galindo, H. S., Moran, J. S., Cavazos-Garduño, A., & Serrano-Niño, J. C. (2024). Assessment of acrolein development during frying and its relation in acrylamide formation. *İçinde Research Square*. <https://doi.org/10.21203/rs.3.rs-5291157/v1>
- Hani Suhaimi, N., Sidik Fadhlullah Zuhair, J., Arlamsyah Azlan, M., Hamid Juliana, A., Noor Mohd Mustazil, M., Zainalabidin, S., Jaarin, K., Mohamed, S., & Kamisah, Y. (2020). Addition of citrus leaf extract into frying oil prevents hypertension and improves vascular reactivity in heated oil-fed rats. *Journal of food and nutrition research*, 8(8), 417-423. <https://doi.org/10.12691/jfnr-8-8-5>

- Houhoula, D. P., Oreopoulou, V., & Tzia, C. (2003). The effect of process time and temperature on the accumulation of polar compounds in cottonseed oil during deep-fat frying. *Journal of the Science of Food and Agriculture*, 83(4), 314-319. <https://doi.org/10.1002/jsfa.1314>
- Javeed, S., Alimgeer, K. S., Javed, W., Atif, M., & Uddin, M. (2018). A modified artificial neural network based prediction technique for tropospheric radio refractivity. *PloS One*, 13(3), e0192069. <https://doi.org/10.1371/journal.pone.0192069>
- Jiang, H., Chen, W., Jia, Z., & Tao, F. (2020). Physiochemical properties of short-term frying oil for chicken wing and its oxidative stability in an oil-in-water emulsion. *Food Science & Nutrition*, 8(1), 668-674. <https://doi.org/10.1002/fsn3.1355>
- Kampa, J., Frazier, R., & Rodriguez-Garcia, J. (2022). Physical and chemical characterisation of conventional and nano/emulsions: Influence of vegetable oils from different origins. *Foods (Basel, Switzerland)*, 11(5), 681. <https://doi.org/10.3390/foods11050681>
- Kanner, J. (2007). Dietary advanced lipid oxidation endproducts are risk factors to human health. *Molecular Nutrition & Food Research*, 51(9), 1094-1101. <https://doi.org/10.1002/mnfr.200600303>
- Karakaya, S., & Şimşek, Ş. (2011). Changes in total polar compounds, peroxide value, total phenols and antioxidant activity of various oils used in deep fat frying. *Journal of the American Oil Chemists' Society*, 88(9), 1361-1366. <https://doi.org/10.1007/s11746-011-1788-x>
- Karami, H., Rasekh, M., & Mirzaee-Ghaleh, E. (2020). Application of the E-nose machine system to detect adulterations in mixed edible oils using chemometrics methods. *Journal of Food Processing and Preservation*, 44(9). <https://doi.org/10.1111/jfpp.14696>
- Khaled, A. Y., Abd Aziz, S., Rokhani, F. Z., & Ibrahim, N. U. A. (2018). Interdigitated electrode for degradation assessment of palm olein during batch deep fat frying. *Transactions of the ASABE*, 61(1), 15-24. <https://doi.org/10.13031/trans.11840>
- Khor, Y. P., Hew, K. S., Abas, F., Lai, O. M., Cheong, L. Z., Nehdi, I. A., Sbihi, H. M., Gewik, M. M., & Tan, C. P. (2019). Oxidation and polymerization of triacylglycerols: In-depth investigations towards the impact of heating profiles. *Foods (Basel, Switzerland)*, 8(10), 475. <https://doi.org/10.3390/foods8100475>
- Kim, J. K., Lim, H.-J., Shin, D.-H., & Shin, E.-C. (2015). Comparison of nutritional quality and thermal stability between peanut oil and common frying oils. *Journal of the Korean Society for Applied Biological Chemistry*, 58(4), 527-532. <https://doi.org/10.1007/s13765-015-0075-1>
- Kita, A. (2014). The effect of frying on fat uptake and texture of fried potato products: Effect of frying on fat uptake and texture of fried potato. *European Journal of Lipid Science and Technology: EJLST*, 116(6), 735-740. <https://doi.org/10.1002/ejlt.201300276>
- Ku, H.-H., Lung, C.-F., & Chi, C.-H. (2023). Design of an Artificial Intelligence of Things-based sesame oil Evaluator for quality assessment using gas sensors and deep learning mechanisms. *Foods (Basel, Switzerland)*, 12(21), 4024. <https://doi.org/10.3390/foods12214024>
