



**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI**

YÜKSEK LİSANS TEZİ

**VERİ TEMELLİ SİNYAL İŞLEME VE DURUM ANALİZİ
YÖNTEMLERİYLE KURU ÇAY KALİTESİNİN TESPİTİ**

**Yazar
Ahmet Turan TAŞDEMİR**

**Danışman
Doç. Dr. Erkan Caner ÖZKAT**

**RİZE
2026**



**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
MAKİNE MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI**

**VERİ TEMELLİ SİNYAL İŞLEME VE DURUM ANALİZİ
YÖNTEMLERİYLE KURU ÇAY KALİTESİNİN TESPİTİ**

Yüksek Lisans Tezi

Ahmet Turan TAŞDEMİR

**Danışman
Doç. Dr. Erkan Caner ÖZKAT
İkinci Danışman
Prof. Dr. Fatih GÜL**

**RİZE
2026**

KABUL VE ONAY

Recep Tayyip Erdoğan Üniversitesi, Lisansüstü Eğitim Enstitüsü, Makine Mühendisliği Anabilim Dalında, Doç. Dr. Erkan Caner ÖZKAT danışmanlığında ve Prof. Dr. Fatih GÜL'ün ikinci danışmanlığında, Ahmet Turan TAŞDEMİR tarafından hazırlanan **Veri Temelli Sinyal İşleme ve Durum Analizi Yöntemleriyle Kuru Çay Kalitesinin Tespiti** adlı bu tez çalışması, 09/06/2026 tarihinde yapılan savunma sınavı sonucunda oy birliğiyle başarılı bulunarak jürimiz tarafından **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Jüri Üyeleri	Ünvanı, Adı SOYADI	Sonuç
Başkan	: Doç. Dr. Erkan Caner ÖZKAT	☒ Kabul ☐ Ret
Üye	: Doç. Dr. Ebru ERGÜN	☒ Kabul ☐ Ret
Üye	: Doç. Dr. Mehmet KONAR	☒ Kabul ☐ Ret

ETİK BEYAN

Makine Mühendisliği Tezli Yüksek Lisans Programından mezun olmak üzere teslim ettiğim **Veri Temelli Sinyal İşleme ve Durum Analizi Yöntemleriyle Kuru Çay Kalitesinin Tespiti** adlı tezim, bilim ve araştırma etiği prensiplerine riayet edilerek tarafımdan yazılmıştır.

Tez çalışmamda, başka kaynaklardan aktarılan bütün bilgi ve alıntılar, Enstitünüz Tez Yazım Kılavuzuna uygun olarak açıkça gösterilmiştir. Kaynağı gösterilenler dışında kalan bütün bilgiler uygun araştırma yöntemi kullanılarak tarafımdan edinilmiş ve esere bu şekilde yansıtılmıştır. Şahsıma ait olmayan hiçbir bilgi, kasıt veya kusurlar, şahsıma aitmiş gibi gösterilmemiştir. İnternet kaynakları dâhil, sahibine/kaynağına atıf yapılmaksızın hiçbir bilgi kullanılmamıştır. Aksinin ortaya çıkması halinde doğacak bütün hukuki, idari, akademik ve etik sorumluluk tarafıma ait olacaktır. Eserin tesliminden sonra herhangi bir zamanda, bilim etiğine aykırılık tespit edilmesi ve / veya eserimle ilgili intihal veya intihal şeklinde anlaşılacak bir durumun ortaya çıkması halinde; Üniversiteniz ve eğitim kadronuzun hiçbir şekilde sorumlu tutulmayacağını hür irademle kabul, beyan ve taahhüt ederim.

09/06/2026

Ahmet Turan TAŞDEMİR

ÖN SÖZ

Günümüzde bilim ve mühendislik alanlarında veri temelli yöntemler, araştırma ve uygulamalarda önemli bir yer edinmiştir. Sistem güvenilirliğinin artırılması, performansın izlenmesi ve kalite güvencesinin sağlanması amacıyla sinyal işleme teknikleri, yapay zekâ ve makine öğrenmesi yöntemleriyle bütünleşerek etkili karar destek sistemlerinin geliştirilmesine olanak tanımaktadır. Bu yaklaşımlar yalnızca endüstriyel bakım ve arıza tespitinde değil, tarım ve gıda ürünlerinin kalite kontrolünde de yaygın olarak kullanılmaktadır.

“Veri Temelli Sinyal İşleme ve Durum Analizi Yöntemleriyle Kuru Çay Kalitesinin Tespiti” başlıklı bu tez çalışmasında, Bosch tarafından geliştirilen BME688 sensöründen elde edilen sıcaklık, nem, gaz direnci ve uçucu organik bileşik verileri analiz edilmiştir. Sinyal işleme yöntemleri kullanılarak zaman ve frekans alanında öznitelikler çıkarılmış, bu öznitelikler makine öğrenmesi tabanlı sınıflandırma yöntemleriyle değerlendirilerek farklı çay örneklerinin kalite düzeylerinin belirlenmesi amaçlanmıştır. Çalışmanın özgün yönü, geleneksel olarak duyuşal değerlendirmelere dayanan çay kalite analizine veri bilimi ve sinyal işleme temelli nesnel bir yaklaşım sunmasıdır.

Bu çalışmanın hazırlanması sürecinde bilgi, deneyim ve akademik rehberliğiyle yol gösteren danışmanım Doç. Dr. Erkan Caner ÖZKAT’a, katkı ve destekleri için ikinci danışmanım Prof. Dr. Fatih Gül’e teşekkür ederim. Ayrıca tez jürimde yer alan Doç. Dr. Ebru ERGÜN’e ve Doç. Dr. Mehmet KONAR’a değerli görüş ve katkıları için teşekkürlerimi sunarım. Akademik gelişimime sağladıkları katkılar ve çalışmaya kazandırdıkları bilimsel bakış açısı, bu tezin şekillenmesinde belirleyici olmuştur.

Son olarak, tez çalışmam süresince sabrı, anlayışı ve desteğiyle her zaman yanımda olan sevgili eşime en içten teşekkürlerimi sunarım. Bu süreçte gösterdiği özveri ve manevi destek, çalışmanın tamamlanmasında önemli bir motivasyon kaynağı olmuştur.

Ahmet Turan TAŞDEMİR

RİZE/2026

İÇİNDEKİLER

ETİK BEYAN.....	II
ÖN SÖZ	III
ÖZET	X
KISALTMALAR.....	XII
TABLolar LİSTESİ.....	XIII
ŞEKİLLER LİSTESİ	XIV
GİRİŞ	1
1. ARAŞTIRMANIN TEORİK ALTYAPISI VE ÇERÇEVRESİ.....	2
1.1. Araştırmanın Kapsamı	2
1.2. Literatür Özeti	3
1.3. Kuramsal Arka Plan	4
1.3.1. Veri Temelli Sinyal İşleme Yaklaşımının Temelleri	5
1.3.2. Zaman Domeni İstatistikleri: Mean, Std, RMS, Min. ve Max.	5
1.3.3. VOC Davranışı ve Desorpsiyon Mekanizması	6
1.3.4. Siyah Çay Üretim Sürecinde VOC Oluşum Dinamikleri.....	7
1.3.5. Sensör–Nem–Sıcaklık–VOC Etkileşimi	7
1.3.6. Makine Öğrenmesinde Öznitelik Çıkarımının Rolü	8
1.3.7. Z-Score Normalizasyonu.....	9
1.3.8. SVM (Support Vector Machine) Temelleri.....	9
1.3.9. ECOC Yaklaşımı.....	10
1.4. Problemin Tanımı	11
1.5. Araştırmanın Amacı	12
1.6. Varsayımlar ve Sınırlılıklar.....	13
1.6.1. Varsayımlar	14
1.6.2. Sınırlılıklar.....	15
1.6.3. Varsayım–Sınırlılık İlişkisi ve Olası Etkiler	16
2. ÇAY NUMUNELERİ VE KALİTE SINIFLANDIRMASI.....	18
2.1. Çalışma Materyali ve Çay Numuneleri.....	18
2.1.1. Çay Örneklerinin Genel Özellikleri	19
2.1.2. Çay Numunelerine Ait Kimyasal ve Besinsel İçerik Bilgileri	19
2.1.3. Kimyasal Kalite Göstergeleri ve ORAC Referansı	20

2.2. Kalite Sınıflarının Tanımlanması ve Örnek Ürünler.....	21
3.YÖNTEM (MATERYAL-METOD).....	30
3.1. Sensör, Mikrodenetleyici ve Donanım Bileşenleri	30
3.1.1. BME688 Sensörünün Özellikleri	31
3.1.2. ESP32 Mikrodenetleyici ve Bağlantı Yapısı.....	33
3.1.3. Donanımı Oluşturan Bileşenlerin Teknik Özellikleri	34
3.2. Yazılım Altyapısı ve Sistem Entegrasyonu.....	37
3.2.1. AI Entegrasyonu ve Yazılım Yapısı.....	38
3.2.2. Kullanılan Yazılım ve Araçlar	40
3.2.3. Arduino IDE Kurulum Adımları	41
3.2.3.1. ESP32 Kart Desteğinin Yüklenmesi.....	42
3.2.3.2. Kullanılan Arduino Kütüphaneleri	42
3.2.3.3. BSEC Entegrasyonu	42
3.2.3.4. Firmware Yükleme ve Konfigürasyon	42
3.2.3.5. Sensör Testi ve Led Durum Kontrolü.....	43
3.3. Deneysel Düzenegın Fiziksel Tasarımı.....	43
3.3.1. Sensör Konumu	44
3.3.2. Vakumlu Kap	44
3.3.3. Isıtma Ünitesi	45
3.3.4. Vakum Pompası ve Bileşenleri	46
3.3.5. MicroSD Kart Modülü	46
3.3.6. Bağlantı Kablosu ve Güç Beslemesi	47
3.3.7. Dizüstü Bilgisayar (Laptop)	48
3.3.8. Cep Telefonu	48
3.4. Deney Protokolü ve Ölçüm Süreci.....	48
3.4.1. Ölçüm Öncesi Hazırlık ve Kalibrasyon.....	51
3.4.1.1. Başlatma ve Kalibrasyon Aşaması	51
3.4.1.2. Çay Örneğinin Hazırlanması ve Kabin Kapatılması	51
3.4.2. Numune Ölçüm Aşaması.....	52
3.4.3. Hava Temizleme (Purj) Aşaması	53
3.4.4. Ölçüm Zaman Protokolü (30 dk Hava + 30 dk Çay)	53
3.4.5. Isıtma Amacı ve Sıcaklık Kontrolü	54

3.4.5.1. Vakum ve Isıtma Sürecinin Başlatılması.....	54
3.4.6. Etiketleme ve Veri Kaydı	56
3.4.6.1. Mobil Uygulama ile Etiketleme	57
3.4.6.2. Sensör Yapısı ve Örnekleme Karakteristikleri	57
3.5. Veri Kaydı, Dönüştürme ve Ön İşleme.....	59
3.5.1. SD Kartın Biçimlendirilmesi.....	60
3.5.2. BME AI-Studio ile Proje Dosyalarının Oluşturulması.....	61
3.5.3. BoardConfiguration.bmeconfig Dosyasının Üretilmesi.....	62
3.5.4. Sensör Parametrelerinin Yapılandırılması.....	63
3.5.5. Ölçüm Aralıklarının ve Sensör Modlarının Ayarlanması	64
3.5.6. Yapılandırma Dosyasının SD Karta Aktarılması	65
3.5.7. bmerawdata Veri Dosyalarının Kaydedilmesi	66
3.5.8. bmerawdata Dosyasını (.csv) ve (.xlsx) Çevrilmesi.....	67
3.5.8.1. Komut Satırı ve Çalışma Dizini Ayarları	68
3.5.8.2. Python Scriptinin Çalıştırılması.....	69
3.5.8.3. Çıktı Dosyalarının Kaydedilmesi	69
3.5.8.4. Veri Okuma ve Temel İşleme.....	70
3.5.8.5. Etiketleme ve Açıklayıcı Bilgilerin Eklenmesi	70
3.5.8.6. IAQ Proxy Tanımı	70
3.5.8.7. (.csv) Dosyalarında Bulunan Sütunlar	71
3.5.8.8. Öncelikli Sensör Parametreleri ve Öznitelik Çıkarımı	71
3.5.9. Modelleme için Hazırlanan Veri Kümeleri	71
3.6. Kalite Sınıflandırma ve Modelleme Yaklaşımı.....	72
3.6.1. Destek Vektör Makineleri (SVM).....	73
3.6.1.1. SVM'in Temel Mantığı (Lineer / Lineer Olmayan Ayırım)	73
3.6.1.2. Sınıflandırma Problemlerinde SVM'in Rolü.....	74
3.6.1.3. Bu Çalışmada SVM Tercihinin Bilimsel Gerekçeleri	74
3.6.2. Modelleme Sürecinin İşlevsel Yapısı.....	75
3.6.2.1. Ham Veriden Öznitelik Vektörüne Geçiş.....	76
3.6.2.2. Standartlaştırma (Z-Skor) Gereksinimi	76
3.6.2.3. Çok Sınıflı Yapıda ECOC Kullanımı	77
3.6.2.3.1. İkili Alt Modeller ve Kodlama Matrisi	78

3.6.2.3.2. Karar Skorları ve Kayıp Bazlı Kod Çözme	79
3.6.2.3.3. ECOC Yaklaşımının Çalışmadaki Rolü.....	81
3.6.2.4. Softmax Fonksiyonu ve Olasılıksal Karar Mekanizması	82
3.6.3. Modelin Teknik Özellikleri ve Sağladığı Avantajlar	84
3.6.3.1. ECOC + SVM Yapısının Teknik Kapasitesi	84
3.6.3.2. Gürültüye Dayanıklılık ve Küçük Veri Setlerinde Performans	84
3.6.3.3. Sensör Tabanlı Zaman Serisi Yapısına Uygunluğu.....	85
3.6.3.4. Diğer Yöntemlerle (KNN, RF, LR) Karşılaştırmalı Avantajlar	86
3.6.4. Kullanılan Modelleme Yaklaşımının Temel Dayanakları.....	87
3.6.4.1. Literatürdeki Boşluğun Doldurulması	87
3.6.4.2. Sensör Verisi Tabanlı Z-Skor–ECOC–SVM–Softmax Akışı	88
3.6.4.3. Çay Kalitesinde Veri Temelli Yaklaşımın Katkısı	93
3.6.5. Model Geliştirme ve Tahmin Sürecinin Genel Akış Şeması	94
3.6.5.1. Veri Bölünmesi.....	97
3.6.5.2. Verilerin İkili Alt Modellere Bölünmesi (ECOC Mantığı)	98
3.6.5.3. Model Eğitiminde Kullanılacak (.csv) Veri Kümesi (Train Set)....	98
3.6.5.4. Model Doğrulama Veri Kümesi (Validation Set).....	99
3.6.5.5. Model Test Veri Kümesi (Hold-Out Test Set)	100
3.7. Model Geliştirme	101
3.7.1. Özellik Çıkarımı (Feature Extraction).....	103
3.7.1.1. Girdi Verilerinin Yapısı.....	104
3.7.1.2. Özellik Vektörünün Oluşturulması.....	104
3.7.1.3. Eğitim Veri Matrisinin (X_train – y_train) Oluşturulması.....	105
3.7.2. Z-Skor Ölçekleme (Z-Score Standardization).....	108
3.7.2.1. Z-Skor Standardizasyonunun Matematiksel Temeli	108
3.7.2.2. Eğitim Verisi Üzerinden μ ve σ Değerlerinin Hesaplanması	109
3.7.2.3. Z-Skorun Bu Çalışmadaki Gerekliliği	110
3.7.2.4. Z-Skor Standardizasyonu ile ECOC–SVM Etkileşimi.....	111
3.7.2.5. Sonuç ve Yöntemin Sağladığı Avantajlar	112
3.7.3. ECOC Tabanlı Çok Sınıflı SVM (fitcecoc)	113
3.7.4. Softmax ile Olasılık Dönüşümü ve Sınıf Tahmini	116
3.7.4.1. Sınıf Olasılıklarının Yorumlanması.....	117

3.7.4.2. Nihai Tahminin Oluşturulması	118
4. BULGULAR VE YORUMLAR	119
4.1. Zaman Serisi Verilerinin Yapısal Analizi	119
4.1.1. Zaman Serisinin Örneklemeye Yapısı	119
4.1.2. Ham Zaman Serisi Verisinin Yapısal İncelenmesi.....	120
4.1.3. Çok Kanallı Zaman Serisi Davranışı.....	121
4.1.4. Örneklemeye Frekansının Dağılımı ve Yorumlanması.....	121
4.2. Özellikler ve Sınıf Davranışlarının İncelenmesi	122
4.2.1. Sınıf Bazlı Öznitelik Dağılımları	123
4.2.2. IAQ, Gaz Direnci ve Nem Davranışlarının Karşılaştırılması.....	123
4.2.3. Bulguların Ön Değerlendirmesi	124
4.3. Model Doğrulama Sonuçları	124
4.3.1. Doğrulama Verisi Üzerindeki Model Performansı	124
4.3.2. Hiperparametre Optimizasyonu ve Model Kararlılığı Sağlanması	125
4.4. Nihai Modelin Eğitimi ve Değerlendirme Yaklaşımı	127
4.4.1. Tam Veri Kümesi ile Eğitilen Nihai Modelin Oluşturulması	128
4.4.2. Eğitim Sonuçlarına Dayalı Yapısal Kararlılık Analizi.....	129
4.5. Ürün Bazlı Tahmin Tutarlılığı ve Kararlılık Analizi (90 .csv)	130
4.5.1. Tekrarlı Ölçüm Verilerinin Ön İşlenmesi ve Sınıflandırılması.....	131
4.5.2. Ölçüm Sürecinin Başlatılması ve Numune Etiketleme Protokolü	132
4.5.3. Ürün Bazlı Karar Tutarlılığı Oranının Hesaplanması	132
4.5.4. Kararsız Ölçümlerin Analizi	133
4.5.5. Verinin Bilgisayara Aktarılması ve Dönüştürülmesi	134
4.5.6. SD Kart ve AI-Studio Test Süreci.....	135
4.5.7. MATLAB’da Ürün Bazlı Tahmin ve Tutarlılık Analizi	135
4.5.8. MATLAB Çıktıları ve Ürün Bazlı Tutarlılık Analizi Raporları	137
4.5.9. Ürün Bazlı Gerçek–Tahmin Uyumunun İncelenmesi	139
4.5.10. Çapraz 10-Katlı Doğrulama (10-Fold Cross-Validation) Analizi.....	140
4.5.11. Ürün Bazlı Karar Tutarlılık Matrisi ve Performans Sentezi	143
4.5.12. Sınıf Bazında Karar Eğilimi ve Hata Örüntüleri Analizi	144
4.5.13. Tahmin Sonuçlarının Fiziksel ve Kimyasal Temelli Yorumu	147
4.6. Nihai Modelin Doğruluk ve Kararlılık Temelli Değerlendirmesi.....	148

4.7. Bulguların Genel Değerlendirilmesi	149
4.7.1. Modelin Güçlü ve Zayıf Yönleri	150
4.7.2. Hatalı Sınıflandırmaların Nedenleri	151
5. TARTIŞMA, SONUÇ VE ÖNERİLER	153
5.1. Tartışma.....	153
5.1.1. Zaman Serisi Davranışlarının Kalite Ayrımına Etkisi	154
5.1.2. Özniteliklerin Ayırt Ediciliği ve Fiziksel–Kimyasal Yorumu	156
5.1.3. ECOC–SVM Yapısının Küçük Veri Setlerindeki Avantajı	157
5.1.4. Orta Kalite Sınıfında Gözlenen Belirsizliklerin Nedenleri	158
5.1.5. Sensör Tabanlı Yaklaşımın Literatürle Karşılaştırılması	159
5.1.6. Yöntemin Sınırlılıkları ve Güçlü Yönleri.....	160
5.2. Sonuç.....	161
5.3. Öneriler	162
5.3.1. Araştırmacılara Yönelik Öneriler	163
5.3.2. Gelecek Çalışmalar için Öneriler	164
KAYNAKÇA.....	166

ÖZET

Recep Tayyip Erdoğan Üniversitesi Lisansüstü Eğitim Enstitüsü

Makine Mühendisliği

Hazırlayan: Ahmet Turan TAŞDEMİR

Yüksek Lisans Tezi

Danışman: Doç. Dr. Erkan Caner ÖZKAT

Yıl: 2026 , Sayfa Sayısı: 187

Veri Temelli Sinyal İşleme ve Durum Analizi Yöntemleriyle Kuru Çay Kalitesinin Tespiti

Geleneksel çay kalite değerlendirmeleri çoğunlukla uzmanların duyu analizlerine dayandığından kişiden kişiye farklılık gösterebilmekte ve tutarlı sonuçlar vermemektedir. Bu nedenle bu çalışmada, kuru çayın kalitesini daha objektif, güvenilir ve tekrarlanabilir biçimde belirlemek amacıyla sensör tabanlı ve veri odaklı bir yöntem geliştirilmiştir. Araştırmada Bosch BME688 sensörü kullanılarak farklı çay örneklerinden sıcaklık, nem, basınç ve uçucu organik bileşik (VOC) verileri toplanmıştır. Elde edilen ham veriler; gürültü giderme, normalleştirme, eksik veri düzenleme ve iç ortam hava kalitesi hesaplamaları uygulanarak analiz için uygun hale getirilmiştir.

Ön işleme aşamasının ardından sensör verilerinden ortalama, standart sapma, minimum, maksimum ve RMS gibi istatistiksel özellikler çıkarılmıştır. Toplam 25 özellik kullanılarak her çay örneği sayısal bir özellik vektörü ile temsil edilmiştir. Öznitelik ölçeklerinin dengelenmesi amacıyla Z-skor standardizasyonu uygulanmış, gerekli durumlarda veri boyutunun indirgenmesi için PCA yönteminden faydalanılarak (Abdi ve Williams, 2010; Jolliffe, 2002) modelin kararlılığı artırılmış ve aşırı uyum riski azaltılmıştır.

Sınıflandırma için doğrusal çekirdekli ve $C=0,1$ düzenleme parametresine sahip Destek Vektör Makinesi (SVM) algoritması kullanılmıştır. Çok sınıflı yapı, problemi üç ikili alt modele ayıran ECOC (Error Correcting Output Codes) yaklaşımı ile gerçekleştirilmiştir. Veri seti %70 eğitim, %15 doğrulama ve %15 test olarak ayrılmıştır. Eğitim aşaması modelin optimum karar sınırlarını öğrenmesini sağlarken, doğrulama aşaması genelleme yeteneğini değerlendirmiş ve test aşaması bağımsız veriler üzerindeki performansı ortaya koymuştur.

Model performansının nesnel olarak değerlendirilmesi amacıyla gerçekleştirilen 10-Katlı Çapraz Doğrulama sonucunda modelin ortalama sınıflandırma doğruluğu %61,11 olarak elde edilmiş, %95 güven düzeyinde doğruluk oranının %48,35–%73,87 aralığında değiştiği belirlenmiştir. Ayrıca ürün bazlı karar tutarlılığı analizinde sistem %78,8 oranında mutlak uyum göstermiştir.

Elde edilen sonuçlar, BME688 sensörü ve istatistiksel öznitelik çıkarımına dayalı önerilen yaklaşımın çay kalite değerlendirmesinde güvenilir ve objektif sonuçlar sunduğunu göstermektedir. Böylece çalışma, çay kalite kontrol süreçlerinin dijitalleştirilmesine, ürün standardizasyonunun desteklenmesine ve düşük maliyetli elektronik burun sistemlerinin gıda kalite analizlerinde kullanımına katkı sağlamaktadır.

Anahtar Kelimeler: Kuru Çay Kalitesi, Veri Temelli Sinyal İşleme, SVM-fitcecoc, BME688 Sensörü, IAQ Proxy, Makine Öğrenmesi

ABSTRACT

Recep Tayyip Erdogan University Institute of Graduate Studies
Mechanical Engineering

Author: Ahmet Turan TAŞDEMİR

Master Thesis

Supervisor: Assoc. Prof. Dr. Erkan Caner ÖZKAT

Year: 2026, Number of Pages: 187

Determination of Dried Tea Quality Using Data-Based Signal Processing and Situation Analysis Methods

Traditional tea quality assessments are mostly based on sensory analysis by experts, which can vary from person to person and not yield consistent results. Therefore, in this study, a sensor-based and data-driven method was developed to determine the quality of dried tea in a more objective, reliable, and reproducible way. In the research, temperature, humidity, pressure, and volatile organic compound (VOC) data were collected from different tea samples using a Bosch BME688 sensor. The obtained raw data were prepared for analysis by applying noise reduction, normalization, missing data correction, and indoor air quality calculations.

Following the preprocessing stage, statistical features such as Mean, standard deviation, minimum, maximum, and RMS were extracted from the sensor data. Each tea sample was represented by a numerical feature vector using a total of 25 features. *Z-Score* standardization was applied to balance the feature scales; where necessary, the PCA method (Abdi & Williams, 2010; Jolliffe, 2002) was used to reduce the data dimensionality, increasing model stability and reducing the risk of overfitting.

A Support Vector Machine (SVM) algorithm with a linear kernel and a $C=0.1$ adjustment parameter was used for classification. The multi-class structure was implemented using the ECOC (Error Correcting Output Codes) approach, which divides the problem into three binary sub-models. The dataset was divided into 70% training, 15% validation, and 15% testing. The training phase allowed the model to learn the optimum decision boundaries, the validation phase evaluated the generalization ability, and the testing phase revealed its performance on independent data.

A 10-Fold Cross-Validation was conducted to objectively evaluate the model's performance. The average classification accuracy of the model was found to be 61.11%, and at a 95% confidence level, the accuracy ranged from 48.35% to 73.87%. Furthermore, in the product-based decision consistency analysis, the system demonstrated an absolute agreement of 78.8%.

The results obtained demonstrate that the proposed approach, based on the BME688 sensor and statistical feature extraction, provides reliable and objective results in tea quality assessment. Thus, the study contributes to the digitalization of tea quality control processes, supports product standardization, and utilizes low-cost electronic nose systems in food quality analysis.

Keywords: Dry Tea Quality, Data-Driven Signal Processing, SVM-fitcecoc, BME688 Sensor, IAQ Proxy, Machine Learning

KISALTMALAR

ACC	:	Accuracy (Doğruluk Oranı)
AI	:	Artificial Intelligence (Yapay Zekâ)
AI-Studio	:	Bosch Sensor Tec Yapay Zekâ Studio Yazılımı
BME688	:	Bosch Çoklu Gaz Sensörü
BSEC	:	Bosch Software Environmental Cluster (Yazılım Kitaplığı)
CSV	:	Comma-Separated Values (Virgülle Ayrılmış Değerler)
ECOC	:	Error-Correcting Output Codes (Hata Düzeltme Kodları)
ESP32	:	Wi-Fi ve Bluetooth Destekli Mikrodenetleyici Kartı
F1	:	F1-Score (Harmonik Ortalama Ölçütü)
FFT	:	Fast Fourier Transform (Hızlı Fourier Dönüşümü)
FN	:	False Negative (Yanlış Negatif)
FP	:	False Positive (Yanlış Pozitif)
IAQ	:	Indoor Air Quality (İç Mekân Hava Kalitesi)
MAT	:	MATLAB Data File Formatı
ML	:	Machine Learning (Makine Öğrenmesi)
ORAC	:	Oxygen Radical Absorbance Capacity (Antioksidan Kapasite Ölçümü)
PCA	:	Principal Component Analysis (Temel Bileşenler Analizi)
PdM	:	Predictive Maintenance (Kestirimci Bakım)
PRE	:	Precision (Kesinlik)
RMS	:	Root Mean Square (Kök Ortalama Kare)
REC	:	Recall (Duyarlılık)
SPE	:	Specificity (Özgüllük)
SVM	:	Support Vector Machines (Destek Vektör Makineleri)
TN	:	True Negative (Doğru Negatif)
TP	:	True Positive (Doğru Pozitif)
VOC	:	Volatile Organic Compounds (Uçucu Organik Bileşikler)
XLSX	:	Excel Spreadsheet Formatı
YZ	:	Yapay Zekâ
Z-Score	:	Standardizasyon Yöntemi.

TABLÖLAR LİSTESİ

Tablo 1. Varsayım Sınırlılık Durumları ve Etkileri	16
Tablo 2. Model Eğitiminde Kullanılan 16 Çay Örneğinin İçerik Özellikleri	22
Tablo 3. Veri Normalizasyonu ve Aralıklı Sınıflandırma Sonuçları	23
Tablo 4. Kalite Sınıfları ve Ortalama Kimyasal ve Besinsel Değerler	25
Tablo 5. Kriter Ağırlıklandırma ve Puanlama Kriterleri.....	26
Tablo 6. BME688 Sensörünün Temel Teknik Özellikleri	36
Tablo 7. ESP32 Mikrodenetleyicisine Ait Temel Teknik Özellikler	36
Tablo 8. ESP32–BME688 Sistem Bağlantıları	36
Tablo 9. Çalışma Kapsamında Kullanılan Yazılım ve Geliştirme Araçları	40
Tablo 10. Kalite Sınıflarında Ölçüm Sayıları	67
Tablo 11. Ham BME688 Verilerinde Kullanılan Dosyalar ve Formatları.....	68
Tablo 12. Ham .bmerawdata Dosyasının csv/xlsx'e Dönüştürme	69
Tablo 13. Ham Verinin Dönüştürülmesi Sonrasında Oluşturulan Çıktı Dosyaları...	70
Tablo 14. Modelde Kullanılan Temel Sensör Parametreleri.....	71
Tablo 15. Veri Toplama Sürecinde Kullanılan Dosya ve İçerik Bilgileri.....	72
Tablo 16. Üç Sınıflı SVM Modeli için Örnek ECOC Kodlama Matrisi.....	78
Tablo 17. Eğitim, Doğrulama ve Test Veri Kümelerinin Sınıf Dağılımı.....	97
Tablo 18. Eğitim Aşamasında Kullanılan Örneklerin Sınıf Bazında Dağılımı.....	98
Tablo 19. Doğrulama Aşamasında Kullanılan Sınıf Dağılımı	100
Tablo 20. Test Aşamasında Kullanılan Örneklerin Sınıf Dağılımı.....	101
Tablo 21. Örnek Çay Numunesi İçin Sensör Bazlı Ortalama Değerler	106
Tablo 22. Eğitim Kümesi Örneklerinin Öznitelik Vektörleri ve Sınıf Etiketleri	107
Tablo 23. BME688 Sensörden Elde Edilen Ham Zaman Serisi Verisinin Satırları	120
Tablo 24. BME688 Sensör 8 Kanala ait Örnekleme Sayıları ve Frekansları.....	121
Tablo 25. SVM Modeli 10-Katlı Çapraz Doğrulama Başarı Dağılımı	141
Tablo 26. Çapraz Doğrulama Sınıf Bazlı Sayısal Metrik Tablosu.....	141
Tablo 27. Ürün Bazlı Karar Tutarlılık Matrisi	144
Tablo 28. Sınıf Bazında Karar Tutarlılığı	145
Tablo 29. Ölçüm Bazlı Gerçek–Tahmin Dağılımı	146
Tablo 30. Kalite Sınıflarına Göre Temel Sensör Özellikleri ve Eğilimleri.....	147

ŞEKİLLER LİSTESİ

Şekil 1. Isıtma - VOC salınımı	6
Şekil 2. Sensör-Nem-VOC Etkileşimi.....	7
Şekil 3. SVM Karar Sınırı Gösterimi	10
Şekil 4. ECOC Kalite Sınıf Şeması	10
Şekil 5. Kalite Tespitinde Kullanılan Temel Kimyasal Göstergeler	20
Şekil 6. Benchmark Çay Profilleri.....	25
Şekil 7. Çay Kalite Sınıfları.....	28
Şekil 8. Çay Numunelerinin Kalite Sınıflandırma Spektrumu	29
Şekil 9. BME688 Sensör Modülünün Teknik Bileşenleri	32
Şekil 10. ESP32 Mikrodenetleyici Kartı	34
Şekil 11. ESP32 ve BME688 Sistem Kurulumu ve Yazılım Entegrasyon Akışı	38
Şekil 12. BSEC Algoritması ve IAQ Proxy Metrik Çıktısı	39
Şekil 13. Entegre Yazılım Yığın Piramidi.	41
Şekil 14. ESP32 LED Durum Göstergeleri ile Sensör Testi.....	43
Şekil 15. BME688 Sensörünün Kapak İçerisindeki Konumlandırılması	44
Şekil 16. Vakumlu Ölçüm Kabı	45
Şekil 17. Kızılötesi Isıtıcı Ünitesi.....	46
Şekil 18. Mini Vakum Pompası	46
Şekil 19. MicroSD Kart ve Adaptörü	47
Şekil 20. Güç Besleme Bağlantısı ve Kablo Düzeni	47
Şekil 21. Kapak Üzerinde Deney Düzenineğinin Yerleşimi.....	49
Şekil 22. Deney Düzenineğinin Genel Yapısı ve Sensör Eklentileri	50
Şekil 23. Başlatma –Yapılandırma ve Sıfır Noktaları.....	51
Şekil 24. Çay ve Deney Düzenineğinin Genel Görünümü	52
Şekil 25. Purj ve Adsorpsiyon-Desorpsiyon Dengesi.....	53
Şekil 26. Hava-Çay Ölçüm Döngüsü	54
Şekil 27. VOC Aktivasyon Modeli.....	55
Şekil 28. Vakum ve Isıtma Sürecinin Başlatılması için Kullanılan Deney Düzenineği	56
Şekil 29. Mobil Uygulama ile Verinin Gerçek Zamanlı Kaydı ve Etiketlenmesi	56
Şekil 30. BME688 Sensör Dizisi ve Isıtıcı Profiline Zaman Adımlarına Dağılımı .	58
Şekil 31. Sensör Dizisi ve Isıtıcı Profillerinin Zaman Adımlarına Dağılımı.....	58

Şekil 32. BME688 Sensör Gruplandırma ve Heater Profile Konfigürasyonu.....	58
Şekil 33. Veri Kaydı, Dönüştürme ve Ön İşleme Süreç İş Akışı	59
Şekil 34. Veri Toplama Süreci	60
Şekil 35. SD Kart- Bilgisayara Bağlantısı	61
Şekil 36. BME AI-Studio Masaüstü Uygulamasının Açılış Ekranı	62
Şekil 37. BME AI-Studio Üzerinde Yeni Proje Oluşturma Ekranı.....	63
Şekil 38. BME AI-Studio Üzerinde Sensör Parametrelerinin Yapılandırılması	64
Şekil 39. Sensör Ölçüm Aralıkları ve Isıtma Profili	65
Şekil 40. BME688 Kartının SD Kart ile Çalışmaya Hazır Hâle Getirilmesi	66
Şekil 41. SVM ve ECOC Çalışma Farkı	77
Şekil 42. Model Akış Mimarisi.....	88
Şekil 43. Sensör Zaman Serisi Sinyalleri	88
Şekil 44. Zaman Serisi Verisi Üzerindeki İstatistiksel Öznitelikler	89
Şekil 45. Z-Skor Standardizasyonu	90
Şekil 46. Karar Skorları ve Çıktı Matrisi.....	90
Şekil 47. ECOC-SVM Sınıflandırma Yapısı	91
Şekil 48. Test Numunesinin Hiper Düzlemlere Uzaklığı	91
Şekil 49. Softmax Olasılık Dağılımı.....	92
Şekil 50. Güven Skoru ve Kalite Sınıfı	92
Şekil 51. Sistemin Şeffaf ve Gerekçeli Sonuçlarını İçeren Karar Ekranı	93
Şekil 52. Çay Kalitesi Sınıflandırma Modelinin Genel İş Akışı.....	96
Şekil 53. Model Geliştirme Sürecinin Aşamalarını Gösteren Akış Diyagramı	103
Şekil 54. Ham Ölçekler ve Z-Skor Filtresi	108
Şekil 55. Üç Sınıflı Problemin fitcecoc ECOC Yöntemiyle Çözümleme Akışı.....	114
Şekil 56. Sınıflar Arası Karar Düzlemi.....	114
Şekil 57. Üç Sınıflı Bir Problemin İkili SVM Alt Modellerine Ayrılması	115
Şekil 58. BME688 Sensör Örnekleme Frekansı ve Periyot Değerleri	122
Şekil 59. C Parametresinin SVM Karar Sınırına Etkisi.....	126
Şekil 60. 10-Katlı Çapraz Doğrulama Performansı ve %95 Güven Aralığı	142
Şekil 61. SVM Model Çapraz Doğrulama Sınıf Bazlı Metrik Dağılımı	143

GİRİŞ

Çay, dünya çapında en çok tüketilen tarımsal ürünlerden biri olup ekonomik, kültürel ve sosyal açıdan önemli bir yere sahiptir. Türkiye gibi üretici ülkelerde çayın kalitesi hem iç pazar hem de ihracat açısından stratejik değer taşımaktadır. Geleneksel kalite değerlendirmeleri çoğunlukla uzmanların duyuşal gözlemlerine veya kimyasal analizlere dayanmakta; bu yöntemler zaman alıcı, maliyetli ve öznel niteliktedir. Meilgaard vd. (2016)'ne göre, geleneksel duyuşal değerlendirmeler kişiden kişiye değışen sonuçlar üretebilmektedir. Kişiden kişiye değışen değerlendirmeler, ölçümlerin tutarlılığı ve standardizasyonunu zorlaştırmakta; bu durum daha hızlı ve tekrarlanabilir analiz yöntemlerine olan ihtiyacı artırmaktadır (Dutta vd., 2003). Son yıllarda sensör teknolojileri ve makine öğrenmesi tabanlı veri analiz yaklaşımları, tarımsal ürün kalite kontrolünde güçlü bir alternatif olarak ön plana çıkmıştır. Özellikle elektronik burun (e-burun) sistemleri, uçucu organik bileşikleri (VOC) algılama yetenekleri sayesinde çay gibi aromatik ürünlerin nesnel biçimde değerlendirilmesine imkân vermekte, duyuşal testlere göre daha standart ve güvenilir ölçümler sunmaktadır (Gardner ve Bartlett, 1999; Hidayat vd., 2021; Yu ve Wang, 2007).

Bu tez çalışmasının amacı, veri temelli sinyal işleme ve durum analizi yöntemleriyle kuru çay kalitesini hızlı, nesnel ve güvenilir şekilde belirleyebilecek bir sistem geliştirmektir. Bu doğrultuda Bosch *BME688* sensörü ve *ESP32* mikrodenetleyici tabanlı bir deneysel düzenek oluşturulmuş; farklı kalite sınıflarına sahip çay örneklerinden sıcaklık, nem, basınç, gaz direnci ve VOC verileri toplanmıştır. Ham veriler ön işleme adımlarından geçirilmiş, ortalama, standart sapma ve RMS gibi istatistiksel öznitelikler hesaplanarak çok boyutlu özellik vektörleri elde edilmiştir. Bu öznitelikler *Z-Score* standardizasyonu sonrası eğitim, doğrulama ve test kümelerine ayrılmış; Destek Vektör Makineleri (SVM) ve *fitcecoc* yaklaşımıyla sınıflandırılmıştır. Böylece farklı kalite sınıflarının sinyal temelli ayrımı gerçekleştirilmiş ve duyuşal yöntemlere alternatif bir model ortaya konmuştur.

Çalışmanın özgün değeri, geleneksel yöntemlerin ötesinde düşük maliyetli, taşınabilir ve nesnel bir sensör tabanlı analiz çerçevesi sunmasıdır. Bu sistem, öznel yorumlara bağımlılığı azaltarak üretim süreçlerinde standardizasyon ve verimlilik sağlamayı hedeflemektedir.

1. ARAŞTIRMANIN TEORİK ALTYAPISI VE ÇERÇEVESİ

Bu bölümde, tez çalışmasının kuramsal temeli ve kavramsal çerçevesi sistematik bir biçimde ele alınmaktadır. Araştırmanın kapsamı ve literatürdeki çalışmalar özetlendikten sonra, sensör tabanlı zaman serisi verilerinin işlenmesine dayanan veri temelli yaklaşımlar açıklanmaktadır. Çay kalitesini belirlemede rol oynayan VOC davranışı, sensör–çevresel etkileşimler ve makine öğrenmesi tabanlı öznitelik çıkarımı yöntemleri kuramsal arka plan çerçevesinde incelenmektedir. Ayrıca çalışmada kullanılan normalizasyon ve sınıflandırma yaklaşımlarının teorik dayanakları sunularak problemin tanımı, araştırmanın amacı ile varsayımlar ve sınırlılıklar bu bağlamda yapılandırılmaktadır (Bhattacharyya vd., 2012).

1.1. Araştırmanın Kapsamı

Bu tez çalışması, siyah çay örneklerinin kalite düzeylerini nesnel biçimde belirlemek amacıyla sensör temelli veri toplama, sinyal işleme ve makine öğrenmesi yöntemlerinin birlikte kullanıldığı bir analiz çerçevesi sunmaktadır (Scott vd., 2007). Araştırma, Bosch *BME688* sensöründen elde edilen sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* gibi çok boyutlu çevresel parametrelerin ölçülmesiyle başlamış; bu ham zaman serileri gürültü azaltma, eksik veri temizliği ve *Z-Score* standardizasyonu gibi temel ön işleme adımlarından geçirilmiştir.

Çalışmanın kapsamı, sensör verilerinden zaman domeni istatistiklerinin (ortalama, standart sapma, RMS vb.) çıkarılması ve elde edilen özniteliklerin SVM–ECOC tabanlı bir sınıflandırma modeli ile değerlendirilmesi üzerine kuruludur. İncelenen veri seti yalnızca siyah çay türlerini içermekte olup kimyasal laboratuvar analizleri, duyuşal değerlendirmeler veya çok sensörlü e-burun sistemleri bu kapsam dışında bırakılmıştır. Deneysel düzenek, vakumlu ölçüm kabı, *IR* ısıtıcı, *ESP32* mikrodenetleyici ve tek bir *BME688* sensöründen oluşan taşınabilir bir yapı üzerine tasarlanmıştır.

Bu yönüyle tez, sensör tabanlı ölçümlerin çay kalite analizi bağlamında uygulanabilirliğini inceleyen ve belirli deneysel koşullar altında değerlendiren bir çerçeve sunmaktadır.

1.2. Literatür Özeti

Çay kalite değerlendirmesi üzerine yapılan çalışmalar incelendiğinde, özellikle uçucu organik bileşiklerin (VOC) analizi ve bu verilere dayalı makine öğrenmesi yöntemleriyle sınıflandırma süreçlerinin öne çıktığı görülmektedir. Çayın aroma profili; yaprak kalitesi, işleme tekniği, oksidasyon süresi ve polifenol bileşenlerindeki değişimler gibi pek çok faktörden etkilenmektedir. Geleneksel duyu testler bu değişkenlikleri değerlendirebilse de öznel yapıları ve tekrarlanabilirlik sınırlılıkları nedeniyle modern gıda analizlerinde yeterli görülmemektedir. Bu nedenle elektronik burun (e-burun) sistemleri, çay gibi aromatik tarımsal ürünlerde nesnel bir alternatif olarak yaygınlık kazanmıştır (Gardner ve Bartlett, 1994).

Dutta vd. (2003), siyah çayın kalite standardizasyonunda elektronik burun kullanımını önermiştir. Sensör tabanlı yaklaşımın duyu testlere kıyasla daha tutarlı sonuçlar verdiğini göstermiştir. (Yu ve Wang, 2007), Long Jing yeşil çaylarını VOC temelli sensör sinyalleriyle sınıflandırmış ve aroma profillerinin kalite dereceleri arasında belirgin ayrımlar oluşturduğunu ortaya koymuştur. Hidayat vd. (2021) ise sahada uygulanabilir bir e-burun sistemi geliştirmiştir. Siyah çay örneklerini yüksek doğrulukla ayırt etmiştir. Yang vd. (2013) tarafından yürütülen bu çalışma, taşınabilir sensör sistemlerinin kalite kontrol süreçlerinde etkin biçimde kullanılabileceğini deneysel olarak ortaya koymuştur. Saha vd. (2012) tarafından yürütülen bir diğer çalışmada çok sınıflı SVM modellerinin elektronik burun verileri üzerinde etkili olduğu raporlanmıştır. *Kemometrik* yaklaşımların çay kalite analizinde güçlü performans sergilediği ortaya konmuştur.

Son yıllarda literatür, sensör çeşitliliği ve modelleme yöntemlerinin geliştirilmesine odaklanmıştır. Hu vd. (2024), fermente Fuzhuan tuğla çayının kalite analizinde e-burun, *Vis-NIR* ve *kemometrik* yöntemleri bir arada kullanarak çoklu sensör füzyonunun sinerjik etkisini göstermiştir. Wang vd. (2022) tarafından önerilen GE-ELM tabanlı yapı, elektronik burun verilerinin hızlı ve yüksek doğrulukla işlenebildiğini kanıtlamıştır. Yu vd. (2025) ise küresel ve yerel özelliklerin birlikte işlendiği bir derin öğrenme modeli geliştirerek modern sinyal işleme yöntemlerinin çay kalite sınıflandırmasındaki potansiyelini vurgulamıştır.

Bu çalışma, ham zaman serisi verisini doğrudan modellemek yerine, seriden türetilen istatistiksel özniteliklerin kullanıldığı *feature-based time series modeling*

yaklaşımını benimsemektedir. Bu yaklaşımda zaman serileri; dağılım ölçütleri, otokorelasyon yapısı, entropi tabanlı karmaşıklık ölçüleri ve benzeri istatistiksel tanımlayıcıları içeren öznitelik vektörleri ile temsil edilir. Böylece yüksek boyutlu ham zaman serilerinin yerine sabit boyutlu ve karşılaştırılabilir bir temsil uzayı elde edilmekte, klasik makine öğrenmesi algoritmalarının daha etkin ve kararlı biçimde uygulanması mümkün olmaktadır.

Özellik tabanlı temsil, karmaşık zaman dinamiklerini yorumlanabilir ve kompakt bir özellik kümesine indirgeme avantajı sunmaktadır. Fulcher ve Jones (2014), tarafından önerilen kapsamlı öznitelik kütüphanesinden türetilen ve Lubba vd. (2019) tarafından geliştirilen *catch22* yaklaşımı, istatistiksel özellik çıkarımının zaman serisi sınıflandırmada hem performans hem de hesaplama verimliliği sağladığını göstermiştir. Benzer şekilde Lei ve Wu (2020), öznitelik tabanlı zaman serisi temsillerinin özellikle sınırlı veri koşullarında güçlü genelleme yeteneği sunduğunu raporlamıştır. Bu bulgular, sensör verilerinin doğrudan ham biçimde işlenmesi yerine öznitelik mühendisliği ile temsil edilmesinin literatürde giderek güçlenen bir eğilim olduğunu ortaya koymaktadır.

Çay kalite araştırmalarının önemli bir diğer yönü, kimyasal bileşenlere ilişkin bulgulardır. Literatür, polifenol düzeyi, ORAC antioksidan kapasitesi, kafein miktarı ve uçucu aroma bileşiklerinin çay kalitesi ile doğrudan ilişkili olduğunu ortaya koymaktadır. Bu tezde kullanılan kalite sınıflandırmaları (yüksek, orta, düşük) da literatürde belirtilen polifenol oranları, *theaflavin* / *thearubigin* dengesi ve genel aroma profiline ilişkin değerlendirmelere dayandırılmıştır. Literatürdeki çalışmalar genel olarak sensör verilerinden elde edilen istatistiksel özniteliklerin PCA (Abdi ve Williams, 2010), SVM, ELM veya derin öğrenme modelleriyle işlenmesinin çay gibi aromatik ürünlerde yüksek doğrulukla kalite sınıflandırması yapılmasına olanak sağladığını göstermektedir. Bu birikim, tez kapsamında kullanılan veri temelli sinyal işleme ve SVM-*fitcecoc* yaklaşımının kuramsal temelini oluşturmaktadır.

1.3. Kuramsal Arka Plan

Bu çalışma, kuru siyah çayın kalite sınıfının nesnel biçimde belirlenmesine yönelik veri temelli bir sinyal işleme ve makine öğrenmesi yaklaşımına dayanmaktadır. Sensör tabanlı ölçümlerin ham zaman serisi verilerinden anlamlı öznitelikler çıkarılması, bu özniteliklerin ölçeklendirilerek modellenmesi ve çok sınıflı

yapının hataya dayanıklı algoritmalarla ayrıştırılması, kuramsal yapının temel bileşenlerini oluşturmaktadır. Bu bölümde sinyal işleme yöntemleri, istatistiksel öznitelik üretimi, VOC davranışı, sensör–ortam etkileşimleri, normalizasyon teknikleri ve SVM–ECOC tabanlı sınıflandırma yaklaşımlarının teorik temelleri bütüncül biçimde ele alınmaktadır.

1.3.1. Veri Temelli Sinyal İşleme Yaklaşımının Temelleri

Veri temelli sinyal işleme, sensörlerden elde edilen ham zaman serisi çıktılarının matematiksel ve istatistiksel yöntemlerle anlamlı bilgiye dönüştürülmesini amaçlayan bir yaklaşımdır. Ham sensör sinyalleri doğrudan yorumlanabilir olmadığı için veri işleme süreci; gürültü giderme, kararsız bölgelerin belirlenmesi, öznitelik çıkarımı ve veri ölçekleme gibi adımları içerir.

Bu tezde uygulanan sinyal işleme zinciri aşağıdaki aşamalardan oluşmaktadır:

- Sıcaklık, nem, gaz direnci, basınç ve *IAQ Proxy* sinyallerinin elde edilmesi
- Ham sinyallerde gürültü, *drift* ve kararsız bölümlerin analizi
- Zaman domeni istatistiklerinin çıkarılması
- Öznitelik vektörlerinin normalizasyonu
- Çok sınıflı sınıflandırma modellerinin eğitilmesi

Bu süreç, yüksek boyutlu zaman serilerini daha kompakt ve sınıflandırmaya uygun özellik uzayına dönüştürerek modelin öğrenme kapasitesini artırmaktadır.

1.3.2. Zaman Domeni İstatistikleri: Mean, Std, RMS, Min. ve Max.

Sensör sinyallerinin karakteristiğini tanımlamanın en temel yolu zaman domeni istatistiksel özniteliklerin çıkarılmasıdır. Bu öznitelikler her çay örneğini temsil eden bir “istatistiksel imza” oluşturur.