- Kumar, A., O'Leary, C., Winkless, R., Thompson, M., Davies, H. L., Shaw, M., Andrews, S. J., Carslaw, N., & Dillon, T. J. (2025). Fingerprinting the emissions of volatile organic compounds emitted from the cooking of oils, herbs, and spices. *Environmental Science. Processes & Impacts*, 27(1), 244-261. <https://doi.org/10.1039/d4em00579a>
- Lahat, D., Adali, T., & Jutten, C. (2015). Multimodal data fusion: An overview of methods, challenges, and prospects. *Proceedings of the IEEE. Institute of Electrical and Electronics Engineers*, 103(9), 1449-1477. <https://doi.org/10.1109/jproc.2015.2460697>

- Leong, X.-F. (2021). Lipid oxidation products on inflammation-mediated hypertension and atherosclerosis: A mini review. *Frontiers in Nutrition*, 8, 717740. <https://doi.org/10.3389/fnut.2021.717740>
- Li, X., Liu, Y.-J., Liu, Y.-F., & Xu, Y.-J. (2023). Deep-frying oil intake and risk of intestinal barrier dysfunction: a systematic review and meta-analyses. *International Journal of Food Science & Technology*, 58(4), 1720-1727. <https://doi.org/10.1111/ijfs.16343>
- Lima, J. de J. A. de, Maldaner, L. F., & Molin, J. P. (2021). Sensor fusion with NARX neural network to predict the mass flow in a sugarcane harvester. *Sensors (Basel, Switzerland)*, 21(13), 4530. <https://doi.org/10.3390/s21134530>
- Liu, X., Wang, S., Tamogami, S., Chen, J., & Zhang, H. (2022). An evaluation model for the quality of frying oil using key aldehyde detected by HS-GC/MS. *Foods (Basel, Switzerland)*, 11(16), 2413. <https://doi.org/10.3390/foods11162413>
- Ma, M., Yang, X., Ying, X., Shi, C., Jia, Z., & Jia, B. (2023). Applications of gas sensing in food quality detection: A review. *Foods (Basel, Switzerland)*, 12(21), 3966. <https://doi.org/10.3390/foods12213966>
- Mazı, B. G., & Çoban Bayram, M. (2025). Reduced-sugar cocoa hazelnut spread: The effect of Stevia-inulin substitution on physicochemical, microbiological, and sensory properties. *Cukurova University, Agriculture Faculty, 1*. <https://doi.org/10.36846/cjafs.2025.179>
- Mehany, T., González-Sáiz, J. M., Martínez, J., & Pizarro, C. (2024). Evaluation of sensorial markers in deep-fried extra virgin Olive oils: First report on the role of hydroxytyrosol and its derivatives. *Foods (Basel, Switzerland)*, 13(23), 3953. <https://doi.org/10.3390/foods13233953>
- Messina, V., Sancho, A., & Walsøe de Reca, N. (2015). Monitoring odour of heated extra-virgin olive oils from Arbequina and Manzanilla cultivars using an electronic nose: Odour profile of extra-virgin olive oil using electronic nose. *European Journal of Lipid Science and Technology: EJLST*, 117(8), 1295-1300. <https://doi.org/10.1002/ejlt.201400651>
- Milli, Mehmet, Söylemez Milli, N., & Parlak, İ. H. (2025). Rapid detection of honey adulteration using machine learning on gas sensor data. *Npj Science of Food*, 9(1), 74. <https://doi.org/10.1038/s41538-025-00440-9>
- Milli, Musa, & Milli, M. (2025). Reducing false positives in building fire detection systems via multiple metal oxide sensors. *IEEE access: practical innovations, open solutions*, 1-1. <https://doi.org/10.1109/access.2025.3606584>
- Miyagi, A., & Nakajima, M. (2003). Regeneration of used frying oils using adsorption processing. *Journal of the American Oil Chemists' Society*, 80(1), 91. <https://doi.org/10.1007/s11746-003-0657-5>
- Molina-Garcia, L., Santos, C. S. P., Cunha, S. C., Casal, S., & Fernandes, J. O. (2017). Comparative fingerprint changes of toxic volatiles in low PUFA vegetable oils under deep-frying. *Journal of the American Oil Chemists' Society*, 94(2), 271-284. <https://doi.org/10.1007/s11746-016-2943-1>
- Negishi, H., Nishida, M., Endo, Y., & Fujimoto, K. (2003). Effect of a modified deep-fat fryer on chemical and physical characteristics of frying oil. *Journal of the American Oil Chemists' Society*, 80(2), 163-166. <https://doi.org/10.1007/s11746-003-0670-8>
- Nicolle, A., Deng, S., Ihme, M., Kuzhagaliyeva, N., Ibrahim, E. A., & Farooq, A. (2024). Mixtures recomposition by neural nets: A multidisciplinary overview. *Journal of Chemical Information and Modeling*, 64(3), 597-620. <https://doi.org/10.1021/acs.jcim.3c01633>
- Oliveira, S. M. de, Jesus, T. A. B. de, Lariú, K. A., Jesus, C. G. da S. de, & Akil, E. (2024). Quality investigation of the most consumed refined seed oils after French fries' domestic short-

term deep-frying process. *OBSERVATÓRIO DE LA ECONOMÍA LATINOAMERICANA*, 22(3), e3917. <https://doi.org/10.55905/oelv22n3-189>

- Ooi, E. Z. H., Ab Karim, N. A., Chan, E.-S., Wang, Y., Tang, T.-K., Tong, S. C., Khor, Y. P., & Lee, Y.-Y. (2024). Underutilised palm stearin as hard stock for deep-frying medium and its performance for oil uptake in instant noodles. *Journal of the Science of Food and Agriculture*, 104(7), 3958-3970. <https://doi.org/10.1002/jsfa.13278>
- Parlak, İ. H., Milli, M., & Milli, N. S. (2025). Machine learning-based detection of Olive oil adulteration using BME688 gas sensor matrix. *Food Analytical Methods*, 18(7), 1454-1464. <https://doi.org/10.1007/s12161-025-02803-0>
- Pereira, J., Mota, A., Couto, P., Valente, A., & Serôdio, C. (2025). Potential use of BME Development Kit and machine learning methods for odor identification: A case study. *Applied Sciences (Basel, Switzerland)*, 15(17), 9687. <https://doi.org/10.3390/app15179687>
- Pires, I. M., Garcia, N. M., Pombo, N., Flórez-Revuelta, F., Spinsante, S., & Teixeira, M. C. (2018). Identification of activities of daily living through data fusion on motion and magnetic sensors embedded on mobile devices. *Pervasive and Mobile Computing*, 47, 78-93. <https://doi.org/10.1016/j.pmcj.2018.05.005>
- Pires, I. M., Marques, G., Garcia, N. M., Flórez-Revuelta, F., Canavarro Teixeira, M., Zdravevski, E., Spinsante, S., & Coimbra, M. (2020). Pattern recognition techniques for the identification of activities of daily living using a mobile device accelerometer. *Electronics*, 9(3), 509. <https://doi.org/10.3390/electronics9030509>
- Quiles, J. L., Huertas, J. R., Battino, M., Ramírez-Tortosa, M. C., Cassinello, M., Mataix, J., Lopez-Frias, M., & Mañas, M. (2002). The intake of fried virgin olive or sunflower oils differentially induces oxidative stress in rat liver microsomes. *The British Journal of Nutrition*, 88(1), 57-65. <https://doi.org/10.1079/bjn2002588>
- Rasekh, M., Karami, H., Wilson, A. D., & Gancarz, M. (2021). Performance analysis of MAU-9 electronic-nose MOS sensor array components and ANN classification methods for discrimination of herb and fruit essential oils. *Chemosensors (Basel, Switzerland)*, 9(9), 243. <https://doi.org/10.3390/chemosensors9090243>
- Romano, R., Giordano, A., Le Grottaglie, L., Manzo, N., Paduano, A., Sacchi, R., & Santini, A. (2013). Volatile compounds in intermittent frying by gas chromatography and nuclear magnetic resonance: Volatile compounds in intermittent frying. *European Journal of Lipid Science and Technology: EJLST*, 115(7), 764-773. <https://doi.org/10.1002/ejlt.201200341>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Sanibal, E. A. A., & Mancini-Filho, J. (2004). Frying oil and fat quality measured by chemical, physical, and test kit analyses. *Journal of the American Oil Chemists' Society*, 81(9), 847-852. <https://doi.org/10.1007/s11746-004-0990-8>
- Sarif, R., Al-Okby, M. F. R., Roddelkopf, T., & Thurow, K. (2024). Mobile gas sensing for laboratory infrastructure. *IJUM engineering journal*, 25(1), 178-207. <https://doi.org/10.31436/iiumej.v25i1.2727>