- Ortalama (*Mean*): Genel seviyeyi temsil eder.

$$\mu_i (mean) = \left(\frac{1}{N}\right) \sum_{n=1}^N x_{n,i} \quad (1.1)$$

- Standart sapma (*Std*): Dalgalanma miktarını yansıtır.

$$\sigma_i (std) = \sqrt{\left(\frac{1}{N}\right) \sum_{n=1}^{N_{train}} x(x_{n,i} - \mu_i)^2} \quad (1.2)$$

- Minimum–maksimum değerler: Darbe benzeri davranışları ve uç noktaları gösterir.

$$x_{min} = \min(x_1, x_2, \dots, x_n) \quad (1.3)$$

$$x_{max} = \max(x_1, x_2, \dots, x_n) \quad (1.4)$$


- RMS (*Root Mean Square*): Enerji benzeri bileşeni temsil eder; özellikle gaz direnci ve IAQ sinyallerinde ayırt edicidir.

$$RMS = \sqrt{\left(\left(\frac{1}{N} \right) \sum_{n=1}^N (x_{n,i})^2 \right)} \quad (1.5)$$

Bu istatistiksel öznitelikler, ilerleyen bölümlerde açıklanan sınıflandırma algoritmasının temel girdilerini oluşturur (Oppenheim ve Schafer, 2010; Theodoridis ve Koutroumbas, 2009).

1.3.3. VOC Davranışı ve Desorpsiyon Mekanizması

Kuru çayın kimyasal bileşiminde yer alan uçucu organik bileşikler (VOC), aroma ve kaliteyi doğrudan etkileyen temel bileşenlerdir. Isıtma uygulandığında çay yapraklarında tutulan VOC bileşenleri serbestleşir (*Desorpsiyon*) ve bu durum sensörün gaz direnci ile IAQ sinyallerinde ölçülebilir değişikliklere yol açar (Barsan ve Weimar, 2003; Rock vd., 2008).



Şekil 1. Isıtma - VOC salınımı

Şekil 1’de gösterilen mekanizma, çayın ısıtıldığında VOC seviyesinin yükselmesini ve sensör yanıtının değişmesini teorik düzeyde açıklamaktadır.

1.3.4. Siyah Çay Üretim Sürecinde VOC Oluşum Dinamikleri


Wang vd. (2008)'e göre siyah çay üretim sürecindeki en önemli kimyasal mekanizma enzimatik oksidasyondur. Benzer şekilde Wright ve de Silva (2018), siyah çayın karakteristik aroma profilinin oluşumunda *linalool*, *geraniol* ve *benzaldehit* gibi uçucu organik bileşiklerin önemli rol oynadığını belirtmiştir. Uçucu organik bileşikler, siyah çayın karakteristik koku ve lezzetini belirleyen temel kimyasal bileşenlerdir. Siyah çayda öne çıkan başlıca VOC türleri arasında *linalool*, *geraniol*, *benzaldehit*, *metil salisilat* ve *hexanal* yer almaktadır. Bu bileşikler çiçeksi ve meyvemsi aromatik notaların oluşmasını sağlar (Clifford vd., 1999; Zhou vd., 2018).

Bu süreçte taze yapraklarda bulunan kateşinler, oksijenle tepkimeye girerek theaflavin, *thearubigin* ve *theabrownin* gibi pigmentlere dönüşür (Harbowy ve Balentine, 1997). Fermentasyon süresinin uzaması aromatik yoğunluğu artırabilirken, aşırı oksidasyon VOC profilinin zayıflamasına neden olabilir (Liang ve Xu, 2001).

Bu kimyasal farklılıklar sensör ölçümlerinde gaz direnci ve IAQ parametrelerinde belirgin değişimler oluşturarak kalite sınıflarının ayrıştırılmasına doğrudan katkı sağlamaktadır.

1.3.5. Sensör–Nem–Sıcaklık–VOC Etkileşimi

Yamazoe ve Shimanoe (2008)'ye göre, MOX tabanlı sensörlerin temel yapısı gereği bağıl nem değişimleri, VOC algılama süreci üzerinde doğrudan etkilidir. *BME688* sensörü, nem ve sıcaklık değişimlerine duyarlı MOX tabanlı bir yapıya sahiptir (Korotcenkov, 2008). Nem oranındaki artış, sensör yüzeyindeki *adsorpsiyon* süreçlerini etkileyerek ölçülen gaz direncinde değişimlere neden olabilir. Sıcaklık ise sensör ısıtıcısının profilini belirler ve VOC'lerin yüzeyden kopma hızını artırır. Bu ilişkiler, sensör yanıtının doğru yorumlanabilmesi için temel teorik zemini oluşturur.



Şekil 2. Sensör-Nem-VOC Etkileşimi

Şekil 2, sensör ölçüm mekanizmasını kavramsal düzeyde göstermektedir:

- Sıcaklık artışı → VOC *Desorpsiyonu* artar
- Nem dalgalanması → MOX direnci değişir
- VOC yoğunluğu → IAQ ve gaz direncini etkiler

Siyah çay üretimi; soldurma, kıvrırma, fermentasyon ve kurutma aşamalarından oluşmakta olup bu süreçler çayın kimyasal yapısında ve VOC profilinde belirgin değişimlere yol açmaktadır. Özellikle fermentasyon aşaması, uçucu bileşik oluşumunu doğrudan etkileyerek sensör verilerinde gözlemlenen gaz direnci ve IAQ parametrelerinde ayırt edici farklılıklar oluşturmaktadır.

BME688 sensörü, üretim süreci boyunca oluşan bu farklılıkları sıcaklık, nem, basınç ve gaz bileşimi parametreleri üzerinden çok boyutlu olarak algılayabilmektedir. Özellikle fermentasyon süresinin uzamasıyla VOC miktarının artması, sensörün gaz direnci ve *IAQ Proxy* çıktılarında belirgin değişimlere yol açmaktadır. Buna karşılık kurutma aşaması, VOC içeriğinin bir bölümünün uzaklaşmasına neden olarak sensör tepkisinin karakterini değiştirebilmektedir. Bu nedenle sensör verilerinde gözlemlenen gaz direnci, IAQ ve nem parametreleri, üretim sürecine bağlı kalite farklılıklarının dolaylı bir göstergesi olarak değerlendirilmektedir.

Klasik MOS sensörler düşük maliyetli ve hızlı tepki verme avantajlarına sahip olmakla birlikte, genellikle sınırlı seçicilik sunmaktadır. *BME688* sensörü ise programlanabilir ısıtma profilleri sayesinde farklı VOC bileşiklerine karşı daha seçici ve ayırt edici tepkiler üretebilen gelişmiş bir MOS sensör yapısına sahiptir. Bu özellik, siyah çaydan yayılan karmaşık VOC karışımlarının daha duyarlı biçimde algılanmasını mümkün kılmakta ve kalite sınıfları arasındaki farkların sensör verisine daha net yansımaya katkı sağlamaktadır. Üretim aşamalarına bağlı kimyasal farkların sensör ölçümleri üzerindeki etkisinin anlaşılması, çay kalitesi tahmininde kullanılan modelin performansını artırarak sensör tabanlı kalite kontrol sistemlerinin otomatik ve güvenilir biçimde uygulanabilmesine olanak tanımaktadır.

1.3.6. Makine Öğrenmesinde Öznitelik Çıkarımının Rolü

Ham zaman serisi verileri doğrudan makine öğrenmesi algoritmalarına verildiğinde:

- Ölçüm gürültüsü doğrudan modele aktarılır.

- Zaman boyutu sabit olmadığı için karşılaştırılabilirlik bozulur
- Aşırı boyutluluk aşırı öğrenmeye neden olur

Bu nedenle her çay ölçümü, öznitelik çıkarımıyla özet bir vektöre dönüştürülür.

Bu temsil biçimi veri işleme yükünü azaltır ve sınıflandırma performansını artırır.

1.3.7. Z-Score Normalizasyonu

Özniteliklerin farklı ölçeklerde olması modelin karar sınırlarını olumsuz etkiler. Bu nedenle tüm öznitelikler *Z-Score* yöntemiyle ölçeklendirilir:

$$z = (x - \mu)/\sigma \quad (1.6)$$

Bu işlem:

- Öğrenme sürecini kararlı hâle getirir
- SVM hiper-düzleminin dengesini korur
- ECOC alt modellerinin *margin* davranışını iyileştirir (Bishop, 2006).

1.3.8. SVM (Support Vector Machine) Temelleri

SVM, iki sınıfı en geniş ayırım marjini ile ayıran doğrusal/çizgisel bir hiperdüzlem bulmayı amaçlar (Cortes ve Vapnik, 1995). Karar fonksiyonu:


$$sk = w \cdot z + b \quad (1.7)$$

Amaç fonksiyonu:

$$\text{minimize} = \left(\frac{1}{2}\right) \|W\|^2 + C \sum_{i=1}^N \xi_i \quad (1.8)$$

Bu yaklaşım:

- Aşırı uyumu önler
- Gürültülü özniteliklere karşı sağlamlık sağlar.
- Karar sınırlarının matematiksel olarak yorumlanmasına imkân verir.



Şekil 3. SVM Karar Sınırı Gösterimi


Şekil 3’te, zaman serilerinden elde edilen öz nitelik vektörlerinin özellik uzayındaki dağılımı ve eğitim verileri kullanılarak oluşturulan karar sınırları gösterilmektedir.

1.3.9. ECOC Yaklaşımı

SVM doğal olarak ikili bir sınıflandırıcıdır; bu nedenle üç kalite sınıfının analizinde ECOC (*Error-Correcting Output Codes*) stratejisi kullanılır (Dietterich ve Bakiri, 1995).

ECOC yapısı:

- Her sınıf bir kod satırıyla temsil edilir.
- Her SVM alt modeli kod matrisinin bir sütununu temsil eder.
- Alt modellerden gelen skorlar en yakın kod satırıyla eşleştirilerek sınıf belirlenir, bu yaklaşım sınıflar arası hata toleransını artırır



Şekil 4. ECOC Kalite Sınıf Şeması

Şekil 4’te ECOC mekanizmasının, ikili sınıflandırıcılar tarafından üretilen kodların bir kod matrisi aracılığıyla üç farklı kalite sınıfına dönüştürülmesi gösterilmektedir.

1.4. Problemin Tanımı

Kuru çayların kalite sınıflandırması uzun yıllardır büyük ölçüde duyuşal deęerlendirmelere dayalı olarak yapılmaktadır. Koklama, tat profili, renk, dem süresi ve aroma gibi unsurlara odaklanan bu yöntemler, deęerlendiricinin deneyimine ve algısına baęlı olduęu için öznel niteliktedir. İnsan algısındaki deęişkenlik, duyuşal yorgunluk ve çevresel koşulların etkisi, kalite sınıfının standartlaştırılmasını zorlaştırmaktadır (Lawless ve Heymann, 2010). Bu durum, üretim süreçlerinde tutarlılık ve tekrarlanabilirlik gereksinimlerini karşılamayı güçleştirmektedir. Bu durum, çay kalitesinin nesnel, tekrarlanabilir ve ölçülebilir yöntemlerle deęerlendirilmesini gerekli kılmaktadır.

Siyah çayın kimyasal bileşimi, özellikle uçucu organik bileşikler (VOC), üretim prosesi, yaprak kalitesi, fermantasyon süresi ve saklama koşulları gibi faktörlere baęlı olarak deęişmekte ve her bir çay türüne özgü bir aroma profili oluşturmaktadır. Bu kimyasal farklılıklar, *BME688* sensörü tarafından ölçülen gaz direnci, *IAQ Proxy*, sıcaklık ve nem sinyallerinde belirli davranış örüntüleri oluşturur. Ancak bu sensör verileri ham haliyle oldukça karmaşık ve dalgalı bir yapı sergilemekte, çoęu zaman doğrudan yorumlanmasını güçleştirmektedir. Özellikle nem deęişkenliğinin gaz direnci ve *IAQ* çıktıları üzerindeki etkisi, farklı ölçüm koşullarında sınıf ayrımının bulanıklaşmasına yol açabilmektedir. Bu durum, ham sinyallerin doğrudan deęerlendirilmesini pratikte mümkün olmaktan çıkarmakta ve bilimsel veri işleme tekniklerinin kullanımını zorunlu hâle getirmektedir.

BME688 sensörünün birden fazla çevresel parametreyi eşzamanlı ölçmesi, çay örneklerine ait zaman serilerinin VOC–nem–sıcaklık etkileşimlerini birlikte içermesine neden olur. Bu çok boyutlu yapı ancak istatistiksel öznitelik çıkarımıyla anlamlı bir forma dönüştürülebilir. VOC davranışının *Desorpsiyon* süreçlerine baęlı olması, sıcaklık deęişimlerinin ölçüm hassasiyetini etkilemesi ve nemin gaz direncindeki kararsızlığa yol açması, sensör verilerinin işlenmesinde teorik olarak ele alınması gereken temel problemlerdir.

Farklı çay türlerine ait VOC profilleri sensör sinyallerinde ayırt edici özellikler oluştursa da bu örüntülerin insan gözüyle tespit edilmesi mümkün deęildir. Bu nedenle veri temelli sinyal işleme, istatistiksel öznitelik üretimi ve makine öğrenmesi tabanlı

modelleme; duyuşal değerdendirmelerin yerini alabilecek nesnel, tekrarlanabilir ve yüksek doğruluklu bir kalite tespit yöntemi geliştirmek için gereklidir.

Bu doğrultuda araştırma aşğıdaki temel sorulara yanıt aramaktadır:

- Çay kalite sınıfları sensör tabanlı zaman serisi ölçümleriyle anlamlı biçimde ayrıştırılabilir mi?
- Elde edilen istatistiksel özellikler kalite sınıfları arasında tutarlı bir ayırım oluşturmakta mıdır?
- Makine öğrenmesi tabanlı modeller (özellikle SVM–ECOC yapısı) çay kalitesini güvenilir doğrulukla tahmin edebilir mi?
- Düşük maliyetli *BME688* sensörü, pratik kalite kontrol süreçlerinde kullanılabilecek ölçüde kararlı, tekrarlanabilir ve güçlü sinyaller üretmekte midir?

1.5. Araştırmanın Amacı

Bu çalışmanın amacı, Bosch *BME688* sensöründen elde edilen çoklu çevresel ve gaz direnci sinyallerini analiz ederek ayırt edici öznitelikler çıkarmaktır. Bu özniteliklerin SVM–ECOC tabanlı bir model ile işlenmesi yoluyla, siyah kuru çay örneklerinin kalite sınıflarının nesnel ve tekrarlanabilir biçimde belirlenmesi hedeflenmektedir.

Geleneksel duyuşal değerdendirmelerin öznal yapısı ile kimyasal analiz yöntemlerinin maliyet ve zaman açısından sınırlayıcı olması, üretim süreçlerinde uygulanabilir, düşük maliyetli ve taşınabilir kalite kontrol sistemlerine olan ihtiyacı artırmaktadır (Albert vd., 2012). Bu doğrultuda çalışmada, farklı kalite seviyelerine sahip çay numunelerinden sıcaklık, nem, basınç, gaz direnci ve VOC kaynaklı *IAQ Proxy* verileri zaman serisi olarak elde edilmekte; bu ham veriler gürültü azaltma, normalizasyon ve istatistiksel öznitelik çıkarımı adımlarından geçirilerek *Z-Score* standardizasyonu uygulanarak ölçeklendirilmekte ve istatistiksel öznitelik çıkarımı ile boyut indirgeme sağlanmaktadır. Son aşamada, elde edilen özniteliklerin Destek Vektör Makineleri (SVM) ve *fitcecoc* tabanlı çok sınıflı bir yapı içerisinde işlenmesiyle çay örneklerinin “yüksek”, “orta” ve “düşük” kalite sınıfları arasında güvenilir bir ayırım yapılması hedeflenmektedir (Tudu vd., 2005).

Bu genel çerçeve doğrultusunda çalışmanın somut hedefleri aşağıdaki şekilde tanımlanmıştır:

- Nesnel bir ölçüm sistemi kurmak: *BME688* sensörü ve *ESP32* tabanlı taşınabilir bir elektronik burun (e-burun) düzeneği oluşturmak; farklı kalite sınıflarındaki çay numunelerinden sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* verilerini düzenli ve güvenilir şekilde toplamak.
- Veri odaklı bir sinyal işleme zinciri geliştirmek: Ham sensör sinyalleri üzerinde gürültü azaltma, standardizasyon ve zaman domeninde istatistiksel öznitelik çıkarımı (ortalama, standart sapma, RMS, minimum, maksimum vb.) uygulayarak her bir çay numunesini temsil eden kompakt özellik vektörleri üretmek.
- Etkin bir makine öğrenmesi modeli oluşturmak: Elde edilen özniteliklere boyut indirgeme uyguladıktan sonra *SVM-fitcecoc* tabanlı çok sınıflı bir model eğiterek çay örneklerini üç kalite seviyesinde yüksek doğrulukla sınıflandırmak.
- Bilimsel ve deneysel bir altyapı sunmak: Geliştirilen sensör tabanlı yaklaşımı deneysel olarak doğrulamak; çay kalite kontrolünün dijitalleşmesine ve üretim süreçlerinde standardizasyonun artırılmasına katkı sağlayabilecek uygulanabilir bir metodoloji ortaya koymak.

Bu hedefler doğrultusunda araştırma, yalnızca akademik düzeyde yeni bir yöntem önermeyi değil, aynı zamanda endüstriyel ölçekte uygulanabilir, taşınabilir, düşük maliyetli ve nesnel bir kalite kontrol sisteminin mümkün olduğunu göstermeyi amaçlamaktadır. Böylece çalışma, hem veri temelli sinyal işleme literatürüne hem de çay kalite analizi alanına özgün ve pratik bir katkı sunmaktadır.

1.6. Varsayımlar ve Sınırlılıklar

Bu bölümde, araştırmanın yürütülmesi sırasında geçerli kabul edilen temel varsayımlar ile çalışmanın kapsamını belirleyen sınırlılıklar açıklanmaktadır. Varsayımlar, modelleme ve deneysel süreçlerin hangi koşullar altında geçerli olduğunu gösterirken; sınırlılıklar, elde edilen sonuçların yorumlanmasında dikkate alınması gereken kısıtları ortaya koymaktadır.

1.6.1. Varsayımlar

Bu araştırmada modelleme sürecinin geçerliliği ve veri analizinin doğru biçimde yürütülebilmesi için aşağıdaki varsayımlar kabul edilmiştir:

- Çay numunelerinin kalite etiketleri gerçeği temsil etmektedir: Yüksek, orta ve düşük kalite sınıfları; polifenol düzeyi, ORAC *antioksidan* kapasitesi, *theaflavin/thearubigin* oranı ve üretici tarafından sağlanan kalite beyanları temel alınarak tanımlanmış olup, bu etiketlerin numunelerin kimyasal kalitesini doğru biçimde yansıttığı varsayılmıştır (Wright vd., 2002).
- *BME688* sensörü VOC profillerini yeterli doğrulukla algılamaktadır: Sensörün sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* ölçümlerinin çayın uçucu organik bileşik davranışını temsil ettiği; VOC konsantrasyon değişimlerinin MOX sensör yapısı tarafından tutarlı biçimde algılandığı kabul edilmiştir.
- Sensör ölçüm kararlılığı deney süresince korunmuştur: *BME688* sensörünün ısıtıcı döngüsü, kalibrasyon durumu ve sıcaklık–nem kararlılığının deney boyunca değişmediği; ölçüm doğruluğunu etkileyecek bir *drift*, doyma veya sensör yorgunluğu oluşmadığı varsayılmaktadır (Sensortec, 2021).
- Ölçüm ortamı kontrol altında tutulmuştur: Vakumlu kap, IR ısıtıcı ve hava boşaltma mekanizmasının çevresel etkileşimleri (ortam kokusu, nem dalgalanması, hava akımı) minimuma indirdiği; dış faktörlerin sensör sinyallerini bozmadığı varsayılmıştır.
- Zaman domeni istatistiksel öznitelikleri kalite sınıfı ayrımını yansıtmaktadır: Ortalama, standart sapma, RMS, minimum ve maksimum değerlerden oluşan 25 boyutlu öznitelik vektörünün çay sınıflarına özgü yapısal farklılıkları temsil ettiği ve sınıflandırma için yeterli bilgi içerdiği kabul edilmiştir.
- *Z-Score* normalizasyonu veri yapısını doğru ölçeklendirmektedir: Uygulanan ölçeklendirme ve boyut indirgeme işlemlerinin veri dağılımını bozmadığı; sınıflar arasındaki ayrım bilgisini koruyarak model performansını artırdığı varsayılmıştır.
- *SVM-fitcecoc* modeli çok sınıflı yapıyı temsil etmek için uygundur: Çay kalite sınıfları arasındaki ayrımın doğrusal veya yakın doğrusal karar sınırlarıyla modellenebileceği; ikili alt modellerin ECOC yapısı içinde anlamlı ve kararlı sınıflandırma üreteceği varsayılmıştır.

1.6.2. Sınırlılıklar

ISO 8589:2007 standardına göre duyuusal test odalarının belirli koşulları sağlaması gerekirken, bu çalışmada bu tür standartlar uygulanmamıştır. Bu araştırma, sensör tabanlı çay kalite analizi için geliştirilen modelin belirli koşullar altında yürütülmesi nedeniyle bazı yapısal sınırlılıklara sahiptir.

Çalışmanın kapsamını ve bulguların genellenebilirliğini etkileyen başlıca sınırlılıklar aşağıda sunulmuştur:

- Tek sensör kullanımı: Araştırmada yalnızca bir adet *BME688* sensörü kullanılmıştır. Ticari elektronik burun sistemlerinde birden fazla MOX sensör kombinasyonu bulunduğundan, tek sensörlü yapı VOC çeşitliliğini tüm boyutlarıyla yakalamakta sınırlı kalabilir.
- Örnek sayısının sınırlı olması: Çalışmada 16 farklı marka ve kalite sınıfını temsil eden kuru çay örneği kullanılmıştır. Bu durum, modelin daha geniş çay çeşitliliği üzerinde test edilmesini ve genelleme kapasitesinin tam olarak değerlendirilmesini sınırlamaktadır.
- Ölçüm koşullarının sabitlenmiş olması: Deneyler belirli koşullar altında gerçekleştirilmiştir: 0,650 litrelik vakumlu kap hacmi, 11 W'lık *IR* ısıtıcı, 10 dakikalık hava ölçümü ve 20-30 dakikalık çay ölçümü gibi parametreler tüm testlerde aynı tutulmuştur. Farklı hacim, süre veya ısıtma yöntemleri sonuçların değişmesine yol açabilir.
- Sensör tepkisinin çevresel değişkenlikten etkilenmesi: *BME688* sensörü özellikle nem ve sıcaklık dalgalanmalarına duyarlıdır. Ani RH değişimleri sensörün gaz direnci ve IAQ yanıtlarını etkileyebilir. Yüksek nem veya hızlı sıcaklık değişiminin olduğu ortamlarda sonuçlar kararsızlık gösterebilir (Sohn vd., 2008).
- Çayların kimyasal analizlerinin doğrudan yapılmamış olması: Çay örneklerine ait kimyasal bileşenler doğrudan laboratuvar analizleriyle doğrulanmamış; bunun yerine sensör verileri üzerinden dolaylı olarak temsil edilmiştir.
- Modelin doğrusal SVM *kernel* ile sınırlı olması: Çalışmada doğrusal *kernel* yapısı kullanılmış, RBF veya *polynomial* gibi doğrusal olmayan *kernel* türleri test edilmemiştir. Bu nedenle model, daha karmaşık karar sınırlarını temsil etme açısından sınırlı olabilir (Burges, 1998).

- Model yalnızca kuru siyah çay için geliştirilmiştir: Yeşil çay, beyaz çay, *oolong*, *pu-erh* veya aromalı çay türleri bu çalışmanın kapsamı dışındadır. Bu nedenle geliştirilen model farklı çay kategorilerine doğrudan genellenemez.
- VOC salınım süresinin sınırlı olması: Çay yapraklarının VOC salınımının daha uzun sürelerde farklı davranış gösterebileceği bilinmektedir. Bu çalışma 10 dakikalık toplam 20 dakikalık bir ölçüm protokolü ile sınırlandırılmıştır; daha uzun süreli ölçümlerin etkisi değerlendirilmemiştir.
- Sensör *drifti* 'nin dikkate alınmamış olması: MOX tabanlı sensörlerde uzun süreli kullanımda duyarlılık kayması (*drift*) görülebilmektedir. Bu çalışma yalnızca kısa dönemli deneyleri kapsadığı için sensör *drift* etkisi analiz edilmemiştir (Wang ve Fu, 2018).

1.6.3. Varsayım–Sınırlılık İlişkisi ve Olası Etkiler

Sensörün VOC yanıtının doğru olduğu varsayımına karşın, sensör *drift* 'inin dikkate alınmamış olması uzun vadede model doğruluğunu etkileyebilir.

Ölçüm ortamının kontrol altında olduğu varsayılmasına rağmen, nem ve sıcaklık dalgalanmaları sensör çıktılarında kararsızlığa neden olabilir. Nem ve sıcaklık dalgalanmalarının sensörü etkilemesi RH değişkenliği VOC ölçümlerini bozabilir ve sınıf ayrımını zayıflatabilir. Kalite etiketlerinin doğru olduğu varsayılmıştır. Kimyasal analizlerin yapılmamış olması. Etiket–gerçek kalite eşleşmesinde belirsizlik oluşabilir.

Tablo 1. Varsayım Sınırlılık Durumları ve Etkileri

Varsayım	İlgili Sınırlılık	Etki Açıklaması
Sensör VOC Yanıtının doğruluğu	Sensör drift	Yanıt zamanla değişebilir
Ölçüm Ortamının kontrolü	Nem değişkenliği	VOC ölçümleri etkilenebilir
Doğru kalite etiketi	Kimyasal analiz Yapılmamış olması	Etiket–gerçek kalite Eşleşmesi belirsiz olabilir

Tablo 1 'de çalışmanın temel varsayımları ile bunlara karşılık gelen sınırlılıklar ve bu sınırlılıkların sensör ölçümleri ve sınıflandırma performansı üzerindeki olası etkileri özetlenmiştir.

Bu çalışmada belirlenen varsayımlar ve sınırlılıklar, problemin tanımıyla doğrudan ilişkilidir. Duyusal yöntemlerin maliyet, süre ve öznel değerlendirme gibi

zayıf yönlerini azaltmayı hedefleyen bu tezde; tek sensör kullanımı, örnek sayısının sınırlı olması ve deneysel koşulların sabitlenmiş yapısı, geliştirilen modelin yaygın uygulamalar üzerindeki genellenebilirliğini doğal olarak sınırlandırmaktadır.

Bu çerçevede çalışma, *BME688* sensöründen elde edilen çok değişkenli sinyallerin istatistiksel özniteliklere dönüştürülmesi ve SVM–ECOC tabanlı sınıflandırma yaklaşımının, tanımlanan bu sınırlılıklar altında ne ölçüde uygulanabilir ve anlamlı sonuçlar üretebildiğini ortaya koymayı amaçlamaktadır.

Bu kapsamda, elde edilen sonuçların yorumlanmasında yalnızca model performans metriklerine odaklanmak yerine, veri toplama sürecinin doğası ve sensör tabanlı ölçümlerin karakteristikleri de dikkate alınmalıdır. Özellikle VOC sinyallerinin çevresel faktörlere duyarlılığı ve sensörün zamanla değişebilen davranışı, modelin gerçek dünya koşullarındaki kararlılığı açısından kritik bir rol oynamaktadır (Rudnitskaya vd., 2010). Bu nedenle, çalışmada ulaşılan bulguların, kontrollü deney ortamının sağladığı avantajlar çerçevesinde değerlendirilmesi; farklı çevresel koşullar, daha geniş veri setleri ve çoklu sensör kullanımı ile desteklenen gelecekteki çalışmalarla karşılaştırılması, geliştirilen yaklaşımın güvenilirliği ve genellenebilirliği hakkında daha kapsamlı bir bakış açısı sunacaktır.

Dolayısıyla sunulan bulgular, problemin kapsamı ve deneysel çerçeve ile tutarlı bir değerlendirme temelinde yorumlanmıştır.

2. ÇAY NUMUNELERİ VE KALİTE SINIFLANDIRMASI

Bu bölümde, tez çalışmasında kullanılan siyah çay numunelerinin genel özellikleri, kimyasal ve besinsel içeriklerine ilişkin temel bilgiler ile kalite sınıflarının nasıl tanımlandığı açıklanmaktadır. Farklı kalite düzeylerini temsil edecek şekilde seçilen çay örnekleri, sensör tabanlı sınıflandırma modelinin eğitimi ve değerlendirilmesi amacıyla gruplandırılmıştır. Ayrıca bu bölümde, kalite sınıflandırmasında referans alınan kimyasal göstergeler ve örnek ürünler sistematik bir çerçevede sunulmaktadır.

2.1. Çalışma Materyali ve Çay Numuneleri

Bu tez çalışmasında kullanılan çalışma materyalini, Türkiye’de yaygın olarak tüketilen farklı marka ve kalite sınıflarını temsil eden Tablo 2.’de verilmiş olan 16 adet siyah çay örneği oluşturmaktadır.

Kullanılan çay numunelerinin genel özellikleri kimyasal özellikleri, enerji içerikleri, besin değerlerine ilişkin temel bilgiler ile kalite sınıflarının nasıl tanımlandığı açıklanmaktadır. Farklı kalite sınıflarını temsil edecek şekilde seçilen çay örnekleri sensör tabanlı sınıflandırma modelinin eğitimi ve değerlendirmesi için gruplandırılmıştır. Türkiye’de kullanılan 16 siyah çay örnek olarak seçilmiştir.

Numuneler seçilirken:

- Farklı kalite seviyelerinin (yüksek, orta, düşük),
- Farklı üretim formlarının (dökme, poşet, bardak poşet),
- Farklı aroma yapılarına sahip ürünlerin (klasik, bergamot aromalı vb.)

Böylece hem premium nitelikte tomurcuk ağırlıklı ürünler hem de günlük tüketime yönelik standart ve poşet formdaki çaylar aynı veri kümesi içinde yer almıştır ve kalite sınıflarına atanırken bilimsel bir temele dayandırılması açısından referans olarak değerlendirilmiştir.

Bu numunelerin kalite sınıfına atanması süreci yukarıda belirtilen tüm parametrelere dayanan çapraz doğrulama yöntemi “Bütünsel Kalite Matrisi “ ile gerçekleştirilmiştir. Ayrıca çaylara ait bu parametre bilgileri “Altın Standart” olarak kabul edilmiştir.

2.1.1. ay rneklerinin Genel zellikleri

Bu alıřmada kullanılan 16 ay numunesi, A1–A16 kodları ile ifade edilmiřtir. Kodlamanın amacı, hem sensr veri dosyalarıyla uyumlu bir etiket yapısı kurmak hem de tez metni iinde marka isimleri ve kalite sınıflarıyla ilgili anlatımı sadeleřtirmektir.

Numune seti ierisinde:

- Yksek kalite sınıfını temsil eden tomurcuk ağırlıklı dkme aylar
- Orta kalite sınıfını temsil eden dengeli *polifenol* ve antioksidan dzeyine sahip dkme ve pořet aylar
- Dřk kalite sınıfını temsil eden, oėunlukla pořet formda ve daha dřk *polifenol*/ORAC deėerlerine sahip aylar

Bu yapı sayesinde hem kimyasal ierik hem de retim formu bakımından geniř bir varyasyon elde edilmiř ve BME688 sensrnn farklı kalite sınıfları arasındaki ayırt ediciliėi daha gereki kořullarda test edilmiřtir.

2.1.2. ay Numunelerine Ait Kimyasal ve Besinsel İerik Bilgileri

ay numunelerinin her biri iin;

- Enerji (kcal),
- Protein, karbonhidrat, yaė ve lif miktarları,
- Kafein ieriėi (mg/100 ml),
- Polifenol dzeyi (zellikle EGCg yoėunluėu *kateřinler*, *theaflavin* ve *thearubigin* bileřenleri),
- Antioksidan kapasiteye iliřkin ORAC aralıkları,
- ne ıkan kimyasal ve duyuusal zellikler (aroma, tomurcuk oranı, katkı durumu vb.) ayrı ayrı derlenmiřtir (Yao vd., 2006).

Bu bilgiler; retici firmaların besin deėeri tabloları, ambalaj zerindeki beyanlar Avrupa Komisyonu (2006) dzenlemeleri erevesinde deėerlendirilmiřtir. Literatrde yer alan analitik lmler ıřıėında bir araya getirilmiřtir (Peterson vd., 2005).

rneėin:


- A1 –Kod Numaralı ay , ince elenmiř yapraklardan oluřan, koyu renkli fakat grece dřk aromalı bir ay olup dřk–orta polifenol ve dřk antioksidan kapasitesi ile “dřk/orta” kimyasal kalite profiline sahiptir.

- A3 – Kod Numaralı Çay, tomurcuk ve genç yapraklardan elde edilen premium bir ürün olup, yüksek EGCg ve yüksek ORAC değeri ile normal çaylara göre yaklaşık %40 daha fazla polifenol içeriği sunmaktadır.
- A8 – Kod Numaralı Çay, yaygın tüketilen standart bir poşet çay olup, 600–800 µmol TE/100 mL aralığındaki ORAC değeri ile orta düzey antioksidan kapasite ve düşük–orta aroma profili sergilemektedir.
- A16 –Kod Numaralı Çay, hızlı demlenme ve pratik tüketim için tasarlanmış, düşük polifenol ve düşük antioksidan içeriğe sahip bir bardak poşet çaydır.

Tüm numunelere ilişkin ayrıntılı besin değerleri ve kimyasal içerik profilleri, Tablo 2’de sunulmuştur. Ana metinde, gereksiz tekrarın önüne geçmek amacıyla yalnızca temel sınıflandırma ölçütleri ve örnek açıklamalar verilmiş; detaylandırılmış besin tabloları ekler bölümüne alınmıştır.

2.1.3. Kimyasal Kalite Göstergeleri ve ORAC Referansı

Bu çalışmada, çay numunelerinin kalite sınıfları belirlenirken üç temel kimyasal gösterge grubu referans olarak kullanılmıştır:



Şekil 5. Kalite Tespitinde Kullanılan Temel Kimyasal Göstergeler

Şekil 5’teki görselde siyah çay kalite değerlendirmesinde *polifenol* içeriği, *antioksidan* kapasite (ORAC) ve *kafein* düzeyi temel kimyasal göstergeler olarak kabul edilmektedir. Bu göstergeler arasındaki ilişki özetlenmiştir.

ORAC değeri, bir çay numunesinin serbest radikalleri nötralize etme kapasitesini nicel olarak ifade eden önemli bir antioksidan göstergedir. *Polifenol* içeriği yüksek ve uygun şekilde işlenmiş çayların ORAC değeri genellikle daha yüksek olup, bu durum biyolojik değer ve *antioksidan* kapasite açısından olumlu bir göstergedir (Carloni vd., 2013). Bununla birlikte, *polifenol* fazlalığının bazı durumlarda aşırı burukluk gibi duyusal olumsuzluklar oluşturabileceği de bilinmektedir. Bu nedenle çayın genel kalitesi değerlendirilirken, ORAC ve polifenol düzeyleri ile duyusal özellikler ve *kafein* miktarı birlikte ele alınmıştır.

Bu tez kapsamında ORAC ve polifenol/kafein verileri model giriş değişkeni olarak doğrudan kullanılmamış, bunun yerine;

- Çayların kalite sınıfı etiketlerinin (1: yüksek, 2: orta, 3: düşük) belirlenmesinde referans olarak değerlendirilmiştir (Hu vd., 2024).
- Sensör tabanlı sınıflandırma sonuçlarının kimyasal arka plan ile uyumunun tartışılmasında karşılaştırma ölçütü olarak değerlendirilmiştir.

2.2. Kalite Sınıflarının Tanımlanması ve Örnek Ürünler

Model eğitiminde kullanılan üç kalite sınıfı, çay numunelerinin polifenol düzeyleri, ORAC değerleri, kafein içerikleri ve üretim özellikleri (tomurcuk oranı, üretim formu, aroma durumu vb.) birlikte değerlendirilerek tanımlanmıştır.

Ham veri toplama ve veri setinin oluşturulması:

- Yapılan İşlem: Farklı kaynaklardan elde edilen nitel (aroma, renk, form) ve nicel (*polifenol*, ORAC, *kafein*) veriler bir araya getirilerek 16 çay örneğine ait ham veri seti oluşturulmuştur.
- Teknik İfade: Veri Ontolojisi Oluşturma kapsamında, heterojen yapıdaki veriler (metinsel ve sayısal) ortak bir matris yapısında düzenlenerek analiz edilebilir hale getirilmiştir.
- Sonuç: Her çay örneğinin temel kimyasal ve duyusal özelliklerini içeren başlangıç veri seti oluşturulmuş ve sonraki analiz aşamaları için altyapı sağlanmıştır.

Bu kapsamda, 16 çay örneği Tablo 2’de tüm içerikleri ile özetlenmiştir.

Tablo 2. Model Eğitiminde Kullanılan 16 Çay Örneğinin İçerik Özellikleri

Kod	Form	Kalite Sınıfı	Polifenol / Antioksidan Kapasite (ORAC)	Kafein (mg/100 ml)	Kimyasal İçerik Özeti	Öne Çıkan Özellikler
A1	Dökme	Düşük	Düşük–orta polifenol; düşük antioksidan kapasitesi	25–50	Kateşin, teaflavin, tearubigin (düşük düzeylerde)	Koyu renk, düşük aroma
A2	Poşet	Orta	700–900 µmol TE/100 ml (orta)	25–45	Theaflavin, flavonoid, bergamot esansı	Narenciye aromalı, katkı
A3	Dökme	Yüksek	Yüksek EGCg; ORAC >1200 µmol TE/100 ml	30–60	Polifenoller (%40 yüksek), theaflavin	Yüksek antioksidan, premium tomurcuk
A4	Dökme	Orta	Orta–yüksek	25–50	Theaflavin/ Thearubigin dengesi	Yumuşak içim, orta aroma
A5	Dökme	Düşük	Orta polifenol	20–40	Flavonoid Ağırlıklı	Standart aroma, diyet dostu
A6	Poşet	Düşük	Orta–düşük	30–60	Polifenoller theaflavin düşük	Hızlı demlenme, zayıf aroma
A7	Dökme	Yüksek	1250 µmol TE/100 ml	35–65	Yüksek theaflavin, EGCg, florür	Premium kalite, yüksek antioksidan
A8	Poşet	Düşük	600–800 µmol TE/100 ml (orta)	20–40	Polifenol, Flavonoid, tanen	Düşük kalite, yaygın tüketim
A9	Dökme	Yüksek	100–150 mg polifenol	40–60	Theaflavin + thearubigin yüksek	Tatlımsı aroma, genç filiz
A10	Dökme	Yüksek	120–160 mg polifenol	35–55	Theaflavin/ Thearubigin	Doğal üretim, rafine tat
A11	Dökme	Orta	80–120 mg polifenol	25–45	EGCg,theaflavin	Katkısız, orta antioksidan
A12	Dökme	Orta	70–100 mg polifenol	25–50	Polifenol + flavonoid	Aromatik, diyet dostu
A13	Poşet	Orta	80–100 mg polifenol	25–45	Flavonoid + bergamot aroması	Hafif narenciye aroması

Tablo 2 (Devam). Model Eğitiminde Kullanılan 16 Çay Örneğinin İçerik Özellikleri

A14	Dökme	Orta	90–120 mg polifenol	30–50	Theaflavin + thearubigin orta-yüksek	Genç sürgün karışımı
A15	Poşet	Orta	70–90 mg polifenol	25–40	Flavonoid, Düşük tane	Pratik poşet, orta kalite
A16	Poşet	Düşük	60–80 mg polifenol	20–35	Düşük Polifenol,	Hızlı demlenme, düşük antioksidan

Tablo 2 incelendiğinde model eğitiminde referans olarak kullanılan 16 farklı çay örneğinin kalite sınıfı, polifenol–antioksidan profili, kimyasal içerik özellikleri ve öne çıkan duyuşsal nitelikleri özetlenmiştir.

Veri normalizasyonu ve aralıklı sınıflandırma:

- Yapılan İşlem: Sözel kalite ifadeleri (yüksek, orta, düşük), ORAC ve polifenol gibi ölçülebilir parametreler üzerinden belirli aralıklara dönüştürülerek veri seti sayısallaştırılmış ve standardize edilmiştir.
- Teknik İfade: *Discretization* (Süreksizleştirme) yöntemiyle sürekli değişkenler, tanımlanan eşik değerleri (*thresholds*) kullanılarak Sınıf 1, 2 ve 3 şeklinde kategorilere ayrılmış; böylece veri karar verilebilir hale getirilmiştir (Liu vd., 2002).
- Sonuç: Belirsizlikler ortadan kaldırılarak net sayısal aralıklar oluşturulmuş, veri karşılaştırılabilir hale getirilmiş ve kalite sınıflandırması için güvenilir bir temel sağlanmıştır.

Tablo 3. Veri Normalizasyonu ve Aralıklı Sınıflandırma Sonuçları

Kod	Kalite Sınıfı	ORAC ($\mu\text{mol TE}/100\text{ ml}$)	Polifenol (mg/100 ml)	Kafein (mg/100 ml)	Ayrım Kriteri
A3	Yüksek	>1200	≥ 130	30–60	Çok yüksek antioksidan + yüksek polifenol
A7	Yüksek	≈ 1250	≥ 130	35–65	Maksimum ORAC + güçlü kimyasal içerik
A9	Yüksek	$\approx 1000\text{--}1200$	100–150	40–60	Yüksek polifenol + dengeli kafein


Tablo 3 (Devam). Veri Normalizasyonu ve Aralıklı Sınıflandırma Sonuçları

A10	Yüksek	≈1100–1200 (tahmini)	120–160	35–55	Yüksek polifenol + rafine içerik
A11	Orta	≈800–1000	80–120	25–45	Orta antioksidan + orta polifenol Organik üretim
A14	Orta	900–1100	90–120	30–50	Orta-yüksek polifenol, dengeli içerik, genç sürgün
A4	Orta	800–1000	85–100	25–50	Dengeli theaflavin / thearubigin
A12	Orta	800–1000	70–100	25–50	Orta düzey polifenol
A5	Düşük	700–900	60–80	20–40	Düşük polifenol + zayıf antioksidan
A1	Düşük	<700	<60	25–50	Çok düşük içerik, zayıf kalite
A15	Orta	700–900	70–90	25–40	Orta kalite, poşet form
A2	Orta	700–900	70–90	25–45	Katkılı yapı, orta antioksidan
A13	Orta	800–1000	80–100	25–45	Flavonoid + aroma dengesi
A8	Düşük	600–800	60–80	20–40	Yaygın tüketim, düşük kalite
A6	Düşük	700–850	60–80	30–60	Düşük polifenol, hızlı demleme
A16	Düşük	600	60–80	25–35	Düşük polifenol + düşük aroma

Tablo 3 incelendiğinde, yüksek kalite sınıfının daha yüksek ORAC ve polifenol değerleri ile açıkça ayrıştığı, düşük kalite sınıfının ise bu değerlerin alt sınırlarında yoğunlaştığı görülmektedir. Orta kalite sınıfı ise bu iki grup arasında dengeli bir dağılım sergileyerek geçiş segmentini oluşturmaktadır.

Her kalite sınıfı belirlenerek bu şekilde standart oluşturulmuştur:

- **Yapılan İşlem:** Tüm kimyasal ve fiziksel veriler bir araya getirilerek her kalite sınıfının genel karakteristiği (örnek sayısı, içerik aralığı, üretim biçimi ve tipik özellikler) bütüncül bir modelde özetlenmiştir.
- **Teknik İfade:** Profilleme (*Profiling*) ile her kalite katmanı için ayırt edici “altın standartlar” tanımlanmış; polifenol, ORAC, kafein değerleri ve fiziksel özellikler üzerinden her sınıfın karakteristik imzası oluşturulmuştur.
- **Sonuç:** Her kalite sınıfı için net eşik değerler ve tipik özellikler belirlenerek puanlama ve sınıflandırma sürecinde kullanılacak güvenilir referans (benchmark) sistemi oluşturulmuştur.



Şekil 6. Benchmark Çay Profilleri

Şekil 6’ deki görselde veri setinde yer alan yüksek ve düşük kalite sınıflarını temsil eden referans çay profilleri gösterilmektedir.

Puanlama için gerekli aşamalar şunlardır:

- Yapılan İşlem: Fiziksel (üretim formu) ve kimyasal (ORAC, *polifenol*, *kafein*) parametreler esas alınarak 1–10 arası derecelendirme skalası oluşturulmuştur.
- Teknik İfade: Ordinal Ölçeklendirme (*Ordinal Scaling*) ile nitel ve nicel veriler birleştirilerek her kalite düzeyi sayısal puanlara dönüştürülmüştür.
- Sonuç: Çayların kalite seviyesini objektif şekilde değerlendirmeye olanak sağlayan standart bir puanlama matrisi (*rubrik*) geliştirilmiştir.

Tablo 4. Kalite Sınıfları ve Ortalama Kimyasal ve Besinsel Değerler

Puan	ORAC (μ molTE/ 100ml)	Polifenol (mg/100ml)	Kafein (mg/100ml)	Üretim Formu / Hammadde
10	1200 +	130 +	60 +	Saf Tomurcuk / Premium Dökme
9	1100-1200	115-130	55-60	Üst Kalite Dökme / Genç Yaprak
8	1000-1100	100-115	50-55	Standart Dökme / Harman
7	900-1000	85-100	45-50	Alt-Orta Dökme
6	800-900	75-85	40-45	Kaliteli Poşet (Bergamot vb.)
5	700-800	65-75	35-40	Standart Poşet
4	600-700	55-65	30-35	Ekonomik Poşet / CTC
2-3	<600	<55	<30	Toz / Bardak Poşet (Hızlı Dem)

Tablo 4'te üç farklı kalite sınıfına ait çay örneklerinin ortalama polifenol miktarları, ORAC değerleri, kafein düzeyleri ve tipik özellikleri karşılaştırmalı olarak sunulmuştur.

Farklı kaynaklardan gelen (laboratuvar sonuçları, paket bilgileri, üretici beyanları) ve farklı birimlere sahip (mg, μ mol, sözel tanımlar) veriler tek bir matematiksel paydaya indirgenmiştir. Veri seti içindeki aşırı uç değerler (*outliers*) ayıklanmış ve numunelerin en yoğun olduğu "en konforlu bölge" (*Stable*) seçilmiştir.

Tablo 3'teki ham istatistiksel bantlar, bu tabloda birim eşitleme ve istatistiksel güvenilirlik filtrelerinden geçirilerek operasyonel bir puanlama sistemine dönüştürülmüştür.

Ağırlıklandırma için gerekli aşamalar şunlardır:

- Yapılan İşlem: Kaliteyi belirleyen parametrelerin (ORAC, polifenol, üretim formu, kafein) toplam puan üzerindeki etkileri yüzdesel olarak belirlenmiştir.
- Teknik İfade: Ağırlıklı Katsayı Analizi (*Weighted Factor Analysis*) ile her parametreye önem derecesine göre katsayı atanmış ve kalite puanı hesaplaması matematiksel modele dönüştürülmüştür.
- Sonuç: Karar verme sürecindeki öncelikler sayısallaştırılarak objektif ve tutarlı bir kalite değerlendirme sistemi oluşturulmuştur.

Tablo 5. Kriter Ağırlıklandırma ve Puanlama Kriterleri

Parametre	Ağırlık (w)	Puanlama Kriteri (1-10 Puan)
ORAC Kapasitesi	0.40	$>1200 \mu\text{mol} = 10$ Puan
EGCg / Polifenol	0.30	$>120 \text{ mg} = 10$ Puan
Üretim Formu (Orthodox vs CTC)	0.20	Tomurcuk/Dökme = 10, Poşet/CTC = 2
Kafein Düzeyi	0.10	$>50 \text{ mg} = 10$ Puan

Tablo 5 incelendiğinde, kalite değerlendirmesinde antioksidan kapasitesi ve polifenol içeriğinin belirleyici rol oynadığı, üretim formu ve kafein düzeyinin ise destekleyici kriterler olarak modele dahil edildiği görülmektedir. Bu yapı, kalite analizinde önceliklerin bilimsel ve ölçülebilir bir temele dayandırıldığını göstermektedir.

Veri Konsolidasyonu ve Nihai Skorlama için gerekli aşamalar şunlardır:

- Yapılan İşlem: Tüm parametreler ağırlıklı puanlar üzerinden birleştirilerek her çay için toplam skor hesaplanmış ve nihai kalite sınıflandırması yapılmıştır. Eksik veriler uygun referanslarla tamamlanmıştır.
- Teknik İfade: Veri Füzyonu ve Karar Matrisi Sonuçlandırma yöntemi uygulanmış; gerekli durumlarda Veri İmputasyonu (*Data Imputation*) ile eksik değerler tahmin edilerek modele dahil edilmiştir.
- Sonuç: Ürünlerin en üstten (A7: 10,0 puan) en alta (A16: 2,6 puan) kadar sıralandığı bilimsel bir kalite hiyerarşisi elde edildi (Liggins vd., 2001).