- Sathyanarayanan, S. (2024). Confusion matrix-based performance evaluation metrics. *African Journal of Biomedical Research*, 4023-4031. <https://doi.org/10.53555/ajbr.v27i4s.4345>
- Scientific, Industrial and Technological Application and Research Center (SITARC), Bolu Abant İzzet Baysal University, Bolu, Turkey, Söylemez Milli, N., Parlak, İ. H., Department of Computer Engineering, Bolu Abant İzzet Baysal University, Bolu, Turkey, Milli, M., & Department of Computer Engineering, Bolu Abant İzzet Baysal University, Bolu, Turkey. (2025). A new approach for machine learning-based recognition of meat species using a BME688 gas sensors matrix. *Warasan Khana Witthayasat, Mahawitthayalai Chiang Mai*

- Seppanen, C. M., & Csallany, A. S. (2006). The effect of intermittent and continuous heating of soybean oil at frying temperature on the formation of 4-hydroxy-2-trans-nonenal and other α -, β -unsaturated hydroxyaldehydes. *Journal of the American Oil Chemists' Society*, 83(2), 121-127. <https://doi.org/10.1007/s11746-006-1184-0>
- Sharanke, K., & Sivakanthan, S. (2022). Comparative study on stability of coconut oil, sunflower oil and palm oil during continuous deep frying. *Ceylon journal of science*, 51(4), 359. <https://doi.org/10.4038/cjs.v51i4.8053>
- Simsek, O. I., & Alagoz, B. B. (2023). Optimal architecture artificial neural network model design with exploitative alpha gray wolf optimization for soft calibration of CO concentration measurements in electronic nose applications. *Transactions of the Institute of Measurement and Control*, 45(4), 686-699. <https://doi.org/10.1177/01423312221119648>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Takhar, M., Li, Y., Ditto, J. C., & Chan, A. W. H. (2023). Formation pathways of aldehydes from heated cooking oils. *Environmental Science. Processes & Impacts*, 25(2), 165-175. <https://doi.org/10.1039/d1em00532d>
- Tarmizi, A. H. A., & Lin, S. W. (2008). Quality assessment of palm products upon prolonged heat treatment. *Journal of Oleo Science*, 57(12), 639-648. <https://doi.org/10.5650/jos.57.639>
- Thao, L. Q., Kien, D. T., Thien, N. D., Bach, N. C., Dung, T. T., & Thuy, L. T. M. (2024). Rapid assessment of degraded frying oil quality using interdigitated microelectrode capacitive sensors. *European Journal of Lipid Science and Technology: EJLST*, 126(1). <https://doi.org/10.1002/ejlt.202300138>
- Thelen, M. M., Flores, S. A., Kelley, J. A., Swank, B. R., Winkler-Moser, J. K., & Phaner, M. J. (2025). Toward rapid analysis of unsaturated fatty acid oxidation in edible oils via square-wave voltammetry. *Journal of the American Oil Chemists' Society*, 102(9), 1339-1349. <https://doi.org/10.1002/aocs.12973>
- Tomović, V., Šojić, B., Savanović, J., Kocić-Tanackov, S., Pavlić, B., Jokanović, M., Đorđević, V., Parunović, N., Martinović, A., & Vujadinović, D. (2020). New formulation towards healthier meat products: *Juniperus communis* L. essential oil as alternative for sodium nitrite in dry fermented sausages. *Foods (Basel, Switzerland)*, 9(8), 1066. <https://doi.org/10.3390/foods9081066>
- Velasco, J., Marmesat, S., Márquez-Ruiz, G., & Dobarganes, M. C. (2004). Formation of short-chain glycerol-bound oxidation products and oxidised monomeric triacylglycerols during deep-frying and occurrence in used frying fats. *European Journal of Lipid Science and Technology: EJLST*, 106(11), 728-735. <https://doi.org/10.1002/ejlt.200401032>
- Vu, P. T., & Boonyarattanakalin, S. (2013). Trans fat formation and lipid oxidation in palm olein during prolonged thermal treatments. *Journal of medical and bioengineering*, 2(3), 214-217. <https://doi.org/10.12720/jomb.2.3.214-217>
- Waluyo, B., Sinuraya, A., & Bintang, S. (2020). Fiber optic sensor array for perfume detection using neural network. *Proceedings of the Proceedings of the the 3rd Annual Conference of Engineering and Implementation on Vocational Education, ACEIVE 2019, 16 November 2019, Universitas Negeri Medan, North Sumatra, Indonesia*. Proceedings of the the 3rd Annual Conference of Engineering and Implementation on Vocational Education, ACEIVE 2019, 16 November 2019, Universitas Negeri Medan, North Sumatra, Indonesia, Medan, Indonesia. <https://doi.org/10.4108/eai.16-11-2019.2293244>

- Wang, L., Chen, W., Tian, Y., Duan, X., Yuan, Y., Wang, N., Xu, C., Liu, X., & Liu, Z. (2022). Preventive effects of sesamol on deep-frying oil-induced liver metabolism disorders by altering gut Microbiota and protecting gut barrier integrity. *Molecular Nutrition & Food Research*, 66(9), e2101122. <https://doi.org/10.1002/mnfr.202101122>
- Wang, L., Csallany, A. S., Kerr, B. J., Shurson, G. C., & Chen, C. (2016). Kinetics of forming aldehydes in frying oils and their distribution in French fries revealed by LC-MS-based chemometrics. *Journal of Agricultural and Food Chemistry*, 64(19), 3881-3889. <https://doi.org/10.1021/acs.jafc.6b01127>
- Wang, Y., Yu, X., Chen, X., Yang, Y., & Zhang, J. (2014). Application of Fourier transform near-infrared spectroscopy to the quantification and monitoring of carbonyl value in frying oils. *Analytical methods: advancing methods and applications*, 6(19), 7628-7633. <https://doi.org/10.1039/c4ay00703d>
- Waraho, T., Cardenia, V., Rodriguez-Estrada, M. T., McClements, D. J., & Decker, E. A. (2009). Prooxidant mechanisms of free fatty acids in stripped soybean oil-in-water emulsions. *Journal of Agricultural and Food Chemistry*, 57(15), 7112-7117. <https://doi.org/10.1021/jf901270m>
- Warner, K., & Laszlo, J. A. (2005). Addition of ferulic acid, ethyl ferulate, and feruloylated monoacyl- and diacylglycerols to salad oils and frying oils. *Journal of the American Oil Chemists' Society*, 82(9), 647-652. <https://doi.org/10.1007/s11746-005-1123-0>
- Weerakoon, N. P., Senadheera, S., & Jayawardhana, I. (2019). Repeated heating of edible oils: effects on polyphenolic content and antioxidant capacity. *Anuradhapura Medical Journal*, 13(1), 4. <https://doi.org/10.4038/amj.v13i1.7655>
- Weisshaar, R. (2014). Quality control of used deep-frying oils: Quality control of used deep frying oils. *European Journal of Lipid Science and Technology: EJLST*, 116(6), 716-722. <https://doi.org/10.1002/ejlt.201300269>
- Wilson, A. D. (2015). Advances in electronic-nose technologies for the detection of volatile biomarker metabolites in the human breath. *Metabolites*, 5(1), 140-163. <https://doi.org/10.3390/metabo5010140>
- Wu, J., Xu, L., Chen, Q., & Ye, Z. (2024). Multi-sensor data fusion path combining fuzzy theory and neural networks. *Intelligent Decision Technologies*, 18(4), 3365-3378. <https://doi.org/10.3233/idt-240316>
- Xu, L., Wu, G., Ji, X., Zhang, H., Jin, Q., & Wang, X. (2021). Influence of prolonged deep-frying using various oils on volatile compounds formation of French fries using GC-MS, GC-O, and sensory evaluation. *Journal of the American Oil Chemists' Society*, 98(6), 657-671. <https://doi.org/10.1002/aocs.12489>
- Yılmaz, B., Şahin, T. Ö., & Ağagündüz, D. (2023). Oxidative changes in ten vegetable oils caused by the deep-frying process of potato. *Journal of Food Biochemistry*, 2023, 1-11. <https://doi.org/10.1155/2023/6598528>
- Yildiz, A. Y., Echegaray, N., Öztekin, S., & Lorenzo, J. M. (2024). Quality and stability of frying oils and fried foods in ultrasound and microwave-assisted frying processes and hybrid technologies. *Comprehensive Reviews in Food Science and Food Safety*, 23(4), e13405. <https://doi.org/10.1111/1541-4337.13405>