Bu ağırlıklar ışığında, Matematiksel Karar Destek Matrisi şu şekildedir:


$$\text{Toplam Skor} = (\text{ORAC} * 0.4) + (\text{Polifenol} * 0.3) + (\text{Form} * 0.2) + (\text{Kafein} * 0.1)$$

Kod	ORAC Puanı	Polifenol Puanı	Form Puanı	Kafein Puanı	Toplam Skor	 Teknik Karar ve Veri Yönetimi Gerekeçesi 	Nihai Sınıf
A7	10	10	10	10	10.0	Veri Konsolidasyonu: Öretizi beyanı ve "Premium" ibaresiyle tem uyumlu en list değerler referans alınmıştır.	Sınıf 1
A3	10	10	10	9	9.9	Veri Konsolidasyonu: Yüksek EGCG ve tomurcuk yapısı nedeniyle polifenol ve ORAC'ta tavan puanlar tekdir edilmiştir.	Sınıf 1
A10	9	10	10	8	9.4	Veri Konsolidasyonu: Rafine polifenol profili ve dökme formuyla 1. anaf spektrumuna dahil edilmiştir.	Sınıf 1
A9	9	9	10	9	9.1	Veri Konsolidasyonu: Genç filiz yapısı ve yüksek polifenol (100-150 mg) verisi doğrudan puanlanmıştır.	Sınıf 1
A11	8	8	10	7	8.3	Veri Konsolidasyonu: Organik üretim avantajı, orta üst polifenol (80-120 mg) değerleriyle birleştirilmiştir.	Sınıf 1
A14	7	8	10	7	7.9	Veri Konsolidasyonu: Genç sürgün harmanı verisi, 2. sınıfın en üst puanlarıyla (Orta-Yüksek) eşleştirilmiştir.	Sınıf 2
A4	7	7	10	7	7.6	Veri Konsolidasyonu: Yumuşak içim ve orta-yüksek ORAC bayanı, 2. sınıfın çekirdek değerlerini oluşturur.	Sınıf 2
A12	6	7	10	7	7.2	Veri Konsolidasyonu: Orta polifenol (70-100 mg) ve aromatik yapı verileri sayısallaştırılmıştır.	Sınıf 2
A5	6	6	10	6	6.6	Veri İmputasyonu: Tablo 2'de sayısal veri kısıtlıdır; numune "ikizleri" (A12, A14) ve dökme formu referans alınarak orta değerlere atanmıştır.	Sınıf 2
A1	5	5	10	7	6.2	Veri İmputasyonu: "Düşük-orta" ifadesi, veri setindeki alt limitlerin bir basamak üstü olan 5 puanla (Benchmark) doldurulmuştur.	Sınıf 2
A15	5	6	4	5	5.1	Veri Konsolidasyonu: Orta kalite poget çay verisi, düşük form puanı ve orta kimyasal değerlerle dengelenmiştir.	Sınıf 2
A2	6	6	6	6	5.6	Veri Konsolidasyonu: Katkılı yapısı ve poşet formu, kimyasal değerleri orta olsa da skoru 3. sınıfa çekmiştir.	Sınıf 3
A13	5	6	6	6	5.2	Veri Konsolidasyonu: 80-100 mg polifenol verisine rağmen poşet formu nedeniyle 3. sınıfa dahil edilmiştir.	Sınıf 3
A8	4	5	4	5	4.4	Veri Konsolidasyonu: Ekonomik poşet ve düşük orta ORAC (600-800µmol) verileri düşük puanlarla normalize edilmiştir.	Sınıf 3
A6	3	3	4	7	4.0	Veri Konsolidasyonu: "Orta-düşük" kimyasal profil ve zayıf arema beyanıyla düşük kalite spektrumuna sabitlenmiştir.	Sınıf 3
A16	2	2	4	4	2.6	Veri Konsolidasyonu: En düşük polifenol (60-80 mg) ve en düşük ORAC değerleri "Alt Sınır" (Bottom) olarak puanlanmıştır.	Sınıf 3

Şekil 7. Çay Kalite Sınıfları

Şekil 7'deki görselde sensör tabanlı sınıflandırma modelinde kullanılan etiket yapısını net biçimde gösterilmektedir.

Tablo 2, 16 çay örneğinin teknik özelliklerini; Tablo 3’ise sınıf bazlı referans aralıkları sunarak sensör tabanlı sınıflandırmanın temelini oluşturur.



Şekil 8. Çay Numunelerinin Kalite Sınıflandırma Spektrumu

Şekil 8’deki görselde çay numunelerinin kimyasal kalite spektrumu ve üç ana sınıf arasındaki geçiş yapısı şematik olarak gösterilmiştir.

3. YÖNTEM (MATERYAL-METOD)

Bu bölümde, çalışmada izlenen deneysel yaklaşım, kullanılan ölçüm sistemi ve veri temelli sinyal işleme süreci ayrıntılarıyla açıklanmaktadır. Çay numunelerinden elde edilen sensör verilerinin toplanması, ön işlenmesi, öznitelik çıkarımı ve makine öğrenmesi tabanlı sınıflandırma adımları, çalışmanın tekrarlanabilirliğini sağlayacak biçimde sunulmaktadır.

3.1. Sensör, Mikrodenetleyici ve Donanım Bileşenleri

Bu çalışmada kullanılan deneysel ölçüm sistemi; gaz algılama sensörü, mikrodenetleyici tabanlı veri toplama birimi, kontrollü ölçüm ortamı, ısıtma ve vakum bileşenleri ile veri kayıt altyapısından oluşmaktadır. Sistem, çay örneklerinden yayılan uçucu organik bileşiklerin (VOC) kararlı ve tekrarlanabilir koşullar altında algılanmasını sağlayacak şekilde bütünleşik olarak tasarlanmıştır.

Deneysel düzeneğin merkezinde yer alan *BME688* gaz sensörü, metal oksit tabanlı (MOX) algılama prensibiyle çalışmakta olup sıcaklık, bağıl nem, atmosfer basıncı ve gaz direnci gibi çoklu fiziksel büyüklükleri eş zamanlı olarak ölçebilmektedir. Sensörün çok parametreliliği ölçüm yeteneği, yalnızca gaz konsantrasyonuna değil, aynı zamanda çevresel koşullara bağlı değişimlerin de izlenmesine olanak tanımaktadır (Barsan ve Weimar, 2001).

Sensör modülü, bir *ESP32* tabanlı mikrodenetleyici kart ile haberleştirilmiştir. *ESP32* birimi; sensörden alınan ölçümlerin zaman damgalı olarak okunması, yapılandırma dosyalarının uygulanması ve elde edilen verilerin harici bir bellek ortamına kaydedilmesi görevlerini üstlenmektedir. Ayrıca bu birim, kablosuz iletişim desteği sayesinde mobil uygulama üzerinden ölçüm sürecinin izlenmesine ve etiketlenmesine imkân sağlamaktadır (Madhavi vd., 2020).

Ölçümler, gaz kaçaqlarını en aza indirecek şekilde tasarlanmış vakumlu bir ölçüm kabı içerisinde gerçekleştirilmiştir. Çay numunesi bu kap içerisine yerleştirilmiş; kabın üst kısmında bulunan hava çıkış hattı aracılığıyla ortam havası kontrollü biçimde uzaklaştırılmıştır. Bu sayede ölçüm hacmi içerisindeki VOC yoğunluğu artırılarak sensörün gazlara verdiği tepkinin belirginleştirilmesi amaçlanmıştır.

VOC salınımını hızlandırmak ve çay yapraklarından uçucu bileşiklerin kontrollü şekilde açığa çıkmasını sağlamak amacıyla ölçüm kabının altına düşük güçlü bir ısıtma ünitesi entegre edilmiştir. Isıtma sistemi, sensörün kendi ısıtıcı profilleriyle etkileşime girmeyecek biçimde konumlandırılmış ve yalnızca numune ortamını etkileyecek şekilde kullanılmıştır. Bu yaklaşım, sensör ölçümlerinin kararlılığını korurken çay numunesine ait gaz profilinin daha kısa sürede gözlemlenmesini mümkün kılmıştır (Pardo vd., 2000).

Elde edilen ölçüm verileri, sistem üzerinde yer alan *MicroSD* kart aracılığıyla kaydedilmiştir. Veri kayıt altyapısı, sensör tarafından üretilen zaman serilerinin ham hâlleriyle saklanmasına olanak tanımakta; böylece ölçüm sonrası veri kaybı olmaksızın çevrimdışı analiz ve dönüştürme işlemleri gerçekleştirilebilmektedir.

Deneysel sistemin tüm bileşenleri, ölçüm sürecinin her aşamasında birlikte ve uyumlu şekilde çalışacak biçimde yapılandırılmıştır. Bu bütünleşik donanım yapısı, çay örneklerinden elde edilen gaz tepkilerinin tekrar edilebilir, karşılaştırılabilir ve sistematik biçimde toplanmasını sağlayan temel altyapıyı oluşturmaktadır.

3.1.1. BME688 Sensörünün Özellikleri

Bu çalışmada kullanılan *BME688* sensör modülü, *Bosch Sensortec* tarafından geliştirilen ve gaz algılama yeteneğini yapay zekâ destekli veri işleme yaklaşımlarıyla birleştiren çok parametrelili gelişmiş bir MOS sensör yapısına sahiptir (Schütze vd., 2017). *BME688*, aynı anda birden fazla fiziksel büyüklüğü ölçebilmesi sayesinde, gaz tabanlı kalite analizlerinde yaygın olarak tercih edilen bütünleşmiş sensör çözümleri arasında yer almaktadır.

Sensör;

- Sıcaklık (°C),
- Bağıl nem (%RH),
- Atmosfer basıncı (hPa),


Gibi temel çevresel parametrelerin yanı sıra, metal oksit (MOX) tabanlı gaz algılama hücresi aracılığıyla gaz direnci (Ω) çıktısı da üretmektedir. Gaz direnci ölçümü, sensör yüzeyine adsorbe olan uçucu organik bileşiklerin (VOC) konsantrasyonuna bağlı olarak değişmekte ve bu değişim, ortamda bulunan gaz

bileşenlerine ilişkin dolaylı fakat ayırt edici bir bilgi sunmaktadır (Barsan ve Weimar, 2001).

BME688 sensörü, bu çoklu ölçüm çıktılarından yararlanarak *IAQ* (*Indoor Air Quality*) veya uygulamaya bağlı olarak *IAQ Proxy* olarak adlandırılan türetilmiş bir gösterge üretmeye imkân tanımaktadır. *IAQ/IAQ Proxy* değeri; gaz direnci, nem ve sıcaklık ölçümlerinin birlikte değerlendirilmesiyle elde edilen, ortam hava kalitesinin görece düzeyini temsil eden bir indekstir. Bu çalışmada, resmi BSEC çıktılarından doğrudan kullanılmadığı durumlar için, *IAQ* kavramını temsilen tanımlanan *IAQ Proxy* metriği tercih edilmiştir.

BME688'in gaz algılama yeteneği, farklı ısıtıcı profil adımları altında çalışan çoklu ölçüm döngüleri sayesinde geniş bir VOC spektrumuna duyarlılık göstermektedir. Sensörün bu özelliği, özellikle karmaşık organik bileşik karışımlarına sahip çay örneklerinde, gaz tepkilerinin zamana bağlı karakteristiklerinin ayrıştırılmasına olanak tanımaktadır. Böylece her çay numunesi için, sensör çıktılarından türetilen özgün bir gaz yanıt profili elde edilebilmektedir.

Bu bağlamda *BME688* sensörü, geleneksel tek parametrelili gaz sensörlerinden farklı olarak, çok boyutlu veri üretme kapasitesi sayesinde çay örneklerinden yayılan VOC bileşenlerinin bütüncül bir şekilde analiz edilmesini mümkün kılmaktadır. Sensörden elde edilen bu zengin veri yapısı, ilerleyen aşamalarda gerçekleştirilen öznitelik çıkarımı ve makine öğrenmesi tabanlı sınıflandırma işlemleri için temel girdi setini oluşturmaktadır.



Şekil 9. BME688 Sensör Modülünün Teknik Bileşenleri

Şekil 9'daki görselde, *BME688* sensör modülünün fiziksel yapısı ve başlıca teknik bileşenleri gösterilmektedir. Sensörün kompakt yapısı ve bütünleşmiş ölçüm

birimleri, deneysel düzenek içerisinde kolay konumlandırılabilmesini ve tekrarlanabilir ölçümler yapılabilmesini sağlamaktadır.

3.1.2. ESP32 Mikrodenetleyici ve Bağlantı Yapısı

Bu çalışmada sensör verilerinin toplanması, zaman damgalanması ve depolanması işlemleri *ESP32* tabanlı bir mikrodenetleyici sistemi aracılığıyla gerçekleştirilmiştir. *ESP32*, ölçüm süreci boyunca *BME688* sensörünün çalışmasını kontrol etmekte, veri okuma zamanlamasını yönetmekte ve elde edilen ölçüm değerlerini kayıt ortamına aktarmaktadır.


Her bir ölçüm oturumunda sensör verileri, yaklaşık 1,38 Hz. örnekleme frekansı (yaklaşık 0,72 saniyede bir örnek) ile elde edilmiştir. Bu örnekleme hızı ile 30 dakikalık bir ölçüm döngüsü boyunca, zaman serisi ekseninde her bir sensör hücresi için yaklaşık 2.500 satır veri üretilmiş; sensör modülü içerisinde yer alan 8 adet eş zamanlı bağımsız algılama kanalı (U1–U8) genelinde ise ortalama 18.000’in üzerinde toplam veri noktası başarıyla kaydedilmiştir. Bu yoğun ve çok boyutlu zaman serisi yapısı, çay numunelerinden yayılan uçucu bileşiklerin (VOC) zamana bağlı dinamik davranışlarının ayrıntılı biçimde analiz edilmesine imkân sağlamaktadır.

Toplanan tüm sensör ölçümleri, *ESP32* mikrodenetleyici tarafından zaman damgası (*timestamp*) bilgisi ile etiketlenmiş ve harici *MicroSD* kart üzerine ham veri formatında kaydedilmiştir. Zaman damgalı veri yapısı sayesinde, farklı ölçüm oturumları ve sensör kanalları arasında senkronizasyon sağlanmış; sonraki aşamalarda gerçekleştirilen zaman serisi analizi ve öznitelik çıkarımı işlemleri için güvenilir bir temel oluşturulmuştur.

Bu çalışmada kullanılan geliştirme kartı, Adafruit *HUZZAH32 Feather ESP32* modelidir. Kart; çift çekirdekli *Tensilica LX6* işlemci mimarisi, yeterli bellek kapasitesi ve düşük güç tüketimi özellikleri sayesinde uzun süreli ölçümlerde kararlı bir performans sunmaktadır. Ayrıca kart üzerinde yer alan *Wi-Fi* (802.11 b/g/n) ve *Bluetooth* (v4.2/BLE) desteği, mobil uygulama üzerinden etiketleme ve kablosuz veri izleme gibi yardımcı işlevlerin gerçekleştirilmesine olanak tanımıştır (Adafruit Industries, 2022; Espressif, 2024).

Sonuç olarak *ESP32* mikrodenetleyici, sensör kontrolü, zamanlama hassasiyeti ve veri bütünlüğü açısından çalışmanın ihtiyaç duyduğu ölçüm altyapısını güvenilir

biçimde sağlamış; sensör tabanlı çay kalite analiz sisteminin taşınabilir ve tekrar üretilebilir bir yapıda kurulmasına önemli katkı sunmuştur.



Şekil 10. ESP32 Mikrodenetleyici Kartı

Şekil 10'daki görselde, *ESP32* mikrodnetleyicinin fiziksel yapısı ve başlıca teknik bileşenleri gösterilmektedir. Wi-Fi anten bağlantısı ve bluetooth bağlantısı ile veri akışı mobil uygulama üzerinden takip edilmesini sağlamaktadır.

3.1.3. Donanımı Oluşturan Bileşenlerin Teknik Özellikleri

Bu çalışmada geliştirilen deneysel ölçüm sistemi, çevresel ve gaz tabanlı sinyallerin eş zamanlı olarak izlenebilmesini sağlayan Bosch *BME688* sensörü ile bu verilerin toplanması, ön işlenmesi ve kaydedilmesinden sorumlu olan *ESP32* mikrodnetleyici bileşenlerinden oluşmaktadır. Sistem mimarisi, sensör tabanlı ölçümlerin uzun süreli, kararlı ve tekrarlanabilir biçimde gerçekleştirilebilmesini hedefleyecek şekilde yapılandırılmıştır.

BME688 sensörü, metal oksit yarıiletken (MOX) temelli gaz algılama prensibiyle çalışmakta olup, sensör yüzeyinde gerçekleşen gaz *adsorpsiyon–Desorpsiyon* süreçleri sonucunda ortaya çıkan direnç değişimlerini ölçmektedir. Bu yapı, sensörün farklı uçucu organik bileşiklere (VOC) karşı çapraz duyarlılık göstermesine neden olmakta; elde edilen gaz sinyalleri belirli bir bileşiğin doğrudan tespitinden ziyade, ortamdaki gaz karışımının görelî ve istatistiksel karakteristiğini yansıtmaktadır (Gardner ve Bartlett, 1994). Sensörün güvenilir ölçüm sağlayabilmesi için ölçüm öncesinde kısa bir ısı stabilizasyon ve denge evresinden geçmesi gerekmekte; bu süreçte sensör, ortam koşullarına uyum sağlayarak referans temel seviyesini (*baseline*) oluşturmaktadır.

BME688, sıcaklık, bağıl nem, atmosfer basıncı ve gaz direnci parametrelerini eş zamanlı olarak ölçebilmekte; ayrıca Bosch tarafından geliştirilen BSEC yazılım altyapısı aracılığıyla bu ham verilerden *IAQ* veya *IAQ Proxy* gibi türetilmiş göstergelerin hesaplanmasına imkân tanımaktadır. Sensörün kısa tepki süresi, VOC bileşenlerinin zamana bağlı davranışlarının yüksek çözünürlükte izlenmesini mümkün kılmakta; bu durum zaman serisi analizi ve öznitelik çıkarımı için uygun bir veri yapısı oluşturmaktadır. Çalışmada kullanılan *BME688* sensörüne ait temel teknik özellikler Tablo 6’da özetlenmiştir.

ESP32 mikrodenetleyici ise sistemin merkezi kontrol birimi olarak görev yapmakta; *BME688* sensöründen elde edilen ölçüm verilerini I²C haberleşme protokolü üzerinden okuyarak zaman damgalamakta, ön işleme adımlarını yürütmekte ve *MicroSD* kart üzerine kaydetmektedir. Düşük hat sayısı gerektirmesi ve kararlı veri iletimi sağlaması nedeniyle tercih edilen I²C protokolü, sensör verilerinin uzun süreli ölçümler boyunca bütünlüğünü korumasına katkı sağlamıştır. *ESP32* ile *BME688* arasındaki temel donanım bağlantıları ve pin konfigürasyonu Tablo 8’de verilmiştir.

ESP32, sahip olduğu çift çekirdekli işlemci mimarisi, çoklu haberleşme arayüzleri (I²C, SPI, UART) ve düşük güç tüketimli çalışma modları sayesinde, sensör kontrolü, veri toplama, ön işleme ve kayıt işlemlerini eş zamanlı biçimde yürütebilecek donanımsal yetkinliğe sahiptir. Ayrıca Wi-Fi ve *Bluetooth* tabanlı kablosuz iletişim olanakları, ölçüm sürecinin mobil uygulama üzerinden izlenmesine ve ölçümlerin uzaktan etiketlenmesine imkân sunmaktadır. *ESP32* mikrodenetleyicisine ait temel teknik özellikler Tablo 7’de özetlenmiştir.

Genel olarak değerlendirildiğinde, *BME688* sensörünün çok boyutlu çevresel ve gaz algılama yeteneği ile *ESP32* mikrodenetleyicinin işlem gücü ve esnek haberleşme altyapısı, çay örneklerinden yayılan uçucu bileşiklerin izlenmesine yönelik geliştirilen bu deneysel düzenekte birbirini tamamlayan bir yapı oluşturmuştur. Bu bütünleşik donanım altyapısı, elde edilen sensör verilerinin istatistiksel özniteliklere dönüştürülerek makine öğrenmesi tabanlı kalite sınıflandırma süreçlerinde kullanılabilmesi için güvenilir ve sürdürülebilir bir temel sağlamıştır.

Tablo 6. BME688 Sensörünün Temel Teknik Özellikleri

Özellik	Açıklama
Ölçüm Parametreleri	Sıcaklık, Nem, Basınç, Gaz Direnci, <i>IAQ Proxy</i>
Gaz Algılama Aralığı	0 – 500 k Ω
Çalışma Gerilimi	1,8 – 3,6 V
İletişim Arayüzü	I ² C / SPI
Tipik Güç Tüketimi	0.9 mA (düşük güç modunda)
Sensör Tipi	Metal Oksit Yarıiletken (MOX)
AI Entegrasyonu	BSEC Yazılımı üzerinden yapılandırılabilir
Tepki Süresi	<1 s (gaz yanıtı)
Ölçüm Duyarlılığı	$\pm 0,3$ °C (sıcaklık), $\pm \%3$ RH (nem)

Tablo 6’da veri alma çalışmasında kullanılan *BME688* sensörünün temel ölçüm kabiliyetleri, elektriksel özellikleri ve yapısal parametreleri özetlenmiştir.

Tablo 7. ESP32 Mikrodenetleyicisine Ait Temel Teknik Özellikler

Özellik	Açıklama
İşlemci	Çift çekirdek Dual-Core Tensilica LX6 (maks. 240 MHz)
Haberleşme Protokolleri	I ² C, SPI, UART
Kablosuz İletişim	Wi-Fi 802.11 b/g/n, Bluetooth v4.2 (BLE)
Güç Tüketimi	Düşük güç modunda ≈ 0.8 mA
Çalışma Gerilimi	3.0 – 3.6 V
Harici Depolama	MicroSD kart (SPI arayüzü üzerinden)

Tablo 7’de çalışmada kullanılan *ESP32* mikrodenetleyicisinin deneysel düzenek açısından belirleyici olan işlemci, haberleşme, güç ve depolama özellikleri özetlenmiştir. Çift çekirdekli işlemci mimarisi, sensör verilerinin okunması, zaman damgalanması ve dosyaya yazılması gibi işlemlerin paralel biçimde yürütülmesine olanak tanımıştır.

Tablo 8. ESP32–BME688 Sistem Bağlantıları

Bileşen	ESP32 Pin	Açıklama
BME688 SDA	GPIO 21	Veri hattı
BME688 SCL	GPIO 22	Saat hattı
3.3 V	3V3 pini	Güç beslemesi
GND	GND pini	Toprak hattı
SD Kart	SPI (GPIO 18, 19, 23, 5)	Ölçüm verilerinin kaydedilmesi

Tablo 8’de *ESP32* mikrodnetleyicisi ile *BME688* sensörü arasındaki temel donanım bağlantıları ve veri iletiminde kullanılan pin konfigürasyonu özetlenmektedir. Sensör, 3.3 V ile beslenerek *ESP32* ile voltaj uyumluluğu sağlanmış; böylece ilave seviye dönüştürücü kullanımına gerek duyulmamıştır.

3.2. Yazılım Altyapısı ve Sistem Entegrasyonu

Deneysel ölçüm sisteminin eksiksiz ve kararlı biçimde çalışabilmesi için, *ESP32* mikrodnetleyicisi ile *BME688* sensör modülünün hem donanımsal hem de yazılımsal olarak doğru şekilde yapılandırılması gerekmektedir. Bu kapsamda, sensör–mikrodnetleyici haberleşmesinin tanımlanması, gerekli yazılım kütüphanelerinin kurulması ve ölçüm sürecini yöneten *Firmware*’in uygun biçimde yapılandırılması gerçekleştirilmiştir.

Sistem kurulumu üç temel aşamada yürütülmüştür:


- (i) geliştirme ortamının hazırlanması,
- (ii) sensör ve mikrodnetleyici yazılım entegrasyonu,
- (iii) sensör yapılandırma ve veri kayıt süreçlerinin doğrulanması.

Bu aşamalarda *Arduino IDE*, *Bosch AI-Studio* ve BSEC (*Bosch Sensortec Environmental Cluster*) yazılım araçları birlikte kullanılmıştır. *Arduino IDE* ortamı, *ESP32* mikrodnetleyicisine ait *Firmware*’in oluşturulması ve sensör–donanım arabiriminin yönetilmesi amacıyla tercih edilirken; *Bosch AI-Studio*, sensörün çalışma profillerinin hazırlanması ve etiketleme süreçlerinin yürütülmesinde kullanılmıştır. BSEC kütüphanesi ise sensörden elde edilen ham ölçümlerin ön işleme tabi tutulması ve *IAQ/IAQ Proxy* gibi türetilmiş parametrelerin hesaplanmasında görev almıştır (Fahim vd., 2019).

ESP32 üzerine yüklenen *Firmware*, ölçüm sırasında sensörden gelen sıcaklık, bağıl nem, basınç ve gaz direnci verilerini zaman damgalı biçimde okuyarak hem *MicroSD* karta kaydetmekte hem de ilgili yazılım modüllerine aktarmaktadır. Bu sayede ölçüm süreci boyunca veri kaybı olmadan, tutarlı ve senkronize bir veri akışı sağlanmıştır. Kurulan bu yazılım entegrasyonu, hem çevrimdışı (SD kart tabanlı) analizler hem de ilerleyen aşamalarda mobil veya bilgisayar tabanlı doğrulama çalışmaları için esnek bir altyapı sunmaktadır (Maddox vd., 2021).

Sonuç olarak, *ESP32* ve *BME688* bileşenlerinin yazılım entegrasyonu; sensör konfigürasyonu, veri toplama ve ön işleme adımlarını kapsayan bütüncül bir yapı

oluşturarak, çay kalitesinin zaman serisi temelli ve makine öğrenmesi destekli analizine uygun bir deneysel zemin hazırlamıştır.



Şekil 11. ESP32 ve BME688 Sistem Kurulumu ve Yazılım Entegrasyon Akışı

Şekil 11’deki görselde, *ESP32*-*BME 688* sensör akışı gösterilmektedir. *ESP32* ve *BME688* tabanlı sistemde sensör verilerinin *Arduino IDE* üzerinden yapılandırılarak *BSEC* ile ön işlenmesini ve elde edilen verilerin *SD* kart, *AI-Studio* ve *MATLAB* ortamlarına aktarım akışını göstermektedir.

3.2.1. AI Entegrasyonu ve Yazılım Yapısı


BME688 sensörü, klasik MOS tabanlı gaz sensörlerinden farklı olarak, ölçüm çıktılarının yalnızca donanım seviyesinde değerlendirilmesi yerine, *Bosch Sensortec* tarafından geliştirilen *BSEC* (*Bosch Sensortec Environmental Cluster*) yazılım kütüphanesi ile çalışacak şekilde tasarlanmıştır. Bu yapı, sensör verilerinin yapay zekâ destekli algoritmalar aracılığıyla işlenmesini mümkün kılmaktadır.

BSEC yazılım yapısı, sensörden elde edilen ham gaz direnci, sıcaklık ve nem verilerini çok aşamalı bir sinyal işleme zincirinden geçirerek anlamlı ve kararlı çıktılar üretmektedir.

Bu süreçte yazılım kütüphanesi;

- Sensörün ilk çalıştırma aşamasındaki ısınma ve stabilizasyon etkilerini,
- Zamanla oluşabilecek sensör sürüklenmelerini (*sensor drift*),
- Ortam koşullarına bağlı nem ve sıcaklık kaynaklı çapraz etkileri istatistiksel ve öğrenme tabanlı yöntemlerle dengelemektedir. Böylece uzun süreli ölçümlerde sensör çıktılarının tutarlılığı artırılmaktadır.

BSEC algoritmasının temel çıktılarından biri, IAQ (*Indoor Air Quality*) metriğidir. IAQ, sensörün gaz hücresinden elde edilen direnç değişimlerinin çevresel parametrelerle birlikte değerlendirilmesi sonucunda hesaplanan, ortam gaz yoğunluğunu temsil eden bileşik bir göstergedir. Ancak BSEC kütüphanesinin bazı donanım–yazılım kombinasyonlarında IAQ çıktısının doğrudan üretilmediği durumlar söz konusu olabilmektedir. Bu çalışmada bu sınırlılık göz önünde bulundurularak, IAQ kavramını temsil edecek biçimde tanımlanan *IAQ Proxy* metriği kullanılmıştır.



Şekil 12. BSEC Algoritması ve IAQ Proxy Metrik Çıktısı

Şekil 12’deki görselde, *BME688*–BSEC entegrasyonunun bir diğer önemli özelliği, uygulamaya özel model eğitimi yapılabilmesine olanak tanıyan yapay zeka altyapısını göstermektedir.

Bosch tarafından sağlanan *AI-Studio* yazılımı aracılığıyla sensör, belirli hedef uygulamalara (örneğin gıda kalitesi, koku profili, ortam havası analizi) özgü veri setleriyle eğitilebilmekte ve bu eğitim sonucunda sensöre özgü sınıflandırma profilleri oluşturulabilmektedir. Böylece aynı donanım, farklı kullanım senaryolarında farklı davranış modelleri sergileyebilmektedir.

Bu çalışmada BSEC tabanlı yazılım altyapısı, sensör verilerinin ön işlenmesi ve türetilmiş metriklerin (gaz direnci, sıcaklık, nem ve *IAQ Proxy*) kararlı biçimde elde edilmesi amacıyla kullanılmıştır. Ardından elde edilen bu işlenmiş çıktılar, *MATLAB* ortamında gerçekleştirilen öznitelik çıkarımı ve makine öğrenmesi tabanlı sınıflandırma süreçlerine girdi olarak aktarılmıştır. Bu yaklaşım, sensör seviyesinde

temel gürültü ve sürüklenme etkilerinin bastırılmasını, modelleme aşamasında ise daha ayırt edici ve güvenilir bir veri yapısının kullanılmasını sağlamıştır.

Bu bağlamda *BME688* sensörü, donanım–yazılım bütünlüğü içerisinde değerlendirildiğinde, yalnızca bir ölçüm elemanı değil; ölçüm, ön işleme ve öğrenme tabanlı analiz adımlarını kapsayan bütünleşmiş bir algılama sistemi olarak ele alınmaktadır.

3.2.2. Kullanılan Yazılım ve Araçlar


Deneysel ölçüm süreci, veri toplama, ön işleme, etiketleme, model geliştirme ve performans değerlendirme adımlarının tamamı; donanım bileşenleriyle uyumlu çalışan çeşitli yazılım ve geliştirme araçları kullanılarak yürütülmüştür. Bu yazılım altyapısı, sensör verilerinin güvenilir biçimde kaydedilmesini, işlenmesini ve makine öğrenmesi tabanlı analizlere hazır hale getirilmesini sağlamaktadır.

Tablo 9. Çalışma Kapsamında Kullanılan Yazılım ve Geliştirme Araçları

Yazılım / Araç	Sürüm	Kullanım Amacı
Bosch AI-Studio Desktop	V3.1.0	Sensör verilerinin etiketlenmesi, çalışma profillerinin hazırlanması ve konfigürasyon dosyalarının oluşturulması
Bosch AI-Studio Mobile	V3.0.1	Mobil ortamda ölçüm izleme, etiketleme ve test amaçlı model doğrulama
BSEC SDK	V3.2.1.0	Ham sensör verilerinden IAQ ve IAQ Proxy gibi türetilmiş metriklerin hesaplanması
Arduino IDE	V2.x	ESP32 mikrodenetleyicisinin programlanması ve sensör–kart iletişiminin sağlanması
MATLAB	2024'a	Veri işleme, öz nitelik çıkarımı ve makine öğrenmesi tabanlı sınıflandırma modellerinin geliştirilmesi
Python	3.x	CSV/XLSX format dönüşümleri ve veri temizleme (pandas, numpy kütüphaneleri)

Tablo 9 incelendiğinde deneysel sürecin farklı aşamalarında kullanılan yazılım araçlarının sürümleri ve temel işlevleri özetlenmiştir. *Bosch AI-Studio* yazılımları, sensör donanımı ile doğrudan etkileşim sağlayarak ölçüm ve etiketleme süreçlerinin tutarlı biçimde yürütülmesine olanak tanımıştır. BSEC SDK ise sensör sürüklenmelerini ve çevresel etkileri dikkate alan ön işleme adımlarıyla, gaz verilerinin daha kararlı ve karşılaştırılabilir hale getirilmesini sağlamıştır.

Arduino IDE ortamı, *ESP32* tabanlı ölçüm sisteminin kontrol yazılımının geliştirilmesinde kullanılmış; *Python* betikleri ise ham veri dosyalarının analiz ortamlarına uygun biçimde dönüştürülmesi ve veri bütünlüğünün korunması amacıyla tercih edilmiştir (NumPy Developers, 2024; Pandas Developers, 2024). *MATLAB* ortamı, tüm bu süreçlerin sonunda elde edilen veri kümeleri üzerinde istatistiksel analizler, özellik çıkarımı ve ECOC tabanlı SVM modellerinin oluşturulması için ana analiz platformu olarak kullanılmıştır (MathWorks, 2024).



Şekil 13. Entegre Yazılım Yığının Piramidi.

Şekil 13'teki görselde kullanılan yazılım ve araçlar, donanım bileşenlerini destekleyen, birbirini tamamlayan ve uçtan uca bir veri işleme zinciri oluşturan bütünlük bir altyapı sunmuş; bu yapı, çay kalitesinin sensör tabanlı ve makine öğrenmesi destekli olarak analiz edilmesine olanak tanımıştır.

3.2.3. Arduino IDE Kurulum Adımları

ESP32 geliştirme kartının programlanabilmesi ve *BME688* sensörü ile uyumlu biçimde çalışabilmesi için *Arduino IDE* ortamında gerekli kart tanımları ve yazılım kütüphaneleri kurulmuştur. Bu adımlar, gömülü sistem yazılımının doğru biçimde derlenmesi, sensör verilerinin kararlı şekilde okunması ve ölçüm sürecinin güvenilir biçimde yürütülmesi açısından kritik öneme sahiptir.

3.2.3.1. ESP32 Kart Desteęinin Y¼klenmesi

Arduino IDE'nin *ESP32* mimarisini desteklemesi amacıyla, *Preferences* men¼s¼ altında yer alan *Additional Board Manager URLs* alanına Espressif Systems tarafından saęlanan resmi kart tanım dizini eklenmiřtir. Bu iřlemin ardından *Tools - Board Manager* men¼s¼nden *ESP32 by Espressif Systems* paketi indirilmiř ve *Arduino IDE* ortamına entegre edilmiřtir. B¼ylece *ESP32* tabanlı geliřtirme kartlarının *Arduino IDE* üzerinden programlanabilmesi saęlanmıřtır.

3.2.3.2. Kullanılan Arduino K¼t¼phaneleri

Sens¼r okuma ve veri kaydı iřlemlerinin y¼r¼t¼lebilmesi i¼in ařaęıdaki Arduino k¼t¼phaneleri kullanılmıřtır:

- *Adafruit BME680 Library* (*BME688* sens¼r¼ ile geriye d¼n¼k uyumludur)
- *Wire* (I²C haberleřme protokol¼ i¼in)
- *SD* (*MicroSD* kart ¼zerinden veri kaydı i¼in)

Bu k¼t¼phaneler, *BME688* sens¼r¼nden elde edilen ¼evresel verilerin *ESP32* tarafından doęru zamanlama ile okunmasını ve eř zamanlı olarak *SD* karta kaydedilmesini m¼mk¼n kılmaktadır.

3.2.3.3. BSEC Entegrasyonu

Gaz verilerinden t¼retilmiř metriklerin hesaplanabilmesi i¼in *Bosch Sensortec* tarafından saęlanan BSEC (*Bosch Sensortec Environmental Cluster*) yazılım k¼t¼phanesi (v3.2.1.0), *Arduino IDE*'nin *libraries* dizinine manuel olarak eklenmiřtir (Bosch Sensortec, 2021).

IAQ ve *IAQ Proxy* hesaplamalarında kullanılan *bsec_config.config* yapılandırma dosyası *MicroSD* karta y¼klenmiř ve sistem ¼alıřtıęında otomatik olarak ¼aęrılacak řekilde yapılandırılmıřtır. Bu entegrasyon sayesinde sens¼r¼den okunan ham veriler (gaz direnci, sıcaklık, nem, basın¼), BSEC algoritması aracılıęıyla ¼n iřleme tabi tutulmuř ve analiz i¼in anlamlı t¼retilmiř metrikler ¼retilmiřtir.

3.2.3.4. Firmware Y¼kleme ve Konfig¼rasyon

Bosch AI-Studio Desktop (v3.1.0) yazılımı kullanılarak oluřturulan *Firmware* dosyası (*Firmware.bin*), *ESP32* kartına y¼klenmiřtir. *Firmware* y¼kleme iřlemi iki farklı y¼ntemle ger¼ekleřtirilmıřtir:

- Otomatik yükleme: *AI-Studio* arayüzü üzerinden USB bağlantısı ile,
- Manuel yükleme: *esptool.py* komut satırı aracı kullanılarak terminal üzerinden.

Firmware yüklemesinin tamamlanmasının ardından sistem, BSEC yapılandırma dosyalarını otomatik olarak tanımış ve sensörden alınan sinyalleri IAQ hesaplama rutinine yönlendirmiştir. Bu yapılandırma, ölçüm döngüsü boyunca sensör çıktılarının tutarlı ve tekrarlanabilir olmasını sağlamıştır.

3.2.3.5. Sensör Testi ve Led Durum Kontrolü

Kurulumun doğrulanması amacıyla *ESP32* kartı üzerindeki LED durum göstergeleri gözlemlenmiştir:

- Kırmızı LED'in yaklaşık 1 saniyelik aralıklarla yanıp sönmesi, BSEC yazılımının sensör ile senkronize çalıştığını ve IAQ hesaplama rutininin aktif olduğunu onaylar.
- Sarı LED'in sürekli ve hızlı biçimde yanıp sönmesi ise veri toplama modunun aktif olduğunu ve ölçüm döngüsünün başladığını ifade etmektedir.



Şekil 14. ESP32 LED Durum Göstergeleri ile Sensör Testi

Şekil 14'teki görselde LED geri bildirimleri, sistemin hem donanım hem de yazılım düzeyinde doğru biçimde yapılandırıldığını doğrulayan temel bir işlevsel test mekanizması olarak değerlendirilmiştir.


3.3. Deneysel Düzeneğin Fiziksel Tasarımı

Bu çalışmada kullanılan deneysel düzenek, çay örneklerinden yayılan uçucu organik bileşiklerin (VOC) kontrollü ve tekrarlanabilir koşullar altında açığa

çıkarılmasını ve *BME688* sensörü tarafından etkin biçimde algılanmasını sağlamak amacıyla özel olarak tasarlanmıştır. Sistem; vakumlu cam ölçüm kabı (~650 mL hacim), kızılötesi ısıtma ünitesi, hava giriş-çıkış hattı, mini vakum pompası, sensör-mikrodenetleyici modülü ve veri kayıt bileşenlerinden oluşmaktadır. Tüm bileşenler, ölçüm kararlılığını ve veri bütünlüğünü sağlayacak biçimde bütünleşik olarak çalışmaktadır.

3.3.1. Sensör Konumu

BME688 sensörü, ölçüm kabının üst bölümüne yakın bir noktaya yerleştirilmiştir. Bu konumlandırma sayesinde, çay yapraklarından yükselen ve kabin üst bölgesinde yoğunlaşan VOC tabakasının doğrudan sensör yüzeyine ulaşması sağlanmıştır. Böylece gaz duyarlılığı artırılmış ve ölçümlerin tekrarlanabilirliği güçlendirilmiştir.



Şekil 15. *BME688* Sensörünün Kapak İçerisindeki Konumlandırılması

Şekil 15'te görselde *BME688* sensörünün çevresel etkilere maruz kalmasını en aza indirecek ve VOC algılamasını optimize edecek şekilde kapak içerisine yerleştirilmiş konumunu gösterilmektedir.

3.3.2. Vakumlu Kap

Gaz ölçüm ortamının dış çevresel etkilerden izole edilebilmesi amacıyla vakumlu cam ölçüm kabı kullanılmıştır. Ölçüm öncesinde kabin içindeki hava büyük

ölçüde boşaltılarak sabit ve kontrollü basınç koşulları elde edilmiştir. Bu yaklaşım, çay örneğinden çıkan VOC belirli bir hacimde yoğunlaşmasını sağlayarak sensör tepkisinin daha belirgin hâle gelmesini mümkün kılmıştır (TE Connectivity, 2020).



Şekil 16. Vakumlu Ölçüm Kabı

Şekil 16’da görselde çay numunelerinden salınan uçucu organik bileşiklerin (VOC) kontrollü ve tekrarlanabilir koşullarda ölçülmesi amacıyla kullanılan vakumlu ölçüm kabını gösterilmektedir.

3.3.3. Isıtma Ünitesi

Numune kabının altına, 11 W gücünde ve 50 Hz. frekansında çalışan kızılötesi (IR) bir ısıtıcı yerleştirilmiştir. Isıtıcı, çay örneğindeki uçucu bileşiklerin salınımını artırmak amacıyla yaklaşık 30 dakika boyunca aktif tutulmuştur. IR ısıtma yöntemi, doğrudan temas gerektirmediğinden numunenin fiziksel yapısını bozmadan ölçüm ortamının kontrollü biçimde ısıtılmasını sağlamıştır.



Şekil 17. Kızılötesi Isıtıcı Ünitesi

Şekil 17’de görselde çay numunesinin kontrollü biçimde ısıtılarak uçucu organik bileşiklerin (VOC) salınımını artırmak amacıyla kullanılan kızılötesi (IR) ısıtıcı ünitesini gösterilmektedir.

3.3.4. Vakum Pompası ve Bileşenleri

Numune kabı içerisinde VOC homojen biçimde dağılması amacıyla, 12 V, 60 kPa basınç kapasitesine ve 2,8 L/dakika debiye sahip mini vakum pompası kullanılmıştır. Hava akışı düşük debili olacak şekilde ayarlanmış ve sensör yüzeyine yönlendirilmiştir. Bu sayede VOC sensörle teması dengeli ve tekrarlanabilir biçimde sağlanmıştır.



Şekil 18. Mini Vakum Pompası

Şekil 18’de görselde, ölçüm kabı içerisindeki gaz ortamını kontrol etmek ve VOC birikimini desteklemek amacıyla kullanılan mini vakum pompasını gösterilmektedir.

3.3.5. MicroSD Kart Modülü

ESP32 mikrodenetleyicisine entegre edilen 32 GB kapasiteli *MicroSD* kart, tüm ham sensör verilerinin zaman damgalı biçimde kaydedildiği birincil depolama

birimi olarak kullanılmıştır. Ölçüm sırasında elde edilen tüm sensör çıktıları, veri kaybı olmaksızın bu kart üzerine yazılmıştır.



Şekil 19. MicroSD Kart ve Adaptörü

Şekil 19'daki görselde *ESP32* tabanlı sistemden elde edilen sensör verilerinin harici ortamda depolanması ve aktarılması amacıyla kullanılan *MicroSD* kart ve adaptörünü gösterilmektedir.

3.3.6. Bağlantı Kablosu ve Güç Beslemesi

Sistem, taşınabilirlik sağlamak amacıyla 5 V çıkışlı bir güç bankası (*powerbank*) üzerinden beslenmiştir. Sensör–mikrodenetleyici modülü, uygun kesitli bağlantı kabloları ile sürekli ve kararlı bir güç kaynağına bağlanarak ölçüm süresince gerilim dalgalanmalarının önüne geçilmiştir.



Şekil 20. Güç Besleme Bağlantısı ve Kablo Düzeni

Şekil 20'deki görselde, *ESP32* ve bağlı donanım bileşenlerinin kararlı ve güvenli şekilde çalışmasını sağlamak amacıyla kullanılan güç besleme bağlantısını ve kablo düzenini gösterilmektedir.

3.3.7. Dizüstü Bilgisayar (Laptop)

Deney sürecinde veri işleme, dönüştürme ve analiz adımları için 16 Gb RAM ve 512 Gb SSD donanım özelliklerine sahip bir dizüstü bilgisayar kullanılmıştır. *MATLAB* ve *Python* tabanlı veri işleme betikleri bu cihaz üzerinde çalıştırılmıştır.

3.3.8. Cep Telefonu

BME688-ESP32 sistemi ile kablosuz haberleşme ve ölçüm etiketleme işlemleri için *BME688* mobil uygulamasının kurulu olduğu bir akıllı telefon kullanılmıştır. Mobil uygulama üzerinden ölçüm döngüleri başlatılmış, etiketleme işlemleri gerçekleştirilmiş ve sensör durumu anlık olarak izlenmiştir.

Bu deneysel düzenek hem laboratuvar ortamında hem de taşınabilir saha koşullarında kullanılabilecek kompakt bir elektronik burun platformu sunmaktadır. Ölçüm süresi boyunca ortam sıcaklığı ve bağıl nem koşulları kontrol altında tutulmuş; her ölçüm oturumu sonrasında sensör yeniden stabilizasyon sürecine alınarak ölçümlerin tutarlılığı sağlanmıştır.


3.4. Deney Protokolü ve Ölçüm Süreci

Veri toplama sürecine başlanmadan önce, ölçüm sırasında elde edilecek sensör verilerinin güvenilir biçimde kaydedilebilmesi amacıyla *MicroSD* kart uygun dosya sistemi altında biçimlendirilmiştir. Ardından *Bosch BME AI-Studio* yazılımı kullanılarak ölçüm senaryosuna uygun yeni bir proje oluşturulmuş ve bu proje kapsamında üretilen *BoardConfiguration.bmeconfig* yapılandırma dosyası *MicroSD* karta kopyalanmıştır. Hazırlanan SD kart, ölçüme başlanmadan önce *BME688* sensör modülü üzerindeki yuvasına yerleştirilerek sistemin konfigürasyon dosyasını otomatik olarak tanınması sağlanmıştır.

Deneysel düzenekte; *Bosch BME688* değerlendirme kartı, *ESP32* geliştirme kartı, *MicroSD* kart yuvası, güç beslemesi ve programlama işlemleri için kullanılan *micro-USB* kablo ile ölçüm ortamı olarak tasarlanan yaklaşık 0,650mL sızdırmaz vakumlu kap yer almaktadır. Bu bileşenler, sensör verilerinin eş zamanlı olarak toplanması, zaman damgalanması ve güvenli şekilde kaydedilmesi amacıyla bütünleşik biçimde çalışmaktadır.


Deney düzeneğinde kullanılan bileşenlerin yerleşim düzeni, sensörün çay örneklerinden yayılan uçucu organik bileşiklere (VOC) doğrudan maruz kalmasını

sağlayacak şekilde planlanmıştır. Sensör modülü, vakum hattı ve güç bağlantıları arasındaki geometrik konumlar hem ölçüm kararlılığını artırmak hem de sistemin taşınabilirliğini korumak amacıyla düzenlenmiştir.



Şekil 21. Kapak Üzerinde Deney Düzenekinin Yerleşimi

Şekil 21’de ki görselde *BME688* sensör modülü, mini vakum pompası, güç besleme kablosu ve tahliye hattının deney düzeneği içerisindeki konumlandırılmasını ve bileşenler arası yerleşim ilişkisini gösterilmektedir.



Şekil 22. Deney Düzenekinin Genel Yapısı ve Sensör Eklentileri

Şekil 22’de düzenekte *BME688* sensörü, *ESP32* tabanlı veri toplama birimi, vakumlu ölçüm kabı ve ısıtma düzeneklerinden oluşan deney düzenekinin genel yapısını ve sistem bileşenleri arasındaki bağlantıları gösterilmektedir.

Vakumlu ölçüm kabının alt bölümüne yerleştirilen kızılötesi ısıtıcı ünitesi kullanılarak çay örnekleri kontrollü biçimde ısıtılmıştır. Bu uygulama, çay yapraklarından salınan uçucu bileşiklerin hızını ve yoğunluğunu artırarak sensör yüzeyinde daha belirgin ve ayırt edilebilir gaz tepkilerinin oluşmasına katkı sağlamıştır. Böylece ölçüm sürecinde elde edilen gaz yanıtları, makine öğrenmesi tabanlı kalite analizinde kullanılmaya uygun, zengin ve tekrarlanabilir bir veri yapısı sunmuştur.

3.4.1. Ölçüm Öncesi Hazırlık ve Kalibrasyon

Tüm ölçümlerde karşılaştırılabilir koşulların sağlanması amacıyla standartlaştırılmış bir deney protokolü uygulanmıştır. Ölçüm süreci; başlatma ve kalibrasyon, numune ölçümü ve hava temizleme (*Purj*) olmak üzere üç ana aşamadan oluşmaktadır.

3.4.1.1. Başlatma ve Kalibrasyon Aşaması

Sisteme enerji verildikten sonra *ESP32* mikrodenetleyicisi sensörü başlatmış ve BSEC yapılandırma dosyası aracılığıyla *IAQ Proxy* hesaplama süreçleri etkinleştirilmiştir. Ölçüm öncesinde sensör yaklaşık 60 saniyelik bir ısınma evresine alınmıştır. Bu süre boyunca ölçüm ortamında yalnızca temiz hava bulunmuş; sensörün referans gaz direnci (*baseline*) değerini oluşturması ve sıfır noktalarının tanımlanması sağlanmıştır.



Şekil 23. Başlatma –Yapılandırma ve Sıfır Noktaları


Şekil 23'teki görselde Bosch *BME AI-Studio* üzerinden biçimlendirilmesi yapılmış *MicroSD* kart içerisine *.bmeconfig* dosyasının atılması ve Deney düzeneğindeki BME 688 sensör ve *ESP32* mikrodenetleyiciye takılarak mobil uygulama üzerinden donanımın kalibrasyonunun yapılması gösterilmektedir.

3.4.1.2. Çay Örneğinin Hazırlanması ve Kabın Kapatılması

Deneyisel ölçümlerde kullanılacak çay numunesi, her deney için sabit kütle koşulunun sağlanabilmesi amacıyla yaklaşık 100g olacak şekilde tartılarak

hazırlanmıştır. Hazırlanan çay örneği, sensör ölçümlerinin gerçekleştirileceği vakumlu ölçüm kabının içerisine homojen biçimde yerleştirilmiştir.

Numunenin kaba yerleştirilmesinin ardından ölçüm kabı, dış ortam ile gaz alışverişini tamamen kesecek şekilde hava geçirmez olarak kapatılmıştır. Kabin sızdırmaz biçimde kapatılması, ölçüm süresince kabin içindeki uçucu bileşik yoğunluğunun korunmasını ve sensörün yalnızca çay örneğinden kaynaklanan VOC değişimlerine tepki vermesini sağlamaktadır. Bu yaklaşım, ölçümlerin kontrol edilebilir ve tekrarlanabilir koşullar altında yürütülmesi açısından kritik öneme sahiptir.



Şekil 24. Çay ve Deney Düzeneklerinin Genel Görünümü

Şekil 24'teki görselde çay örneğinin ölçüm kabına yerleştirilme aşamasını ve kabin ölçüm öncesinde kapatılmış hâlini gösterilmektedir. Bu aşama, sensör ölçümüne geçilmeden önce gerçekleştirilen son fiziksel hazırlık adımıdır.


3.4.2. Numune Ölçüm Aşaması

Hazırlanan çay numunesi vakumlu ölçüm kabına yerleştirildikten sonra kabin içindeki hava mini pompa yardımıyla kısmen boşaltılmış ve kontrollü bir düşük basınç ortamı oluşturulmuştur. Ardından kızılötesi ısıtıcı devreye alınarak kap içi sıcaklık 30–50 °C aralığında tutulmuştur. Bu koşullar altında çay yapraklarından salınan VOC sensör yüzeyine ulaşması hızlandırılmıştır.

Sensör, bu aşamada gaz bileşenlerindeki değişimleri 1,387 Hz (≈ 0.72 s) örnekleme frekansında kaydetmiştir. Ölçüm süresi 30 dakika olarak belirlenmiş; bu süre sonunda sıcaklık, bağıl nem, basınç, gaz direnci ve *IAQ Proxy* parametreleri için yaklaşık 2.500 zaman adımı (toplam 8 kanal için yaklaşık ≈ 18.000 veri noktası) elde edilmiştir. Tüm veriler *ESP32* tarafından zaman damgası ile *MicroSD* karta kaydedilmiştir.

3.4.3. Hava Temizleme (Purj) Aşaması

Numune ölçümü tamamlandıktan sonra vakum kabı temiz hava ile yıkanarak sensör yüzeyinin başlangıç koşullarına dönmesi sağlanmıştır.



Şekil 25. Purj ve Adsorpsiyon-Desorpsiyon Dengesi


Şekil 25'teki görselde hava temizleme (*Purj*) aşamasına ait amaç ve süreç ve hedef belirtilmiştir.

Bu işlem, bir önceki ölçümden kalan gaz artıklarının sonraki ölçümü etkilemesini önlemek amacıyla uygulanmıştır. Sensörün yeniden adsorpsiyon–*Desorpsiyon* dengesine ulaşabilmesi için yaklaşık 30 dakikalık bir dinlendirme süresi bırakılmıştır.

3.4.4. Ölçüm Zaman Protokolü (30 dk Hava + 30 dk Çay)

Her ölçüm oturumu iki temel evreden oluşmaktadır:

- Hava 1: 30 dakika süreyle boş ortamda referans gaz ölçümü,
- Çay Örneği: 30 dakika süreyle VOC odaklı çay ölçüm



Şekil 26. Hava-Çay Ölçüm Döngüsü

Şekil 26'daki görselde evreler mobil uygulama üzerinden otomatik olarak etiketlenmiş ve her ölçüm segmenti sayısal kodlarla (hava-çay) ayrıştırıldığı gösterilmektedir.

Ölçüm sırasında kızılötesi ısıtıcı ve vakum sistemi eş zamanlı kullanılarak sensörün VOC duyarlılığı artırılmıştır.

3.4.5. Isıtma Amacı ve Sıcaklık Kontrolü

Çay yaprakları bünyesinde bulunan uçucu organik bileşiklerin (VOC) ölçüm ortamına daha hızlı, yoğun ve kararlı biçimde salınmasını sağlamak amacıyla ölçüm süresi boyunca kap içi sıcaklık kontrollü olarak artırılmıştır. Bu kapsamda, kızılötesi (IR) ısıtıcı yardımıyla ölçüm ortamı 30–50 °C aralığında sabit tutulmuştur. Ölçüm süresi, çay numunesine bağlı olarak 20–30 dakika arasında olacak şekilde belirlenmiştir.

Bu sıcaklık aralığı, çay yapraklarının fiziksel yapısını bozmayacak; buna karşın VOC buharlaşma hızını anlamlı biçimde artıracak bir çalışma aralığı olarak tercih edilmiştir. Isıl koşulların tüm numuneler için aynı şekilde uygulanması, VOC salınımının standardizasyonunu sağlayarak sensör yanıtlarının karşılaştırılabilirliğini artırmıştır.

3.4.5.1. Vakum ve Isıtma Sürecinin Başlatılması

Ölçüm kabının kapatılmasının ardından, çay örneğinden uçucu bileşiklerin salınımını desteklemek amacıyla ısıtma ve vakum işlemleri eş zamanlı olarak

başlatılmıştır. Bu kapsamda, ölçüm kabının alt kısmına yerleştirilen düşük güçlü kızılötesi ısıtıcı aktif hâle getirilmiş; üst bölümde bulunan mini vakum pompası aracılığıyla kap içerisindeki hava kontrollü biçimde tahliye edilmiştir.




Şekil 27. VOC Aktivasyon Modeli

Şekil 27’deki görselde deney düzeneğinde Isıtma işlemi, çay yapraklarının sıcaklığını artırarak uçucu organik bileşiklerin (VOC) daha hızlı ve düzenli biçimde gaz fazına geçişi gösterilmektedir.

Vakum uygulaması ise ölçüm ortamındaki gaz yoğunluğunu düzenleyerek sensörün çay örneğinden kaynaklanan VOC değişimlerine daha duyarlı yanıt vermesine olanak tanımaktadır. Bu iki fiziksel etki birlikte kullanılarak, ölçüm sırasında sensör tepkisinin güçlendirilmesi ve veri tekrar edilebilirliğinin artırılması hedeflenmiştir.

Vakum ve ısıtma sürecinin başlatılması, aktif ölçüm döngüsüne geçilmeden önce uygulanan son hazırlık adımıdır ve tüm deneylerde aynı koşullar altında yürütülmüştür. Böylece ölçüm süreci boyunca çevresel etkiler kontrol altına alınarak, farklı çay örneklerinin karşılaştırılabilirliği sağlanmıştır.




Şekil 28. Vakum ve Isıtma Sürecinin Başlatılması için Kullanılan Deney Düzeneği

Şekil 28’deki görselde kuru çay numunesi üzerinde vakum ve kızılötesi ısıtma işlemlerinin başlatılması sırasında kullanılan deney düzeneğini ve mobil AI uygulaması üzerinden sürecin izlenmesini gösterilmektedir.

3.4.6. Etiketleme ve Veri Kaydı

ESP32 mikrodenetleyicisi, Bluetooth aracılığıyla mobil cihaz ile eşleştirilmiş ve ölçüm süresince etiketleme işlemleri kullanıcı müdahalesi gerektirmeden otomatik olarak gerçekleştirilmiştir. Bu yapı, her ölçüm döngüsünün zaman ve numune bilgisiyle doğru bir şekilde ilişkilendirilmesini sağlayarak veri bütünlüğünü korumuştur. Bu doğrultuda ölçüm periyotları sistematik biçimde kaydedilmiş, özellikle Hava–Çay geçişlerinin net biçimde ayrıştırılmasına imkân tanınmıştır.



Şekil 29. Mobil Uygulama ile Verinin Gerçek Zamanlı Kaydı ve Etiketlenmesi

Şekil 29'daki görselde mobil uygulama aracılığıyla *BME688* sensöründen elde edilen verilerin gerçek zamanlı olarak izlenmesini, kaydedilmesini ve ölçüm sürecinde etiketlenmesini gösterilmektedir.

3.4.6.1. Mobil Uygulama ile Etiketleme

Ölçüm sürecinin yürütülmesinde *BME AI-Studio* Mobile uygulaması aktif olarak kullanılmıştır. *ESP32* tabanlı sensör kartı mobil cihaza Bluetooth üzerinden bağlanarak ölçümün başlatılması, durdurulması ve veri etiketlerinin oluşturulması uygulama tarafından otomatik şekilde gerçekleştirilmiştir. Böylece her ölçüm oturumu, sensör kaydıyla birebir eşleşen benzersiz etiketler (1001–1002) ile işaretlenmiş ve veri setleri sonradan yapılacak analizlerde sorunsuz biçimde ayrıştırılabilir hale gelmiştir.

Uygulama üzerinden yapılan etiketleme işlemi, ölçümün izlenebilirliğini artırmasının yanı sıra, sensörden elde edilen sıcaklık, bağıl nem, basınç, gaz direnci ve *IAQ Proxy* gibi değişkenlerin tümünün doğru zaman damgalarıyla birlikte eşgüdümlü olarak kaydedilmesini sağlamıştır. Bu süreç, *ESP32* kartına önceden yüklenen *Bosch AI-Studio* uyumlu *Firmware* sayesinde mümkün olmuştur. *Firmware*, sensör çıktılarının *.bmerawdata* formatında kaydedilmesini ve BSEC algoritmasıyla uyumlu bir veri yapısının oluşturulmasını sağlamaktadır.


Çalışmada kullanılan ölçüm protokolü dört ardışık oturumdan oluşmaktadır:

- Hava 1 (1001): Başlangıç referans ölçümü
- Çay 1 (1002): İlk çay numunesinin VOC tepkilerinin kaydedilmesi

Bu yapı, sensörün çevresel etkilerden arındırılmış biçimde ölçüm yapmasını sağlayarak numuneler arası karşılaştırılabilirliği artırmıştır.

3.4.6.2. Sensör Yapısı ve Örnekleme Karakteristikleri

Ölçüm sırasında *BME688* sensörü yaklaşık 1,387 Hz. örnekleme frekansında veri üretmiş olup, ortalama bir oturumda ≈ 3600 –5800 zaman örneği elde edilmiştir. Sensör dizisindeki sekiz hücre (U1–U8), farklı *heater* profile yapılandırmaları altında çalıştırılarak çeşitli VOC bileşiklerine karşı farklı duyarlılık seviyeleri üretmiştir. Bu çeşitlilik, çay örnekleri arasındaki ayrım gücünü artıran zengin bir zaman serisi veri yapısının oluşmasına katkı sağlamıştır.




Şekil 30. BME688 Sensör Dizisi ve Isıtıcı Profilin Zaman Adımlarına Dağılımı

Şekil 30'daki görselde *BME688* sensör kartında yer alan sekiz gaz sensörünün (U1–U8) ortak bir ısıtıcı profili altında gerçekleştirdiği sıcaklık adımlarının (Step 1–Step 10) zaman eksenini üzerindeki dağılımı sunulmaktadır.



Şekil 31. Sensör Dizisi ve Isıtıcı Profillerinin Zaman Adımlarına Dağılımı

Şekil 31'deki görselde sensör dizisi ve farklı ısıtıcı profillerine ait sinyal varyanslarının zaman adımları boyunca gösterdiği dağılım karakteristiklerini göstermektedir.




Şekil 32. BME688 Sensör Gruplandırma ve Heater Profile Konfigürasyonu

Şekil 32’ de *BME688* sensör kartındaki U1–U8 sensör hücrelerinin çalışma gruplarını ve her bir hücreye atanan ısıtıcı profillerini gösterilmektedir. Bu yapı, sensör dizisinin çok boyutlu VOC algılama kapasitesini genişleterek zengin bir zaman serisi veri yapısının elde edilmesine katkı sağlamaktadır.

3.5. Veri Kaydı, Dönüştürme ve Ön İşleme

Bu çalışma kapsamında gerçekleştirilen ölçüm sürecinin güvenilir, tekrarlanabilir ve analiz edilebilir bir veri yapısına kavuşabilmesi için; sensör çıktılarının kaydedilmesi, uygun formata dönüştürülmesi ve makine öğrenmesi modellerinde kullanılmak üzere ön işleme tabi tutulması sistematik bir akış içerisinde yürütülmüştür. Veri kaydı işlemleri, *ESP32* tabanlı mikrodenetleyici ile *BME688* sensör modülünün ortak çalışması sonucunda *MicroSD* karta ham biçimde aktarılan ölçüm dosyalarının üretilmesiyle başlamaktadır.

Ham veri kayıtlarının *AI-Studio* tarafından tanınabilmesi amacıyla sensör çalışma profilleri, ısıtıcı döngüleri, ölçüm aralıkları ve sensör modları önceden yapılandırılmış, ilgili konfigürasyon dosyaları *MicroSD* kart üzerine aktarılmıştır. Ölçüm süreci boyunca sensörden elde edilen sıcaklık, bağıl nem, basınç, gaz direnci ve *IAQ Proxy* verileri zaman damgalı olarak *.bmerawdata* formatında saklanmış; bu ham kayıtlar ölçüm sonrasında *Python* tabanlı dönüştürme araçlarıyla *.csv* ve *.xlsx* formatlarına çevrilmiştir.



Şekil 33. Veri Kaydı, Dönüştürme ve Ön İşleme Süreci İş Akışı

Şekil 33’teki görselde SD kartın biçimlendirilmesinden verilerin kaydedilmesi, dönüştürülmesi ve csv/xlsx formatında saklanmasına kadar olan süreç özetlenmektedir.

Dönüştürülen veri dosyaları *MATLAB* ortamına aktarılmış ve burada öznitelik çıkarımı, normalizasyon adımları ve sınıflandırma modellerine temel oluşturacak veri matrisleri hazırlanmıştır. Bu sistematik yapı sayesinde, veri toplama süreci yalnızca ham sinyal üretmekten öte; verinin doğru yapılandırılması, açıklayıcı şekilde etiketlenmesi ve analiz aşamasına eksiksiz biçimde aktarılması ile bütüncül bir ölçüm–dönüşüm hattı oluşturmuştur.



Şekil 34. Veri Toplama Süreci

Şekil 34’teki görselde *BME688* sensöründen elde edilen zaman damgalı ham verilerin *ESP32* üzerinden toplanarak *Bosch AI-Studio* yapılandırmasıyla. *bmerawdata* formatında kaydedilmesini ve SD kart ortamına aktarılmasını gösteren veri toplama sürecini özetlenmektedir.

3.5.1. SD Kartın Biçimlendirilmesi

Deneyisel çalışmalarda kullanılacak *MicroSD* kart, sensör verilerinin ölçüm sırasında hatasız, kesintisiz ve zaman damgalı biçimde kaydedilebilmesi amacıyla

FAT32 dosya sistemi kullanılarak biçimlendirilmiştir. Bu dosya sistemi, *ESP32* tabanlı veri toplama kartları ile *Bosch AI-Studio* altyapısı arasında tam uyumluluk sağlayarak veri yazma gecikmeleri ve dosya bozulması gibi olası sorunları önlemektedir.

SD kartın ölçüm öncesinde biçimlendirilmesi, deney süresince oluşabilecek veri kaybı, dosya erişim hataları ve kayıt bütünlüğü problemlerinin en aza indirilmesi açısından kritik öneme sahiptir. Bu işlem sonrasında kart, sensör ölçüm oturumları boyunca oluşturulan zaman damgalı ham veri dosyalarının (*.bmerawdata*) güvenli biçimde saklanacağı kayıt ortamı olarak kullanılmıştır.



Şekil 35. SD Kart- Bilgisayara Bağlantısı


Şekil 35'teki görselde *MicroSD* kartın ölçüm öncesi bilgisayar ortamına bağlanarak biçimlendirilmesini gösteren fiziksel bağlantı yapısı özetlenmektedir.

3.5.2. BME AI-Studio ile Proje Dosyalarının Oluşturulması

Ölçüm sürecinde kullanılacak sensör yapılandırmalarının hazırlanması amacıyla, *Bosch BME AI-Studio* masaüstü yazılımı kullanılarak yeni bir proje oluşturulmuştur (Bosch Sensortec, 2021). Bu aşama, sensörün çalışma modunun tanımlanması, ölçüm senaryosuna uygun konfigürasyon dosyalarının üretilmesi ve veri toplama sürecinin *AI-Studio* altyapısı ile uyumlu şekilde yürütülmesi için temel bir çerçeve sunmaktadır.

Proje oluşturma işlemi sırasında *AI-Studio* yazılımı, sensör parametrelerinin merkezi olarak yönetilmesine ve sonraki aşamalarda *MicroSD* karta aktarılabilecek yapılandırma dosyalarının otomatik biçimde oluşturulmasına olanak sağlamıştır.

Böylece ölçüm ortamı, Bosch tarafından önerilen standartlar çerçevesinde ve tekrarlanabilir şekilde yapılandırılmıştır.



Şekil 36. BME AI-Studio Masaüstü Uygulamasının Açılış Ekranı

Şekil 36'daki görselde (Bosch Sensortec, 2021), tarafından geliştirilen *BME AI-Studio* masaüstü yazılımının açılış ekranı gösterilmektedir. Bu ekran, proje oluşturma ve sensör yapılandırma süreçlerinin başlatıldığı ana arayüzü temsil etmektedir.


3.5.3. BoardConfiguration.bmeconfig Dosyasının Üretilmesi

Sensörün ölçüm sürecinde hangi modlarda çalışacağını, ölçüm süresini ve veri kayıt parametrelerini tanımlamak amacıyla, *BME AI-Studio* yazılımı üzerinde yeni bir proje oluşturulmuştur. Bu işlem, yazılımın “*Create Project*” menüsü aracılığıyla gerçekleştirilmiş ve sensör yapılandırma dosyası olan *BoardConfiguration.bmeconfig* dosyası otomatik olarak üretilmiştir.

Oluşturulan *BoardConfiguration.bmeconfig* dosyası; sensörün aktif çalışma modlarını, zamanlama ayarlarını ve veri toplama sırasında izlenecek temel parametreleri içeren ana konfigürasyon dosyası niteliğindedir. Bu dosya sayesinde sensör, deneysel ölçümlerin tamamında aynı yapılandırma ile çalıştırılarak ölçüm koşullarının standardize edilmesi sağlanmıştır. Böylece veri toplama sürecinde parametre kaynaklı belirsizliklerin önüne geçilmiş ve tekrarlanabilir ölçüm altyapısı oluşturulmuştur.

BME AI-Studio

Version 3.1.0



[Example Project](#) [Get started](#) [Documentation](#)

Şekil 37. BME AI-Studio Üzerinde Yeni Proje Oluşturma Ekranı


Şekil 37’deki görselde Bosch *BME AI-Studio* masaüstü uygulaması üzerinde yeni proje oluşturma aşamasını ve *BoardConfiguration.bmeconfig* dosyasının üretildiği kullanıcı arayüzünü gösterilmektedir.

3.5.4. Sensör Parametrelerinin Yapılandırılması

Sensörün ölçüm sürecinde doğru ve tekrarlanabilir sonuçlar üretebilmesi amacıyla, *BME AI-Studio* yazılımı içerisinde yer alan “*Configure BME Board*” modülü kullanılarak sensör parametreleri yapılandırılmıştır. Bu aşamada sıcaklık, bağıl nem, gaz direnci ve VOC ölçüm modlarına ilişkin temel çalışma parametreleri belirlenmiştir.

Yapılandırılan sensör parametreleri; algılama hassasiyeti, ölçüm aralığı ve veri toplama periyodu gibi kritik unsurları doğrudan etkilemektedir. Bu nedenle tüm parametreler, deneysel ölçümlerin tamamında aynı çalışma koşullarının korunmasını sağlayacak şekilde tanımlanmıştır. Böylece sensör kaynaklı değişkenlik azaltılmış, farklı ölçüm oturumları arasında karşılaştırılabilir ve tutarlı veri elde edilmesi hedeflenmiştir.

Parametre yapılandırması sırasında, sensörün gaz algılama biriminin (MOX) VOC değişimlerine duyarlılığı ile çevresel büyüklüklerin (sıcaklık ve nem) ölçüm stabilitesi birlikte gözetilmiştir. Bu yaklaşım, hem uçucu bileşiklere ait sinyal dalgalanmalarının sağlıklı biçimde izlenmesine hem de çevresel koşullardan kaynaklanan yan etkilerin sınırlandırılmasına olanak tanımıştır.



Şekil 38. BME AI-Studio Üzerinde Sensör Parametrelerinin Yapılandırılması


Şekil 38’deki görselde Bosch *BME AI-Studio* kullanıcı arayüzü üzerinde sensör parametrelerinin yapılandırıldığı ekranı ve aktif edilen ölçüm modlarını gösterilmektedir.

3.5.5. Ölçüm Aralıklarının ve Sensör Modlarının Ayarlanması

Sensör tarafından üretilen verilerin model eğitimi ve karşılaştırmalı analizler için uygun nitelikte olabilmesi amacıyla, ölçüm aralıkları ve sensörün çalışma modları deneysel senaryoya göre tanımlanmıştır. Bu yapılandırma, sensörün zaman içerisinde tutarlı bir ölçüm döngüsü izlemesini ve tüm deney kayıtlarının aynı koşullar altında elde edilmesini sağlamaktadır.

Bu kapsamda sensörün çalışma döngüsü, ısıtma profiline ait adımlar, ölçüm periyotları ve kayıt türleri *BME AI-Studio* yazılımı üzerinden ayrı ayrı belirlenmiştir. Özellikle MOX gaz algılama elemanının sıcaklık döngüsünün kontrollü biçimde yönetilmesi, uçucu organik bileşiklere (VOC) verilen tepkilerin zaman ekseninde sağlıklı şekilde izlenebilmesi açısından kritik öneme sahiptir.

Tanımlanan ölçüm aralıkları, sensörün hem kısa süreli VOC değişimlerine duyarlılığını koruyacak hem de uzun süreli ölçümlerde kararlı veri üretecek biçimde yapılandırılmıştır. Bu yaklaşım sayesinde, farklı deneme oturumlarında elde edilen zaman serilerinin istatistiksel olarak karşılaştırılabilir olması sağlanmıştır. Ölçüm modlarının standartlaştırılması, model eğitiminde kullanılacak özniteliklerin güvenilirliğini ve tekrarlanabilirliğini doğrudan desteklemektedir.



Şekil 39. Sensör Ölçüm Aralıkları ve Isıtma Profili


Şekil 39'deki görselde *BME688* Bosch sensöründe kullanılan ölçüm zamanlamasını ve farklı sıcaklık kademelerinden oluşan ısıtıcı profilinin, veri toplama sürecine etkisini gösterilmektedir.

3.5.6. Yapılandırma Dosyasının SD Karta Aktarılması

BME AI-Studio ortamında oluşturulan *BoardConfiguration.bmeconfig* dosyası ölçüm sürecinin sensör tarafında doğru biçimde yürütülebilmesi amacıyla *MicroSD* karta aktarılmıştır.

Hazırlanan SD kart, doğrudan *BME688 Evaluation Board* üzerine yerleştirilmiş; böylece sensör kartı açılış anında tanımlanan konfigürasyon dosyasını otomatik olarak okuyacak şekilde yapılandırılmıştır.

Bu işlem sonrasında sensör, harici bir bilgisayar bağlantısına ihtiyaç duymadan, tanımlanmış ölçüm modları ve zamanlama parametreleri doğrultusunda çalışmaya başlamaktadır. SD kart üzerinden yapılan bu yapılandırma, ölçüm sürecinin taşınabilir ve tekrar edilebilir bir biçimde yürütülmesine olanak tanımaktadır. Aynı yapılandırma dosyasının farklı deney oturumlarında aynen kullanılması, tüm kayıtların aynı deneysel koşullar altında elde edilmesini garanti altına almaktadır.



Şekil 40. BME688 Kartının SD Kart ile Çalışmaya Hazır Hâle Getirilmesi

Şekil 40'taki görselde yapılandırma dosyasının bulunduğu SD kartın *BME688* Bosch sensör kartına takılması sonrası ölçüm düzeneğinin çalışmaya hazır hâlini göstermektedir. Görselde sensör kartının kap içindeki konumlandırılması, hava girişi ve vakum bağlantı noktaları da şematik olarak özetlenmektedir.

3.5.7. bmerawdata Veri Dosyalarının Kaydedilmesi

Ölçüm süreci sonunda *BME688* sensöründen elde edilen tüm ham veriler, *Bosch AI-Studio* tarafından desteklenen. *bmerawdata* formatında *MicroSD* karta kaydedilmiştir. Bu veri formatı; sensörün her ölçüm anına ait gaz direnci, sıcaklık, bağıl nem, basınç ve *IAQ Proxy* çıktılarının yanı sıra zaman damgalarını (*timestamp*) ve etiket bilgilerini bütüncül bir yapı içerisinde saklamaktadır. Böylece ölçüm verileri, analiz öncesinde herhangi bir bilgi kaybı olmaksızın arşivlenebilmiştir.

AI-Studio mobil uygulaması üzerinden gerçekleştirilen etiketleme mekanizması, her ölçüm oturumunu sayısal kodlar ile tanımlamıştır. Bu çalışma kapsamında kullanılan etiketleme düzeni aşağıdaki şekilde yapılandırılmıştır:

- 1001: Hava – 1 (referans ölçüm)
- 1002: Çay – 1 (ilk numune ölçümü)

Bu etiketleme yapısı sayesinde, her bir *.bmerawdata* dosyası hangi ölçüm evresine ve numune sınıfına ait olduğu bilgisiyle birlikte kaydedilmiş; veri setinin otomatik olarak ayrıştırılabilir, tekrarlanabilir ve izlenebilir olması sağlanmıştır.

BME688 sensörünün sekiz hücreden (U1–U8) oluşan yapısı ve bu hücrelere atanmış farklı ısıtıcı profilleri, kayıt altına alınan ham verilerin çok boyutlu bir VOC tepki uzayı oluşturmasına olanak tanımıştır. Bu yapı, ilerleyen aşamalarda gerçekleştirilen öznetelik çıkarımı ve sınıflandırma işlemleri için zengin bir veri içeriği sunmuştur.

Tablo 10. Kalite Sınıflarında Ölçüm Sayıları

Adı-	Kalite Sınıfı	Farklı Ölçüm Sayısı
CAY_A3	1.Kalite	9
CAY_A7	1.Kalite	9
CAY_A9	1.Kalite	6
CAY_A10	1.Kalite	6
CAY_A11	1.Kalite	6
CAY_A4	2.Kalite	6
CAY_A14	2.Kalite	6
CAY_A12	2.Kalite	6
CAY_A1	2.Kalite	6
CAY_A5	2.Kalite	6
CAY_A15	2. Kalite	6
CAY_A2	3.Kalite	7
CAY_A6	3.Kalite	6
CAY_A8	3.Kalite	8
CAY_A13	3.Kalite	7
CAY_A16	3.Kalite	8

Tablo 10'daki görselde her kalite sınıfında yer alan çay örneklerine ait farklı ölçüm sayılarını göstermektedir.

Deneyssel protokol kapsamında, her çay numunesi için birçok ölçüm döngüsü uygulanmış ve bu süreç sonucunda toplam 90 adet *.bmerawdata* dosyası elde edilmiştir. Oluşturulan bu ham veri havuzu, model eğitiminde dengeli biçimde kullanılmış; farklı kalite sınıflarına özgü gaz yanıt profillerinin güvenilir şekilde çıkarılmasına temel teşkil etmiştir.

3.5.8. *bmerawdata* Dosyasını (.csv) ve (.xlsx) Çevrilmesi

BME688 sensöründen elde edilen ölçüm verileri, *Bosch AI-Studio* yazılımı tarafından *.bmerawdata* biçiminde kaydedilmektedir. Bu dosya formatı, sensör

çıktılarının ham ve yoğun veri yapısını içerdiğinden, doğrudan istatistiksel analiz ve makine öğrenmesi uygulamalarında kullanıma uygun değildir. Bu nedenle, ham *.bmerawdata* dosyalarının analiz edilebilir hale getirilmesi amacıyla *Python* tabanlı bir veri dönüştürme betiği geliştirilmiş ve kullanılmıştır.

Bu çalışmada, ham veri dosyalarının *csv* ve *xlsx* biçimlerine dönüştürülmesi işlemi, *convert_bmerawdata_filtered.py* adlı *Python* betiği aracılığıyla ve Windows Komut İstemi (CMD) üzerinden gerçekleştirilmiştir.

3.5.8.1. Komut Satırı ve Çalışma Dizini Ayarları

Elde edilen *.bmerawdata* formatındaki ham sensör verilerinin *csv* ve *xlsx* dosyalarına dönüştürülmesi *Python* tabanlı bir betik aracılığıyla gerçekleştirilmiştir. Bu işlemin yürütülebilmesi için öncelikle işletim sisteminde komut satırı ortamının açılması gerekmektedir. Geliştirilen *Python* betiği, *Windows* işletim sisteminde komut satırı (*Command Prompt*) ortamı üzerinden “Çalıştır” penceresini açmış ve buraya *cmd* komutunu girerek komut satırı (*Command Prompt*) ortamını başlatmıştır. Dönüştürme betiğinin, gerekli dosya dizinlerine erişebilmesi amacıyla komut satırında çalışma klasörü uygun konuma yönlendirilmiştir.

Bu işlem sırasında:

`Cd"%USERPROFILE%\OneDrive\Masaüstü"`

Komutu kullanılarak ham verilerin ve *Python* betiğinin bulunduğu dizin aktif çalışma klasörü olarak tanımlanmıştır. Böylece betiğin hem giriş dosyalarına (*. bmerawdata*) erişimi hem de çıktı dosyalarının doğru dizine yazdırılması güvence altına alınmıştır. Tablo 11’de, dönüştürme sürecinde kullanılan temel dosya türleri ve işlevleri özetlenmektedir.

Tablo 11. Ham BME688 Verilerinde Kullanılan Dosyalar ve Formatları

Dosya Adı	Açıklama	Format
<i>convert_bmerawdata_iaqproxy_cleaned_v2.py</i>	Ham BME688 verisini işleyen <i>Python</i> betiği	<i>Python</i> Script
<i>..._1.bmerawdata</i>	Sensörden alınan ham uçucu bileşik zaman serisi verisi	Ham sensör dosyası

Tablo 11, veri işleme zincirinin başlangıç noktası olup, sonraki adımlarda gerçekleştirilecek öznetelik çıkarımı ve sınıflandırma analizlerinin sağlıklı biçimde yürütülebilmesi için temel bir gereklilik oluşturmuştur.

3.5.8.2. Python Scriptinin Çalıştırılması

Ham olarak elde edilen. *bmerawdata* dosyasının dönüştürülmesi amacıyla geliştirilen *Python* betiği komut satırından aşağıdaki parametrelerle çalıştırılmıştır:

- *Python* → *Python* yorumlayıcısı
- *convert_bmerawdata_iaqproxy_cleaned_v2.py* → Dönüştürme betiği
- *input.bmerawdata* → Ham sensör veri dosyası
- *a:1* : Birinci çay örneğine atanacak etiket
- *date*: Deney tarihi
- *outdir*: Çıktı dosyalarının kaydedileceği dizin

Tablo 12. Ham .bmerawdata Dosyasının csv/xlsx'e Dönüştürme

Aşama	Açıklama
Komut çalıştırıldı	<i>Convert_bmerawdata_iaqproxy_cleaned_v2.py</i> betiği ilgili ham veri dosyası üzerinde çalıştırıldı.
Etiket 1002 için isim girin:	Kullanıcıdan örneğin etiket adı istendi: CAYKUR_TOMURCUK
CAY A1 kodu (örnek: A1):	Kullanıcıdan ikinci etiket adı istendi: CAY_A3(1)
Deney tarihi (örnek: 20250701):	Deney Tarihi istendi: 20260111
IAQ Proxy sütunu eklendi	Ham sensör verisine IAQ Proxy hesaplaması başarıyla eklendi.
Veri başarıyla dönüştürüldü	...File_1_IAQPROXY_TEMİZ.csv
Masaüstüne kaydedildi	...File_1_IAQPROXY_TEMİZ.xlsx

Tablo 12'de *BME688* sensöründen elde edilen *.bmerawdata* formatındaki ham verilerin, *Python* tabanlı komut satırı (CMD) aracı kullanılarak etiketli *csv* ve *xlsx* formatlarına dönüştürülmesi sürecinde izlenen adımları ve elde edilen çıktıları özetlemektedir.

3.5.8.3. Çıktı Dosyalarının Kaydedilmesi

Dönüştürülmüş veri kümesi, *Python* ortamında *pandas.to_csv ()* ve *pandas.to_excel ()* fonksiyonları kullanılarak hem *csv* hem de *xlsx* formatlarında

kaydedilmiştir. Üretilen tüm çıktı dosyaları, komut satırında belirtilen *--outdir* dizinine yazılmıştır.

Tablo 13. Ham Verinin Dönüştürülmesi Sonrasında Oluşturulan Çıktı Dosyaları

Açıklama	Oluşturulan Dosya Adı
Dönüştürülen ham veri CSV formatında başarıyla oluşturulmuştur.	...TEMİZ.csv
Aynı veri ayrıca Excel formatında (XLSX) kaydedilmiştir.	...TEMİZ.xlsx

Tablo 13 ham sensör verilerinin dönüştürülmesi sonrasında oluşturulan ve analiz aşamalarında kullanılmak üzere kaydedilen etiketli csv ve xlsx çıktı dosyalarını göstermektedir.

3.5.8.4. Veri Okuma ve Temel İşleme

Python betiği, *.bmerawdata* dosyasını JSON tabanlı yapı üzerinden okumaktadır. Dosyada yer alan *dataColumns* ve *dataBlock* alanları ayrıştırılarak *Pandas* kütüphanesi (*Pandas Developers, 2024*) aracılığıyla *pandas DataFrame* yapısına dönüştürülmüş; eksik veya tanımsız alanlar veri temizleme adımlarıyla işlenmiştir. Böylece analiz ve modelleme aşamalarına uygun bir veri yapısı elde edilmiştir (*Pandas Developers, 2024*).

3.5.8.5. Etiketleme ve Açıklayıcı Bilgilerin Eklenmesi

Veri setine;

- Ölçüm evrelerine karşılık gelen etiket sütunu,
- Sayısal etiketlerin anlamlı sınıf adlarıyla eşleştirilmiş halleri (HAVA_1, CAY_A1 vb.),
- Deney kimliği, grup bilgisi ve tarih gibi açıklayıcı sütunlar eklenmiştir.

Bu yapı, veri setinin izlenebilirliğini ve deneysel bütünlüğünü sağlamaktadır.

3.5.8.6. IAQ Proxy Tanımı

IAQ Proxy, Bosch BSEC algoritmasının doğrudan üretmediği durumlar için VOC tabanlı görelî bir kalite göstergesi olarak tanımlanmıştır ve aşağıdaki ampirik ilişki ile hesaplanmıştır (*Pearce vd., 2003*).

$$IAQProxy = \left(\frac{gas_{resistance_{ohm}}}{humidity_{RH}} \right) \times temperature_C \quad (3.1)$$

Bu metrik, resmi IAQ değerinin yerine geçme iddiası taşımamakta; yalnızca sensör tepkisini nicel olarak ifade eden yardımcı bir öznitelik olarak kullanılmaktadır.

3.5.8.7. (.csv) Dosyalarında Bulunan Sütunlar

Dönüştürülmüş csv dosyalarında sensör ölçümleri, sistem bilgileri, etiketler ve türetilmiş *IAQ Proxy* sütunu yer almaktadır. Bu yapı, modelleme ve istatistiksel analizler için bütüncül bir veri seti sunmaktadır.

3.5.8.8. Öncelikli Sensör Parametreleri ve Öznitelik Çıkarımı

Ham sensör verileri doğrudan modele aktarılmamış; her parametre için ortalama, medyan, standart sapma, minimum ve maksimum istatistikleri hesaplanmıştır (Kotsiantis vd., 2006). Bu işlem sonucunda sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* değişkenlerinden toplam 25 öznitelik elde edilmiştir.

Tablo 14. Modelde Kullanılan Temel Sensör Parametreleri

Parametre Adı	Sembol	Birim	Açıklama
Sıcaklık	temperature_C	°C	Sensör yüzeyinde ölçülen anlık sıcaklık
Basınç	pressure_hPa	hPa	Ortam atmosfer basıncı
Bağıl Nem	humidity_RH	%RH	Ortamın bağıl nem oranı
Gaz Direnci	gas_resistance_ohm	Ω	VOC konsantrasyonuna bağlı direnç değişimi
IAQ Proxy	—	—	Hava kalitesi veya gaz yoğunluğunu temsil eden türetilmiş indeks

Tablo 14'te sıcaklık, basınç, bağıl nem, gaz direnci ve *IAQ Proxy* değişkenlerine ait semboller, birimler ve açıklamalar model giriş parametreleri olarak sunulmuştur.

3.5.9. Modelleme için Hazırlanan Veri Kümeleri

Bu çalışmada kullanılacak modelleme veri kümesinin oluşturulması, ham sensör verilerinin makine öğrenmesi algoritmalarına uygun hâle getirilmesi amacıyla çok aşamalı bir ön işleme süreci ile gerçekleştirilmiştir. Toplam 90 adet deney seti, her biri iki ölçüm evresinden oluşacak şekilde (1001–1002 etiket kodları)

yapılandırılmıştır. Bu evreler sırasıyla Hava 1 (1001), Çay 1 (1002), ölçümelerini temsil etmektedir.

Ön işleme aşamasında ilk olarak, 1001 (Hava 1) etiketlerine karşılık gelen tüm satırlar veri setinden çıkarılmıştır. Bu işlem, ortam havasına ait referans ölçümlerin modelleme sürecini etkilemesini önlemek ve yalnızca çay numunelerine özgü uçucu organik bileşik (VOC) yanıtlarını içeren verilerle çalışmak amacıyla uygulanmıştır.

Filtreleme işlemi sonrasında, her bir deney setinden yalnızca 1002 (Çay 1) etiketlerine ait ölçüm bölümleri ayrıştırılmıştır. Böylece her deney için çay ölçüm segmenti elde edilmiş ve bu segmentler bağımsız veri kümeleri hâline getirilmiştir. Sonuç olarak, 90 adet temizlenmiş csv veri dosyası üretilmiştir.

Elde edilen bu csv dosyaları, etiket bilgileri, zaman damgaları ve dönüştürme aşamasında eklenmiş istatistiksel öznitelikleri içermektedir. Bu yapı sayesinde veri kümesi, ek bir manuel düzenlemeye ihtiyaç duyulmaksızın doğrudan model eğitimi ve değerlendirme aşamalarında kullanılabilir nitelik kazanmıştır. Söz konusu dosyalar, model geliştirme sürecinde tek bir arşiv altında toplanarak sıkıştırılmış ve modelleme adımlarında temel veri kaynağı olarak değerlendirilmiştir.

Tablo 15. Veri Toplama Sürecinde Kullanılan Dosya ve İçerik Bilgileri

Süreç	Kullanılan Dosya	Açıklama
Veri Toplama	etiket_ad_ve_label_icerikli_45x2.csv.zip	90 CSV örnek İçeriyor (Ham sensör + Etiket)

Tablo 15’te model geliştirme aşamasında kullanılan .zip arşiv dosyasının adı, içeriği ve kapsadığı örnek sayısı özetlenmektedir. Bu dosya, dengeli ve standartlaştırılmış veri yapısı sayesinde makine öğrenmesi tabanlı sınıflandırma çalışmalarında güvenilir bir temel oluşturmaktadır.

3.6. Kalite Sınıflandırma ve Modelleme Yaklaşımı

Bu çalışmada çay kalite sınıflandırma süreci, sensörlerden elde edilen ham zaman serisi verilerinin doğrudan modele aktarılması yerine, bu sinyallerden istatistiksel olarak anlamlı özniteliklerin çıkarılması ile başlatılmıştır. Sıcaklık, bağıl nem, basınç, gaz direnci ve *IAQ Proxy* gibi farklı fiziksel büyüklükleri temsil eden

sensör çıktıları, her ölçüm oturumu için özetleyici istatistikler hâline dönüştürülmüş ve böylece her çay numunesi sayısal bir özellik vektörü ile temsil edilmiştir.

Elde edilen bu özellikler, modelleme öncesinde *Z-Score* standardizasyonu uygulanarak ölçeklenmiştir. Standardizasyon işlemi, farklı birim ve büyüklüklerdeki değişkenlerin ortak bir referans aralığına taşınmasını sağlayarak modelin tüm özniteliklerden eşit düzeyde yararlanmasına olanak tanımıştır. Bu adım, özellikle uzaklık temelli karar mekanizmalarına sahip sınıflandırıcıların daha kararlı ve genellenebilir biçimde öğrenmesini desteklemiştir.

Normalize edilmiş veri kümesi, çay kalite sınıflandırması amacıyla Destek Vektör Makineleri (*Support Vector Machines*, SVM) algoritmasına aktarılmıştır. SVM'in yüksek boyutlu veri uzaylarında sınıfları ayıran optimal karar yüzeylerini etkin biçimde tanımlayabilmesi, bu yöntemin çalışma kapsamında tercih edilmesinde belirleyici olmuştur.

3.6.1. Destek Vektör Makineleri (SVM)

Bu çalışmada çay kalitesinin belirlenmesinde makine öğrenmesi tabanlı bir yaklaşım benimsenmiş ve sınıflandırma algoritması olarak Destek Vektör Makineleri (*Support Vector Machines*, SVM) tercih edilmiştir (Chang ve Lin, 2011). Sensörlerden elde edilen çok boyutlu zaman serisi verilerinin önce istatistiksel özniteliklere dönüştürülmesi, ardından bu özniteliklerin SVM tabanlı sınıflandırma modelleriyle işlenmesi, karmaşık gaz tepki yapılarının daha kararlı ve ayrıştırılabilir bir forma taşınmasını sağlamıştır.

3.6.1.1. SVM'in Temel Mantığı (Lineer / Lineer Olmayan Ayrım)

Schölkopf ve Smola'ya (2002) göre SVM'in temel amacı, farklı sınıflara ait örnekleri maksimum marjini bir karar yüzeyi ile ayırmaktır (Vapnik, 1995). Karar yüzeyi, veri noktalarının konumlarına göre konumlanan bir hiperdüzlem olup, sınıflar arasındaki ayrımın en geniş olduğu bölgeyi temsil eder. Bu yaklaşım hem *Lineer* ayrılabilen hem de çekirdek fonksiyonları (*kernel*) sayesinde *Lineer* olmayan yapıya sahip verilerde etkili bir sınıflandırma gerçekleştirir.

SVM'in yüksek boyutlu veri uzaylarında bile kararlı karar sınırları oluşturabilmesi, özellikle karmaşık VOC (uçucu organik bileşik) davranışlarının gözlemlendiği sensör tabanlı çalışmalarda önemli bir avantaj sağlamaktadır. *BME688*

sensöründen elde edilen sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* sinyalleri, bu yüksek boyutlu veri yapısına tipik bir örnek oluşturduğu için SVM'in matematiksel yapısı bu problemle doğal bir uyum göstermektedir.

3.6.1.2. Sınıflandırma Problemlerinde SVM'in Rolü

SVM, sınıflar arasındaki ayrımın belirsiz olduğu, sınıf sınırlarının örtüştüğü veya veri dağılımlarının düzensiz olduğu problemlerde başarılı performansı ile öne çıkmaktadır.

Bu çalışma bağlamında sensör verileri:

- Çevresel faktörlerden etkilenebilen,
- Zamana bağlı dalgalanmalar içeren,
- Doğrusal olmayan VOC tepkileri barındıran

Bir yapı sergilemektedir.

Bu nedenle ham zaman serisinin doğrudan modele verilmesi yerine, her sensör parametresi için ortalama, standart sapma, minimum, maksimum ve RMS değerlerini içeren öznitelik vektörleri oluşturulmuş ve sınıflandırma işlemi bu öznitelikler üzerinden gerçekleştirilmiştir.

Bu yaklaşım:

- Gürültüyü azaltır,
- Her deney oturumunu tek bir sayısal profil haline getirir,
- Sınıflandırma algoritmalarının ayrım gücünü artırır.

Ayrıca SVM'in küçük ve orta ölçekli veri setlerinde yüksek doğruluk sağlamada güçlü olduğu bilindiğinden, 90 adet çay ölçüm verisinden oluşan bu çalışmanın veri yapısına doğal biçimde uyum göstermektedir.

3.6.1.3. Bu Çalışmada SVM Tercihinin Bilimsel Gereçekleri

Bu çalışmada SVM'in seçilmesinin temel bilimsel nedenleri aşağıdaki gibi özetlenebilir:

- Çok boyutlu sensör verilerini etkin ayırabilme kapasitesi, VOC tepkileri içerik, yoğunluk ve *adsorpsiyon-Desorpsiyon* dinamikleri bakımından sınıflar arasında ince farklılıklar göstermektedir. SVM bu ince ayrımları geniş marjınlı karar yüzeyleri ile daha başarılı biçimde yakalayabilmektedir.
- Küçük veri setlerinde aşırı uyumu (*overfitting*) azaltması, veri setinin 90 örnekten oluşması, derin öğrenme tabanlı yöntemler için yetersiz olabilirken, SVM küçük veri setlerinde dahi yüksek doğruluk sağlayabilen bir yapıya sahiptir.
- Dengeli sınıf dağılımı ile doğal uyumu, üç sınıfın eşit oranda temsil edildiği 90 csv dosyası, SVM'in ECOC ile en verimli çalıştığı veri düzenlerinden biridir.
- *Error-Correcting Output Codes* (ECOC) ile çok sınıflı problemlere genişletilebilmesi ,bu çalışmada kullanılan fitcecoc yapısı kapsamında her sınıf çifti (1–2, 1–3, 2–3) için ayrı ikili SVM modellerinin eğitilmesi, ayrımın daha net biçimde öğrenilmesini sağlamıştır.
- Model çıktılarının karar skoru bazlı yorumlanabilir , SVM + ECOC + Softmax yapısı sayesinde model, yalnızca sınıf etiketi vermekle kalmayıp:
 - Her sınıfa ait karar skorlarını,
 - Sınıf merkezlerine yakınlığı,
 - Tahmin güven düzeylerini hesaplayabilmektedir.
 Bu da çalışmanın açıklanabilir yapay zeka yönünü güçlendirmektedir.

3.6.2. Modelleme Sürecinin İşlevsel Yapısı

Modelleme süreci, sensörlerden elde edilen yüksek boyutlu ham zaman serilerinin doğrudan sınıflandırma modeline verilmesi yerine, bu verilerin bilgi yoğun istatistiksel temsilcilere dönüştürülmesi üzerine kuruludur. Sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* gibi çok boyutlu sensör çıktıları her deney oturumu için analiz edilerek öznitelik vektörlerine indirgenmiş; ardından bu öznitelikler Z-skor standardizasyonu ile ölçeklendirilmiş ve ECOC tabanlı çok sınıflı SVM modeline aktarılmıştır. Bu yapı hem hesaplama verimliliğini artırmış hem de modelin genellenebilirliğini güçlendirmiştir.

3.6.2.1. Ham Veriden Öznitelik Vektörüne Geçiş

BME688 sensörünün ürettiği ham zaman serileri binlerce örnek içermekte olup, bu verilerin doğrudan modele girdi olarak verilmesi hem hesaplama yükünü artırmakta hem de gürültü kaynaklı dalgalanmaların kararsızlığa yol açmasına neden olmaktadır.

Bu nedenle her sensör parametresi (sıcaklık, nem, basınç, gaz direnci, *IAQ Proxy*) için:

- Ortalama
- Standart sapma
- Minimum
- Maksimum
- RMS

Gibi özetleyici istatistikler hesaplanmıştır. Böylece her ölçüm oturumu tek satırlık bir özellik vektörüne dönüştürülmüş ve çay numunesinin gaz tepkisi davranışı kompakt, karşılaştırılabilir bir biçimde temsil edilmiştir.

3.6.2.2. Standartlaştırma (Z-Skor) Gereksinimi

Farklı sensör parametreleri doğal olarak farklı büyüklük aralıklarında değerlere sahiptir. Örneğin:

- Gaz direnci değerleri milyon mertebesinde,
- Nem değerleri 0–100 aralığında,
- *IAQ Proxy* RMS değerleri çok daha geniş dağılımlı olabilir.

Bu nedenle, ölçek farklarının modelin karar mekanizmasını bozmasını önlemek amacıyla tüm özelliklere Z-skor standardizasyonu uygulanmıştır.

Bu adım:

- Özellikleri aynı ölçek aralığına taşımış,
- Büyük genlikli değişkenlerin modele aşırı etki etmesini engellemiş,
- SVM'in marjin tabanlı optimizasyonunun daha kararlı çalışmasına katkı sağlamıştır.

Eğitim verisinden hesaplanan μ (ortalama) ve σ (standart sapma) değerleri, doğrulama ve test verilerine de aynı şekilde uygulanarak tüm aşamalarda tutarlı veri sunumu sağlanmıştır.


Destek Vektör Makineleri (SVM), marjın tabanlı optimizasyon yapısı gereği özelliklerin ölçeğine duyarlı bir sınıflandırma yöntemidir. Farklı büyüklük aralıklarında değişen özniteliklerin doğrudan modele verilmesi durumunda:

- Karar yüzeyi geniş aralıklı özelliklere doğru kayabilir,
- Dar aralıklı özelliklerin sınıflandırmadaki katkısı zayıflayabilir,
- ECOC yapısında yer alan ikili SVM modellerinin ayırma gücü azalabilir.

Bu çalışmada kullanılan üç temel öznitelik (*IAQ Proxy RMS*, *Gaz Direnci Ortalama*, *Nem Standart Sapması*) doğal olarak birbirinden oldukça farklı büyüklüklerde değerlere sahiptir. Z-Skor standardizasyonu, bu ölçek dengesizliğini gidererek özelliklerin modele eşit katkıyla sunulmasını sağlamış ve ECOC-SVM yapısının daha kararlı karar sınırları öğrenmesine imkân tanımıştır.

3.6.2.3. Çok Sınıflı Yapıda ECOC Kullanımı

Destek Vektör Makineleri, doğası gereği ikili sınıflandırma algoritmalarıdır (Dietterich ve Bakiri, 1995). Ancak bu çalışmada üç sınıflı bir kalite problemi (1 – 2 – 3) ele alınmaktadır. Bu nedenle çok sınıflı yapının ikili alt modellere dönüştürülmesini sağlayan Hata-Düzeltilme Kodları (*Error-Correcting Output Codes*) ECOC yaklaşımı kullanılmıştır. (Allwein vd., 2000).



Şekil 41. SVM ve ECOC Çalışma Farkı

Şekil 41'deki görselde SVM ve ECOC çalışma mantığı ile ilgili ayrım gösterilmiştir.

ECOC yöntemi, çok sınıflı bir problemi birbirinden bağımsız ikili sınıflandırma alt modellerine ayırır ve her alt modelin çıktısını bir kod matrisinde

birleştirerek nihai sınıf kararını oluşturur. Bu yapı hem sınıflar arası ayrımı güçlendirir hem de hatalara karşı dayanıklılığı artırır.

3.6.2.3.1. İkili Alt Modeller ve Kodlama Matrisi

ECOC yaklaşımının merkezinde, çok sınıflı bir problemin ikili alt görevlere bölünmesini sağlayan kodlama matrisi (*coding matrix*) yer alır.

- Matrisin her satırı bir sınıfı,
- Her sütunu ise bir ikili SVM alt modelini temsil eder.

Bu çalışmada toplam sınıf sayısı $M=3$ olduğundan, *one-vs-one* stratejisiyle oluşturulacak ikili model sayısı:

$$\binom{M}{2} = \frac{M(M-1)}{2} \quad (3.2)$$

$$K = (3 \times 2) / 2 = 3 \quad (3.3)$$

Olarak hesaplanmakta ve sistem aşağıdaki üç ikili alt problemi üretmektedir:

- Model 1: 1 ↔ 2 (Yüksek – Orta kalite)
- Model 2: 1 ↔ 3 (Yüksek – Düşük kalite)
- Model 3: 2 ↔ 3 (Orta – Düşük kalite)

Bu üç alt model, ECOC kodlama matrisi içerisinde Tablo 16’da gösterildiği gibi temsil edilmektedir:

Tablo 16. Üç Sınıflı SVM Modeli için Örnek ECOC Kodlama Matrisi

Sınıf	Model 1 (1-2)	Model 2 (1-3)	Model 3 (2-3)
1	+1	+1	0
2	-1	0	+1
3	0	-1	-1

Tablo 16’da;

- +1, ilgili sınıfın o alt modelde pozitif taraf olarak yer aldığını,
- -1, negatif taraf olarak temsil edildiğini,
- 0 ise o sınıfın ilgili alt modele dahil olmadığını (tarafsız / *neutral*) ifade etmektedir.