- Ying, X., Li, X., Ma, L., Wang, F., Xiao, G., Benjakul, S., & Liu, D. (2024). Lipidomics-based study of lipid quality of fish by-products: a case study of sea bass (*Lateolabrax japonicus*). *International Journal of Food Science & Technology*, 59(5), 3097-3105. <https://doi.org/10.1111/ijfs.17051>
- Yongyod, R., & Kerdsin, A. (2025). Modified test kit for detecting polar compounds and evaluating their distribution in reused frying oil. *Foods (Basel, Switzerland)*, 14(9), 1572. <https://doi.org/10.3390/foods14091572>

- Yurko, G., Roostaei, J., Dittrich, T., Xu, L., Ewing, M., Zhang, Y., & Shreve, G. (2019). Real-time sensor response characteristics of 3 commercial metal oxide sensors for detection of BTEX and chlorinated aliphatic hydrocarbon organic vapors. *Chemosensors (Basel, Switzerland)*, 7(3), 40. <https://doi.org/10.3390/chemosensors7030040>
- Zhang, C.-X., Xi, J., Wang, S.-T., Ma, Y.-X., & Wang, X.-D. (2022). Effects of deep fat frying conditions on the formation of heterocyclic aromatic amines in chicken meat. *Food Science and Technology*, 42(e67321). <https://doi.org/10.1590/fst.67321>
- Zhang, J., Chen, X., Yang, R., Ma, Q., Qi, W., Sanidad, K. Z., Park, Y., Kim, D., Decker, E. A., & Zhang, G. (2019). Thermally processed oil exaggerates colonic inflammation and colitis-associated colon tumorigenesis in mice. *Cancer Prevention Research (Philadelphia, Pa.)*, 12(11), 741-750. <https://doi.org/10.1158/1940-6207.CAPR-19-0226>
- Zhang, Q., Qin, W., Li, M., Shen, Q., & Saleh, A. S. M. (2015). Application of chromatographic techniques in the detection and identification of constituents formed during food frying: A review: Chromatographic analysis of frying oil.... *Comprehensive Reviews in Food Science and Food Safety*, 14(5), 601-633. <https://doi.org/10.1111/1541-4337.12147>
- Zhang, Y., Wu, G., Chang, C., Lv, Y., Lai, W., Zhang, H., Wang, X., & Jin, Q. (2020). Determination of origin of commercial flavored rapeseed oil by the pattern of volatile compounds obtained via GC–MS and flash GC electronic nose. *European Journal of Lipid Science and Technology: EJLST*, 122(3), 1900332. <https://doi.org/10.1002/ejlt.201900332>
- Zhao, Y., Xu, Y., Shi, L., & Fan, Y. (2021). Perovskite nanomaterial-engineered multiplex-mode fluorescence sensing of edible oil quality. *Analytical Chemistry*, 93(31), 11033-11042. <https://doi.org/10.1021/acs.analchem.1c02425>
- Zribi, A., Jabeur, H., Aladedunye, F., Rebai, A., Matthäus, B., & Bouaziz, M. (2014). Monitoring of quality and stability characteristics and fatty acid compositions of refined olive and seed oils during repeated pan- and deep-frying using GC, FT-NIRS, and chemometrics. *Journal of Agricultural and Food Chemistry*, 62(42), 10357-10367. <https://doi.org/10.1021/jf503146f>
- Zribi, A., Jabeur, H., Matthäus, B., & Bouaziz, M. (2016). Quality control of refined oils mixed with palm oil during repeated deep-frying using FT-NIRS, GC, HPLC, and multivariate analysis: Quality control of deep-frying oil blends. *European Journal of Lipid Science and Technology: EJLST*, 118(4), 512-523. <https://doi.org/10.1002/ejlt.201500149>
- Zulim Botega, D., Bastida, S., Marmesat, S., Pérez-Olleros, L., Ruiz-Roso, B., & Sánchez-Muniz, F. J. (2009). Carob fruit polyphenols reduce tocopherol loss, triacylglycerol polymerization and oxidation in heated sunflower oil. *Journal of the American Oil Chemists' Society*, 86(5), 419-425. <https://doi.org/10.1007/s11746-009-1368-5>
- Zulu, N., Kayitesi, E., & Ogundele, O. M. (2021). Chemical and deep-frying oxidative stability of sunflower–red palm olein blends. *British Food Journal (Croydon, England)*, 123(12), 3938-3953. <https://doi.org/10.1108/bfj-09-2020-0837>