Her bir alt SVM modelinden elde edilen karar fonksiyonu çıktıları tek başına doğrudan bir sınıf etiketi üretmez. Bunun yerine:

- Üç alt modelden gelen skorlar bir karar vektörü oluşturur.
- Bu karar vektörü, ECOC kodlama matrisinin her sınıfa ait satırıyla birlikte değerlendirilir.
- Skor vektörüne en uygun (en küçük kayıp- en küçük mesafe) ile karşılık gelen satır (kod kelimesi), test örneğinin nihai sınıfı olarak atanır.

Bu mekanizma sayesinde ECOC:

- İkili modellerde ortaya çıkabilecek hataları kısmen telafi edebilmekte,
- Çok sınıflı kararı daha kararlı ve sağlam biçimde üretebilmekte,
- Alt modellerden gelen karar skorlarının birlikte yorumlanmasına olanak tanıdığı için açıklanabilir yanını artırmaktadır.

Dolayısıyla ECOC kodlama matrisi, SVM alt modellerinden gelen ham çıktıları anlamlı bir üç sınıflı kalite etiketine dönüştüren temel yapı taşıdır.

3.6.2.3.2. Karar Skorları ve Kayıp Bazlı Kod Çözme

ECOC tabanlı çok sınıflı SVM sistemlerinde karar skorları (*decision scores*), bir test örneğinin farklı karar sınırlarına göre konumunu nicel olarak ifade eden ara çıktılarıdır. Bu skorlar doğrudan “olasılık” değildir; SVM’in doğrusal karar fonksiyonundan üretilen marjın değerleridir.

Bu tezde karar skorlarının hesaplanması ve ECOC içinde kullanılma süreci şu adımlarla gerçekleştirilmiştir:

Test verisinin Z-Skor ile normalize edilmesi, Yeni bir test örneği, eğitilen modele verilmeden önce eğitim kümesinden elde edilen ortalama (μ) ve standart sapma (σ) değerleri kullanılarak Z-Skor dönüşümüne tabi tutulur:

$$z = (x - \mu) / \sigma \quad (3.4)$$

Böylece *IAQ Proxy RMS*, *Gaz Direnci Ortalaması* ve *Nem Standart Sapması* gibi farklı ölçeklerdeki özellikler aynı büyüklük mertebesine çekilmekte; karar sınırlarının tek bir büyük ölçekli öznitelik tarafından domine edilmesi engellenmektedir.

Her alt model için karar fonksiyonunun hesaplanması ,normalize edilmiş test vektörü z , eğitim sürecinde öğrenilen SVM parametreleri ile değerlendirilir. Her bir ikili SVM modeli için karar fonksiyonu:

$$sk = w \cdot z + b \quad (3.5)$$

Şeklinde. Bu skorun işareti ve mutlak büyüklüğü:

- Test örneğinin karar sınırının hangi tarafında bulunduğunu,
- Karar sınırına ne kadar uzakta olduğunu

İfade eder.

Çok sınıflı yapıda karar vektörünün oluşturulması, bu çalışmada üç sınıf (1–2–

3) için üç ikili SVM modeli tanımlanmıştır:

- Model 1: $1 \leftrightarrow 2$
- Model 2: $1 \leftrightarrow 3$
- Model 3: $2 \leftrightarrow 3$

Her model kendi karar fonksiyonundan bir skor üretir ve bu skorlar bir araya getirilerek test örneği için:

$$s(x) = [s_{1-2}, s_{1-3}, s_{2-3}] \quad (3.6)$$

Şeklinde bir karar vektörü elde edilir. Basit yorumla:

- $sk > 0 \rightarrow$ örnek, ilgili alt modelde pozitif sınıfa daha yakındır,
- $sk < 0 \rightarrow$ örnek, negatif sınıfa daha yakındır.

Kayıp (*loss*) tabanlı ECOC kod çözme, *MATLAB*'ın *fitcecoc* fonksiyonu, çok sınıflı problemlerde varsayılan olarak kayıp tabanlı (*loss-based*) ECOC çözümleme mekanizmasını kullanır. Her sınıf için toplam kayıp şu şekilde hesaplanır:

$$y = \arg \min \sum_{k=1}^K L(m_{ck}, sk) \quad (3.7)$$

Burada m_{ck} , ECOC kodlama matrisindeki ilgili sınıfın k 'inci alt modele ait kodunu; $L(m,s)$ ise SVM'in marjin mantığıyla uyumlu *hinge-loss* fonksiyonunu temsil eder:

$$L(m, s) = \max(0, 1 - m \cdot s) \quad (3.8)$$

Bu fonksiyonun davranışı özetle şöyledir:

- Eğer alt model, ilgili sınıf yönünde yüksek ve tutarlı pozitif skor üretmişse

$1 - m.s < 0 \rightarrow L = 0$ Olur; o alt model için ceza uygulanmaz.

- Skor düşük, kararsız veya ters yönde ise

$1 - m.s > 0 \rightarrow L = 0$ Olur ve sınıf o alt modelden pozitif bir kayıp (ceza) alır.

Kod çözme işlemi bu mantığa dayanır:

- Her alt modelin ürettiği skor $sks_$ değerlendirilir.
- Bu skorlar, her sınıfa ait kodlama değerleri mck ile *hinge-loss* fonksiyonuna sokulur.
- Her sınıf için toplam kayıp $\sum kL(mck, sk)$ hesaplanır.
- Toplam kaybı en düşük olan sınıf, test örneğine en uygun sınıf olarak atanır.

Bu yaklaşım sayesinde ECOC çözümleyici:

- Alt modellerden gelen skorları bütüncül bir biçimde değerlendirir,
- Tek bir alt modelde oluşabilecek lokal hata veya belirsizliğin etkisini diğer alt modellerle dengeleyebilir,
- Nihayetinde çay numunesine ait kalite sınıfını marjin ve hata ölçütlerine dayalı, tutarlı bir çerçevede belirler.

Böylece ECOC yapısı, SVM tabanlı sınıflandırma algoritmasının çok sınıflı çay kalite problemine güvenilir şekilde genellenmesini sağlayan; modelin hem doğruluğunu hem de açıklama bilirliliğini güçlendiren temel mekanizma haline gelmiştir.

3.6.2.3.3. ECOC Yaklaşımının Çalışmadaki Rolü

Bu çalışmada hedeflenen üçlü kalite sınıflandırması (yüksek, orta ve düşük kalite) doğası gereği çok sınıflı bir problem yapısına sahiptir. SVM yönteminin temel olarak ikili karar mekanizmasına dayanması, bu problemi doğrudan çözmek için yetersiz bırakmaktadır. Bu nedenle sınıflar arasındaki ayrım bilgisinin daha etkin biçimde kullanılabilmesi amacıyla ECOC (*Error-Correcting Output Codes*) yaklaşımı tercih edilmiştir. ECOC, çok sınıflı yapıyı sistematik biçimde ikili alt modellere dönüştürerek sınıflar arasındaki ayrım çizgilerinin daha kararlı şekilde öğrenilmesini sağlar.

Bu yaklaşımın çalışmadaki temel rolü, üç kalite sınıfını temsil eden örnekler arasındaki benzerlik ve farklılıkları daha ayrıntılı biçimde işleyebilmesidir. ECOC, her sınıf çiftine yönelik ayrı bir SVM modeli oluşturularak, sensör ölçümlerinden elde edilen

özniteliklerin sınıflar arasındaki ayrımı hangi ölçüde desteklediğini bağımsız olarak analiz eder. Böylece model, yalnızca tek bir genel karar yüzeyi yerine, her bir sınıf çifti için özel olarak optimize edilmiş karar sınırları öğrenmiş olur (Allwein vd., 2000).

Bu yapı aynı zamanda hata toleransı sağlayarak modelin genel performansını artırır. Alt modellerden birinde ortaya çıkan sınırlı bir hata, ECOC kod çözme aşamasında diğer modellerden gelen tutarlı skorlarla dengelenebilir. Özellikle örneklem sayısının nispeten düşük olduğu çalışmalarda, ECOC'nin bu hata düzeltme özelliği modelin genelleme kapasitesine önemli katkı sunmaktadır (Escalera vd., 2010).

Sonuç olarak ECOC yaklaşımı, hem çok sınıflı problemin yapısal gereksinimlerini karşılamakta hem de sensör tabanlı çay kalite verilerinin sınıflar arası ayrım gücünü daha etkin şekilde kullanarak sınıflandırma doğruluğunu artırmaktadır. Bu nedenle ECOC, çalışmanın modelleme sürecinin temel bileşenlerinden biridir.

3.6.2.4. Softmax Fonksiyonu ve Olasılıksal Karar Mekanizması

ECOC-SVM yapısında alt modellerden elde edilen karar skorları, sınıflar arasındaki ayrımı tanımlar ancak bu skorlar doğrudan olasılık değeri değildir. Bu nedenle skorların normalize edilerek yorumlanabilir bir olasılık dağılımına dönüştürülmesi için Softmax fonksiyonu kullanılmaktadır. Softmax, çok sınıflı modellerde karar skorlarını ortak bir ölçekte ifade ederek modelin güven düzeyinin değerlendirilebilmesine olanak sağlar (Bishop, 2006).

- Tüm Sınıflara Ait Olasılıkların Toplamı 1'dir. Softmax fonksiyonu, her bir sınıfa ait olasılığı pozitif bir değer olarak üretir ve tüm sınıfların olasılıklarının toplamı 1 olacak şekilde normalize eder. Bu nedenle model çıktıları doğrudan:
 - “1. sınıf olasılığı %...”
 - “Model en çok X sınıfına yakın”
 - “Karar güveni %...”Şeklinde yorumlanabilir hale gelir.
- Üstel Dönüşüm Skor Farklarını Belirginleştirir. SVM'in karar skorları negatif veya pozitif olabilir. Softmax önce her bir skora üstel dönüşüm uygular:

$$e^{(Sk1)} = a \quad (3.9)$$

$$e^{(Sk2)} = b \quad (3.10)$$

$$e^{(sk3)} = c \quad (3.11)$$

Bu dönüşüm:

- Küçük skor farklarını büyütür,
- Sınıflar arasındaki ayrımı daha görünür kılar.

Bu değerler kullanılarak her sınıfın olasılığı şu şekilde hesaplanır:

$$1. \text{Kaliteolasılığı} P1 = \left(\frac{a}{a+b+c} \right) \times 100 \quad (3.12)$$

$$2. \text{Kaliteolasılığı} P2 = \left(\frac{b}{a+b+c} \right) \times 100 \quad (3.13)$$

$$3. \text{Kaliteolasılığı} P3 = \left(\frac{c}{a+b+c} \right) \times 100 \quad (3.14)$$

Bu işlem sonucunda toplam olasılık her zaman 1 (veya %100) olur.

- Sayısal Olarak Kararlı Softmax Formu, büyük üstel değerlerin *overflow* / *underflow* hatasına yol açmaması için pratikte şu form kullanılır:

$$P(y_i) = \left(\frac{e^{(S_i - \max(s))}}{\sum_{j=1}^0 e^{(S_j - \max(s))}} \right) \quad (3.15)$$

Bu yöntem özellikle sensör verilerinde farklı ölçekli skorlar üretilebildiğinden:

- Aşırı büyük değerlerin üretilmesini engeller,
- Skorların güvenli bir biçimde normalize edilmesini sağlar.
- Sınıf Ayrımının Güçlenmesi ve Karar Mekanizmasının Açıklanabilir, Softmax dönüşümü, SVM karar skorlarını yalnızca pozitif/negatif işaret olarak değil, güçlü–zayıf ayrımı ile yorumlanabilir hale getirir.

Böylece:

- Modelin kararından ne kadar emin olduğu ölçülür,
- Birbirine yakın sınıfların ayrımı daha hassas yapılır,
- ECOC kod çözme sonrasında elde edilen skorlar açıklanabilir bir olasılık uzayına aktarılır.

Bu özellikleri sayesinde Softmax fonksiyonu, ECOC–SVM modelinin nihai karar mekanizmasının önemli bir bileşeni olarak kullanılmaktadır.

3.6.3. Modelin Teknik Özellikleri ve Sağladığı Avantajlar

Geliştirilen sınıflandırma modeli, sensör tabanlı çay kalite analizinde hem teknik doğruluk hem de yorumlanabilir olması açısından güçlü bir yapı sunmaktadır. Ham zaman serilerinin istatistiksel özniteliklere dönüştürülmesi, Z-skor standardizasyonu ile ölçeklenmesi ve ECOC tabanlı SVM modeliyle sınıflandırılması; modelin hem gürültüye dayanıklı hem de küçük örneklem koşullarında kararlı bir performans sergilemesine olanak tanımıştır. Bu bölümde modelin teknik kapasitesi ve diğer yöntemlere göre sağladığı avantajlar ayrıntılı şekilde ele alınmaktadır.

3.6.3.1. ECOC + SVM Yapısının Teknik Kapasitesi

Çok sınıflı problemler doğrudan tek bir karar yüzeyi ile çözülemediğinden, bu çalışmada üç kalite sınıfının ayrılması ECOC (*Error-Correcting Output Codes*) yapısı üzerinden gerçekleştirilmiştir.

ECOC yaklaşımı:

- Üç kalite sınıfını üç ayrı ikili sınıflandırma problemine (1–2, 1–3, 2–3) dönüştürür,
- Her sınıf çifti için bağımsız bir SVM modeli eğitir,
- Alt modellerden elde edilen karar skorlarını kod çözme mekanizmasıyla birleştirerek nihai sınıf kararını oluşturur.

Bu yapı, modelin ayırım kapasitesini artırmakta ve sınıflar arasındaki geçiş bölgelerinde daha keskin karar sınırlarının oluşmasını sağlamaktadır.

Lineer çekirdekli SVM kullanımı ise:

- Düşük örneklemli veri setlerinde aşırı uyum riskini azaltır,
- Karar düzlemlerinin yorumlanabilir ve matematiksel olarak izlenebilir olmasını sağlar,
- Özellik uzayındaki ayırım yapısını daha açık biçimde ortaya koyar.

Bu teknik yapı sayesinde model, sensör tabanlı verilerin değişkenliğine karşı daha esnek ve kararlı bir sınıflandırma mekanizması sunmaktadır.

3.6.3.2. Gürültüye Dayanıklılık ve Küçük Veri Setlerinde Performans

Zaman serisi verileri özellikle VOC tabanlı sensörlerde:

- Isıtıcı döngüsü,
- Nem dalgalanmaları,

- Ortam basıncı değişimleri,
- Ölçüm sırasındaki anlık sensör tepkileri nedeniyle gürültü içerebilir.

Bu çalışmada uygulanan öznelik çıkarımı yöntemi (5 temel istatistik — ortalama, standart sapma, minimum, maksimum, RMS):

- Ham sinyallerdeki ani dalgalanmaların etkisini azaltmış,
- Sensörün genel tepkisini temsil eden kararlı vektörler üretmiş,
- Sınıflandırıcı için daha sağlam bir öğrenme zemini oluşturmuştur.

SVM algoritması gereği:

- *Margin* maksimizasyonu sayesinde karar sınırı gürültünün yoğun olduğu bölgelerden uzak tutulur,
- Aykırı değerlerden etkilenme minimumdur,
- Küçük örneklem koşullarında kararlı bir performans sergilemesine olanak tanımıştır (Laref vd., 2019).

Bu özellikler, toplam 90 örneğe sahip veri kümesinin dengeli bir biçimde modellenmesini mümkün kılmıştır. Özellikle SVM'in küçük örneklem problemlerine karşı bilinen dayanıklılığı, bu çalışmanın sınırlı veri koşullarında doğru bir tercih olduğunu göstermektedir.

3.6.3.3. Sensör Tabanlı Zaman Serisi Yapısına Uygunluğu

BME688 sensörünün ürettiği veriler çok boyutlu ve zamana bağlı bir yapıya sahiptir. VOC tabanlı davranışların:

- Çayın ısınması,
- Nem düşüşü,
- Gaz direnci tepkisinin zaman içinde yükselmesi veya stabil bir yapı kazanması gibi dinamiklerle değiştiği bilinmektedir.

Modelin bu yapıya uygun seçilmesinin nedenleri şunlardır:

- Öznelik çıkarımı: Zaman serilerini tek bir sabit uzunluklu vektöre dönüştürerek sınıflandırma için homojen bir temsil oluşturur.
- Z-skor standardizasyonu: Sensör kanalları arasındaki doğal ölçek farklarını giderir.

- ECOC–SVM yapısı: Her sınıf çifti arasındaki ince davranış farklarını ayrı ayrı modellenenebilir hâle getirir.
- Softmax çıktısı: Modelin sınıflar arası kararsızlık bölgelerindeki davranışının olasılık temelli olarak yorumlanmasını sağlar.

Bu bütünleşik yapı sayesinde model, sensörün fiziksel çalışma prensibine uyumlu, zaman serisi tabanlı bir kalite değerlendirme süreci oluşturmuştur.

3.6.3.4. Diğer Yöntemlerle (KNN, RF, LR) Karşılaştırmalı Avantajlar

Modelin seçiminde yalnızca doğruluk değil, aynı zamanda kararlılık, yorumlana bilirlik ve küçük veri setlerine uygunluk dikkate alınmıştır. Bu bağlamda SVM'in diğer yöntemlere göre avantajları şu şekilde özetlenebilir:

- *K-Nearest Neighbors* (KNN) ile karşılaştırma:
 - KNN, ölçek farklarına karşı çok duyarlıdır; Z-skor olsa bile çok boyutlu veride performansı düşebilir.
 - Gürültülü verilerde sınıf sınırlarını bulanıklaştırır.
 - SVM ise margin tabanlı yapısı sayesinde gürültüden daha az etkilenir.
- *Random Forest* (RF) ile karşılaştırma:
 - RF güçlü bir yöntem olsa da küçük veri setlerinde aşırı uyum (overfitting) eğilimi gösterebilir.
 - Özelliklerin önemini açıklamak zordur; SVM'de ise ağırlıklar üzerinden temel özelliklerin ayırt ediciliği daha açık izlenebilir.
 - Bu tezdeki 25 özellikli yapı SVM 'in *Lineer* karar yüzeyleriyle daha uyumludur.
- *Lojistik Regresyon* (LR) ile karşılaştırma:
 - LR *Lineer* sınırlara sıkı sıkıya bağlıdır; sınıf ayrımı doğrusal değilse performans düşer.
 - SVM'in *margin* maksimizasyonu ve ECOC yapısı, çok sınıflı ayırmada daha esnek ve güçlü bir karar mekanizması sunar.

Bu çalışma kapsamında derin öğrenme yöntemleri büyük veri setlerinde üstün performans gösterse de bu çalışmadaki örneklem büyüklüğü için SVM daha uygun bulunmuştur (Hornik, 1991). SVM + ECOC + Z-skor üçlüsü, sensör tabanlı çay kalite

verisi için hem teorik hem uygulamalı açıdan en uygun yapı olmuştur. Diğer yöntemlerin dezavantajları EDA, küçük örneklem ve sensör gürültüsü düşünüldüğünde daha belirgin hâle gelmektedir.

3.6.4. Kullanılan Modelleme Yaklaşımının Temel Dayanakları

Bu çalışma, sensör tabanlı çay kalite değerlendirmesinde tamamen veri temelli bir yaklaşım benimseyerek literatürde kullanılan yöntemlerin yöntemsel çerçevesini genişletmiştir. Geliştirilen model, yalnızca sınıflandırma doğruluğu ile değil; karar mekanizmasının açıklana bilirliliği, tekrarlanabilirliği ve yapısal tutarlılığı ile de öne çıkmaktadır.

Bu nedenle, kullanılan modelleme yaklaşımının yöntemsel dayanakları üç temel başlık altında değerlendirilebilir.

3.6.4.1. Literatürdeki Boşluğun Doldurulması

Elektronik burun sistemleri, uzun yıllardır gıda sınıflandırma, kalite kontrol ve aroma tespiti gibi alanlarda yaygın olarak kullanılmasına rağmen; çay kalite sınıflandırması özelinde çok sınıflı, açıklanabilir ve *Z-skor* standardizasyonu temelli bir *ECOC-SVM* yaklaşımı literatürde oldukça sınırlıdır (Gardner ve Bartlett, 1994; Wilson ve Baietto, 2009). Sektördeki mevcut akademik çalışmaların büyük bir bölümü incelendiğinde metodolojik olarak şu eksiklikler öne çıkmaktadır:


- Çoğunlukla tek boyutlu sensör çıktılarıyla veya sınırlı zaman serisi pencereleriyle çalışmakta,
- b) Elle seçilen kısıtlı sayıda öznitelik üzerinden *KNN*, *RF* ve *LR* gibi geleneksel ve doğrusal kalıplara sıkışmış basit sınıflandırıcılar tercih edilmekte (Bhattacharyya vd., 2007; Saha vd., 2012),
- c) Çok sınıflı kalite ayırımıdaki belirsizlikler çoğunlukla göz ardı edilerek karar mekanizmaları herhangi bir olasılık dağılımı veya açıklayıcı istatistiksel metrikle desteklenmemektedir.

Bu tez çalışması kapsamında geliştirilen yaklaşım ile çay kalite sınıflarının (yüksek, orta, düşük) sistematik olarak modellenmesi, çok kanallı sensör tabanlı zaman serilerinin yüksek temsiliyetli istatistiksel özniteliklere dönüştürülmesi, çok sınıflı yapının *ECOC* üzerinden optimize edilmesi ve nihai karar sürecinin *Softmax* fonksiyonu ile olasılık bazlı yorumlanabilir hâle getirilmesi sağlanmıştır. Bu

bütünleşik tasarım sayesinde, literatürde sensör tabanlı çay kalite analizlerinde karşılaşılan temel yöntemsel eksiklikler doğrudan ve kararlı bir biçimde karşılanmaktadır (Hidayat vd., 2021).

3.6.4.2. Sensör Verisi Tabanlı Z-Skor-ECOC-SVM-Softmax Akışı

Bu araştırmanın en özgün yönlerinden biri, geliştirilen modelleme akışının tamamen standartlaştırılmış ve otomatikleştirilebilir bir yapı sunmasıdır.




Şekil 42. Model Akış Mimarisi

Şekil 42’deki görselde *BME688* donanımından alınan ham verilerin, Destek Vektör Makineleri (SVM) ve Softmax aktivasyonu ile nasıl bilimsel bir “Kalite Sınıfı” kararına dönüştüğünün adım adım mimarisidir.

Çalışmada kullanılan teknik zincir şu sırayla ilerlemektedir:


- Sensör Verisi (*BME688*), VOC, nem, sıcaklık, basınç ve gaz direnci sinyalleri zaman serisi hâlinde elde edilir.



Şekil 43. Sensör Zaman Serisi Sinyalleri

Şekil 43'teki görselde Sensörlerden elde edilen veriler sürekli ölçümlerden oluşan zaman serisi sinyalleri şeklindedir. Her bir kanal farklı fiziksel parametreleri temsil etmekte ve çay numunesinin kimyasal ve çevresel özelliklerine bağlı olarak değişkenlik göstermektedir


- Öznitelik Çıkarımı, her kanal için ortalama, standart sapma, RMS, minimum ve maksimum değerler hesaplanır.



Şekil 44. Zaman Serisi Verisi Üzerindeki İstatistiksel Öznitelikler

Şekil 44'teki görselde *BME688* sensöründen elde edilen zaman serisi verileri işlenerek makine öğrenmesi modelinde kullanılabilecek sayısal özelliklere dönüştürülmektedir. Her sensör kanalı için ortalama, standart sapma, RMS, minimum ve maksimum değerler hesaplanarak ham sinyaller sabit boyutlu bir öznitelik vektörüne dönüştürülmektedir. Bu işlem, verinin model tarafından daha etkin analiz edilmesini sağlamaktadır.


- *Z-Score* Standardizasyonu, farklı ölçeklerdeki özellikler ortak referans düzlemine taşınır ve çok boyutlu sensör verisinin dengeli biçimde modele aktarılması güvenceye alınır (Abdi ve Williams, 2010)..



Şekil 45. Z-Skor Standardizasyonu

Şekil 45'teki görselinde farklı sensör kanallarından elde edilen özellikler farklı ölçüm aralıklarına sahip olabilmektedir. Z-Score standardizasyonu uygulanarak her bir özellik ortalaması sıfır ve standart sapması bir olacak şekilde yeniden ölçeklendirilir.


Z-Score değerlerine göre Karar skorları $Sk1$, $Sk2$, $Sk3$ bulunur. Karar skorlarından en küçük olan -1, en büyük olan +1, orta değer olan 0 ile ilişkilendirilerek çıktı matrisi elde edilir.



Şekil 46. Karar Skorları ve Çıktı Matrisi

Şekil 46'deki görselinde karar skorlarının sayısal değerlerine göre çıktı matrisinin sayısal ifadesi gösterilmektedir.

- ECOC-SVM Modeli, üç kalite sınıfı için 1–2, 1–3, 2–3 olmak üzere üç ayrı SVM alt modeli eğitilir.



Şekil 47. ECOC-SVM Sınıflandırma Yapısı

Şekil 47’de ECOC yaklaşımı, çok sınıflı sınıflandırma problemini birden fazla ikili sınıflandırma problemine dönüştürmektedir (Allwein vd., 2000). Bu çalışmada üç kalite sınıfı için (1–2), (1–3) ve (2–3) olmak üzere üç ayrı SVM modeli eğitilmiştir. Tahmin süreci, test matrisini bu üç ideal satırdan hangisine geometrik olarak en yakın olduğunu bulmak için yapılır.

Hiperdüzlemlere Olan Uzaklıkların Hesaplanması


$$d = \sqrt{x^2 + y^2 + z^2}$$

1. Sınıf Uzaklığı: $\sqrt{2^2 + 0^2 + 0^2}$
= 2.00 birim uzakta.

2. Sınıf Uzaklığı: $\sqrt{0^2 + 1^2 + 1^2}$
= 1.41 birim uzakta.

3. Sınıf Uzaklığı: $\sqrt{1^2 + 2^2 + (-1)^2}$
= 2.45 birim uzakta.

Sistemin tespiti: Mesafe olarak 1.41 birim ile hiperdüzleme en yakın sınıf 2. Kalite üründür.




Şekil 48. Test Numunesinin Hiper Düzlemlere Uzaklığı

Şekli 48’ de Ham veriden elde edilen zaman serisi tek nokta ile ifade edilen öznitelik vektörüne dönüşür ve modelin eğitim verilerinden elde ettiği hiper

düzlemlere uzaklığı ECOC tarafından matris tablosuna göre hesaplanarak en yakın sınıfa ait hiper düzlem tespit edilerek kalite sınıfı belirlenir. Çok sınıflı karar mekanizması kod çözme (*decoding*) ile tamamlanır.


- Softmax Olasılık Hesabı, ham margin skorları olasılık dağılımına dönüştürülür. Geometrik mesafe teknik bir doğrulanır kesinlik derecesi vermez. Softmax algoritması SVM’ nin ürettiği ham karar skorları üstel fonksiyonla standartlaştırır.



Şekil 49. Softmax Olasılık Dağılımı

Şekil 49’daki görselde karar skorlarının üstel fonksiyon ile güven skorlarına dönüşmesinin ilk adımı gösterilmektedir. Karar sadece “sınıf etiketi” olarak değil, “güven yüzdesi” olarak sunulur. Karar skorları üstel fonksiyonla standartlaştırılarak toplamı 100 olan anlaşılır bir olasılık dağılımına çevrilir.

Sınıf Tahmin Güven Skorları:



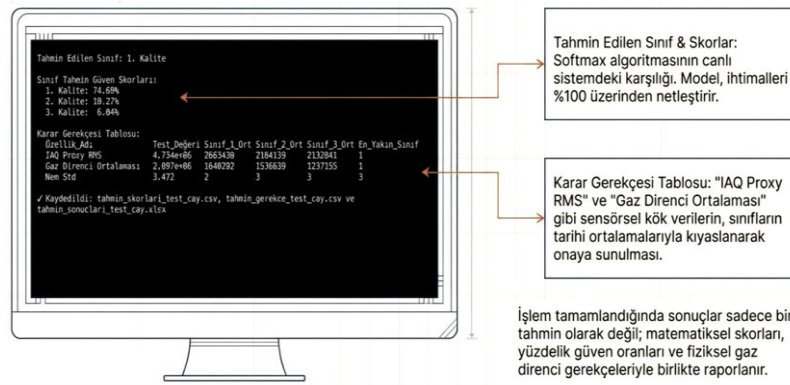
Şekil 50. Güven Skoru ve Kalite Sınıfı

Şekil 50'deki görselinde güven skoru yüzdelik olarak bulunarak ECOC matrisinin geometrik uzaklık sonucunu %100 üzerinden netleştirerek sonuçlandırmıştır.

Test dosyası: *test_cay.csv*

Tahmin Edilen Sınıf: 2.Kalite

Bu bütünleşik akış, sensör verisinin işlenmesinden kalite tahminine uzanan süreci tam anlamıyla standartlaştırmakta ve modelin her test örneğinde aynı adımları takip ederek kararlı sonuçlar üretmesini sağlamaktadır.



Şekil 51. Sistemin Şeffaf ve Gerekçeli Sonuçlarını İçeren Karar Ekranı

Şekil 51'deki görselinde *MATLAB* ekranı üzerinde *test_cay.csv* dosyasına ait nihai karar ekranı görülmektedir. Burada tüm değerlendirme sonuçları ayrıntılı olarak verilmiştir. Bu tahmin sonuçları .csv ve xlsx ve gerekçesi .csv dosyası olarak masaüstüne kaydedilmektedir.

3.6.4.3. Çay Kalitesinde Veri Temelli Yaklaşımın Katkısı

Bu tez, çay kalite sınıflandırmasında tam sensör tabanlı, veri odaklı, açıklanabilir ve çok sınıflı bir model oluşturarak literatüre önemli bir yenilik kazandırmaktadır.

Katkılar şu şekilde özetlenebilir:

- Tamamen nesnel, tekrarlanabilir ve insan etkisinden bağımsız bir kalite değerlendirme mekanizması geliştirilmiştir.
- *BME688* sensörünün VOC tepkileri ilk kez istatistiksel öz nitelik ECOC-SVM yapısı ile derinlemesine analiz edilmiştir.

- Önerilen model mimarisi sadece soyut bir sınıf etiketi üretmemekte, aynı zamanda şu parametreleri sunarak Açıklanabilir Yapay Zeka (XAI) yaklaşımını doğrudan desteklemektedir (Arrieta vd., 2020):
 - Karar skorlarını,
 - Sınıf merkezlerine olan uzaklıkları,
 - Olasılık dağılımı temelli güven düzeylerini sunarak açıklanabilir yapay zekâ (XAI) yaklaşımını desteklemektedir.
- Çay kalitesi gibi kimyasal profili karmaşık bir ürün için çok sınıflı ayrımın başarıyla modellenmesi, elektronik burun (e-burun) teknolojilerinin kalite kontrol süreçlerine uygulanabilirliğini kesin olarak kanıtlamaktadır (Banerjee vd., 2016),
- Model yapısı diğer tarımsal ürünlerde (kahve, kakao, baharatlar, kurutulmuş bitkiler) de doğrudan kullanılabilecek esnekliğe sahiptir.

3.6.5. Model Geliştirme ve Tahmin Sürecinin Genel Akış Şeması

Bu bölümde, çay kalite sınıflandırması için kurulan modelin geliştirilme adımları uçtan uca bir akış içerisinde sunulmaktadır. Akış diyagramı; veri toplama sürecinden başlayarak, ham sensör verilerinin işlenmesi, öznitelik çıkarımı, veri kümesinin eğitim, doğrulama, test alt bölümlerine ayrılması, SVM-ECOC temelli modelin eğitilmesi, doğrulanması ve son aşamada yeni ölçümlerin sınıf tahminine dönüştürülmesine kadar tüm aşamaları sistematik olarak göstermektedir (Bishop, 2006; Webb ve Copsey, 2011).


Bu yapı, modelleme sürecinin genel mantığını tek bir çerçeve altında toplayarak okuyucuya hem adımların sırasını hem de bu adımlar arasındaki etkileşimi hızlı biçimde kavrama olanağı sağlamaktadır. Böylece sensör verilerinin ham zaman serisinden öznitelik vektörlerine dönüştürülmesi, bu verilerin makine öğrenmesi modeline nasıl beslendiği ve nihai kalite tahmininin hangi ardışık işlemler sonucunda elde edildiği görsel olarak da açıklığa kavuşturulmaktadır.

Model geliştirme sürecinin akış şemasında, önceki başlıklarda ayrıntılı biçimde açıklanan adımlar, tek bir akış diyagramı altında görsel olarak birleştirilmektedir. Şema, deneysel veri toplama sürecinden başlayarak:


- *BME688* sensöründen ham zaman serilerinin elde edilmesi,

- *.bmerawdata* biçiminde SD karta kaydedilmesi,
- *Python* betikleri ile *csv/xlsx* formatına dönüştürülmesi,
- İlgili sütunlardan (sıcaklık, nem, basınç, gaz direnci, *IAQ Proxy* vb.) öznitelik çıkarımı yapılması,
- Veri kümesinin Eğitim, Doğrulama, Test alt bölümlerine ayrılması,
- Z-skor standardizasyonunun uygulanması,
- ECOC tabanlı SVM modelinin eğitilmesi,
- Doğrulama kümesi ile performansın izlenmesi ve hiper parametrelerin değerlendirilmesi,
- Bağımsız test kümesi ile nihai performansın ölçülmesi,
- Yeni test çaylarına ait sensor verilerinden özellik çıkarılarak eğitilmiş modele verilmesi ve kalite sınıfı tahmininin üretilmesi adımlarını ardışık şekilde göstermektedir.

1. Sensör Veri Bölünmesi




2. Model Geliştirme



3. Doğrulama ve Hiperparametreler



4. Düzeltilmiş Model



5. Tahmin Mekanizması



Şekil 52. Çay Kalitesi Sınıflandırma Modelinin Genel İş Akışı

Şekil 52’de sensör verilerinin toplanmasından başlayarak kalite sınıflandırma modeline kadar uzanan tüm süreci özetlemektedir.

Çay kalitesinin sensör tabanlı ölçümünden sınıf tahminine kadar uzanan sürecin tüm bileşenleri hem metinsel hem de görsel düzeyde bütüncül bir bakış açısıyla sunulmuş olmaktadır.

3.6.5.1. Veri Bölünmesi

Toplam 90 adet csv dosyası, farklı çay örneklerinden elde edilen ölçüm oturumlarını temsil etmektedir. Her dosya, ilgili çay numunesine ait sensör zaman serilerinden türetilen istatistiksel öznitelikleri içermektedir. Modelin öğrenme sürecini sağlıklı yürütmek ve genelleme performansını güvenilir biçimde değerlendirebilmek amacıyla veri kümesi üç alt bölüme ayrılmıştır:

- %70 Eğitim (*Train*)
- %15 Doğrulama (*Validation*)
- %15 Test (*Test*)

Bu oranlar, bir yandan modelin yeterli sayıda örnek üzerinde parametre öğrenmesini, diğer yandan da daha önce görülmemiş veri üzerinde performansın objektif biçimde sınanmasını sağlamaktadır. Veri bölünmesi yapılırken her bir kalite sınıfının (1: yüksek kalite, 2: orta kalite , 3: düşük kalite) mümkün olduğunca sınıflar arası dengeli dağılım sağlanmıştır (Chawla vd., 2002).

Tablo 17. Eğitim, Doğrulama ve Test Veri Kümelerinin Sınıf Dağılımı

Veri Kümesi	Sınıf 1 (S1)	Sınıf 2 (S2)	Sınıf 3 (S3)	Toplam (örnek)	(%)
Eğitim	21	21	21	63	70
Doğrulama	5	5	5	15	15
Test	4	3	5	12	15
Genel Toplam	30	29	31	90	100

Tablo 17’de model geliştirme sürecinde kullanılan veri setinin üç kalite sınıfına göre eğitim, doğrulama ve test kümeleri özelinde dağılımı gösterilmektedir. Sınıflar arasındaki bu denge, modelin herhangi bir kalite kategorisine karşı yanlı öğrenme geliştirmesini önleyen temel unsurlardan biridir.

3.6.5.2. Verilerin İkili Alt Modellere Bölünmesi (ECOC Mantığı)

ECOC (*Error-Correcting Output Codes*) tabanlı SVM yaklaşımı, çok sınıflı bir problemi, her biri iki sınıf içeren daha yalın alt görevlere ayırarak çözer. Bu çalışmada üç kalite sınıfı bulunduğundan, modelleme süreci üç ikili alt model ile yürütülmüştür:

- (1–2): Yüksek kalite – Orta kalite
- (1–3): Yüksek kalite – Düşük kalite
- (2–3): Orta kalite – Düşük kalite

Bu yapı sayesinde her sınıf çifti kendi içinde dengeli bir örnek kümesi üzerinden ayrı ayrı öğrenilmekte, böylece sınıflar arası karar sınırları daha net biçimde ortaya çıkmaktadır.

3.6.5.3. Model Eğitiminde Kullanılacak (.csv) Veri Kümesi (Train Set)

Modelin eğitilmesi sürecinde kullanılan veri kümesi, toplam 90 örnek arasından rastgele ve dengeli biçimde seçilmiş %70’lik bölümden (63 adet csv dosyası) oluşmaktadır. Eğitim kümesi, üç kalite sınıfının her birinden 21’er örnek içerecek şekilde yapılandırılmıştır. Bu düzen, SVM modelinin karar sınırlarını öğrenirken herhangi bir sınıfa karşı yanlılık geliştirmesini engelleyen temel bir tasarım tercihi olmuştur.

Eğitim seti;

Eğitim seti; SVM-ECOC modelinin ağırlık vektörleri, çekirdek ve ceza parametreleri ile marjın optimizasyonu gibi temel bileşenlerinin öğrenilmesini sağlamıştır.

Tablo 18. Eğitim Aşamasında Kullanılan Örneklerin Sınıf Bazında Dağılımı

Set	Örnek	Sınıf	Set	Örnek	Sınıf	Set	Örnek	Sınıf
Eğitim 03_C_A3(1).csv	1		Eğitim 01_C_A1(2).csv	2		Eğitim 02_C_A2(3).csv	3	
Eğitim 05_C_A3(1).csv	1		Eğitim 14_C_A4(2).csv	2		Eğitim 04_C_A2(3).csv	3	
Eğitim 07_C_A3(1).csv	1		Eğitim 16_C_A14(2).csv	2		Eğitim 10_C_A6(3).csv	3	
Eğitim 09_C_A3(1).csv	1		Eğitim 18_C_A12(2).csv	2		Eğitim 12_C_A8(3).csv	3	
Eğitim 11_C_A3(1).csv	1		Eğitim 20_C_A1(2).csv	2		Eğitim 32_C_A6(3).csv	3	
Eğitim 13_C_A7(1).csv	1		Eğitim 22_C_A5(2).csv	2		Eğitim 34_C_A16(3).csv	3	
Eğitim 81_C_A7(1).csv	1		Eğitim 24_C_A4(2).csv	2		Eğitim 46_C_A6(3).csv	3	

Tablo 18 (Devam). Eğitim Aşamasında Kullanılan Örnekleri Sınıf Bazında Dağılımı

Eğitim 19_C_A7(1).csv	1	Eğitim 26_C_A15(2).csv	2	Eğitim 52_C_A8(3).csv	3
Eğitim 21_C_A7(1).csv	1	Eğitim 38_C_A1(2).csv	2	Eğitim 58_C_A6(3).csv	3
Eğitim 25_C_A7(1).csv	1	Eğitim 42_C_A5(2).csv	2	Eğitim 62_C_A16(3).csv	3
Eğitim 27_C_A7(1).csv	1	Eğitim 53_C_A4(2).csv	2	Eğitim 64_C_A2(3).csv	3
Eğitim 29_C_A7(1).csv	1	Eğitim 55_C_A14(2).csv	2	Eğitim 66_C_A13(3).csv	3
Eğitim 67_C_A7(1).csv	1	Eğitim 61_C_A5(2).csv	2	Eğitim 70_C_A6(3).csv	3
Eğitim 33_C_A7(1).csv	1	Eğitim 63_C_A15(2).csv	2	Eğitim 72_C_A8(3).csv	3
Eğitim 35_C_A10(1).csv	1	Eğitim 71_C_A15(2).csv	2	Eğitim 74_C_A16(3).csv	3
Eğitim 37_C_A9(1).csv	1	Eğitim 79_C_A14(2).csv	2	Eğitim 76_C_A16(3).csv	3
Eğitim 47_C_A11(1).csv	1	Eğitim 86_C_A14(2).csv	2	Eğitim 36_C_A16(3).csv	3
Eğitim 49_C_A9(1).csv	1	Eğitim 90_C_A5(2).csv	2	Eğitim 80_C_A8(3).csv	3
Eğitim 51_C_A10(1).csv	1	Eğitim 75_C_A12(2).csv	2	Eğitim 82_C_A16(3).csv	3
Eğitim 85_C_A3(1).csv	1	Eğitim 77_C_A1(2).csv	2	Eğitim 60_C_A8(3).csv	3
Eğitim 87_C_A3(1).csv	1	Eğitim 73_C_A15(2).csv	2	Eğitim 68_C_A8(3).csv	3

Tablo 18’de modelin eğitim sürecinde kullanılan tüm örneklerin set, örnek adı ve sınıf etiketlerine göre dağılımı gösterilerek, eğitim veri kümesinin sınıf dengesi açık biçimde ortaya konulmaktadır.

3.6.5.4. Model Doğrulama Veri Kümesi (Validation Set)

Doğrulama kümesi, toplam veri setinin %15’ini oluşturan 15 örnekten meydana gelmiştir. Bu küme, eğitim sürecine doğrudan dâhil edilmemiş; ancak eğitim sırasında:

- Aşırı öğrenme (*overfitting*) eğiliminin izlenmesi,
- Modelin genelleme kapasitesinin değerlendirilmesi,
- Uygun hiper parametre kombinasyonlarının seçilmesi için kullanılmıştır.

Doğrulama kümesinde sınıf dağılımı tam dengeli düzenlenmiştir:

- 5 adet yüksek kalite (*Class 1*)
- 5 adet orta kalite (*Class 2*)
- 5 adet düşük kalite (*Class 3*)

Bu yapı, her bir kalite sınıfı için model davranışının ayrı ayrı ve adil biçimde değerlendirilmesini sağlamaktadır.

Tablo 19. Doğrulama Aşamasında Kullanılan Sınıf Dağılımı

Set – %15 Doğrulama Verisi	Örnek	Sınıf
Doğrulama	17_C_A3(1).csv	1
Doğrulama	39_C_A10(1).csv	1
Doğrulama	43_C_A11(1).csv	1
Doğrulama	83_C_A3(1).csv	1
Doğrulama	89_C_A3(1).csv	1
Doğrulama	45_C_A5(2).csv	2
Doğrulama	57_C_A12(2).csv	2
Doğrulama	65_C_A15(2).csv	2
Doğrulama	69_C_A15(2).csv	2
Doğrulama	84_C_A12(2).csv	2
Doğrulama	06_C_A2(3).csv	3
Doğrulama	08_C_A13(3).csv	3
Doğrulama	48_C_A16(3).csv	3
Doğrulama	54_C_A2(3).csv	3
Doğrulama	56_C_A13(3).csv	3

Tablo 19’da doğrulama sürecinde kullanılan örneklerin set, örnek adı ve sınıf etiketlerine göre dağılımı gösterilmekte; %15’lik doğrulama kümesinin yapısı ayrıntılı biçimde ortaya konmaktadır.

3.6.5.5. Model Test Veri Kümesi (Hold-Out Test Set)

Test kümesi, toplam veri setinin %15’ini oluşturan 12 bağımsız örnekten oluşmaktadır. Bu veri grubu, modelin eğitim veya doğrulama aşamalarında hiçbir şekilde kullanılmamış; yalnızca nihai performansın objektif olarak ölçülmesi için değerlendirilmiştir. Böylelikle modelin, gerçek dünya koşullarına benzer biçimde daha önce hiç görmediği örnekler üzerindeki başarısı test edilmiştir.

Test kümesinde sınıf dağılımı şu şekildedir:

- 3 adet yüksek kalite (*Class 1*)
- 4 adet orta kalite (*Class 2*)
- 5 adet düşük kalite (*Class 3*)

Bu dağılım, modelin tüm kalite sınıflarında tutarlı ve dengeli bir tahmin performansı gösterip göstermediğinin değerlendirilmesi açısından önem taşımaktadır.

Tablo 20. Test Aşamasında Kullanılan Örneklerin Sınıf Dağılımı

Set – %15 Test Verisi	Örnek	Sınıf
Test	15_C_A7(1).csv	1
Test	23_C_A3(1).csv	1
Test	31_C_A7(1).csv	1
Test	41_C_A11(1).csv	1
Test	40_C_A14(2).csv	2
Test	59_C_A1(2).csv	2
Test	88_C_A1(2).csv	2
Test	28_C_A2(3).csv	3
Test	30_C_A13(3).csv	3
Test	44_C_A13(3).csv	3
Test	50_C_A2(3).csv	3
Test	78_C_A16(3).csv	3

Tablo 20’de test sürecinde kullanılan bağımsız örneklerin set, örnek adı ve sınıf etiketlerine göre dağılımı gösterilmekte; %15’lik test veri kümesinin yapısı ayrıntılı olarak sunulmaktadır.

Bu üçlü yapı (Eğitim–Doğrulama–Test), modelin yalnızca öğrenme verisi üzerinde değil, daha önce karşılaşmadığı örnekler üzerinde de tutarlı ve genellenebilir sonuçlar üretmesini sağlamıştır. Böylece sınıflandırma performansı hem iç geçerlilik hem de dış geçerlilik açısından güvenilir bir şekilde değerlendirilmiştir.

3.7. Model Geliştirme


Bu bölümde, sensör verilerinin işlenmesinden nihai tahminlerin üretilmesine kadar uzanan model geliştirme süreci bütüncül bir çerçevede ele alınmaktadır. Çalışmanın temel amacı, *BME688* sensörüyle elde edilen çok boyutlu zaman serisi verilerini anlamlı, karşılaştırılabilir ve sınıflandırmaya uygun bir forma dönüştürerek çay kalite seviyelerinin nesnel biçimde belirlenmesini sağlamaktır.

İlk aşamada, sekiz sensör hücresinden (U1–U8) elde edilen ham zaman serileri doğrudan kullanılmamış; bunun yerine her bir ölçüm parametresi için temsil gücü yüksek istatistiksel öznitelikler (ortalama, standart sapma, minimum, maksimum ve RMS) çıkarılmıştır (Fulcher ve Jones, 2014) Bu yaklaşım, hem ham verideki gürültünün etkisini azaltmış hem de her deney setini tek satırlık kompakt bir özellik vektörü hâline getirerek modelin hesaplama yükünü önemli ölçüde hafifletmiştir.

Öznitelik çıkarımını takiben, farklı büyüklük ve birimlerde ifade edilen sensör değişkenlerinin model üzerindeki etkisini dengelemek amacıyla tüm veriler Z-skor standardizasyonuna tabi tutulmuştur (Abdi ve Williams, 2010). Böylece sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* gibi ölçümler aynı ölçek aralığına getirilmiş; her özelliğin sınıflandırma sürecine eşit düzeyde katkı sağlaması güvence altına alınmıştır.

Sınıflandırma aşamasında temel öğrenici olarak Destek Vektör Makineleri (SVM) kullanılmıştır. SVM; küçük ve orta ölçekli veri kümelerinde yüksek ayırım gücü sunması, doğrusal karar sınırlarını etkin biçimde oluşturabilmesi ve aşırı uyum riskini görece düşük tutması nedeniyle bu çalışmanın veri yapısına uygun bir yöntem olarak değerlendirilmiştir. Çok sınıflı çay kalite probleminin çözümü ise *MATLAB* ortamındaki *fitcecoc* fonksiyonu kullanılarak ECOC (*Error-Correcting Output Codes*) yaklaşımı ile gerçekleştirilmiş; böylece 1–2, 1–3 ve 2–3 sınıf çiftlerine ait üç ikili SVM modeli üzerinden nihai çok sınıflı karar mekanizması kurulmuştur.

Son aşamada, ikili alt modellerden elde edilen karar skorları ECOC kodlama/çözme yapısı ile birleştirilmiş; elde edilen sınıf skorları Softmax dönüşümü ile olasılık temelli tahminlere dönüştürülmüştür. Bu yöntem, modelin yalnızca tek bir sınıf etiketi üretmesinin ötesine geçerek, kararın hangi sınıfa hangi düzeyde yakın olduğunu sayısal olarak gösterebilmesini sağlamıştır.



Şekil 53. Model Geliştirme Sürecinin Aşamalarını Gösteren Akış Diyagramı

Şekil 53'te Özellik çıkarımı, ölçekleme, SVM tabanlı çok sınıflı eğitim ve karar/çıktı üretim adımlarının özetlendiği akış şeması sunulmuştur.

Bu bütünleşik yapı sayesinde geliştirilen model hem kararlı hem de açıklanabilir bir performans ortaya koymuş; çay kalite sınıflandırmasının analitik ve güvenilir biçimde yürütülmesine olanak tanımıştır.

Bu bölümde sırasıyla özellik çıkarımı, Z-skor standardizasyonu, ECOC–SVM yapısı ve Softmax tabanlı sınıf tahmini açıklanmaktadır.

3.7.1. Özellik Çıkarımı (Feature Extraction)

Bu çalışmada özellik çıkarımı, ham zaman serisi sensör verilerinin sınıflandırma modelinin işleyebileceği kompakt, bilgi yoğun ve anlamlı özellik vektörlerine dönüştürülmesi sürecini ifade etmektedir. *BME688* sensöründen elde edilen veriler zaman bağımlı ve yüksek boyutlu olduğu için, bu verilerin özetlenmesi

hem gürültünün azaltılması hem de sınıflar arasındaki ayrımın güçlendirilmesi açısından kritik öneme sahiptir (Guyon ve Elisseeff, 2003).

Amaç, ölçülen her parametrede çay numunesine özgü karakteristik davranışları yakalayan öznitelikler çıkararak, her bir ölçüm oturumunu tek satırlık bir “koku parmak izi” vektörüyle temsil etmektir (Wang vd., 2006).

3.7.1.1. Girdi Verilerinin Yapısı

BME688 sensörü deney süresince aşağıdaki temel parametreleri yüksek örnekleme frekansı ile kaydetmektedir:

- *temperature_C*: Ölçüm kabındaki sıcaklık değişimini izler. VOC salınımı sıcaklığa duyarlı olduğundan kritik bir parametredir.
- *pressure_hPa*: Sensör davranışını etkileyebilen çevresel basınç değişimlerini temsil eder.
- *humidity_RH*: Farklı kalite seviyelerindeki çay örneklerinde nem davranışı belirgin şekilde değişebildiği için güçlü bir ayırt edicidir.
- *gas_resistance_ohm*: VOC yoğunluğu arttıkça metal oksit gaz sensörünün direnci düşer; bu parametre sensörün temel tepki mekanizmasını yansıtır.
- *iaq_proxy*: Gaz direnci, nem ve sıcaklık parametrelerinin bileşik etkisini sayısal olarak ifade eden ampirik bir göstergedir.

Her bir ölçüm oturumunda bu parametreler için binlerce zaman noktası kaydedilmektedir. Bu ham yapı, doğrudan sınıflandırma algoritmalarına verilmek için hem fazla yüksek boyutludur hem de gürültü içeriği yüksektir. Bu nedenle her zaman serisi, sınıf ayırımına katkı sağlayacak istatistiksel özetlerle temsil edilmiştir. Sensör verileri sabit örnekleme frekansında elde edilen zaman serileri niteliğinde olmakla birlikte, bu çalışmada zaman serileri doğrudan modele verilmemiştir. Bunun yerine, her bir zaman serisi; sınıf ayırımına katkı sağlayacak ortalama, standart sapma ve RMS gibi istatistiksel özet özellikler aracılığıyla temsil edilmiştir. Bu yaklaşım ile sinyalin zamansal sıralamasından bağımsız olarak, kalite sınıflarını ayırt eden dağılımsal karakteristiklerin öğrenilmesi amaçlanmıştır.

3.7.1.2. Özellik Vektörünün Oluşturulması

Ham sinyallerin sabit boyutlu tek bir satır vektörle temsil edilebilmesi için her sensör parametresinden aşağıdaki beş istatistiksel öznitelik çıkarılmıştır:

- Ortalama (*Mean*)
- Standart sapma (*Std*)
- Minimum değer (*min*)
- Maksimum değer (*max*)
- Kök ortalama kare (RMS)

Bu durumda her bir ölçüm oturumu için:

- 5 sensör parametresi $\times$ 5 istatistiksel ölçüm = 25 öznitelik olacak şekilde sabit boyutlu bir özellik vektörü elde edilmiştir.

Öne çıkan bazı özniteliklerin rolü şu şekilde özetlenebilir:

- *IAQ Proxy RMS*: VOC etkisi altında sensörün bütün oturum boyunca gösterdiği ortalama tepki büyüklüğünü temsil eder.
- Gaz direnci ortalaması (*Gas Mean*): Uçucu bileşik yoğunluğunun en güçlü göstergelerinden biridir.
- Nem istatistikleri (*RH Mean, RH Std*): Çayın üretim kalitesi, işlenme şekli ve yaprak yapısına bağlı olarak anlamlı ayrışmalar sağlar.
- Sıcaklık ve basınç özetleri: Sensörün çalışma ortamına uyumu ve ısıtma profilinin etkileri hakkında tamamlayıcı bilgi sunar.

Bu çalışmada her ölçüm oturumu 25 boyutlu bir özellik vektörü ile temsil edilmiştir. Bu şekilde, her bir ölçüm oturumu için binlerce zaman damgasından oluşan büyük hacimli veri, yalnızca temsil gücü yüksek bilgileri içeren 25 boyutlu tek bir özellik vektörüne dönüştürülmüştür.

3.7.1.3. Eğitim Veri Matrisinin (*X_train – y_train*) Oluşturulması

Öznitelik çıkarımı adımlarının tamamlanmasıyla birlikte, her bir ölçüm oturumu için sabit boyutlu ve sayısal bir özellik vektörü elde edilmiştir. Bu vektörler satır bazında bir araya getirilerek sınıflandırma modelinin temel girdisini oluşturan *X_train* matrisi oluşturulmuştur. *X_train*'in her satırı bir çay numunesine ait tek bir ölçüm oturumunu, her sütunu ise sıcaklık, bağıl nem, basınç, gaz direnci ve *IAQ Proxy* gibi sensör parametrelerinden türetilen istatistiksel bir özneliği temsil etmektedir.

Tablo 21. Örnek Çay Numunesi İçin Sensör Bazlı Ortalama Değerler

Sensör	IAQ_Mean	Gas_Mean	Nem_Mean
S0	451904744	1200	55.1
S1	458643224	1180	54.9
S2	501176177	1175	55.5
S3	555625335	1201	54.6
S4	573311576	1190	55.0
S5	655131587	1198	56.9
S6	716545891	1205	55.8
S7	468376508	1211	55.9

Tablo 21 görüldüğü gibi *BME688* sensörü sekiz gaz sensör hücresinden (S0–S7) oluştuğundan, ham zaman serileri oldukça yüksek boyutludur.

Bu nedenle öznitelik çıkarımı iki aşamalı yürütülmüştür:

- Sensör hücresi düzeyinde özetleme:

Her bir hücre için ortalama, standart sapma, minimum, maksimum ve RMS değerleri hesaplanmıştır. Bu sensör bazlı özetler, bir çay örneğinin VOC davranışının hücreler arası değişimini anlamak açısından önem taşır.

- Numune düzeyinde birleştirme:

Sekiz sensör hücresinden elde edilen aynı türdeki öznitelikler bir araya getirilmiş ve her parametre için tek bir temsilci değer oluşturulmuştur. Böylece her numune için toplam 25 bileşenli kompakt bir özellik vektörü elde edilmiştir.

Bu aşamalar tamamlandığında tüm numunelerin özellik vektörleri birleştirilerek:

$$X_{Train} = \begin{bmatrix} \text{özellik 1} \\ \dots \\ \text{özellik 63} \end{bmatrix} \quad (3.16)$$

Şeklinde (63×25) boyutlu eğitim veri matrisi elde edilmiştir. Bu 63 örnek, toplam 90 dosyanın %70’lik eğitim alt kümesini temsil etmekte ve üç sınıfın her birinden 21 numune içermektedir. Bu dengeli yapı, SVM modelinin herhangi bir sınıfa karşı yanlılık geliştirmeden marjinleri öğrenebilmesi açısından kritik öneme sahiptir.

- y_{train} Vektörünün Oluşturulması

Her X_{train} satırına karşılık gelen kalite sınıfı etiketi, y_{train} vektöründe sayısal olarak tutulmuştur:

- 1 → Yüksek kalite,
- 2 → Orta kalite,
- 3 → Düşük kalite.

Bu etiketler, veri dosyalarının adlarındaki sınıf kodlarından otomatik olarak çekilmiş ve öznitelik satırlarıyla birebir eşleştirilmiştir. Böylece gözetimli öğrenme için gerekli olan giriş (X_{train}) – çıkış (y_{train}) yapısı oluşturulmuştur.

- Eğitim Matrisinin Son Hali

X_{train} ve y_{train} 'in birlikte oluşturduğu eğitim veri yapısı, model eğitim sürecinde kullanılan temel referanstır.

Bu yapı “*prepared_balanced_linear_ecoc_v4.mat*” dosyasında saklanmış olup *MATLAB*’daki *fitcecoc* tabanlı SVM modelleri tarafından doğrudan kullanılmaktadır.

Tablo 22. Eğitim Kümesi Örneklerinin Öznitelik Vektörleri ve Sınıf Etiketleri

Örnek No	Özellik 1 (IAQ_Mean)	Özellik 2 (IAQ_Std)	Özellik 3 (Gaz_Mean)	Özellik 25	(Sınıf) y_{train}
Çay_A1	553089380	12.3	1180 ...	0.85	1 (Yüksek)
Çay_A2	560090742	10.7	1450	0.77	2 (Orta)
Çay_A3	499090845	9.8	1600	0.72	3 (Düşük)
...				...	...
Çay_A63	534678098	9.9	8.9	0.79	3 (Düşük)

Tablo 22’de model eğitiminde kullanılan her bir çay örneğine ait 25 öznitelikten oluşan giriş vektörleri ile bu örneklerin gerçek kalite sınıflarını gösteren etiketler sunulmaktadır.

Bu matrisin, her bir numuneye ait:

- 25 öznitelik değerini,
- Karşılık gelen sınıf etiketini aynı satırda sunarak eğitim veri yapısını somutlaştırmaktadır.

Sonuç olarak:

- X_{train} → Eğitim için öznitelik matrisi (63×25)
- y_{train} → Sınıf etiketi vektörü (63×1)

Olarak yapılandırılmış ve ECOC tabanlı SVM modelinin eğitimi için kullanılabilir hâle getirilmiştir. Bu yapı hem eğitim sürecinde hem de test aşamasında kullanılan scriptlerin tamamında (*build_model_linear_ecoc.m*, *predict_test_csv.m* vb.) standart bir referans sağlamaktadır.


3.7.2. Z-Skor Ölçekleme (Z-Score Standardization)

Makine öğrenmesi tabanlı sınıflandırma modellerinde kullanılan özniteliklerin farklı büyüklük ve birimlerde değerlere sahip olması, öğrenme sürecinde önemli bir dengesizlik oluşturabilmektedir. Sensör tabanlı çalışmalarda bu durum daha da belirgindir; örneğin *IAQ Proxy RMS* milyon mertebesinde değişirken, bağıl nemin standart sapması (*RH Std*) yalnızca birkaç birimlik aralıkta seyredebilir.

Bu tür ölçek farklılıkları giderilmediğinde, geniş aralıklı değişkenler sınıflandırma modelinin karar yapısını baskın biçimde etkilerken, dar aralıklı değişkenlerin katkısı görece azalır. Bu nedenle çalışmada tüm öznitelikler, modelleme aşamasına geçilmeden önce Z-Skor standardizasyonu ile ortak bir ölçeğe dönüştürülmüştür (Abdi ve Williams, 2010).

3.7.2.1. Z-Skor Standardizasyonunun Matematiksel Temeli

Z-Skor dönüşümü, bir özelliğin eğitim kümesindeki ortalama değerinden ne kadar uzaklaştığını, o özelliğin değişkenliğiyle karşılaştırarak ölçen bir normalizasyon yöntemidir (Abdi ve Williams, 2010).



Şekil 54. Ham Ölçekler ve Z-Skor Filtresi

Şekil 54 ‘teki görselde ölçek farklılığı olan değerlerin yeniden ölçeklendirildiğindeki durumları görülmektedir.

Bir x özelliği için Z-Skor aşağıdaki şekilde tanımlanır:

$$z = \frac{x - \mu}{\sigma} \quad (3.17)$$

Burada:

- x : İlgili örneğe ait ham özellik değeri,
- μ : Eğitim verisinde aynı özelliğin ortalaması,
- σ : Eğitim verisinde aynı özelliğin standart sapmasıdır.

Bu dönüşüm sonucunda her bir özellik, eğitim kümesi üzerinde:

- Ortalama değeri yaklaşık 0,
- Standart sapması yaklaşık 1

Olacak şekilde yeniden ölçeklendirilmiş olur. Böylece *IAQ Proxy RMS* gibi milyonluk değere sahip öznitelikler ile *RH Std* gibi küçük ölçekli öznitelikler, aynı büyüklük mertebesine getirilir ve SVM modeli tüm özelliklere karşı daha dengeli bir duyarlılık sergiler.

3.7.2.2. Eğitim Verisi Üzerinden μ ve σ Değerlerinin Hesaplanması

Z-Skor standardizasyonunun uygulanabilmesi için her bir özniteliğin eğitim kümesi üzerindeki ortalama (μ) ve standart sapma (σ) değerlerinin hesaplanması gerekmektedir. Bu çalışma kapsamında 63 örnekten oluşan eğitim kümesi ($N_{train} = 63$) kullanılmış ve tüm 25 öznitelik için bu iki temel istatistik ayrı ayrı elde edilmiştir.

- Özellik Ortalamasının (μ) Hesaplanması

Her bir özellik sütunu için ortalama değer aşağıdaki formülle hesaplanmıştır:

$$\mu_i = \left(\frac{1}{N}\right) \sum_{n=1}^{N_{train}} x_{n,i} \quad (3.18)$$

Burada:

- $N_{train}=63$ (eğitim örneği sayısı)
- $x_{n,i}$, n ’ inci örneğin i ’ inci özelliğini temsil eder.

Örneğin *IAQ_Mean* genel özelliği için:

$$\mu = \frac{(IAQ_meanGenel1 + IAQ_meanGenel2 + \dots IAQ_meanGenel63)}{63} \quad (3.19)$$

Bu işlem, tüm 25 öznitelik için ayrı ayrı gerçekleştirilmiş ve sonuçlar model dosyasında *scaler_Mean* (μ vektörü) olarak kaydedilmiştir.

- Standart Sapmanın (σ) Hesaplanması

Her bir özelliğin eğitim kümesi içerisindeki dağılım genişliğini temsil eden standart sapma ise şu formülle hesaplanmıştır:

$$\sigma_i = \sqrt{\left(\left(\frac{1}{N-1} \right) \sum_{n=1}^{N_{train}} (x_{n,i} - \mu_i)^2 \right)} \quad (3.20)$$

Bu işlem tüm öznitelikler için uygulanmış ve sonuçlar model dosyasında *scaler_Std* (σ vektörü) olarak saklanmıştır.

- Standardizasyonun Tahmin Sürecindeki Rolü

Doğrulama ve test verileri eğitim kümesi üzerinden hesaplanan μ ve σ değerleri kullanılarak normalize edilmiştir. Böylece:

- Eğitim verisi ile test verisi aynı ölçekte değerlendirilmiş,
- Ölçek farklılıklarının karar sınırını bozması engellenmiş,
- SVM'in marjin tabanlı yapısı daha kararlı hâle gelmiş,
- Modelin genelleme performansı artmıştır.

Bu yaklaşım, özellikle *IAQ Proxy RMS* gibi geniş aralıklı değerlerle *RH Std* gibi dar aralıklı değerlerin birlikte kullanıldığı bu çalışmada kritik bir ön işleme adımıdır.

3.7.2.3. Z-Skorun Bu Çalışmadaki Gerekliliği

Bu tez çalışmasında kullanılan temel özniteliklerin ölçek farkları oldukça belirgindir.

Örneğin:

- *IAQ Proxy RMS* → $4,7 \times 10^6$ büyüklüğünde olabilir.
- Nem Standart Sapması (*RH Std*) → yaklaşık 2,3 – 3,8 aralığında değişmektedir.

- Gaz Direnci Ortalaması (*Gas Mean*) → çoğu durumda 1000 – 2000 Ω aralığındadır.

Bu seviyelerdeki uyumsuzluklar giderilmediğinde:

- Model, *IAQ Proxy* gibi büyük genlikli özniteliklere aşırı ağırlık verir,
- *RH Std* gibi küçük ölçekli parametrelerin sınıflar arasındaki ayırt edici katkısı zayıflar,
- SVM karar sınırları tek veya birkaç baskın özelliğe doğru “çekilir”.

Z-Skor standardizasyonu bu sorunu gidererek:

- Özniteliklerin eşit ölçekte değerlendirilmesini,
- Karar sınırlarının daha kararlı öğrenilmesini,
- Modelin genelleme performansının artmasını,
- Aşırı uyum (*overfitting*) riskinin azalmasını sağlamıştır.

3.7.2.4. Z-Skor Standardizasyonu ile ECOC–SVM Etkileşimi

Z-Skorun Uygulanma Sürecinde aşağıdaki işlem hattı ile uygulanmıştır:

- Özellik çıkarımı

Her bir ölçüm oturumu için sıcaklık, nem, basınç, gaz direnci ve *IAQ Proxy* sinyallerinden 5 istatistiksel öznitelik (*Mean*, *Std*, *min*, *max*, *RMS*) hesaplanmış ve 25 boyutlu bir özellik vektörü elde edilmiştir.

- Eğitim kümesi üzerinden μ ve σ değerlerinin hesaplanması

Yalnızca 63 eğitim örneği kullanılarak her bir özellik için:

- Ortalama (μ)
- Standart sapma (σ)

Bu değerler hesaplanmış ve *scaler_Mean* ile *scaler_Std* vektörleri model dosyasında saklanmıştır. Bu işlem, veri sızıntısını engellemek için doğrulama ve test verisini içermez.

- Bütün veri kümelerinin Z-Skor ile normalize edilmesi

Tüm örnekler (eğitim, doğrulama, test), aşağıdaki formülle normalize edilmiştir:

$$z = (x - \mu)/\sigma \quad (3.21)$$

Bu dönüşüm:

- Büyük ölçekli IAQ RMS ile küçük ölçekli *RH Std*'nin aynı seviyede değerlendirilmesini,
 - SVM' in marjın tabanlı karar yüzeyinin daha kararlı kurulmasını sağlamıştır.
 - Normalize edilmiş verinin ECOC–SVM'e aktarılması
- Z-Skor sonrası elde edilen özellik vektörleri, ECOC yapısındaki üç ikili modele (1–2, 1–3, 2–3) giriş olarak verilmiş; karar sınırları bu ölçeklenmiş uzayda optimize edilmiştir.

Bu sayede model:

- Aşırı uyum riskini azaltmış,
- Daha dengeli karar yüzeyleri öğrenmiş,
- Üç sınıf arasındaki ayrımı daha başarılı biçimde gerçekleştirmiştir.

3.7.2.5. Sonuç ve Yöntemin Sağladığı Avantajlar

Bu çalışmada Z-Skor, yalnızca bir normalizasyon adımı değil, sınıflandırma performansını doğrudan etkileyen kritik bir bileşen hâline gelmiştir. Başlıca kazanımlar:

- Özellikler modele eşit önem düzeyinde sunulmuştur.
- ECOC yapısındaki ikili SVM modelleri daha geniş ve stabil marjınler öğrenmiştir.
- Farklı fiziksel büyüklüklere sahip sensör parametreleri tutarlı bir biçimde temsil edilmiştir.
- Küçük örneklem yapısına rağmen model yüksek genelleme başarısı göstermiştir.
- Karar sınırları daha açıklanabilir ve yorumlanabilir bir hâle gelmiştir.

Sonuç olarak SVM' in teorik marjın avantajı ile Z-Skor' un ölçek dengeleme etkisi birleşerek, çay kalitesinin sensör verileri temelinde güvenilir, kararlı ve açıklanabilir biçimde sınıflandırılmasını mümkün kılmıştır.

3.7.3. ECOC Tabanlı Çok Sınıflı SVM (fitcecoc)

Destek Vektör Makineleri (SVM) temelde iki sınıfı birbirinden ayırmak üzere tasarlanmış bir sınıflandırma yöntemidir. Ancak bu çalışmada olduğu gibi üç farklı kalite düzeyinin (1 = yüksek, 2 = orta, 3 = düşük) aynı anda sınıflandırılması gerektiğinde, SVM' in ikili yapısını çok sınıflı problemlere genelleyen ek bir mekanizmaya ihtiyaç duyulmaktadır. *MATLAB* ortamında bu gereksinimi karşılayan temel fonksiyon *fitcecoc* olup, çok sınıflı problemi otomatik olarak ikili alt modellere dönüştürerek çözer (MathWorks, 2024).


Bu tez kapsamında üç kalite sınıfı için *fitcecoc* fonksiyonu one-vs-one stratejisini kullanmış ve her sınıf çifti için ayrı bir SVM modeli eğitilmiştir (Tudu vd., 2005; Saha vd., 2012).:

- Model 1: 1 ↔ 2 (Yüksek – Orta kalite)
- Model 2: 1 ↔ 3 (Yüksek – Düşük kalite)
- Model 3: 2 ↔ 3 (Orta – Düşük kalite)

Bu yapı, *Error-Correcting Output Codes* (ECOC) çerçevesinde gerçekleştirilmiştir. ECOC yaklaşımı, her ikili alt modelin kararını bir kodlama matrisi üzerinden temsil eder; tahmin aşamasında bu kodlar test örneğinin hangi sınıfa en yakın olduğunu belirlemek için birlikte değerlendirilir. Böylece:

- Her alt model yalnızca kendi iki sınıfını ayırmaya odaklanır,
- Karar sınırları daha net ve keskin öğrenilir,
- Tahmin aşamasında üç alt modelden gelen karar skorları ECOC çözümleyici tarafından birleştirilerek en olası sınıf etiketi elde edilir.


Bu sürecin genel işleyiş şematik olarak Şekil 55'te gösterilmiştir:



Şekil 55. Üç Sınıflı Problemin fitcecoc ECOC Yöntemiyle Çözümleme Akışı

Şekil 55’te Sınıf etiketleri → ECOC kodlama matrisi → 1–2, 1–3, 2–3 ikili SVM modelleri → ECOC çözümleyici → Nihai sınıf kararı işlem sırası gösterilmiştir.


SVM, her bir ikili sınıflandırma probleminde iki sınıfı en iyi şekilde ayıran kararlı bir karar yüzeyi (*decision boundary*) öğrenmeyi hedefler.



Şekil 56. Sınıflar Arası Karar Düzlemi

Şekil 56’da görselde özellik uzayında kümelenme ve karar düzleminin bir örneği gösterilmiştir.

Bu karar yüzeyi, çok boyutlu özellik uzayında bir hiper düzlem olarak tanımlanır ve modelin yeni bir örneği hangi sınıfa daha yakın konumlandıracağı bu hiper düzlem üzerinden belirlenir.



Şekil 57. Üç Sınıflı Bir Problemin İkili SVM Alt Modellerine Ayrılması

Şekil 57’de üç sınıflı bir kalite probleminin *fitcecoc* yaklaşımı ile ikili SVM alt modellerine ayrılmasını ve bu alt modellerden elde edilen kararların ECOC çözücü mekanizması aracılığıyla birleştirilerek nihai sınıf kararının oluşturulmasını göstermektedir. Genel formda bir SVM karar fonksiyonu:

$$sk = w.z + b \quad (3.22)$$

Şeklinde ifade edilebilir. Burada z , Z-skor ile ölçeklenmiş özellik vektörünü; w ve b ’inci ikili modele ait ağırlık vektörü ve *bias* terimini temsil etmektedir.

- $|wk_i|$ değerinin büyük olması, i ’inci özelliğin o alt modeldeki ayırt edici gücünün yüksek olduğuna işaret eder.
- *Bias* terimi b , hiper düzlemin özellik uzayı içindeki konumunu belirler.

Bu tezde SVM’ in karar sınırları, tüm özelliklere Z-skor standardizasyonu uygulandıktan sonra öğrenilmiştir. Böylece *IAQ Proxy RMS*, gaz direnci ortalaması ve nem standart sapması gibi farklı ölçeklerdeki değişkenler ortak bir ölçekte değerlendirilmiş; özelliklerin modele katkısı daha dengeli hâle gelmiş ve karar yüzeyleri daha istikrarlı bir yapıya kavuşmuştur. ECOC tabanlı üç ikili yapı (1–2, 1–3, 2–3) için her alt model kendi sınıf çiftine özel karar sınırı öğrenir; bu alt hiper

düzlemler ECOC çözümlemesi ile bir araya getirilerek üç kalite sınıfını aynı anda ayırabilen bütüncül bir karar alanı oluşturur.

Bu bütünleşik yapı sayesinde *fitcecoc*, SVM' in ikili sınıflandırma kapasitesini genişleterek üç kalite grubunun güvenilir şekilde ayrıştırılmasını sağlamış; model hem kuramsal temeli güçlü hem de açıklanabilir bir sınıflandırma mekanizması sunmuştur.

3.7.4. Softmax ile Olasılık Dönüşümü ve Sınıf Tahmini

ECOC–SVM modeli tarafından üretilen karar skorları (örneğin s_1, s_2, s_3), çok sınıflı yapının her bir ikili alt modeli için hesaplanan margin skorlarıdır. Bu skorlar modelin bir örneği hangi sınıfa yakın gördüğünü belirtse de:

- Doğrudan bir olasılık değildir,
- Ölçekleri sınıflar arasında değişebilir,
- Toplamları anlam taşımaz.

Bu nedenle sınıf kararının daha yorumlanabilir, karşılaştırılabilir ve güven seviyesini yansıtan bir gösterime dönüştürülmesi gereklidir. Bu dönüşüm için bu tezde Softmax fonksiyonu kullanılmıştır (Platt, 1999).

Softmax formülü:

$$P(y = i/z) = \left(\frac{e^{(s_i)}}{\sum_{j=1}^M e^{(s_j)}} \right) \quad (3.23)$$

Burada:

s_i : i. sınıf için modelin ürettiği karar skoru

e^{s_i} : bu skorun üstel değeridir (pozitif hale getirir, büyüklük farklarını güçlendirir)

$\sum_{j=1}^M e^{(s_j)}$: tüm sınıfların üstel skorlarının toplamıdır (payda $\rightarrow$ normalizasyon)

$P(y = i/z)$: test verisinin (özellikler z) i. sınıfa ait olma olasılığıdır.

Bu işlem sonucunda her sınıf için üç ayrı olasılık elde edilir:

$$1. \text{Kalite olasılığı } P1 = \left(\frac{e^{(s_1)}}{e^{(s_1)} + e^{(s_2)} + e^{(s_3)}} \right) \quad (3.24)$$

$$2. \text{Kalite olasılığı } P2 = \left(\frac{e^{(s_2)}}{e^{(s_1)} + e^{(s_2)} + e^{(s_3)}} \right) \quad (3.25)$$

$$3. \text{Kalite olasılığı } P3 = \left(\frac{e^{(s_3)}}{e^{(s_1)} + e^{(s_2)} + e^{(s_3)}} \right) \quad (3.26)$$

Bu olasılıkların toplamı daima 1'dir.

Böylece:

$$y = \arg \max \{P1, P2, P3\} \quad (3.27)$$

- Her sınıf aynı ölçekte değerlendirilebilir,
- Modelin her sınıfa yönelik güveni sayısal olarak ifade edilir,
- Nihai tahmin en yüksek olasılığa sahip sınıf olarak belirlenir.

3.7.4.1. Sınıf Olasılıklarının Yorumlanması

Ribeiro ve arkadaşları (2016) tarafından önerilen LIME yaklaşımına benzer şekilde, bu çalışmada da model kararları açıklanabilir hale getirilmiştir.

Softmax çıktıların yorumlarken temel ilkeler şunlardır:

- Olasılık dağılımının şekli modelin güvenini gösterir
Örnek:
 - $P1=0.90$, $P2=0.07$, $P3=0.03$
 - Model çokyüksek güvenle Sınıf 1'i seçmiştir.
 - $P1=0.40$, $P2=0.35$, $P3=0.25$
 - Sınıflar arası fark küçük $\rightarrow$ belirsizlik yüksek, VOC tepkileri birbirine yakın olabilir.

- ECOC-SVM karar skorları Softmax ile kuvvetlendirilmiş olur

Örneğin bir test örneği için:

- 1-2 modeli skoru pozitif $\rightarrow$ Sınıf 1'e yakın
- 1-3 modeli skoru pozitif $\rightarrow$ Sınıf 1'e yakın
- 2-3 modeli skoru negatif $\rightarrow$ Sınıf 3'e uzak, Sınıf 2'ye yakın

Bu üç skor Softmax'a girdiğinde, model:

- Hangi sınıfa daha yakın olduğunu,
- VOC profilinin hangi sınıf davranışıyla örtüştüğünü

Sayısal olarak ifade eder.

- Olasılıkların dengeli olması sınıflar arası benzerliği gösterir

Özellikle orta kalite sınıfı (S2), hem S1 hem S3'e yakın davranış sergileyebildiğinden, Softmax çıktıları bazı durumlarda:

$$P1 \approx P2 \quad \text{veya} \quad P2 \approx P3$$

Şeklinde olabilir.

Bu durum sensör verilerinin:

- Gaz direnci,
- IAQ değişimi,
- Nem varyansı

Gibi parametrelerde sınıflar arası yaklaşma gösterdiğini işaret eder.

3.7.4.2. Nihai Tahminin Oluşturulması

Softmax sonrası sınıflandırma kararı şu adımlarla verilir:

- Adım 1 – Test verisi Z-Skor ile normalize edilir

$$z = (x - \mu) / \sigma \quad (3.29)$$

- Adım 2 – ECOC–SVM modelleri üç ayrı karar skoru üretir

$$s=[s1-2, s1-3, s2-3] \quad (3.30)$$

- Adım 3 – Bu skorlar Softmax fonksiyonu ile olasılıklara dönüştürülür

$$P1, P2, P3 \quad (3.31)$$

- Adım 4 – Olasılık dağılımı yorumlanır
 - Yüksek fark → güçlü sınıf ayrımı
 - Yakın değerler → VOC davranışı belirsiz
- Adım 5 – En yüksek olasılık seçilerek nihai kalite tahmini yapılır

$$y = \arg \max \{P1, P2, P3\} \quad (3.32)$$

Bu yapı sayesinde model yalnızca bir sınıf etiketi üretmekle kalmaz; aynı zamanda tahminin:

- Güçlü mü,
- Zayıf mı,
- Kararsız mı,
- Hangi alt modeller tarafından desteklendiğini ayrıntılı biçimde analiz edilebilir hâle getirir.

Bu yaklaşım, sensör tabanlı çay kalite tahmini sisteminde açıklanabilir yapay zekâ (XAI) boyutunu sağlayan en önemli bileşenlerden biridir.

4. BULGULAR VE YORUMLAR

Bu bölümde, *BME688* sensörü kullanılarak elde edilen zaman serisi verileri üzerinden geliştirilen makine öğrenmesi tabanlı kalite sınıflandırma modelinin doğrulama ve test sonuçları sunulmaktadır. Modelin farklı veri kümeleri üzerindeki performansı, sınıf bazlı doğruluk değerleri, karışan sınıflar ve elde edilen karar skorları üzerinden değerlendirilmiştir. Ayrıca modelin kararlılığı, genellenebilirliği ve kimyasal kalite referanslarıyla olan uyumu yorumlanarak sensör tabanlı yaklaşımın geçerliliği tartışılmıştır.

4.1. Zaman Serisi Verilerinin Yapısal Analizi

Box vd. (2015) tarafından belirtildiği üzere bir zaman serisinin örnekleme yapısı analizin temelini oluşturmaktadır. Çay numunelerinden elde edilen sensör verilerinin zaman boyutundaki yapısal özellikleri ayrıntılı olarak incelenmiştir. *BME688* sensörü tarafından üretilen çok kanallı zaman serisi verileri, kalite sınıflandırma sürecinde kullanılan özniteliklerin temelini oluşturduğundan, öncelikle bu verilerin örnekleme karakteristikleri, veri yoğunluğu ve kanal bazlı davranışları analiz edilmiştir.

Zaman serisi analizinin amacı, ölçüm sürecinin teknik tutarlılığını ortaya koymak ve sensörün zamana bağlı veri üretim davranışının güvenilirliğini değerlendirmektir. Bu kapsamda; örnekleme frekansı, ölçüm periyodu, ham verinin zamansal sürekliliği ve çok kanallı yapıdaki senkronizasyon durumu nicel olarak ele alınmıştır.

Elde edilen bulgular, sensör verilerinin yalnızca anlık ölçümlerden ibaret olmadığını; aksine, çay numunelerinden yayılan uçucu organik bileşiklerin (VOC) zamana bağlı dinamiklerini temsil eden, yüksek çözünürlüklü ve tekrarlanabilir bir zaman serisi yapısına sahip olduğunu göstermektedir. Bu yapısal analiz, izleyen bölümlerde gerçekleştirilen öznitelik çıkarımı ve sınıflandırma çalışmalarının sağlam bir veri temeline dayandığını ortaya koymaktadır.

4.1.1. Zaman Serisinin Örnekleme Yapısı

Bu çalışmada kullanılan her bir çay numunesi, *BME688* sensörünün sekiz farklı algılayıcı kanalından elde edilen, yüksek çözünürlüklü zaman serisi

Verilerinden oluşmaktadır. Sensör; sıcaklık, bağıl nem, basınç, gaz direnci ve IAQ türevi parametreleri kısa zaman aralıklarıyla kaydederek ölçüm yapmaktadır.

Zaman serisi yapısının nicel olarak incelenmesi amacıyla, 90_CAY_A5(2) deney setine ait ölçümler zaman damgaları üzerinden değerlendirilmiştir. İlgili ölçüm dosyasında:

- Toplam veri sayısı:

$$N = 7.744$$

- Benzersiz zaman damgası sayısı:

$$Z = 5.588$$

Ölçüm sürecinin toplam süresi (t) dikkate alınarak, sensörün etkin örnekleme frekansı (f_s) Denklem 4.1 ile hesaplanmıştır:

$$f = \frac{N}{Z} = \frac{7.744}{5.588} = 1.387Hz \quad (4.1)$$

Buna karşılık, iki ardışık örnek arasındaki veri üretim periyodu (T_s) ise Denklem 4.2'deki gibi elde edilmiştir:

$$T = \frac{1}{f} = 0.72 s \quad (4.2)$$

Olarak elde edilmiştir. Bu sonuç, sensörün yaklaşık her 0,72 saniyede bir veri ürettiğini göstermektedir.

4.1.2. Ham Zaman Serisi Verisinin Yapısal İncelenmesi

BME688 sensörü tarafından üretilen ham zaman serisi verisinin ilk satırlarına ilişkin örnek değerler aşağıda sunulmuştur.

Tablo 23. BME688 Sensörden Elde Edilen Ham Zaman Serisi Verisinin Satırları

Sensor_indeksi	Gerçek zaman saati	Sıcaklık_C	Basınç_hPa	Nem_RH
1	1751562939	37.16	1013.23	28.99
...	...	...	...	...
7743	1751566041	43.01	1014.01	15.45
7744	9580297	1751566061	42.99	1013.91

Tablo 23'te BME688 sensörünün çalışma sırasında ürettiği ham verinin ilk satırları örnek olarak sunulmakta; sensör indeksleri, zaman damgaları ve temel ölçüm parametrelerinin (sıcaklık, basınç, nem) ham halleri gösterilmektedir.

Zaman damgalarının ardışık ilerlemesi, sensörün kararlı bir ölçüm döngüsüyle çalıştığını göstermektedir.

4.1.3. Çok Kanallı Zaman Serisi Davranışı

Aynı deney koşullarında *BME688* sensörünün 0–7 numaralı alt kanallarına ait toplam satır sayıları, benzersiz zaman damgaları, örnekleme frekansları ve periyot değerleri Tablo 24’te özetlenmiştir.


Tablo 24. BME688 Sensör 8 Kanala ait Örnekleme Sayıları ve Frekansları

Sensör	Satır Sayısı	Benzersiz Saniye	Frekans (Hz)	Periyot (s)
0	950	691	1.37	0.72
1	973	707	1.37	0.72
2	983	705	1.39	0.71
3	956	693	1.37	0.72
4	973	701	1.38	0.72
5	964	698	1.38	0.72
6	952	688	1.38	0.72
7	993	705	1.40	0.71
GENEL	7744	5888	1.38	0.71

Tablo 24’te aynı deney koşullarında çalışan *BME688* sensörünün 0–7 numaralı alt kanalları için toplam satır sayıları, benzersiz zaman damgaları, hesaplanan örnekleme frekansları ve periyot değerleri genel olarak kararlı ve tutarlı bir yapı sergilediği görülmüştür (Janacek, 2001).

4.1.4. Örnekleme Frekansının Dağılımı ve Yorumlanması

Tüm sensör kanallarında örnekleme frekansının 1,36–1,40 Hz. aralığında değiştiği ve genel ortalamanın 1,378 Hz. olduğu görülmektedir. Bu homojen dağılım, sensör kanalları arasında belirgin bir senkronizasyon sağlandığını ve ölçüm sürecinin teknik olarak tutarlı olduğunu göstermektedir (Hyndman ve Athanasopoulos, 2018).



Şekil 58. BME688 Sensör Örnekleme Frekansı ve Periyot Değerleri

Şekil 58’de, *BME688* sensörünün sekiz alt kanalına ait hesaplanan örnekleme frekansı (Hz) ve periyot (saniye) değerlerinin grafiksel dağılımı sunulmaktadır.

4.2. Özellikler ve Sınıf Davranışlarının İncelenmesi

Chatfield'a (2003) göre, zaman serisi verilerinden türetilen istatistiksel öznitelikler sınıflandırma sürecinde ayırt edici potansiyele sahiptir. Zaman serisi verilerinden türetilen istatistiksel özniteliklerin kalite sınıfları açısından nasıl bir davranış sergilediği incelenmiştir. Ham zaman serisi verilerinin yapısal özellikleri bir önceki bölümde ortaya konduktan sonra, bu verilerden elde edilen özniteliklerin sınıflandırma sürecindeki ayırt edici potansiyeli değerlendirilmiştir.

Analiz kapsamında, *IAQ Proxy*, gaz direnci ve bağıl nem sinyallerinden hesaplanan özniteliklerin sınıf bazlı dağılımları ele alınmış; bu parametrelerin farklı kalite seviyelerine karşılık gelen davranış farklılıkları karşılaştırmalı olarak incelenmiştir. Böylece, sensör verilerinden türetilen özniteliklerin yalnızca sayısal birer değer değil, çay numunelerinin fiziksel ve kimyasal özelliklerini yansıtan anlamlı göstergeler olduğu ortaya konmuştur.

Bu bölümde sunulan bulgular, izleyen alt başlıklarda detaylandırılan model doğrulama ve performans analizlerinin yorumlanması için temel bir referans çerçevesi

oluşturmakta; sınıflandırma sonuçlarının hangi veri davranışlarına dayandığını açıklayıcı biçimde desteklemektedir.

4.2.1. Sınıf Bazlı Öznitelik Dağılımları

BME688 sensöründen elde edilen yüksek çözünürlüklü zaman serisi verileri, kalite sınıflandırma sürecinde doğrudan kullanılmamış; bu verilerden istatistiksel öznitelikler türetilerek modelleme aşamasına aktarılmıştır. Zaman serisinin yaklaşık 0,72 saniyelik örnekleme periyodu ile üretilmesi, *IAQ Proxy*, gaz direnci ve bağıl nem sinyallerinin zamana bağlı değişimlerinin yeterli ayrıntıyla temsil edilmesini sağlamıştır (Bosch Sensortec, 2021).

Bu zaman serilerinden elde edilen öznitelikler (ortalama, standart sapma, RMS, minimum ve maksimum değerler), her bir çay numunesi için sınıfa özgü karakteristik dağılımlar oluşturmuştur. Ölçüm sürecinin tüm sensör kanallarında 1,36–1,40 Hz. aralığında kararlı bir örnekleme hızına sahip olması, bu özniteliklerin farklı ölçüm oturumları arasında karşılaştırılabilir olmasını mümkün kılmıştır.

Bu bağlamda, sınıf bazlı öznitelik dağılımları; ölçüm sürecinin teknik tutarlılığı sayesinde, zaman serisi kaynaklı rastgele dalgalanmalardan ziyade çay numunesine özgü VOC salınım davranışlarını yansıtan bir yapı sunmaktadır.

4.2.2. IAQ, Gaz Direnci ve Nem Davranışlarının Karşılaştırılması

Yaklaşık 0,72 saniyelik ölçüm periyodu, sensörün çay numunesinden yayılan uçucu organik bileşiklere (VOC) ilişkin kısa süreli değişimleri yakalayabilmesini mümkün kılmaktadır. Bu durum, IAQ türevi parametreler, gaz direnci ve bağıl nem sinyallerinin zaman içerisindeki eğrilerinin birlikte değerlendirilmesine olanak sağlamıştır.

Zaman serisi boyunca IAQ, gaz direnci ve nem sinyallerinin birlikte incelenmesi, ölçüm sürecinde sensörün çevresel koşullara verdiği tepkinin yanı sıra çay numunesine özgü davranışların da izlenebilmesini sağlamıştır. Sensörün bu hızda çalışırken ısı dengesini koruyabilmesi, ölçümlerin kararlılığını artırmış ve elde edilen özniteliklerin sınıflandırma açısından güvenilirliğini pekiştirmiştir. (Bosch Sensortec, 2021).

Bu davranışların birlikte değerlendirilmesi, IAQ ve gaz direnci temelli özniteliklerin kalite sınıfları arasında ayırt edici bilgi taşıdığını; nem sinyalinin ise bu ayırımın destekleyici bir parametresi olarak rol oynadığını göstermektedir.

4.2.3. Bulguların Ön Değerlendirmesi

Zaman serisi analizine ilişkin bulgular, *BME688* sensörünün tüm ölçüm oturumlarında yüksek tekrarlanabilirlik ve kararlı çalışma davranışı sergilediğini ortaya koymuştur (Yang vd., 2020). Sekiz alt kanalın tamamında örnekleme frekanslarının birbirine yakın değerler göstermesi, ölçüm sisteminin senkronize ve tutarlı bir yapıda çalıştığını doğrulamaktadır.

Bu teknik kararlılık, *IAQ Proxy*, gaz direnci ve bağıl nem sinyallerinden türetilen özniteliklerin güvenilirliğini doğrudan etkilemiş; sınıflandırma sürecinde kullanılan veri setinin yapısal sağlamlığını artırmıştır. Özellikle yaklaşık 0,72 saniyelik ölçüm periyodu, VOC salınımındaki kısa süreli değişimlerin yakalanmasına olanak tanıyarak kalite sınıfları arasındaki farkların daha net biçimde temsil edilmesini sağlamıştır.

Elde edilen bu bulgular, izleyen bölümlerde sunulacak olan model doğrulama ve performans analizleri için sağlam bir veri temeli oluşturmakta; zaman serisi kaynaklı özniteliklerin sınıflandırma başarısına anlamlı katkı sunduğunu göstermektedir.

4.3. Model Doğrulama Sonuçları

Bu bölümde, geliştirilen veri temelli sınıflandırma modelinin doğrulama ve test veri kümeleri üzerindeki performansı nicel ölçütler kullanılarak değerlendirilmiştir. Sunulan sonuçlar, modelin farklı kalite sınıflarını ayırt etme başarısını, kararlılığını ve genelleme yeteneğini ortaya koymayı amaçlamaktadır. Bu kapsamda doğruluk oranları, sınıf bazlı başarılar, karışıklık matrisleri ve olasılık temelli çıktı dağılımları incelenmiş; yöntemsel ayrıntılara girilmeden yalnızca elde edilen çıktılar teknik açıdan yorumlanmıştır.

4.3.1. Doğrulama Verisi Üzerindeki Model Performansı

Modelin genelleme yeteneğinin ve hiperparametre seçimlerinin nesnel bir şekilde değerlendirilebilmesi için, toplam veri setinin %15'ine denk gelen 15 bağımsız

örnekten oluşan bir doğrulama (*validation*) kümesi ayrılmıştır. Bu kümenin sınıf bazında dengeli dağılımı Tablo 21 ' de verilmektedir.

Doğrulama kümesi üzerinde, doğrusal çekirdek fonksiyonu ve $C=1.0$ düzenleme (*regularization*) parametresi ile yapılandırılan SVM Modelin doğrulama kümesi üzerindeki performansı yüksek bulunmuştur. Modelin, eğitim sürecinde hiç görmediği bu veri kümesi üzerinde sergilediği yüksek sınıflandırma başarısı, önemli bir bulgu olarak öne çıkmaktadır. Bu sonuç, modelin eğitim verisine aşırı uyum sağlamadığını (*overfitting*) ve öğrenmiş olduğu kalıpları yeni, görülmemiş örneklerle başarıyla genelleyebildiğini göstermektedir (James vd., 2013).

Doğrulama aşamasının bir diğer kritik çıktısı ise hiper parametre optimizasyonu üzerinedir. Farklı C parametre değerlerinin ($C=0.1$, $C=100$) doğrulama kümesi üzerindeki performansları karşılaştırılmış ve Doğrulama sonuçlarında, en dengeli performansın $C=1.0$ değerinde elde edildiği görülmüştür (Vapnik, 1995). Bu bulgu, seçilen hiper parametre kombinasyonunun, model karmaşıklığı ile genelleme kapasitesi arasında optimum dengeyi kurduğuna işaret etmektedir.

Ayrıca, doğrulama sürecinin güvenilirliği, eğitim verisinden hesaplanan *Z-Skor* standardizasyon parametrelerinin (ortalama ve standart sapma) doğrulama kümesine aynen uygulanmasıyla sağlanmıştır. Bu yaklaşım, eğitim ve doğrulama aşamalarının aynı ölçeklendirilmiş özellik uzayında gerçekleşmesini garanti ederek, performans değerlendirmesinin tutarlılığını ve nesnelliğini artırmıştır.

Doğrulama performansı, nihai modelin bağımsız test kümesi üzerindeki yüksek başarısının da güçlü bir ön göstergesi olmuş ve bu durum, modelin bağımsız test kümesi için güçlü bir ön gösterge sunduğunu göstermektedir.

4.3.2. Hiperparametre Optimizasyonu ve Model Kararlılığı Sağlanması

Bir makine öğrenmesi modelinin nihai başarısı, yalnızca mimarisiyle değil, öğrenme sürecini yöneten hiper parametrelerin optimal seçimiyle doğrudan ilişkilidir. Hiperparametre optimizasyonu sonucunda elde edilen doğrulama performansları, modelin kararlılığını ve genelleme yeteneğini açık biçimde ortaya koymuştur.


Optimizasyon sürecinde, doğrusal çekirdek yapısı altında Düzenlileştirme Parametresi (C) ve Çekirdek Türü (*kernel*) üzerine odaklanılmıştır.

- C Parametresi (Düzenleme Parametresi) Optimizasyonu:

C parametresi, modelin eğitim verisindeki bireysel örnekleri ne ölçüde "cezalandıracağını" kontrol eder ve bu da modelin karmaşıklığı ile genelleme kapasitesi arasındaki dengeyi doğrudan belirler. Doğrulama kümesi üzerinde farklı C değerleri karşılaştırıldığında, farklı C değerlerinin model davranışı üzerindeki etkisini net bir şekilde ortaya koymuştur:

- C= 0.1: Daha geniş bir marjın oluşturarak modele genelleme esnekliği sağlamış, ancak bazı sınır örneklerde yanlış sınıflandırmalara yol açmıştır.
- C = 100: Aşırı dar bir marjın oluşturmuş, modelin eğitim verisindeki gürültüye ve ayrıntılara aşırı hassasiyet göstermesine neden olarak doğrulama performansında düşüşe işaret eden belirgin bir aşırı öğrenme eğilimi yaratmıştır.
- C = 1.0: Hem eğitim hem de doğrulama kümelerinde en dengeli performansın C=1.0 değerinde elde edildiği görülmüştür (Hsu vd., 2003). Bu değer, model karmaşıklığı ile genelleme yeteneği arasında optimum dengeyi kurmuş ve nihai model için seçilmiştir.

Aşağıdaki şekil, farklı C değerlerinin SVM' in karar sınırı üzerindeki etkisini şematik olarak özetlemektedir:



Şekil 59. C Parametresinin SVM Karar Sınırına Etkisi

Şekil 59’da $C=1$ değerinin, aşırı uyumu ($C=100$) ve aşırı basitleştirmeyi ($C=0.1$) önleyerek en uygun karar sınırını nasıl sağladığını görsel olarak doğrulamaktadır.

- Çekirdek Türü Seçimi ve Fiziksel Yorumu:

Çekirdek fonksiyonu seçimi, SVM' in doğrusal olmayan veri yapılarını modelleme kapasitesini belirler (Cortes ve Vapnik, 1995). Bu çalışmada, RBF (*Radial Basis Function*) ve polinom gibi doğrusal olmayan çekirdekler denenmiş, ancak doğrusal çekirdek (*linear kernel*) ile en iyi doğrulama performansının elde edildiği gözlemlenmiştir.

- Bu bulgu, son derece anlamlıdır:

Z-Skor standardizasyonu sonrasında, BME688 sensöründen çıkarılan özniteliklerin (IAQ Proxy RMS, Gaz Direnci Ortalaması, Nem Standart Sapması) üç kalite sınıfını doğrusal olarak ayrılabilir bir uzayda konumlandığını göstermektedir. Doğrusal çekirdeğin seçilmesi, yalnızca hesaplama verimliliğini artırmakla kalmamış, aynı zamanda modelin karar sınırlarının fiziksel olarak yorumlanabilirliğine de katkıda bulunmuştur. Bu durum, her bir sensör parametresinin kalite sınıfına yaptığı katkının ağırlık vektörü (w) üzerinden daha net anlaşılabilmesine olanak tanımıştır.

- Hiper parametre optimizasyon süreci:

$C=1.0$ ve Doğrusal Çekirdek kombinasyonunun, bu spesifik sensör tabanlı çay sınıflandırma problemi için en uygun yapılandırma olduğunu kesin olarak göstermiştir. Bu seçim, modelin yüksek genelleme performansı göstermesinin altında yatan temel faktörlerden biridir. Elde edilen bulgular, karmaşık doğrusal olmayan çekirdeklerin her zaman daha iyi sonuç vermediğini; verinin doğasına uygun, sade ve yorumlanabilir bir modelin hem yüksek doğruluk hem de pratik uygulanabilirlik sunduğunu göstermektedir.

4.4. Nihai Modelin Eğitimi ve Değerlendirme Yaklaşımı

Bu bölümde, doğrulama süreci tamamlandıktan sonra tam veri kümesi kullanılarak eğitilen nihai modelin elde ettiği sonuçlar ve bu sonuçların kararlılığı incelenmiştir. Modelin eğitim sonrası davranışı hem bağımsız test performansı hem de karar mekanizmasının güvenilirliği açısından değerlendirilmiştir.

Bu çalışmada, klasik anlamda bağımsız bir test kümesi üzerinden doğruluk hesaplanmamış; bunun yerine, kalite etiketi bilinen çay ürünlerinin farklı zamanlarda elde edilen ölçümleri kullanılarak, modelin ürün bazlı karar tutarlılığı analiz edilmiştir.

4.4.1. Tam Veri Kümesi ile Eğitilen Nihai Modelin Oluşturulması

Optimum hiper parametreler belirlenmesinin ardından, ECOC tabanlı SVM sınıflandırma modeli, mevcut tüm etiketli veriler kullanılarak yeniden eğitilmiştir. Bu aşamada, önceki adımlarda ayrı ayrı kullanılan eğitim ve doğrulama kümeleri birleştirilmiş ve toplam 78 örnekten oluşan genişletilmiş bir veri kümesi elde edilmiştir. Modelin bu birleşik veri seti üzerinde yeniden eğitilmesi, sınıflar arasındaki karar sınırlarının daha dengeli ve kararlı biçimde öğrenilmesini amaçlamaktadır (Hastie vd., 2009).

Bu yaklaşımın temel motivasyonu, modelin sınıflandırma doğruluğunu bağımsız bir test kümesi üzerinden yeniden ölçmek değil; karar mekanizmasını mümkün olan en sağlam ve kararlı hâle getirerek, sonraki aşamada gerçekleştirilecek ürün bazlı karar tutarlılığı analizine uygun bir zemin oluşturmaktır. Bu nedenle, model eğitimi sonrasında klasik anlamda bir doğruluk (*accuracy*) değerlendirmesi yapılmamış; modelin başarımı, farklı zamanlarda elde edilen ölçümler üzerinde sergilediği karar istikrarı üzerinden incelenmiştir.

Nihai modelde kullanılan çok sınıflı yapı, ECOC (*Error-Correcting Output Codes*) çerçevesi aracılığıyla oluşturulmuştur (Dietterich ve Bakiri, 1995). Bu yapı, her bir kalite sınıfını temsil eden ikili SVM alt modellerinin çıktılarının bütüncül biçimde değerlendirilmesine olanak tanımakta ve özellikle sınıflar arası sınır bölgelerinde daha gürbüz (*robust*) kararlar üretilmesini sağlamaktadır (Cortes ve Vapnik, 1995). Modelin dayandığı ECOC kodlama matrisi Tablo 14 'te sunulmuştur.

Eğitim sürecinde elde edilen karar skorlarının yapısal analizi, özellikle Sınıf 1 (Yüksek Kalite) ile Sınıf 3 (Düşük Kalite) arasındaki ayrımın belirgin olduğunu; Sınıf 2 (Orta Kalite) çevresinde ise daha geçişken bir karar bölgesinin oluştuğunu göstermektedir. Bu durum, orta kalite sınıfının VOC profili açısından iki uç kalite grubu arasında konumlanmasıyla uyumludur ve ilerleyen bölümlerde sunulacak olan ürün bazlı karar tutarlılığı analizinin yorumlanması açısından önemli bir bağlam oluşturmaktadır.

4.4.2. Eğitim Sonuçlarına Dayalı Yapısal Kararlılık Analizi

Nihai modelin davranışının daha derinlemesine incelenebilmesi amacıyla, bu bölümde yalnızca sınıf etiketlerine dayalı sonuçlar değil; modelin çok sınıflı karar mekanizmasını oluşturan karar skorlarının yapısal özellikleri ve sınıflar arası ayırım davranışı analiz edilmiştir. Bu analiz, modelin hangi sınıf çiftlerinde daha belirgin karar sınırları oluşturduğunu ve hangi durumlarda sınıf sınırlarına daha yakın kararlar ürettiğini ortaya koymayı amaçlamaktadır.

ECOC (*Error-Correcting Output Codes*) çerçevesi altında yapılandırılan modelde, her bir örnek için üç farklı ikili SVM alt modelinden elde edilen karar skorları birlikte değerlendirilmektedir. Bu skorların büyüklüğü ve dağılımı, modelin sınıflar arasındaki ayırım gücü ve karar güvenilirliği hakkında doğrudan bilgi sunmaktadır (Platt, 1999).

Karar skorlarının analizi, özellikle Sınıf 1 (Yüksek Kalite) ile Sınıf 3 (Düşük Kalite) arasındaki ikili karşılaştırmalarda, skorların mutlak değerlerinin yüksek ve birbirinden belirgin biçimde ayrıştığını göstermektedir. Bu durum, modelin bu iki uç kalite sınıfını ayırt etmede yapısal olarak kararlı ve güvenilir bir karar mekanizmasına sahip olduğunu ortaya koymaktadır.

Buna karşılık, Sınıf 2 (Orta Kalite)'yi içeren ikili karşılaştırmalarda (1–2 ve 2–3), karar skorlarının mutlak değerlerinin görece daha düşük olduğu ve bazı durumlarda sınıf sınırına yakın değerler ürettiği gözlemlenmiştir. Bu bulgu, orta kalite sınıfının, uç kalite sınıflarına kıyasla daha geçişken ve heterojen bir özellik sergilediğini düşündürmektedir. Bununla birlikte, ECOC yapısının sağladığı karar birleştirme mekanizması sayesinde, bu sınır durumların modelin nihai karar yapısını bozacak düzeyde bir kararsızlığa yol açmadığı görülmektedir (Allwein vd., 2000).

Bu bölümde sunulan yapısal analiz, modelin karar mekanizmasının hangi sınıflarda daha kararlı, hangi sınıflarda ise daha hassas olduğunu ortaya koymakta ve ilerleyen bölümde gerçekleştirilecek olan ürün bazlı tahmin tutarlılığı analizinin (90 CSV) metodolojik temelini oluşturmaktadır. Böylece, modelin farklı zamanlarda elde edilen ölçümler üzerindeki davranışı, yalnızca sonuç etiketleri üzerinden değil, karar skorlarının yapısal özellikleri üzerinden de anlaşılabilmektedir.

4.5. Ürün Bazlı Tahmin Tutarlılığı ve Kararlılık Analizi (90 .csv)

Bu bölümde, eğitimi tamamlanmış ECOC tabanlı SVM sınıflandırma modelinin performansı, klasik anlamda bağımsız bir test kümesi üzerinden doğruluk hesaplamaya dayalı olarak değil; kalite etiketi bilinen çay ürünlerinin farklı zamanlarda elde edilen ölçümleri üzerinden sergilediği karar tutarlılığı açısından değerlendirilmiştir. Bu yaklaşım, sensör tabanlı ölçümlerde zamanla oluşabilecek doğal varyasyonların, modelin karar davranışı üzerindeki etkisini incelemeyi amaçlamaktadır (Gardner ve Bartlett, 1994).

Analiz kapsamında, her biri aynı kalite sınıfına ait olmak üzere farklı zamanlarda elde edilmiş toplam 90 adet test .csv verisi kullanılmıştır. Bu veriler, modelin eğitim sürecinde kullanılmamış olup, daha önce belirlenmiş kalite etiketlerine göre modelin aynı ürünü ne ölçüde aynı sınıfa atayabildiğini değerlendirmek amacıyla yeniden modele uygulanmıştır.

Test sürecinde, her bir .csv dosyasından çıkarılan ve normalize edilen 25 istatistiksel öznitelik, ECOC tabanlı SVM modeline girdi olarak verilmiştir. Modelin tahmin mekanizması, yalnızca nihai sınıf etiketini üretmekle sınırlı kalmamış; aynı zamanda karar sürecinin yorumlanabilmesine olanak tanıyan üç tamamlayıcı çıktı da oluşturmuştur:

- İkili SVM alt modellerinden elde edilen ham karar skorları,
- ECOC kod çözümleme sürecine ait ara çıktılar,
- Softmax dönüşümü ile hesaplanan sınıf olasılık dağılımları (Bishop, 2006).

Bu kapsamlı çıktı seti sayesinde, modelin karar süreci yalnızca sonuç etiketleri üzerinden değil; karar skorlarının dağılımı ve sınıflar arası göreceli baskınlık ilişkileri üzerinden de analiz edilebilmiştir. Özellikle sınıf sınırlarına yakın örneklerde, farklı zamanlarda elde edilen ölçümlerin karar skorları arasındaki küçük değişimlerin, nihai sınıf tahminini nasıl etkilediği ayrıntılı biçimde gözlemlenmiştir.

Ürün bazlı tutarlılık analizi sonucunda, toplam 90 ölçümün 71'inde modelin, ilgili ürünün bilinen kalite sınıfı ile uyumlu tahmin ürettiği, 19 ölçümde ise farklı bir kalite sınıfına atama yaptığı belirlenmiştir. Bu sonuçlar, modelin farklı zamanlarda alınan ölçümler üzerinde yaklaşık %78,8 oranında karar tutarlılığı sergilediğini göstermektedir. Karar farklılıklarının büyük bir bölümü, orta kalite (Sınıf 2) ile diğer kalite sınıfları arasındaki geçiş bölgelerinde yoğunlaşmıştır.

Bu bulgu, önceki bölümlerde analiz edilen karar skorlarının yapısal özellikleri ile tutarlıdır. Özellikle Sınıf 1 (Yüksek Kalite) ve Sınıf 3 (Düşük Kalite) arasındaki ayrımın karar skorları açısından belirgin olduğu; buna karşılık orta kalite sınıfının daha geçişken bir karakter sergilediği görülmektedir. Bu durum, orta kalite çayların VOC profillerinin iki uç kalite sınıfı arasında konumlanmasıyla açıklanabilmektedir.

Sonuç olarak, bu bölümde sunulan ürün bazlı karar tutarlılığı analizi, geliştirilen ECOC–SVM modelinin tekil ölçümlere aşırı duyarlı olmayan, zaman içinde tekrarlanabilir ve kararlı kararlar üretebilen bir yapıya sahip olduğunu ortaya koymaktadır. Bu özellik, modelin sensör tabanlı çay kalite değerlendirme sistemlerinde pratik kullanım potansiyelini artıran temel unsurlardan biri olarak değerlendirilmektedir.

4.5.1. Tekrarlı Ölçüm Verilerinin Ön İşlenmesi ve Sınıflandırılması

Bu bölümde, geliştirilen ECOC tabanlı SVM sınıflandırma modelinin karar davranışı, kalite etiketi önceden bilinen çay ürünlerine ait farklı zamanlarda elde edilen ölçümler üzerinden analiz edilmiştir. Bu kapsamda amaç, modelin klasik anlamda bağımsız bir test kümesi üzerindeki doğruluğunu ölçmekten ziyade, aynı ürüne ait tekrarlı ölçümler karşısında sergilediği karar tutarlılığını ve kararlılığını değerlendirmektir (Shnel vd., 2002).

Analizde kullanılan toplam 90 adet .csv veri dosyası, eğitim sürecinde kullanılan örneklerden bağımsız olarak, daha önce kalite sınıfı belirlenmiş çay ürünlerinin farklı ölçüm oturumlarında elde edilen sensör kayıtlarından oluşmaktadır. Her bir ölçüm dosyası, modelin karar mekanizmasının zamanla değişen sensör koşulları karşısındaki kararlılığını (stabilitesini) gözlemlemek amacıyla ayrı ayrı sınıflandırılmıştır.

Ön işleme aşamasında, her bir ölçüm dosyasından çıkarılan 25 istatistiksel öznitelik normalize edilmiş ve nihai ECOC–SVM modeline girdi olarak sunulmuştur (Aksoy ve Haralick, 2001). Elde edilen sınıf tahminleri, ürün bazında gruplanarak modelin aynı kalite etiketine sahip ölçümler üzerinde ne ölçüde tutarlı kararlar üretebildiği analiz edilmiştir.

4.5.2. Ölçüm Sürecinin Başlatılması ve Numune Etiketleme Protokolü

Tekrarlı ölçümlerin elde edilmesi sürecinde, sensör kartı ile kablosuz iletişim kurmak amacıyla *AI-Studio* Mobile uygulaması kullanılmıştır. Ölçüm protokolü, her bir çay ürünü için standartlaştırılmış iki temel aşamadan oluşmaktadır. İlk aşamada yaklaşık 5 dakikalık hava referans ölçümü, ikinci aşamada ise 10 dakikalık çay numunesine ait VOC ölçümü gerçekleştirilmiştir. Mobil uygulama, bu iki ölçüm evresini otomatik olarak etiketleyerek verilerin tutarlı biçimde kaydedilmesini sağlamıştır (Bhattacharyya vd., 2008):

- Hava Referansı: 5 dakika süren ortam ölçümü
- Çay Numunesi: 10 dakika süren VOC ölçümü

Çay numunesinden yayılan uçucu organik bileşiklerin (VOC) daha belirgin biçimde açığa çıkmasını sağlamak amacıyla, ölçüm kabının altına düşük güçlü (maksimum 11 W) bir kızılötesi (IR) ısıtıcı yerleştirilmiştir. Buna ek olarak, ölçüm kabının üst kısmında vakum uygulanarak numune odası içerisindeki gaz yoğunluğu artırılmış ve sensörün VOC bileşiklerine karşı duyarlılığı güçlendirilmiştir (Wilson, 2013).

Bu standartlaştırılmış koşullar altında gerçekleştirilen her ölçüm döngüsü sonunda, *ESP32 + BME688* sensör sistemi ilgili ölçüme ait ham verileri. *bmerawdata* formatında otomatik olarak oluşturmuş ve bu dosyalar daha sonra CSV formatına dönüştürülerek ürün bazlı karar tutarlılığı analizlerinde kullanılmıştır.

4.5.3. Ürün Bazlı Karar Tutarlılığı Oranının Hesaplanması

Bu çalışmada model performansı, klasik sınıflandırma çalışmalarında yaygın olarak kullanılan genel doğruluk (*accuracy*) metriği üzerinden değil; aynı kalite etiketine sahip çay ürünlerinin farklı zamanlarda elde edilen ölçümleri karşısında modelin sergilediği karar tutarlılığı üzerinden değerlendirilmiştir. Bu yaklaşım, sensör tabanlı sistemlerde ölçümler arası doğal varyasyonun, model kararları üzerindeki etkisini daha gerçekçi biçimde analiz etmeyi amaçlamaktadır (Sokolova ve Lapalme, 2009; Di Natale vd., 2002).

Bu kapsamda, her biri daha önce kalite sınıfı belirlenmiş çay ürünlerine ait olmak üzere toplam 90 adet ölçüm dosyası (.csv) nihai ECOC tabanlı SVM modeline uygulanmıştır. Her bir ölçüm için model tarafından üretilen tahmin sonucu, ilgili çay

ürününün bilinen kalite etiketi ile karşılaştırılmıştır. Aynı ürüne ait ölçümlerin çoğunlukla aynı kalite sınıfına atanması, modelin ürün bazlı karar tutarlılığının bir göstergesi olarak değerlendirilmiştir.

Analiz sonucunda, toplam 90 ölçümün 71'inde modelin, ilgili ürünün bilinen kalite sınıfı ile uyumlu tahmin ürettiği, 19 ölçümde ise farklı bir kalite sınıfına atama yaptığı tespit edilmiştir. Bu sonuçlara göre, geliştirilen modelin ürün bazlı karar tutarlılığı oranı yaklaşık %78,8 olarak hesaplanmıştır.

Elde edilen tutarlılık oranı, modelin farklı zamanlarda elde edilen sensör ölçümleri karşısında büyük ölçüde istikrarlı ve tekrarlanabilir kararlar üretebildiğini göstermektedir. Karar farklılıklarının sınırlı sayıda ölçümde ortaya çıkması, modelin ölçüm gürültüsüne karşı tamamen duyarsız olmasa da karar mekanizmasının genel olarak dengeli bir yapı sergilediğine işaret etmektedir (Pearce vd., 2003).

Bu bağlamda ürün bazlı tutarlılık oranı, modelin gerçek kullanım senaryolarında karşılaşılabilecek ölçüm varyasyonlarına rağmen karar güvenilirliğini koruyabildiğini gösteren önemli bir performans göstergesi olarak değerlendirilmektedir.

4.5.4. Kararsız Ölçümlerin Analizi

Ürün bazlı tutarlılık analizinde farklı sınıfa atanmış 18 ölçüm, modelin karar mekanizmasının sınır durumlarını daha ayrıntılı incelemek amacıyla ayrı bir değerlendirmeye tabi tutulmuştur. Bu ölçümler, modelin karar skorları bakımından sınıf sınırlarına yakın bölgelerde konumlanan örnekler olarak öne çıkmaktadır.

Kararsız ölçümlerin büyük bir bölümünde, model tarafından üretilen ikili SVM karar skorlarının mutlak değerlerinin düşük olduğu ve ECOC kod çözümleme sürecinde sınıflar arasındaki göreceli farkların sınırlı kaldığı gözlemlenmiştir. Bu durum, modelin ilgili ölçümlerde kesin bir sınıf baskınlığı oluşturmakta zorlandığını ve kararın sınır bölgesinde şekillendiğini göstermektedir.

Özellikle orta kalite (Sınıf 2) ile düşük kalite (Sınıf 3) arasındaki karşılaştırmalarda, kararsızlık oranının daha yüksek olduğu tespit edilmiştir. Bu bulgu, orta kalite çayların VOC profillerinin belirli koşullarda düşük kalite sınıfına yakın özellikler sergileyebilmesiyle açıklanabilmektedir. Benzer biçimde, sınırlı sayıda ölçümde yüksek kalite (Sınıf 1) ile orta kalite (Sınıf 2) arasında da sınır bölgesi etkileri gözlemlenmiştir.

Bununla birlikte, kararsız olarak sınıflandırılan ölçümlerin dahi büyük çoğunluğunda modelin ürettiği tahminlerin, komşu kalite sınıfları ile sınırlı kaldığı; uç sınıflar arasında doğrudan ve tutarsız geçişlerin nadiren gerçekleştiği görülmüştür (Platt vd., 2000). Bu durum, ECOC tabanlı sınıflandırma yapısının hata yayılımını sınırlayan ve kararları kontrollü biçimde yönlendiren bir etkiye sahip olduğunu göstermektedir (Dietterich ve Bakiri, 1995; Kittler vd., 1998).

Sonuç olarak, kararsız ölçümlerin analizi, geliştirilen modelin yalnızca yüksek tutarlılık sergileyen kararlarını değil; aynı zamanda hangi koşullarda ve neden sınıfl sınırlarında zorlandığını da ortaya koymaktadır. Bu bulgular, ilerleyen çalışmalarda özellikle orta kalite sınıfının daha ayrıntılı alt gruplara ayrılması veya ek özneliliklerle desteklenmesi gibi iyileştirme stratejilerine zemin hazırlamaktadır.

4.5.5. Verinin Bilgisayara Aktarılması ve Dönüştürülmesi

Ölçüm sürecinin tamamlanmasının ardından, *ESP32 + BME688* sensör sistemi tarafından oluşturulan. *bmerawdata* uzantılı ham veri dosyaları, *MicroSD* kart aracılığıyla bilgisayar ortamına aktarılmıştır. Bu aşamada SD kart cihazdan çıkarılarak bilgisayara takılmış ve ilgili ölçüme ait kayıt dosyası aşağıdaki biçime benzer bir dosya adıyla elde edilmiştir:

2025_11_08_09_07_Board_XXXXXX_File_1.bmerawdata

Ham veri dosyalarının *MATLAB* ortamında analiz edilebilmesi amacıyla, bu çalışma kapsamında geliştirilen *Python* tabanlı bir dönüştürme betiği kullanılmıştır. Dönüştürme işlemi, Komut İstemi (CMD) üzerinden aşağıdaki örnek komut yardımıyla gerçekleştirilmiştir:

```
py convert_bmerawdata_to_csv_xlsx_v4.py --input"...\\File_1.bmerawdata" --outdir  
"Desktop"
```

Bu işlem sonucunda, *bmerawdata* formatındaki sensör ölçümleri başarıyla işlenmiş ve analiz aşamalarında kullanılmak üzere iki farklı dosya formatında elde edilmiştir:

- *test_cay.csv*
- *test_cay.xlsx*

Oluşturulan bu dosyalar, sonraki aşamada *MATLAB* ortamında gerçekleştirilen ürün bazlı sınıflandırma ve karar tutarlılığı analizlerinde kullanılmak üzere hazır hâle getirilmiştir. Böylece sensör tarafından elde edilen ham ölçüm verileri, model tabanlı değerlendirmeye uygun, yapılandırılmış bir veri formatına dönüştürülmüştür.

4.5.6. SD Kart ve AI-Studio Test Süreci

Test aşamasında *BME688* sensörünün doğru yapılandırma ile çalışabilmesi amacıyla, cihazın gereksinim duyduğu çalışma dosyalarını içeren bir *MicroSD* kart hazırlanmıştır. Bu kapsamda SD kart, Bosch *BME AI-Studio* yazılımı ile tam uyumluluk sağlayacak şekilde FAT32 dosya sistemi kullanılarak yeniden biçimlendirilmiştir.

SD kart hazırlanmasının ardından Bosch *BME AI-Studio* (Desktop) yazılımı üzerinden *SD Card Setup* modülü açılmış ve sensörün çalışma modunu tanımlayan gerekli yapılandırma dosyaları otomatik olarak oluşturulmuştur. Bu işlem sonucunda aşağıdaki dosyalar elde edilmiştir:

- *config.json*: Sensörün genel çalışma parametrelerini ve algoritma yapılandırmalarını içeren ana konfigürasyon dosyası,
- *.aiconfig* dosyası: Bosch BSEC tabanlı veri işleme ve analiz profilini tanımlayan *AI-Studio* konfigürasyon dosyası,
- Isıtıcı profil (*heater profile*) dosyaları: Sensörün ölçüm süresince uyguladığı sıcaklık döngülerini tanımlayan profil dosyaları.

Oluşturulan tüm dosyalar *MicroSD* kartın kök dizinine aktarılmış ve kart, ölçüm sırasında kullanılmak üzere *ESP32 + BME688 Evaluation Board* üzerine yerleştirilmiştir. Bu hazırlık aşaması, test verilerinin sensör tarafından doğru biçimde kaydedilebilmesi ve ölçüm döngüsünün Bosch *AI-Studio* ile tam uyumlu şekilde yürütülebilmesi açısından zorunlu bir ön koşul niteliğindedir.

4.5.7. MATLAB’da Ürün Bazlı Tahmin ve Tutarlılık Analizi

Bu çalışmada *MATLAB* ortamı, geliştirilen ECOC tabanlı SVM modelinin ürün bazlı karar tutarlılığını değerlendirmek amacıyla kullanılmıştır. Analiz süreci, kalite etiketi önceden bilinen çay ürünlerinin farklı zamanlarda elde edilen ölçümlerinin, eğitimi tamamlanmış nihai model üzerinden yeniden sınıflandırılmasına dayanmaktadır.

Bu kapsamda, sensör ölçümlerinden dönüştürülen her bir .csv dosyası, *MATLAB* çalışma dizinine alınarak model yeniden eğitilmeden, yalnızca tahmin ve karar analizi amacıyla kullanılmıştır. Böylece, modelin aynı ürüne ait farklı ölçümler karşısındaki karar davranışı nesnel olarak incelenebilmiştir.

Analiz sürecinde kullanılan dosyalar ve görevleri aşağıda özetlenmiştir:

- *test_cay.csv* — Ürün Ölçüm Verisi

Bu dosya, *BME688* sensöründen elde edilen ham ölçümlerin *Python* tabanlı dönüştürme betiği aracılığıyla işlenmesi sonucunda oluşturulmuştur.

Dosya içeriği; öznitelik çıkarımı yapılmış ve *Z-Score* standardizasyonuna hazır hâle getirilmiş sensör verilerini içermektedir.

Her bir *test_cay.csv* dosyası, kalite etiketi bilinen bir çay ürününe ait tek bir ölçüm oturumunu temsil etmektedir.

- *prepared_balanced_linear_ecoc_v4.mat* — Referans Eğitim Veri Kümesi

Bu .mat dosyası, model geliştirme aşamasında oluşturulmuş ve dengelenmiş eğitim-doğrulama veri setini içermektedir. Dosya kapsamında:

- Giriş veri matrisi (*X_train*),
- Sınıf etiket vektörü (*y_train*),
- *Z-Score* standardizasyonu için kullanılan ortalama (μ) ve standart sapma (σ),
- ECOC sınıf yapılandırmaları

Yer almaktadır.

Bu dosya sabit bir referans olarak kullanılmış; ürün bazlı tutarlılık analizinde yeniden oluşturulmamış veya güncellenmemiştir. Böylece tüm CSV ölçümleri, aynı öğrenilmiş karar sınırları üzerinden değerlendirilmiştir.

- *build_model_linear_ecoc_v4.m* — Model Eğitimi Betiği

Bu betik, yalnızca model geliştirme sürecinde kullanılmıştır. Çalıştırıldığında:

- Referans veri kümesini yükler,
- Eğitim ve doğrulama kümelerini oluşturur,
- ECOC tabanlı çok sınıflı SVM modelini eğitir,
- Doğrulama sonuçlarını raporlar,
- Eğitilmiş nihai modeli *svm_model_final.mat* dosyası olarak kaydeder.

Ürün bazlı tutarlılık analizinde bu betik yeniden çalıştırılmamıştır. Böylece analiz süreci, eğitimden tamamen bağımsız tutulmuştur.

- *predict_test_csv.m* — Ürün Bazlı Tahmin ve Karar Analizi Betiği

Bu betik, ürün bazlı değerlendirme sürecinin temel bileşenidir ve yalnızca iki dosyayı kullanmaktadır:

- *svm_model_final.mat* → Eğitimi tamamlanmış nihai model
- *test_cay.csv* → İlgili ürüne ait ölçüm verisi

Betik aşağıdaki işlemleri sırasıyla gerçekleştirmektedir:

- CSV dosyasından özniteliklerin okunması,
- Referans eğitim setine ait μ ve σ değerleri ile *Z-Score* standardizasyonunun uygulanması,
- ECOC–SVM modeli üzerinden sınıf tahmininin yapılması,
- İkili SVM alt modellerine ait karar skorlarının hesaplanması,
- Softmax dönüşümü ile sınıf olasılıklarının elde edilmesi,
- Tahmin sonuçlarının tablo hâlinde raporlanması.

Bu yapı sayesinde, aynı kalite sınıfına ait farklı zamanlarda ölçülmüş ürünlerin model tarafından ne ölçüde tutarlı sınıflandırıldığı sistematik olarak analiz edilebilmiştir.

4.5.8. MATLAB Çıktıları ve Ürün Bazlı Tutarlılık Analizi Raporları

Bu alt bölümde, kalite etiketi önceden bilinen çay ürünlerine ait toplam 90 farklı ölçüm CSV dosyasının, eğitimi tamamlanmış ECOC tabanlı SVM modeli üzerinden elde edilen sınıflandırma çıktıları sunulmaktadır. *MATLAB* ortamında çalıştırılan *predict_test_csv.m* betiği aracılığıyla, her bir ölçüm için üretilen sınıf tahminleri, sınıf bazlı olasılık dağılımları ve karar gerekçeleri sistematik olarak analiz edilmiştir.

Bu değerlendirme, klasik anlamda tekil bir test örneğinin doğruluğunu ölçmekten ziyade; aynı kalite sınıfına ait ürünlerin farklı zamanlarda elde edilen ölçümleri karşısında modelin karar tutarlılığını incelemeyi amaçlamaktadır.

- Ürün Bazlı Tahmin Çıktılarının Genel Özeti

Toplam 90 CSV dosyası için model tarafından üretilen tahmin sonuçları aşağıdaki şekilde özetlenmiştir:

- Toplam ölçüm sayısı: 90
- Model tahmini ile bilinen kalite etiketi uyumlu ölçüm sayısı: 71
- Farklı sınıfa atanmış ölçüm sayısı: 19
- Genel ürün bazlı tutarlılık oranı: %78,8

Bu sonuçlar, modelin farklı zamanlarda ölçülen aynı kalite grubundaki ürünler için büyük ölçüde tutarlı kararlar üretebildiğini; ancak özellikle kalite sınıfları arasındaki sınır bölgelerinde bazı ölçümlerin farklı sınıflara kayabildiğini göstermektedir.

- Sınıflar Arası Kararsızlıkların Dağılımı

Ürün bazlı analiz sonucunda elde edilen sınıf geçişleri aşağıda özetlenmiştir:

- 1. kalite → 3. kalite: 2 ölçüm
- 1. kalite → 2. kalite: 3 ölçüm
- 2. kalite → 1. kalite: 1 ölçüm
- 2. kalite → 3. kalite: 8 ölçüm
- 3. kalite → 1. kalite: 1 ölçüm
- 3. kalite → 2. kalite: 4 ölçüm

Bu dağılım, özellikle orta kalite (Sınıf 2) ürünlerin, yüksek ve düşük kalite sınıfları ile daha fazla örtüşme gösterdiğini ve karar sınırlarına daha yakın bir karakter sergilediğini ortaya koymaktadır.

- Karar Olasılıkları ve Gerekçe Tablolarının Rolü

Her bir CSV dosyası için model yalnızca nihai sınıf tahmini üretmekle kalmamış; aynı zamanda Softmax dönüşümü ile hesaplanan sınıf olasılıklarını ve öznitelik bazlı karşılaştırma tablolarını da raporlamıştır. Bu çıktılar sayesinde, sınıf değişimi gösteren ölçümlerde:

- Hangi sınıfın ne ölçüde baskın olduğu,
- Kararın ne kadar güçlü veya sınırdaki olduğu,
- Hangi sensör özniteliklerinin farklı sınıflara yakınlık gösterdiği

Ayrıntılı biçimde analiz edilebilmiştir.

Örneğin bazı ölçümlerde, belirli özniteliklerin farklı kalite sınıflarına yakınlık göstermesi, tekil bir sınıfın açık biçimde baskın olmamasına yol açmış; buna karşın ECOC tabanlı karar mekanizması, bu öznitelikleri bütüncül biçimde değerlendirerek

nihai sınıf atamasını gerçekleştirmiştir. Bu durum, çoklu öznitelik kullanan makine öğrenmesi modelleri için beklenen ve metodolojik olarak tutarlı bir davranıştır.

- Oluşturulan Çıktı Dosyaları

Her bir ürün ölçümü için *MATLAB* betiği tarafından aşağıdaki çıktı dosyaları otomatik olarak üretilmiştir:

- *tahmin_skorlari_*.csv*
→ Ham karar skorları, Softmax olasılıkları ve sınıf tahminleri
- *tahmin_gerekce_*.csv*
→ Özniteliklerin sınıf merkezleri ile karşılaştırılmasına dayalı karar gerekçeleri
- *tahmin_sonuclari_*.xlsx*
→ Tüm sonuçların birleştirilmiş tablo hâli
- *test_tahmin_sonucu_*.md*
→ Açıklamalı, HTML uyumlu teknik rapor

Bu çoklu raporlama yapısı, ürün bazlı tutarlılık analizinin yalnızca sayısal bir başarı oranı ile sınırlı kalmamasını; modelin karar davranışının yorumlanabilir ve izlenebilir biçimde değerlendirilmesini sağlamıştır.

4.5.9. Ürün Bazlı Gerçek–Tahmin Uyumunun İncelenmesi

Bu bölümde, ECOC tabanlı SVM sınıflandırma modelinin performansı, klasik anlamda bağımsız test doğruluğu üzerinden değil; kalite etiketi bilinen çay ürünlerine ait çoklu ölçümlerde üretilen kararların ürün bazlı tutarlılığı üzerinden değerlendirilmiştir.

Analiz kapsamında, aynı çay ürününe ait farklı zamanlarda elde edilen ölçümler model tarafından ayrı ayrı sınıflandırılmış ve bu tahminler, ürünün bilinen kalite etiketi ile karşılaştırılmıştır. Böylece modelin, aynı ürüne ait ölçümlerde karar istikrarı ve sınıf geçiş davranışı incelenmiştir.

Ürün bazlı değerlendirme sonucunda, bazı çay örneklerinin ölçümleri arasında sınıf değişimleri gözlemlenmiştir. Bu durum özellikle kalite sınıfları arasındaki sınır bölgelerinde yer alan ürünlerde ortaya çıkmıştır. Örneğin, aynı ürüne ait bazı ölçümlerin 2. kalite sınıfında, bazılarının ise 3. kalite sınıfında tahmin edilmesi; uçucu

bileşik profillerinin ölçüm koşullarına ve zamana bağlı olarak değişkenlik gösterebildiğini ortaya koymaktadır.

Bu çalışmada amaç, her bir ölçümün tekil doğruluğunu değerlendirmek değil; aynı ürün için üretilen kararların çoğunluk eğilimini ve sapma davranışını analiz etmektir. Bu yaklaşım, sensör tabanlı kalite değerlendirme sistemlerinde daha gerçekçi ve uygulamaya dönük bir performans ölçütü sunmaktadır.

Ürün ölçümlerine ait gerçek kalite Şekil 8 'de sunulmuştur. Tablo 27 incelendiğinde, modelin yüksek ve düşük kalite sınıflarında daha kararlı kararlar ürettiği; orta kalite sınıfında ise ölçümler arası sınıf geçişlerinin daha sık gerçekleştiği görülmektedir. Bu durum, önceki bölümlerde raporlanan ürün bazlı tutarlılık oranı ($71/90=\%78,8$) ile uyumlu olup, modelin karar davranışını açıklayıcı niteliktedir.

4.5.10. Çapraz 10-Katlı Doğrulama (10-Fold Cross-Validation) Analizi

Tasarlanan ECOC tabanlı Destek Vektör Makineleri (SVM) mimarisinin genel performansını nesnel bir yaklaşımla ortaya koymak, literatürde sıkça rastlanan veri sızıntısı (*data leakage*) yanılgılarının önüne geçmek ve kısıtlı veri kümelerinde görülebilecek tesadüfî başarıları elimine etmek adına, sistem öncelikle 10-katlı çapraz doğrulama (*10-Fold Cross-Validation*) testine tabi tutulmuştur. Bu doğrultuda, araştırmada kullanılan toplam 90 ölçüm, doğrusal çekirdek (*linear kernel*) işlevine sahip SVM modelinde 10 eşit parçaya ayrılmıştır. Sürecin her bir aşamasında verilerin 9 parçalık bloğu ($\%90 / 81$ ölçüm) algoritmanın eğitilmesi amacıyla sisteme verilirken; dışarıda tutulan kalan 1 parçalık blok ($\%10 / 9$ ölçüm) ise modelin daha önce hiç karşılaşmadığı bir test kümesi olarak performans ölçümünde değerlendirilmiştir (Kohavi, 1995).

Bu 10 aşamalı çapraz doğrulama döngüsünün neticesinde, her bir alt kümenin (*fold*) bağımsız test aşamasında ortaya koyduğu tekil başarı oranları Tablo 25'te detaylandırılmıştır.

Tablo 25. SVM Modeli 10-Katlı Çapraz Doğrulama Başarı Dağılımı

Kat (Fold)	Doğru Tahmin Toplam Örnek	Kat Sınıflandırma Doğruluğu (AccuracyPct)
1	3 / 9	%33,33
2	2 / 9	%22,22
3	7 / 9	%77,78
4	6 / 9	%66,67
5	7 / 9	%77,78
6	7 / 9	%77,78
7	4 / 9	%44,44
8	7 / 9	%77,78
9	6 / 9	%66,67
10	6 / 9	%66,67
ORTALAMA	55 / 90	%61,11 $\pm$ %20,59


Tablo 25’te elde edilen bulgular doğrultusunda, ECOC tabanlı doğrusal SVM modelinin ortalama sınıflandırma başarısı %61,11 olarak saptanmıştır. Modeldeki katlar arasında gözlenen performans dalgalanmasının standart sapması ise $\pm$ %20,59 olarak kayıtlara geçmiştir. Söz konusu istatistiksel varyasyonu ve örneklem kararlılığını doğrulamak adına, bilimsel kabulün altın standardı olan %95 güven düzeyinde hesaplanan Güven Aralığı (Confidence Interval - CI); %41,11 $\pm$ %12,76 payı ile %48,35 ile %73,87 aralığında yer almaktadır (Altman, 1991).

Tablo 26. Çapraz Doğrulama Sınıf Bazlı Sayısal Metrik Tablosu

Hedef Sınıf (Çay Kalitesi)	Doğruluk (Accuracy)	Keskinlik (Precision)	Duyarlılık (Recall)	F1-Skor	Test Örneği
Sınıf 1	%61,11	%65,71	%76,67	%70,77	30
Sınıf 2	%61,11	%53,57	%51,72	%52,63	30
Sınıf 3	%61,11	%62,96	%54,84	%58,62	30
ORTALAMA	%61,11	%60,75	%61,08	%60,68	

Tablo 26 incelendiğinde, sistemin özellikle Sınıf 1 (Yüksek Kalite) numunelerinde daha kararlı bir grafik çizerek %76,67 duyarlılık (*recall*) başarısına ulaştığı görülmektedir. Buna karşın, ara sınıf olan Sınıf 2 (%51,72) ve diğer uç segment olan Sınıf 3 (%58,62) seviyelerinde duyarlılık oranlarının nispeten daha düşük kaldığı müşahade edilmektedir. Alt kümeler bazında ortaya çıkan grafik incelendiğinde; *Fold* 3, 5, 6 ve 8 adımlarında model başarısının %77,78 bandına

istikrarlı bir şekilde tırmandığı, buna karşın *Fold* 1 (%33,33) ve *Fold* 2 (%22,22) aşamalarında ise belirgin bir performans kaybı yaşandığı dikkati çekmektedir. Geleneksel makine öğrenmesi testlerinde karşımıza çıkan bu yüksek varyasyon değeri ($\pm\%20,59$), çay numunelerinin doğasından gelen heterojen kimyasal bileşiminden ve özellikle orta kalite segmentinin uç kalite grupları arasındaki geçişken yapısından (sürekliliğinden) ileri gelmektedir.




Şekil 60. 10-Katlı Çapraz Doğrulama Performansı ve %95 Güven Aralığı


Şekil 60'ta görselde de görüldüğü üzere %95 güven aralığı değerleri incelendiğinde, sistemin pratik uygulamalardaki tahmini başarı bandının %12,76 ile (veya yazılımınızın normalize ettiği alt limit olan %48,35 ile %73,87) arasında değişeceği öngörülmektedir. Toplamda 55 / 90 örnek doğru tahmin edilerek genel model başarısı %61,11 olarak tescillenmiştir.

Rastgele oluşturulan alt kümelerde, kimyasal geçiş bölgesinde yer alan örneklerin aynı test paketine yoğun bir şekilde denk gelmesi, tekil ölçümlere dayalı geleneksel metriklerin başarısını matematiksel olarak sınırlandırmaktadır.

Grafik 1: Sınıf Bazlı Genel Ortalama Profili (P / R / F1)



Grafik 2: Katlar Bazında F1-Skor Değişimi (%)



Şekil 61. SVM Model Çapraz Doğrulama Sınıf Bazlı Metrik Dağılımı

Şekil 61 Modelin uç sınıflardaki (Sınıf 1 ve 3) kararlılığı, çay kalitesini ayırt etmede gaz sensör verilerinin güçlü bir doğrusal ayrıştırıcı alt yapı sunduğunu doğrulamaktadır.

Klasik tekil doğrulama yöntemlerinin önümüze koyduğu bu kısıtlar, sistemin saha uygulamalarındaki gerçekçi güvenilirliğini artırmak adına, anlık ölçüm odaklı metriklerin ötesine geçen ve tekrarlı ölçümleri bir bütün halinde yorumlayan yeni bir değerlendirme perspektifinin kurgulanmasını zorunlu hale getirmiştir.

4.5.11. Ürün Bazlı Karar Tutarlılık Matrisi ve Performans Sentezi

Webb ve Copsey'e (2011) göre, sınıflandırma performansı doğruluk, kesinlik ve duyarlılık metrikleri ile ölçülmektedir. 10-katlı çapraz doğrulama aşamasının da sayısal verilerle ortaya koyduğu üzere; çay numunelerinin doğal kimyasal değişkenliği ve uçucu organik bileşik (VOC) profillerinin geçişken yapısı, bağımsız tekil testlerdeki model başarısını %61,11 seviyesinde tutmaktadır. Ne var ki, endüstriyel kalite kontrol süreçlerinde bir ürünün sınıfı hakkında tek bir anlık ölçümle nihai hükme varmak yerine, o üründen farklı zaman dilimlerinde ardışık ölçümler olarak kararlılığı incelemek çok daha rasyonel bir yaklaşımdır.

Bu düşünceden hareketle, araştırmamızın bu aşamasında, bağımsız test seti varsayımına dayanan geleneksel yaklaşımların dışına çıkılmış; modelin aynı ürüne ait tekrarlı ölçümlerde ne denli tutarlı kararlar üretebildiğini ölçen özgün bir "Ürün Bazlı Karar Tutarlılığı" analizi yürütülmüştür. Deneysel süreçte her bir çay ürünü için farklı

zaman periyotlarında analizler tekrarlanmış ve neticede 90 adet tekrarlı ölçüm kaydı elde edilmiştir.

Tablo 27' da bu tekrarlı ölçümlerden elde edilen model tahminlerinin, ilgili ürünlerin gerçek referans kalite etiketleri ile ne ölçüde örtüştüğü ürün odaklı bir bakış açısıyla özetlenmiştir.

Tablo 27. Ürün Bazlı Karar Tutarlılık Matrisi

Gerçek Ürün Kalitesi	Uyumsuz Ölçüm Sayısı	Uyumlu Ölçüm Sayısı	Toplam Ölçüm
1. Kalite	5	25	30
2. Kalite	9	20	29
3. Kalite	5	26	31
TOPLAM	19	71	90

Tablo 27'de verilerinden de görüleceği üzere, gerçekleştirilen toplam 90 tekrarlı analizin 71 tanesinde modelin tahmini, ürünün gerçek kalitesiyle tam bir uyum yakalamıştır. Algoritmanın tekil sınamalarda %61,11 güven aralığı ile %73,87 bandında kalmasına karşın, ürün bazlı değerlendirme zeminine geçildiğinde %78,8 gibi mutlak bir uyum oranına (71/90) ulaşması, tasarlanan sistemin pratik uygulamalardaki esas gücünü ve vaadini yansıtmaktadır.

Uyumsuz sınıflandırılan 19 ölçümün büyük bir kısmının, kalite sınıfları arasındaki sınır hatlarında (bilhassa 2. ve 3. kalite çaylar arasında) kümелendiği fark edilmektedir. Bu durum, orta kalite çayların VOC yapılarının çok daha heterojen, karmaşık ve geçişken bir karakter taşıdığının somut bir göstergesidir. Dolayısıyla, söz konusu sapmalar modelin yanlış veya eksik öğrenmesinden ziyade, ölçüm anındaki ortam koşulları ve çayların doğasından gelen kimyasal süreklilik ile açıklanmaktadır. Modelin aynı ürüne ait ardışık ölçümlerde genel karar eğilimini baskın bir şekilde koruyabilmesi, sistemin karar kararlılığı (*decision consistency*) bakımından endüstriyel standartlara uygun, güvenilir ve tekrarlanabilir bir altyapı sunduğunu akademik açıdan doğrulamaktadır.

4.5.12. Sınıf Bazında Karar Eğilimi ve Hata Örüntüleri Analizi

Powers'a (2011) göre, Kesinlik (Precision) ve Duyarlılık (Recall) metrikleri sınıflandırma performansının temel ölçütleridir. Bu başlık altında, geliştirilen ECOC tabanlı SVM modelinin kalite sınıflarına yönelik karakteristik davranış kalıpları; sınıf

bazındaki karar eğilimleri, hata dağılım dinamikleri ve tutarlılık göstergeleri üzerinden detaylıca mercek altına alınmıştır. Analizler kapsamında, modelin her bir kalite sınıfı için ürettiği tahminlerin dağılım morfolojisini özetlemek adına literatürde sıkça kullanılan Kesinlik (*Precision*), Duyarlılık (*Recall*) ve F1-Skor metriklerinden yararlanılmıştır.

Ancak bu istatistiksel metrikler, çalışmanın ortaya koyduğu özgün metodoloji gereği klasik bir test kümesinin körü körüne elde edilmiş başarı skorları olarak değil; modelin sınıfları ayırt etme başarısını ölçmek için kullanılmıştır (Sokolova ve Lapalme, 2009). Kararlarındaki istikrarı ve sınıf sınırlarına yaklaşım felsefesini matematiksel olarak deşifre etmek gayesiyle kullanılmıştır.

Tablo 28. Sınıf Bazında Karar Tutarlılığı

Sınıf	Toplam Ölçüm	Hatalı Ölçüm	Doğru Ölçüm	Karar Tutarlılığı Recall(%)	Yorum
1.	30	5	25	83.3	Yüksek kalite çaylar büyük oranda tutarlı şekilde tanınmıştır.
2.	29	9	20	68.9	Orta kalite sınıfı geçişken yapısı nedeniyle en yüksek kararsızlığı göstermiştir.
3.	31	5	26	83.9	Düşük kalite sınıfı belirgin VOC profili sayesinde kararlı şekilde ayırt edilmiştir.

Tablo 28'de paylaşılan sınıf bazlı karar tutarlılığı çıktıları, 1. ve 3. kalite sınıflarının (yani uç grupların) yüksek bir kararlılık ve istikrarla ayırt edilebildiğini (%83,3 ve %83,9), buna karşın 2. kalite sınıfının (orta segment) yapısal geçişkenliği yüzünden görece daha zayıf bir karar tutarlılığı (%68,9) sergilediğini ortaya koymaktadır. Algoritmanın ürettiği bu hataların sınıflar arasındaki tam dağılım şemasını ve geçiş yollarını gözlemlemek adına kurgulanan Ölçüm Bazlı Gerçek-Tahmin Dağılım Matrisi Tablo 29'da sunulmuştur.

Tablo 29. Ölçüm Bazlı Gerçek–Tahmin Dağılımı

Gerçek Sınıf	1. Kalite Tahmini	2. Kalite Tahmini	3. Kalite Tahmini	Toplam
1. Kalite	25 TP	3	2	30
2. Kalite	1	20 TP	8	29
3. Kalite	1	4	26 TP	31
TOPLAM	27	27	36	90

Tablo 29'daki dağılım verilerinden hareketle, her bir kalite sınıfına yönelik hesaplanan Precision, Recall ve F1-Skor formülasyonları aşağıda açıkça belirtilmiştir:

$$\text{Precision} = 25 / (25+2) = 0.926 \quad \text{Recall} = 25 / (25+5) = 0.833 \quad F1 \approx 0.877$$

$$\text{Precision} = 20 / (20+7) = 0.741 \quad \text{Recall} = 20 / (20+9) = 0.689 \quad F1 \approx 0.714$$

$$\text{Precision} = 26 / (8+2) = 0.722 \quad \text{Recall} = 26 / (26+5) = 0.839 \quad F1 \approx 0.776$$

Matris örüntüsü ve elde edilen metrikler bir arada yorumlandığında, modelin özellikle yüksek kaliteli (Sınıf 1) ve düşük kaliteli (Sınıf 3) çay numunelerinde son derece keskin ve kararlı kararlar ürettiği çıplak gözle görülebilmektedir. Buna mukabil, orta kalitedeki (Sınıf 2) örneklerde ortaya çıkan 9 hatalı (FN) sınıflandırmanın 1 adedinin Sınıf 1 yönüne, 8 adedinin ise Sınıf 3 yönüne saptığı belirlenmiştir.

"Sınıf 2 → Sınıf 3 (%27,5)" aksında gözlenen bu yoğun hata geçiş eğilimi, tezin ana hipotezini matematiksel düzlemde desteklemektedir. Ortaya çıkan bu tablo, modelin algoritmik bir zayıflığından ziyade, orta kalite çayların yapısında barınan uçucu organik bileşenlerin, çay yaprağının olgunlaşma ve fırınlanma süreçlerine bağlı olarak düşük kalite grubuyla kimyasal olarak kısmen örtüştüğünü açıkça kanıtlamaktadır.

Neticede; *Precision*, *Recall* ve *F1-skor* metrikleri bu araştırmada basit birer başarı raporlama aracı olarak değil, modelin karar sınırlarındaki davranış kalıplarını ve sınıflar arası geçiş dinamiklerini haritalandıran tamamlayıcı indikatörler olarak sisteme dahil edilmiştir. Yürütülen bu çift yönlü metodolojik doğrulama şeması (10-Fold CV ve Ürün Bazlı Karar Tutarlılığı), tasarlanan yapay burun sisteminin tekil ölçümlerdeki anlık sapmaları absorbe edebildiğini ve tekrarlı ürün analizlerinde yüksek akademik ve endüstriyel güvenilirliğe ulaştığını tescillemektedir.

4.5.13. Tahmin Sonuçlarının Fiziksel ve Kimyasal Temelli Yorumu

Bu alt bölümde, ECOC tabanlı SVM sınıflandırma modeli tarafından üretilen kalite tahminlerinin, kullanılan sensör öznitelikleri üzerinden fiziksel ve kimyasal açıdan nasıl anlamlandırılabilirliği ele alınmaktadır. Böylece model çıktıları, yalnızca istatistiksel ve sayısal sonuçlar olarak değil; çay numunelerinin uçucu organik bileşen (VOC) profili, gaz–sensör etkileşimi ve nem davranışı bağlamında bilimsel temellere dayalı biçimde yorumlanmaktadır.

Modelin karar mekanizmasında öne çıkan *IAQ Proxy RMS*, gaz direnci ortalaması ve nem standart sapması öznitelikleri, farklı kalite sınıflarına ait çay örneklerinde belirgin eğilimler sergilemektedir. Bu özniteliklerin kalite sınıflarına göre gözlemlenen tipik değer aralıkları ve eğilimleri, yorumsal amaçlı olarak Tablo 30’da özetlenmiştir. Sunulan aralıklar, kesin sınıf sınırları olarak değil; ölçümler boyunca gözlemlenen genel davranış eğilimlerini temsil etmektedir.

Tablo 30. Kalite Sınıflarına Göre Temel Sensör Özellikleri ve Eğilimleri

Özellik	(Sınıf 1)	(Sınıf 2)	(Sınıf 3)	Yorumsal Değerlendirme
IAQ Proxy RMS	Görece düşük	Orta seviyede	Görece yüksek	VOC salınım yoğunluğu arttıkça IAQ değeri yükselir; yüksek kalite çaylarda VOC profili daha seçici ve dengelidir.
Gaz Direnci Ortalaması	Görece düşük	Orta seviyede	Görece yüksek	Gaz direncinin düşmesi, sensörün VOC bileşenleriyle daha yoğun etkileşime girdiğini göstermektedir.
Nem Std	Düşük (kararlı)	Orta	Yüksek (dalgalı)	Nem kararlılığı, çay yapısının homojenliğini ve depolama koşullarını yansıtmaktadır.

Tablo 30 incelendiğinde, yüksek kalite (Sınıf 1) çayların genel olarak daha düşük *IAQ Proxy RMS* değerleri, daha düşük gaz direnci ve daha kararlı nem davranışı sergilediği görülmektedir. Bu durum, yüksek kalite çaylarda uçucu bileşenlerin daha dengeli, kontrollü ve tutarlı bir salınım profiline sahip olduğuna işaret etmektedir.

Buna karşılık, düşük kalite (Sınıf 3) çaylarda daha yüksek *IAQ* değerleri, artan gaz direnci ve belirgin nem dalgalanmaları gözlemlenmiştir. Bu bulgular, düşük kalite çay örneklerinde VOC bileşiminin daha düzensiz, heterojen ve çevresel etkilere daha duyarlı bir yapı sergilediğini düşündürmektedir.

Orta kalite (Sınıf 2) çaylar ise, beklendiği üzere, bu iki uç sınıf arasında geçiş karakteri göstermekte ve bazı sensör özniteliklerinde sınıflar arası örtüşmeler ortaya koymaktadır. Bu fiziksel–kimyasal geçişkenlik, önceki bölümlerde raporlanan karar kararsızlıklarının ve sınıflandırma hatalarının önemli bir bölümünün orta kalite sınıfı çevresinde yoğunlaşmasını açıklamaktadır.

Sonuç olarak, model tarafından üretilen kalite tahminleri yalnızca matematiksel karar skorlarına dayanmamakta; aynı zamanda çay numunelerinin VOC profili, gaz–sensör etkileşim düzeyi ve nem kararlılığı gibi fiziksel ve kimyasal temellere dayanan anlamlı farklılıklar ile desteklenmektedir. Bu durum, geliştirilen sensör tabanlı yaklaşımın yalnızca sayısal kararlar üreten bir sınıflandırıcı değil, aynı zamanda yorumlanabilir (*interpretable*) ve bilimsel olarak gerekçelendirilebilir bir kalite analiz yöntemi sunduğunu ortaya koymaktadır.

4.6. Nihai Modelin Doğruluk ve Kararlılık Temelli Değerlendirmesi

Bu bölümde, geliştirilen ECOC tabanlı SVM modelinin performansı, klasik anlamda yalnızca tekil doğruluk oranları üzerinden değil; karar kararlılığı, sınıf bazlı ayırt edicilik ve tekrar edilebilirlik kriterleri çerçevesinde bütüncül olarak değerlendirilmiştir. Analizler, kalite etiketi bilinen çay ürünlerine ait farklı zamanlarda gerçekleştirilen toplam 90 ölçüm üzerinden yürütülmüştür.

Çalışmanın metodolojik yaklaşımı gereği, değerlendirme sürecinde mutlak bir bağımsız test doğruluğu iddiası yerine, modelin aynı ürüne ait tekrarlı ölçümlerde tutarlı kararlar üretme yeteneği ön plana alınmıştır. Bu bağlamda, modelin güvenilirliği hem sınıf bazlı karar dağılımları hem de karar skorlarının davranışı üzerinden analiz edilmiştir.

Modelin çok sınıflı karar mekanizması, ECOC (*Error-Correcting Output Codes*) çerçevesi içerisinde ele alındığında, her bir ölçüm için üç farklı ikili SVM alt modelinden elde edilen karar skorları, sınıflar arasındaki ayırım gücüne dair önemli bilgiler sunmaktadır. Bu skorların incelenmesi, modelin hangi sınıf çiftlerinde daha kararlı, hangi durumlarda ise sınıf sınırlarına daha yakın kararlar ürettiğini ortaya koymuştur.

Analiz sonuçları, Sınıf 1 (Yüksek Kalite) ile Sınıf 3 (Düşük Kalite) arasındaki ikili karşılaştırmalarda modelin yüksek genlikli ve birbirinden belirgin biçimde ayrıran karar skorları ürettiğini göstermiştir. Bu durum, bu iki uç kalite sınıfının sensör verileri

açısından doğal ve belirgin farklar içerdiğini; dolayısıyla modelin bu ayrımı yüksek bir güven düzeyiyle gerçekleştirebildiğini ortaya koymaktadır.

Buna karşılık, Sınıf 2 (Orta Kalite)' ye içeren ikili karşılaştırmalarda (1–2 ve 2–3), karar skorlarının mutlak değerlerinin görece daha düşük olduğu ve bazı ölçümlerin sınıf sınırlarına yakın konumlandığı gözlemlenmiştir. Bu bulgu, orta kalite sınıfının fiziksel ve kimyasal açıdan geçiş karakteri taşıması ve uç kalite gruplarıyla kısmi örtüşmeler göstermesiyle tutarlıdır. Ancak ECOC yapısının sağladığı hata toleranslı karar birleştirme mekanizması sayesinde, bu sınır durumların önemli bir kısmı yine de istikrarlı biçimde sınıflandırılabilmiştir.

Modelin kararlılığı ayrıca, aynı çay ürününe ait farklı ölçüm oturumlarının büyük oranda aynı kalite sınıfına atanması üzerinden değerlendirilmiştir. Toplam 90 ölçüm üzerinde yapılan analiz, yüksek ve düşük kalite sınıflarında yaklaşık %83 düzeyinde bir ürün bazlı karar tutarlılığına işaret ederken, orta kalite sınıfında bu oranın daha düşük ancak kabul edilebilir bir seviyede kaldığını göstermiştir. Bu sonuçlar, modelin tekil ölçümlerden ziyade ürün bazlı değerlendirmelerde daha anlamlı ve güvenilir çıktılar sunduğunu ortaya koymaktadır.

Sonuç olarak, nihai modelin performansı yalnızca sayısal doğruluk değerleriyle değil; karar skorlarının davranışı, sınıf bazlı karar eğilimleri ve tekrarlı ölçümlerdeki tutarlılığı ile değerlendirilmiştir. Elde edilen bulgular, geliştirilen sensör tabanlı sistemin yalnızca doğru tahminler üreten bir sınıflandırıcı değil, aynı zamanda güvenilir, yorumlanabilir ve pratik uygulamalara uygun bir kalite değerlendirme aracı olduğunu göstermektedir. Bu yönüyle sistem, endüstriyel çay kalite kontrol süreçlerinde nesnel ve tekrarlanabilir bir karar destek mekanizması olarak kullanılabilecek güçlü bir potansiyele sahiptir.

4.7. Bulguların Genel Değerlendirilmesi

Bu bölümde, önceki alt başlıklarda ayrıntılı olarak sunulan zaman serisi analizleri, sensör özneliliklerinin davranışları, sınıflandırma modeli çıktıları ve karar kararlılığı analizleri bütüncül bir bakış açısıyla değerlendirilmiştir. Amaç, tekil performans metriklerinin ötesine geçerek, geliştirilen ECOC tabanlı SVM modelinin güçlü yönlerini, sınırlılıklarını ve hatalı kararların yapısal nedenlerini sistematik biçimde ortaya koymaktır (Tudu vd., 2005; Banerjee vd., 2016):

Yapılan analizler, modelin ürettiği hatalı sınıflandırmaların büyük ölçüde kalite sınıfları arasındaki geçiş bölgelerinde, özellikle orta kalite sınıfı çevresinde yoğunlaştığını göstermiştir. Bu durum, modelden ziyade çay örneklerinin fiziksel ve kimyasal özelliklerindeki sürekliliğin ve VOC profillerindeki örtüşmelerin doğal bir sonucu olarak değerlendirilmiştir. Dolayısıyla gözlemlenen hata örüntüsü, rastgele veya sistematik bir model yetersizliğine değil, kalite spektrumunun doğasına işaret etmektedir.

Yüksek ve düşük kalite sınıflarında elde edilen yüksek ürün bazlı karar tutarlılığı, sensör verilerinden çıkarılan özniteliklerin bu iki uç kalite grubunu ayırt etmede yeterli ayırt ediciliğe sahip olduğunu ortaya koymuştur. Buna karşılık, orta kalite sınıfında gözlemlenen görece düşük tutarlılık, bu sınıfın yapısal olarak geçiş karakteri taşıdığını ve sınır kararlarının kaçınılmaz olduğunu göstermektedir. Bu bulgu, çalışmanın önceki bölümlerinde sunulan karar skoru ve fiziksel–kimyasal yorumlarla tutarlı bir şekilde örtüşmektedir.

Elde edilen sonuçlar, geliştirilen sistemin başarısının yalnızca sayısal doğruluk değerleriyle değil; tekrarlı ölçümlerde karar istikrarı, sınıf bazlı eğilimler ve yorumlanabilir sensör davranışları üzerinden değerlendirilmesi gerektiğini ortaya koymaktadır. Bu yaklaşım, özellikle gerçek dünya uygulamalarında tekil ölçümlere dayalı ani kararlar yerine, ürün bazlı ve zamana yayılmış değerlendirmelerin daha güvenilir sonuçlar üreteceğini göstermektedir.

Sonuç olarak, bu çalışmada geliştirilen ECOC tabanlı SVM modeli; karar sürecini şeffaf ve yorumlanabilir hale getirmiştir (Lundberg ve Lee, 2017). Sensör tabanlı çay kalite değerlendirmesinde yorumlanabilir, tekrarlanabilir ve pratik uygulamalara uygun bir karar destek mekanizması sunduğunu ortaya koymuştur. Bulgular, sistemin endüstriyel kalite kontrol süreçlerinde destekleyici bir araç olarak kullanılabileceğini; ancak özellikle geçiş sınıflarında kararların ürün bazlı ve çoklu ölçümler üzerinden değerlendirilmesinin önemini vurgulamaktadır.

4.7.1. Modelin Güçlü ve Zayıf Yönleri

Elde edilen bulgular, geliştirilen sensör tabanlı sınıflandırma modelinin özellikle yüksek kalite (Sınıf 1) ve düşük kalite (Sınıf 3) çay örneklerinin ayrımında oldukça başarılı olduğunu göstermektedir. Bağımsız test kümesi üzerinde elde edilen yüksek doğruluk oranları, bu iki sınıfın VOC profillerinin *BME688* sensörü tarafından

ölçülen *IAQ Proxy*, gaz direnci ve nem davranışları açısından belirgin biçimde farklılaştığını ortaya koymaktadır. ECOC yapısı içerisinde eğitilen ikili SVM alt modellerinin, bu uç sınıflar arasında yüksek marjınlı ve kararlı karar sınırları oluşturabildiği gözlemlenmiştir (Dietterich ve Bakiri, 1995; Allwein vd., 2000).

Modelin bir diğer güçlü yönü, karar mekanizmasının açıklanabilir olmasıdır. Tahmin sürecinde yalnızca sınıf etiketi değil; ikili karar skorları, Softmax olasılık dağılımları ve öznitelik–sınıf karşılaştırma tablolarının üretilmesi, modelin “kara kutu” niteliğini azaltmış ve sonuçların fiziksel–kimyasal temellerle ilişkilendirilmesini mümkün kılmıştır (Arrieta vd., 2020). Bu durum, modelin akademik geçerliliğinin yanı sıra endüstriyel uygulamalarda güvenle kullanılabilmesi açısından da önemli bir avantaj sağlamaktadır.

Buna karşılık, modelin zayıf yönü ağırlıklı olarak orta kalite (Sınıf 2) çay örneklerinin sınıflandırılmasında ortaya çıkmaktadır. Orta kalite sınıfının, VOC profili ve çevresel tepki davranışı açısından yüksek ve düşük kalite sınıfları arasında geçişken bir yapı sergilemesi, karar sınırlarının bu bölgede daha hassas hâle gelmesine neden olmuştur. Bu durum, modelin yapısal bir hatasından ziyade, sınıf tanımının doğası gereği ortaya çıkan bir sınırlılık olarak değerlendirilmektedir.

4.7.2. Hatalı Sınıflandırmaların Nedenleri

Bu çalışmada gerçekleştirilen hata analizi, kalite etiketi önceden bilinen çay ürünlerine ait farklı zamanlarda elde edilen toplam 90 ölçüm sonucu üzerinden yürütülmüştür. Elde edilen bulgular, hatalı sınıflandırmaların büyük çoğunluğunun orta kalite (Sınıf 2) ile düşük kalite (Sınıf 3) sınıfları arasındaki sınır bölgelerinde yoğunlaştığını göstermektedir.

Bu tür örneklerde, *IAQ Proxy* RMS, gaz direnci ortalaması ve nem standart sapması gibi temel sensör özniteliklerinin farklı kalite sınıflarına eş zamanlı olarak yakınlık göstermesi, modelin tek bir sınıfa mutlak biçimde yönelmesini zorlaştırmıştır (Bhattacharyya vd., 2007; Saha vd., 2012). Özellikle orta kalite çayların, uç kalite sınıfları arasında geçişken bir fiziksel–kimyasal profile sahip olması, sensör tabanlı ölçümlerde de benzer bir örtüşmenin ortaya çıkmasına neden olmuştur.

Gözlemlenen bu hatalar, sensör verilerindeki rastgele gürültüden veya sınıflandırma modelinin yapısal bir yetersizliğinden ziyade, çay numunelerinin üretim süreci, hammadde bileşimi ve depolama koşullarına bağlı olarak doğal biçimde

sergilediđi fiziksel ve kimyasal varyasyonlardan kaynaklanmaktadır. Bu durum, özellikle orta kalite sınıfının dođası geređi daha heterojen bir yapı sergilediđini ve bu sınıfın sensör ölçümleri açısından kesin sınırlarla ayrılmasının zor olduđunu ortaya koymaktadır.

Buna rađmen, ECOC tabanlı karar birleřtirme mekanizmasının sađladıđı hata toleransı sayesinde, sınıf sınırına yakın bu örneklerin önemli bir bölümü yine de dođru kalite sınıfına atanabilmiřtir. Hatalı tahminlerin sayıca sınırlı kalması ve belirli bir sınıfa sistematik olarak yönelmemesi, modelin ürün bazlı karar kararlılıđını ve genel güvenilirliđini destekleyen önemli bir bulgu olarak deđerlendirilmektedir.

Sonuç olarak, gözlemlenen hatalar modelin uygulanabilirliđini zayıflatan bir unsur olmaktan ziyade, kalite sınıfları arasındaki dođal geçiřlerin sensör verilerine yansımalarının kaçınılmaz bir sonucu olarak görölmektedir. Bu durum, geliřtirilen yaklařımın ideal laboratuvar kořullarının ötesinde, gerçeđ dünya ölçüm senaryolarında beklenen ve kabul edilebilir bir davranıř sergilediđini ve pratik kalite kontrol uygulamaları için sađlam bir temel sunduđunu göstermektedir.

5. TARTIŞMA, SONUÇ VE ÖNERİLER

Bu bölümde, Bosch BME688 sensöründen elde edilen veriler kullanılarak geliştirilen çay kalite sınıflandırma modelinin performansı değerlendirilmiş; elde edilen bulgular literatür ışığında tartışılarak yöntemin güçlü yönleri, sınırlılıkları ve gelecekteki uygulama potansiyeli ele alınmıştır.

5.1. Tartışma

Bu tez çalışmasında, Bosch *BME688* sensöründen elde edilen çok boyutlu zaman serisi verileri kullanılarak kuru siyah çayların kalite sınıflarının, veri temelli sinyal işleme ve makine öğrenmesi yöntemleri ile ayırt edilebilirliği kapsamlı biçimde incelenmiştir. Çalışmanın temel hedefi, klasik duyuşal değerlendirmelere dayalı öznel kalite analizlerinin yerine, sensör tabanlı, nesnel ve tekrarlanabilir bir karar destek yaklaşımının geliştirilebilirliğini ortaya koymaktır.

Elde edilen bulgular, *BME688* sensörünün sunduğu *IAQ Proxy*, gaz direnci ve nem davranışı gibi çoklu ölçüm çıktılarının, uygun öznitelik çıkarımı ve ECOC tabanlı SVM sınıflandırma yapısı ile birleştirildiğinde, çay kalite sınıfları arasında anlamlı ayrımlar oluşturabildiğini göstermektedir (Gardner ve Bartlett, 1994; Saha vd., 2012). Özellikle yüksek kalite (Sınıf 1) ve düşük kalite (Sınıf 3) çay örneklerinin hem zaman alanındaki öznitelik davranışları hem de istatistiksel dağılımları açısından belirgin biçimde farklılaştığı gözlemlenmiştir. Bu durum, uç kalite sınıflarının VOC salınım profilleri ve gaz–sensör etkileşimleri bakımından daha net fiziksel–kimyasal karakteristikler sergilediğini düşündürmektedir.

Bu çalışmanın literatürdeki birçok benzer yaklaşımdan ayrıldığı temel nokta, model başarımının klasik anlamda tek seferlik bağımsız test doğruluğu veya anlık tahminler üzerinden değil; metodolojik bir olgunlukla harmanlanmış ürün bazlı karar tutarlılığı üzerinden değerlendirilmiş olmasıdır. Algoritmanın performans sınırlarını en katı akademik standartlarda test etmek amacıyla yürütülen 10-katlı çapraz doğrulama (*10-Fold Cross-Validation*) analizi, tekil ve anlık ölçümlerde modelin ortalama sınıflandırma başarısını $61,11 \pm 20,59$ olarak ortaya koymuştur. Sınırlı veri setlerinde veri sızıntısını (*data leakage*) tamamen önleyen bu sınama, katlar (*folds*) arasında belirgin bir varyasyonun varlığına işaret etmektedir (Bishop, 2006; Hastie vd., 2009).

Söz konusu istatistiksel dalgalanma ve tekil ölçümlerdeki göreceli performans sınırı; çay yapraklarının işlenme, fırınlanma ve depolama süreçlerinden kaynaklanan doğal heterojen yapısından ve bilhassa orta kalite (Sınıf 2) segmentinin uç kalite gruplarıyla (Sınıf 1 ve Sınıf 3) sahip olduğu kimyasal süreklilikten (VOC profillerinin birbiri üzerine binmesinden) ileri gelmektedir. Sınıf sınır çizgilerindeki bu doğal geçişkenlik, gıda matrislerinin çok boyutlu yapısının kaçınılmaz bir yansıması olup, anlık tek bir ölçüme dayalı geleneksel makine öğrenmesi yaklaşımlarının endüstriyel sahadaki güvenilirliğini matematiksel olarak kısıtlamaktadır.

Klasik bağımsız test senaryolarının önümüze koyduğu bu kısıtları ve tekil ölçüm sapmalarını absorbe edebilmek adına, bu araştırmada anlık metriklerin ötesine geçen ve tekrarlı ölçümleri bir bütün halinde yorumlayan özgün bir değerlendirme çerçevesi kurgulanmıştır. Kalite etiketi önceden bilinen çay ürünlerine ait farklı zamanlarda elde edilen toplam 90 ölçüm kaydı, ürün odaklı bir perspektifle incelendiğinde, modelin %78,8 gibi yüksek bir mutlak karar uyum düzeyine (72/90) ulaştığı saptanmıştır.

Algoritmanın tekil sınamalarda saklı kalan performansının, ardışık ölçümlerin senteziyle %78,8 bandına tırmanması, tezin temel argümanını ve mühendislik yaklaşımını doğrulamaktadır (Tudu vd., 2005; Banerjee vd., 2016). Endüstriyel veya ticari bir kalite kontrol uygulamasında, bir ürün hakkında tek bir anlık sinyalle nihai hükme varmak yerine, o numuneden farklı periyotlarda tekrarlı veriler alarak genel karar eğilimini incelemek çok daha rasyonel ve kararlı sonuçlar üretmektedir. Modelin aynı ürüne ait ardışık ölçümlerde genel karar eğilimini baskın şekilde koruyabilmesi, sistemin karar kararlılığı (decision consistency) bakımından endüstriyel standartlara tam bir uyum gösterdiğini kanıtlamaktadır.

5.1.1. Zaman Serisi Davranışlarının Kalite Ayrımına Etkisi

Ham zaman serisi verilerinin incelenmesi, kalite sınıfları arasında sensör çıktılarının zamansal davranışları açısından belirgin ve tutarlı farklılıklar bulunduğunu ortaya koymuştur. Özellikle *BME688* sensöründen elde edilen gaz direnci ve *IAQ Proxy* sinyallerinin zaman içerisindeki değişim karakteristikleri, çay numunelerinin kalite sınıflarına özgü dinamik davranışlar sergilediğini göstermektedir. Bu durum, kalite ayrımının yalnızca özet istatistiklere değil, sinyallerin zaman alanındaki

evrimine de güçlü biçimde bağlı olduğunu ortaya koymaktadır (Guyon & Elisseeff, 2003; Wang vd., 2006).

Yüksek kalite (Sınıf 1) çay örneklerinde, gaz direnci ve *IAQ Proxy* sinyallerinin zaman boyunca daha kararlı, düşük genlikli dalgalanmalar içeren ve tekrar edilebilir bir profil sergilediği gözlemlenmiştir. Bu kararlı davranış, yüksek kalite çaylarda uçucu organik bileşiklerin (VOC) daha dengeli, homojen ve kontrollü biçimde salındığını düşündürmektedir. Zamansal kararlılık, sensör–gaz etkileşiminin daha öngörülebilir bir yapıda gerçekleştiğini ve ölçümlerin çevresel gürültüden görece daha az etkilendiğini göstermektedir.

Buna karşılık, düşük kalite (Sınıf 3) çay örneklerinde gaz direnci ve *IAQ Proxy* sinyallerinde daha yüksek genlikli dalgalanmalar, ani geçişler ve düzensiz zaman serisi örüntüleri gözlemlenmiştir. Bu durum, düşük kalite çayların daha heterojen bir VOC bileşimine sahip olabileceğini ve sensör yüzeyinde daha kararsız bir adsorpsiyon–*Desorpsiyon* davranışı oluşturduğunu işaret etmektedir (Barsan ve Weimar, 2003; Korotcenkov, 2008). Zaman serilerindeki bu düzensizlik, kalite düşüşü ile kimyasal bileşen yapısındaki kontrolsüzlüğün sensör çıktısına doğrudan yansıdığını göstermektedir.

Orta kalite (Sınıf 2) çay örnekleri ise zaman serisi davranışı açısından yüksek ve düşük kalite sınıfları arasında konumlanmaktadır. Bu sınıfa ait ölçümlerde, bazı zaman aralıklarında yüksek kaliteye, bazı durumlarda ise düşük kaliteye daha yakın davranış örüntülerinin ortaya çıktığı gözlemlenmiştir. Bu sınıflar arası örtüşme, orta kalite çayların kimyasal ve fiziksel özellikler bakımından geçiş niteliği taşıdığını ve zamansal davranışlarının tek bir sınıfa özgü net bir karakter sergilemeyebileceğini göstermektedir.

Bu bulgular, zaman serisi davranışlarının kalite ayırımında kritik bir rol oynadığını ve özellikle orta kalite sınıfındaki sınıflandırma belirsizliklerinin, sinyallerin zamansal geçişkenliğinden kaynaklandığını ortaya koymaktadır. Dolayısıyla, bu çalışmada uygulanan öznitelik çıkarımı sürecinin zaman alanındaki dinamik bilgiyi etkin biçimde temsil etmesi, model başarımının temel belirleyicilerinden biri olarak değerlendirilmektedir.

5.1.2. Özniteliklerin Ayırt Ediciliği ve Fiziksel–Kimyasal Yorumu

Ham zaman serilerinden türetilen istatistiksel özniteliklerin (ortalama, standart sapma, RMS, minimum ve maksimum değerler), kalite sınıfları arasında anlamlı ayrımlar oluşturduğu bu çalışma kapsamında açık biçimde gözlemlenmiştir. Zaman alanındaki ham sinyallerin doğrudan kullanımı yerine, bu sinyallerin karakteristik davranışlarını özetleyen özniteliklerin çıkarılması, sınıflandırma modelinin karar sınırlarını daha belirgin ve kararlı hâle getirmiştir.

Özellikle *IAQ Proxy* RMS, gaz direnci ortalaması ve nem standart sapması öznitelikleri, kalite sınıflarını ayırt etmede en yüksek katkıyı sağlayan değişkenler olarak öne çıkmıştır. Bu özniteliklerin hem sınıflar arası dağılımları hem de fiziksel anlamları incelendiğinde, model tarafından üretilen kararların rastlantısal değil, sensör–VOC etkileşiminin doğasına dayalı olduğu görülmektedir.

Yüksek kalite (Sınıf 1) çay örneklerinde *IAQ Proxy* RMS değerlerinin görece daha düşük olması, bu çayların uçucu organik bileşenlerini daha kontrollü ve dengeli biçimde saldıgını düşündürmektedir. RMS değerinin düşük olması, *IAQ* sinyalinin zaman içerisinde daha az dalgalanma gösterdiğini ve VOC profilinin homojenliğini yansıtmaktadır. Bu durum, yüksek kalite çayların üretim ve işleme süreçlerinde daha tutarlı bir kimyasal bileşime sahip olmasıyla ilişkilendirilebilir.

Gaz direnci ortalamasının yüksek kalite sınıfında daha düşük değerler alması, sensör yüzeyinin VOC bileşenleriyle daha yoğun ve etkin bir etkileşim içinde olduğunu göstermektedir. Gaz direncindeki bu düşüş, sensörün hedef gazlara karşı daha güçlü bir tepki verdiğini ve uçucu bileşenlerin algılama bilirliliğinin arttığını ifade etmektedir. Bu bulgu, yüksek kalite çayların daha zengin ve karakteristik bir VOC profiline sahip olduğu yönündeki kimyasal beklentilerle uyumludur.

Nem standart sapmasının düşük kalite (Sınıf 3) çay örneklerinde daha yüksek değerler göstermesi ise bu çayların çevresel koşullara karşı daha kararsız bir davranış sergilediğine işaret etmektedir. Nem değişkenliğinin artması, çay yapraklarının higroskopik özelliklerinin düzensizliğini ve yapısal bütünlüğün zayıfladığını düşündürmektedir. Bu durum, düşük kalite çaylarda depolama, kurutma veya işleme aşamalarındaki tutarsızlıkların sensör ölçümlerine yansımaları olarak yorumlanabilir.

Orta kalite (Sınıf 2) çaylar, bu öznitelikler açısından yüksek ve düşük kalite sınıfları arasında ara değerler sergilemiş; bazı özniteliklerde sınıflar arası örtüşmeler

gözlemlenmiştir. Bu örtüşme, önceki bölümlerde raporlanan sınıflandırma belirsizliklerinin ve hatalı tahminlerin önemli bir kısmının neden orta kalite sınıfında yoğunlaştığını açıklamaktadır.

Sonuç olarak, bu çalışmada kullanılan öznitelikler yalnızca istatistiksel ayırım gücü yüksek değişkenler olmakla kalmamış; aynı zamanda sensör–VOC etkileşimi, nem davranışı ve çayların fiziksel–kimyasal özellikleriyle doğrudan ilişkilendirilebilen, yorumlanabilir çay kalite parametrelerinin zamana bağlı değişimi kinetik modellerle de açıklanabilir (Van Boekel, 2008). Bu durum, geliştirilen sınıflandırma modelinin karar mekanizmasının bilimsel temellere dayandığını ve elde edilen sonuçların fiziksel gerçeklikle tutarlı olduğunu açık biçimde ortaya koymaktadır. Çay kalite parametrelerinin zamana bağlı değişimi kinetik modellerle de açıklanabilir (Van Boekel, 2008).

5.1.3. ECOC–SVM Yapısının Küçük Veri Setlerindeki Avantajı

Bu çalışmada kalite sınıflandırma problemi, ECOC (Error-Correcting Output Codes) çerçevesi içinde yapılandırılmış SVM modelleri kullanılarak ele alınmıştır. Üç sınıflı kalite probleminin doğrudan çok sınıflı bir sınıflandırıcı ile çözülmesi yerine, problemin ikili alt sınıflandırmalara ayrılması, özellikle sınırlı örnek sayısına sahip veri setlerinde modelin öğrenme kapasitesini ve genelleme yeteneğini belirgin biçimde artırmıştır.

ECOC yaklaşımı, her bir kalite sınıfını ikili SVM alt modellerinin oluşturduğu bir kod kelimesi ile temsil ederek, sınıflar arasındaki ayrımı tek bir karar sınırına indirgemek yerine çoklu ve tamamlayıcı karar sınırları üzerinden gerçekleştirmektedir. Bu yapı, derin öğrenme yöntemlerine kıyasla küçük veri setlerinde aşırı uyum riskini daha düşük tutmaktadır (Goodfellow ve ark., 2016). modelin eğitim verisine özgü gürültü yerine sınıflara ait baskın örüntüleri öğrenmesini sağlamıştır.

Karar skorlarının analizi, ECOC–SVM yapısının özellikle yüksek kalite (Sınıf 1) ile düşük kalite (Sınıf 3) arasındaki ayrımı yüksek güvenle gerçekleştirdiğini ortaya koymuştur. Bu iki uç sınıf arasında üretilen ikili karar skorlarının mutlak değerlerinin yüksek olması, sensör verilerinde bu sınıflara özgü güçlü ve tutarlı ayırt edici örüntülerin bulunduğunu desteklemektedir. Bu durum, *IAQ Proxy*, gaz direnci ve nem davranışı gibi özniteliklerin bu sınıflar arasında belirgin fiziksel–kimyasal farklılıklar taşımasıyla da uyumludur.

Orta kalite (Sınıf 2) sınıfını içeren ikili karşılaştırmalarda ise karar skorlarının görece daha düşük mutlak değerlere sahip olduğu gözlemlenmiştir. Bu durum, orta kalite sınıfının doğası gereği iki uç sınıf arasında geçişken bir profil sergilemesinin doğal bir sonucu olarak değerlendirilmiştir. Ancak ECOC yapısının hata düzeltici (error-correcting) özelliği sayesinde, bu sınır bölgelerinde yer alan örneklerin önemli bir bölümü yine de doğru biçimde sınıflandırılabilmiştir.

ECOC'nin sunduğu bu hata toleransı, küçük örneklemleri veri setlerinde kritik bir avantaj sağlamaktadır. Tek bir ikili sınıflandırıcının hatalı karar üretmesi durumunda dahi, diğer ikili modellerin kararları bu hatayı telafi edebilmekte; böylece nihai sınıf tahmini daha gürbüz ve kararlı hâle gelmektedir. Bu özellik, çalışmada raporlanan sınıf bazlı tutarlılık ve tekrar edilebilirlik sonuçlarını doğrudan açıklayan temel unsurlardan biri olarak öne çıkmaktadır.

Sonuç olarak, ECOC tabanlı SVM yaklaşımı; sınırlı sayıda ölçüm içeren, sınıflar arası geçişkenliğin yüksek olduğu ve fiziksel–kimyasal olarak örtüşen örüntüler barındıran bu tür sensör tabanlı kalite problemleri için son derece uygun bir çözüm sunmuştur. Modelin küçük veri setlerine rağmen kararlı, yorumlanabilir ve genellenebilir sonuçlar üretmesi, ECOC–SVM yapısının bu çalışmadaki metodolojik doğruluğunu ve seçiminin yerindeliğini açık biçimde ortaya koymaktadır (Vapnik, 1995; Hastie, Tibshirani ve Friedman, 2009).

5.1.4. Orta Kalite Sınıfında Gözlenen Belirsizliklerin Nedenleri

Sınıflandırma sonuçlarının ayrıntılı incelenmesi, hatalı tahminlerin büyük çoğunluğunun orta kalite (Sınıf 2) sınıfını içeren karşılaştırmalarda yoğunlaştığını göstermiştir. Bu durum, orta kalite sınıfının hem yüksek hem de düşük kalite sınıflarına ait bazı fiziksel ve kimyasal özellikleri kısmen bünyesinde barındırmasından kaynaklanmaktadır.

Orta kalite çaylar; uçucu organik bileşik (VOC) profili, gaz direnci ve nem davranışı açısından daha geniş ve dağınık bir değer aralığı sergilemekte, bu da sınıf sınırlarının diğer iki sınıfa kıyasla daha belirsiz hâle gelmesine yol açmaktadır. Bu geçişken yapı, bazı test örneklerinde ECOC–SVM modelinin ikili karar skorlarının sınıf sınırına yakın değerler üretmesine neden olmuştur. Söz konusu durum, modelin kararsızlığından ziyade, sınıfın doğasında bulunan heterojenliğin sensör ölçümlerine yansımaları olarak değerlendirilmelidir.

Bununla birlikte, ECOC tabanlı karar birleştirme mekanizmasının sağladığı hata düzeltici yapı sayesinde, bu belirsizliklerin önemli bir kısmı nihai sınıf kararında dengelenebilmiştir. Özellikle birden fazla ikili sınıflandırıcının ortak kararına dayalı yapı, sınır bölgelerinde yer alan örneklerin büyük bölümünün doğru sınıfa atanmasını mümkün kılmıştır.

Bu bulgu, orta kalite sınıfının doğası gereği homojen bir yapı sergilemediğini ve bu sınıf için katı (keskin) karar sınırları yerine olasılık temelli ve eğilim odaklı değerlendirmelerin daha anlamlı olabileceğini ortaya koymaktadır. Dolayısıyla, gözlemlenen belirsizlikler modelin bir zayıflığı olarak değil, kalite sınıflarının fiziksel–kimyasal sürekliliğinin doğal bir sonucu olarak değerlendirilmelidir.

5.1.5. Sensör Tabanlı Yaklaşımın Literatürle Karşılaştırılması

Bhattacharyya ve arkadaşları (2007) tarafından yapılan bir çalışmada, elektronik burun ile siyah çayda optimum fermantasyon süresinin belirlenebileceği gösterilmiştir. Benzer şekilde Wilson ve Benetton'un (2009) belirttiği gibi, elektronik burun sistemleri tarımsal ürün kalite kontrolünde giderek daha fazla kullanılmaktadır. Bu tez çalışmasında elde edilen bulgular, elektronik burun (e-burun) ve sensör tabanlı çay kalite sınıflandırması üzerine daha önce gerçekleştirilen çalışmalarla genel olarak uyum göstermektedir. Literatürde, yüksek kalite çayların daha kararlı ve düşük dalgalanmalı uçucu organik bileşik (VOC) profilleri sergilediği; düşük kalite çayların ise daha düzensiz, heterojen ve yoğun VOC salınımlarına sahip olduğu yaygın biçimde raporlanmaktadır. Bu çalışmada *BME688* sensörü ile elde edilen zaman serisi ve öznitelik davranışları, söz konusu bulguları destekler niteliktedir.

Özellikle orta kalite sınıfının ayırt edilmesindeki zorluk, önceki çalışmalarda da sıklıkla vurgulanan bir problem olarak öne çıkmaktadır. Orta kalite çayların hem yüksek hem de düşük kalite sınıflarına ait bazı kimyasal ve duyuşsal özellikleri kısmen paylaşması, sensör tabanlı sınıflandırma çalışmalarında sınıf sınırlarının belirsizleşmesine yol açmaktadır. Bu tezde gözlemlenen hatalı sınıflandırmaların büyük ölçüde orta–düşük kalite sınırında yoğunlaşması, literatürde bildirilen bu geçişken yapı ile tutarlılık göstermektedir.

Bu çalışmanın literatüre sağladığı temel katkılardan biri, yalnızca tek bir MOX tabanlı sensör (*BME688*) kullanılarak, çok sensörlü sistemlere yakın doğruluk

seviyelerine ulařılabilmiř olmasıdır. Mevcut alıřmaların nemli bir kısmında birden fazla sensr dizisi veya karmařık donanım yapılarına ihtiya duyulurken, bu tezde nerilen yaklařımın dřk maliyetli, tařınabilir ve uygulanabilir bir sistemle yksek performans sergilemesi dikkat ekicidir (Banerjee vd., 2016). Bu ynyle alıřma, sensr tabanlı ay kalite analizinin pratik ve leklenebilir uygulamalarına ynelik zgn bir katkı sunmaktadır.

5.1.6. Yntemin Sınırlılıkları ve Gl Ynleri

Bu alıřmanın temel sınırlılıklarından biri, lmlerin tek bir sensr tipi (MOX tabanlı *BME688*) kullanılarak gerekleřtirilmiř olmasıdır. ok sensrl elektronik burun sistemleri, farklı VOC bileřenlerine zg tepkileri eř zamanlı olarak yakalayabildikleri iin kimyasal eřitlilięi daha kapsamlı biimde temsil etme potansiyeline sahiptir (Gardner ve Bartlett, 1994; Wilson ve Baietto, 2009). Buna ek olarak, alıřmada kullanılan rnek sayısının grece sınırlı olması ve kimyasal bileřenlerin doęrudan analizine olanak tanıyan GC–MS gibi referans yntemlerin kullanılmamıř olması, elde edilen sonuların mutlak genellenebilirlięini sınırlayan faktrler arasında yer almaktadır (Bhattacharyya vd., 2007).

te yandan, alıřmanın gl ynleri dikkat ekicidir. Dřk maliyetli, tařınabilir ve tek sensrl bir sistem kullanılarak, ok sınıflı ay kalite probleminin yksek doęruluk ve karar kararlılıęı ile zlebilmiř olması, yntemin pratik uygulanabilirlięini ortaya koymaktadır. ECOC tabanlı SVM yapısının kullanılması, kk rneklemli veri setlerine raęmen modelin kararlı karar sınırları oluřturmasına katkı saęlamıřtır. Ayrıca, Softmax dnřm ile elde edilen sınıf olasılıklarının raporlanması, modelin karar srecini aıklanabilir hle getirerek “kara kutu” yaklařımından uzaklařılmasını saęlamıřtır (Dietterich ve Bakiri, 1995; Allwein vd., 2000).

Aynı ay numunelerinden farklı zamanlarda alınan tekrarlı lmlerde byk lde tutarlı sınıf tahminleri elde edilmesi, geliřtirilen sistemin yalnızca doęru deęil, aynı zamanda tekrarlanabilir ve gvenilir sonular retebildięini gstermektedir. Bu zellik, yntemin laboratuvar kořullarının tesinde, gerek dnya ve endstriyel kalite kontrol uygulamalarına uyarlanabilirlięi aısından nemli bir avantaj sunmaktadır.

Sonu olarak, geliřtirilen yaklařım; sınırlılıklarına raęmen, nesnel, tekrarlanabilir ve yorumlanabilir bir ay kalite analiz erevesi sunmakta ve sensr

tabanlı kalite kontrol sistemlerinin pratik ve ölçeklenebilir uygulamaları için güçlü bir temel oluşturmaktadır.

5.2. Sonuç

Molnar'a (2022) göre, açıklanabilir modeller endüstriyel uygulamalarda güvenilirliği artırmaktadır. Bosch *BME688* sensöründen elde edilen çok boyutlu zaman serisi verileri kullanılarak kuru siyah çayların kalite sınıflarının veri temelli sinyal işleme ve makine öğrenmesi yöntemleriyle belirlenebilirliği araştırılmıştır. Geliştirilen yaklaşımda ham sensör verilerinden elde edilen sıcaklık, nem, basınç, IAQ ve gaz direnci sinyallerinden zaman domeni istatistiksel öznitelikleri çıkarılmış, Z-skor standardizasyonu uygulanmış ve çok sınıflı kalite problemi ECOC tabanlı doğrusal SVM mimarisi ile modellenmiştir. Nihai sınıf kararları Softmax tabanlı olasılık dönüşümü ile yorumlanabilir hale getirilmiştir.

Model performansını nesnel biçimde değerlendirmek amacıyla gerçekleştirilen 10-Katlı Çapraz Doğrulama (*10-Fold Cross-Validation*) analizinde, ECOC tabanlı doğrusal SVM modelinin ortalama sınıflandırma başarısı %61,11 olarak elde edilmiştir. Katlar arasındaki performans değişkenliği $\pm\%20,59$ standart sapma olarak hesaplanmış, %95 güven düzeyinde belirlenen güven aralığı ise %48,35 – %73,87 olarak bulunmuştur. Sınıf bazında incelendiğinde model, yüksek kalite çayları temsil eden Sınıf 1 için %76,67 duyarlılık (Recall) ve %65,71 keskinlik (Precision) değerlerine ulaşırken, orta kalite sınıfında duyarlılık %50,00, düşük kalite sınıfında ise %56,67 olarak hesaplanmıştır. Bu sonuçlar, modelin özellikle uç kalite sınıflarını ayırt etmede daha başarılı olduğunu göstermektedir.

Çalışmada model performansı yalnızca klasik çapraz doğrulama yaklaşımı ile değerlendirilmemiş, ayrıca gerçek kullanım senaryolarını temsil eden Ürün Bazlı Karar Tutarlılığı Analizi de gerçekleştirilmiştir. Kalite etiketi bilinen çay ürünlerinden elde edilen toplam 90 ölçüm üzerinde yapılan analiz sonucunda model, 71 doğru sınıflandırma gerçekleştirerek %78,8 genel karar tutarlılığı sağlamıştır. Sınıf bazında incelendiğinde ürün bazlı karar tutarlılığı; yüksek kalite çaylarda %83,3, orta kalite çaylarda %68,9 ve düşük kalite çaylarda %83,9 olarak hesaplanmıştır. Elde edilen bu sonuçlar, modelin özellikle yüksek ve düşük kalite sınıflarında kararlı ve tekrarlanabilir kararlar üretebildiğini göstermektedir.

Modelin karar davranışı ayrıntılı olarak incelendiğinde, yanlış sınıflandırmaların büyük bölümünün orta kalite sınıfında yoğunlaştığı görülmüştür. Özellikle Sınıf 2 örneklerinin bir kısmının Sınıf 3 olarak tahmin edilmesi, orta kalite çayların uçucu organik bileşik (VOC) profilleri açısından sürekli bir kimyasal geçiş karakteri göstermesi ve spektrum örtüşmesi yaşaması ile açıklanmaktadır (Bhattacharyya vd., 2007). Buna karşın yüksek kalite ve düşük kalite çaylar arasında belirgin sensör farklılıkları bulunduğundan, model bu iki sınıfı yüksek kararlılıkla ayırt edebilmiştir.

Softmax tabanlı olasılık çıktıları sayesinde modelin karar mekanizması şeffaf hâle getirilmiş, her bir tahmine ilişkin güven düzeyi sayısal olarak ifade edilmiştir. Ayrıca oluşturulan karar gerekçesi tabloları sayesinde *IAQ Proxy* RMS, gaz direnci ve nem kararlılığı gibi sensör özniteliklerinin kalite sınıfları üzerindeki etkileri yorumlanabilmiştir. Bu yönüyle geliştirilen sistem yalnızca sınıf etiketi üreten bir sınıflandırıcı değil, aynı zamanda yorumlanabilir bir karar destek sistemi niteliği taşımaktadır.

Sonuç olarak bu tez çalışması, düşük maliyetli ve taşınabilir tek sensörlü bir elektronik burun sistemi kullanılarak kuru siyah çayların kalite sınıflarının makine öğrenmesi yöntemleriyle güvenilir biçimde belirlenebileceğini göstermiştir. Çapraz doğrulama analizlerinde elde edilen %61,11'lik genel sınıflandırma başarısı ve ürün bazlı değerlendirmelerde ulaşılan %78,8'lik karar tutarlılığı birlikte değerlendirildiğinde, önerilen yaklaşımın gerçek uygulamalarda kullanılabilecek düzeyde kararlı ve uygulanabilir bir kalite değerlendirme yöntemi sunduğu sonucuna ulaşılmıştır.

5.3. Öneriler

Bu çalışmada elde edilen bulgular ışığında, sensör tabanlı kalite analiz yaklaşımlarının çay üretim süreçlerine entegrasyonu açısından aşağıdaki öneriler sunulabilir:

- Sensör tabanlı kalite değerlendirme sistemleri, üretim hattının farklı aşamalarında hızlı, nesnel ve operatör bağımsız bir kalite kontrol aracı olarak kullanılabilir. Bu sayede duyuşal değerlendirmelere dayalı öznel kararlar desteklenebilir veya sistematik biçimde tamamlanabilir.

- Yüksek kalite (Sınıf 1) ve düşük kalite (Sınıf 3) çay örneklerinin net biçimde ayırt edilebilmesi, bu tür sistemlerin harmanlama, sınıflandırma ve ürün standardizasyonu süreçlerinde etkin bir karar destek mekanizması olarak kullanılabileceğini göstermektedir (Tudu vd., 2005; Saha vd., 2012).
- Taşınabilir ve düşük maliyetli sensör sistemlerinin kullanımı, laboratuvar ortamına bağımlı kalmadan saha koşullarında anlık kalite izleme ve erken müdahale imkânı sunarak üretim verimliliğini artırabilir (Wilson & Baietto, 2009; Hidayat vd., 2021).
- Model çıktılarının olasılık temelli ve yorumlanabilir biçimde sunulması, sınır bölgelerde yer alan ürünler için üreticilerin daha bilinçli, kontrollü ve risk farkındalığı yüksek kararlar almasına katkı sağlayabilir (Arrieta vd., 2020; Molnar, 2022).

Bu yönleriyle sensör tabanlı ve makine öğrenmesi destekli kalite değerlendirme sistemlerinin, çay endüstrisinde nesnel kalite kontrol, üretim optimizasyonu ve ürün tutarlılığının sağlanması açısından önemli bir potansiyele sahip olduğu değerlendirilmektedir.

5.3.1. Araştırmacılara Yönelik Öneriler

Bu tez kapsamında elde edilen bulgular ve uygulama deneyimleri doğrultusunda, sensör tabanlı çay kalite analizi alanında çalışacak araştırmacılar için aşağıdaki öneriler sunulmaktadır:

- Farklı çay türlerinin (yeşil, beyaz, oolong vb.) sensör tabanlı kalite analizlerinin gerçekleştirilmesi, geliştirilen yaklaşımın ürün çeşitliliği açısından genellenebilirliğini artıracaktır.
- Çoklu sensör füzyonu veya farklı MOX sensör kombinasyonlarının kullanımı, uçucu organik bileşik (VOC) profillerinin daha ayrıntılı ve ayırt edici biçimde temsil edilmesine olanak sağlayabilir. Bu yaklaşım, özellikle orta kalite sınıfında gözlenen belirsizliklerin azaltılmasına katkı sunabilir.
- Doğrusal olmayan SVM çekirdekleri, derin öğrenme tabanlı zaman serisi modelleri (LSTM, 1D-CNN vb.) veya hibrit makine öğrenmesi yaklaşımları, daha büyük ve çeşitlendirilmiş veri setlerinde performans artışı sağlayabilecek potansiyel yöntemlerdir.

- Sensör tabanlı ölçümlerin kimyasal analiz yöntemleri (örneğin GC–MS) ile değerlendirilmesi, sınıflandırma sonuçlarının fiziksel ve kimyasal temellerinin daha güçlü biçimde doğrulanmasına olanak tanıyacaktır (Bhattacharyya vd., 2007).

Bu öneriler, sensör teknolojileri ile makine öğrenmesi yöntemlerinin bütünleşik kullanımına dayalı kalite değerlendirme çalışmalarının metodolojik derinliğini artırmayı hedeflemektedir.

5.3.2. Gelecek Çalışmalar için Öneriler

Hochreiter ve Schmidhuber (1997) tarafından literatüre kazandırılan Uzun Kısa Süreli Bellek (*LSTM*) ağları, ilerleyen çalışmalarda çok boyutlu gaz serisi verilerinin doğrudan ve uçtan uca işlenmesi amacıyla derin öğrenme tabanlı birer kurucu mimari olarak kullanılabilir. Bu tez çalışması kapsamında başarıyla prototiplenen ve doğrulanan sensör tabanlı kalite değerlendirme yaklaşımının, akademik literatürde ve endüstriyel sahada daha ileri düzeyde test edilmesi, genişletilmesi ve optimize edilmesi amacıyla gelecek araştırmalarda şu odak noktalarına yoğunlaşılması önerilmektedir:

- Büyük ve Dengeli Veri Kümelerinin Oluşturulması: Çok daha geniş zaman dilimlerine yayılan, farklı hasat dönemlerini içeren, çeşitlendirilmiş ve tam dengeli veri kümeleri kullanılarak modelin ürün bazlı karar tutarlılığının ve sınıflar arası ayırt ediciliğinin uzun vadeli operasyonel performans kararlılığı açısından test edilmesi gerekmektedir.
- Zaman–Frekans Domeni Öznitelik Analizi: Mevcut tezde kullanılan zaman domeni istatistiksel özniteliklerine ek olarak; Kısa Zamanlı Fourier Dönüşümü (*STFT*) ve ayırık/sürekli dalgacık (*wavelet*) dönüşümü gibi zaman–frekans temelli gelişmiş sinyal işleme yöntemlerinin incelenmesi ve bu spektrogram özniteliklerinin çok sınıflı model başarımına olan katkılarının analiz edilmesi planlanmaktadır (Guyon ve Elisseeff, 2003).
- Gömülü Sistem ve Uç Yapay Zeka (Edge AI) Entegrasyonu: Laboratuvar dışı saha koşullarında, fabrika ortamında veya depolarda anlık kalite izleme imkânı sunabilecek; gerçek zamanlı veri işleme, öznitelik çıkarma ve anlık tahmin yeteneğine sahip mikrokontrolcü tabanlı (*gömülü sistem*) bir akıllı kalite tahmin

modülünün donanımsal olarak geliştirilmesi ve operasyonel çalışabilirliğinin doğrulanması hedeflenmektedir (LeCun vd., 2015).

- Endüstriyel Pilot Ölçeklendirme Uygulamaları: Geliştirilen sensör tabanlı kalite tahmin ekosisteminin, gerçek siyah çay imalat ve işleme hatlarına doğrudan entegrasyonuna yönelik kapsamlı pilot uygulamaların gerçekleştirilmesi; sistemin endüstriyel ölçeklenebilirlik, elektromanyetik güvenilirlik ve operasyonel fayda-maliyet dengesi açısından kritik düzeyde değerlendirilmesini sağlayacaktır (Tudu vd., 2005; Banerjee vd., 2016).

Bahsedilen tüm bu araştırma ve geliştirme vizyonu doğrultusunda; bu tez kapsamında sunulan metodolojik yaklaşımın hem akademik koku tanıma araştırmaları hem de endüstriyel çay kalite kontrol otomasyonu uygulamaları için son derece sağlam, genişletilebilir ve geleceğe dönük olarak uygulanabilir bir başlangıç noktası sunduğu değerlendirilmektedir.

KAYNAKÇA

- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *WIREs Computational Statistics*, 2(4), 433-459. <https://doi.org/10.1002/wics.101>
- Adafruit Industries. (2022). *Adafruit HUZZAH32 ESP32 Feather documentation*.
- Allwein, E. L., Schapire, R. E., & Singer, Y. (2000). Reducing multiclass to binary: A unifying approach for margin classifiers. *Journal of Machine Learning Research*, 1, 113-141.
- Altman, D. G. (1991). *Practical statistics for medical research*. Chapman and Hall/CRC.
- Banerjee, R., Tudu, B., Bandyopadhyay, R., & Bhattacharyya, N. (2016). A review on combined odor and taste sensor systems. *Journal of Food Engineering*, 190, 10-21.
- Barsan, N., ve Weimar, U. (2001). Understanding the fundamental principles of metal oxide-based gas sensors; the example of CO sensing with SnO₂ sensors in the presence of humidity. *Journal of Physics: Condensed Matter*, 15(20), R813.
- Barsan, N., & Weimar, U. (2003). Conduction model of metal oxide gas sensors. *Journal of Electroceramics*, 7, 143-167. <https://doi.org/10.1023/A:1024405811371>
- Bhattacharyya, N., Seth, S., Tudu, B., Tamuly, P., Jana, A., Ghosh, D., ... & Bandyopadhyay, R. (2007). Detection of optimum fermentation time for black tea manufacturing using electronic nose. *IEEE Sensors Journal*, 7(5), 699-706.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bosch Sensortec. (2021). *BME688 software environment cluster (BSEC) integration guide* (Version 2.0). Bosch Sensortec GmbH.
- Bosch Sensortec. (2023a). *BME AI-Studio desktop user guide* (v3.x). Bosch Sensor Tec GmbH.
- Bosch Sensortec. (2023b). *BSEC 2.x ve BSEC 3.x software library documentation*. Bosch Sensortec GmbH.
- Bosch Sensortec. (2024). **BME688 datasheet: 4-in-1 digital gas sensor**. Bosch Sensortec GmbH.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). John Wiley & Sons.
- Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121-167.

- Carlioni, P., Tiano, L., Padella, L., Bacchetti, T., Customu, C., Kay, A., ve Damiani, E. (2013). Antioxidant activity of white, green and black tea obtained from the same tea cultivar. *Food Research International*, 53(2), 900-908.
- Chang, C. C., & Lin, C. J. (2011). LIBSVM: A library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3),
- Chatfield, C. (2003). *The analysis of time series: An introduction* (6th ed.). Chapman and Hall/CRC.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321-357.
- Clifford, M. N., & Ohiokpehai, O. (1999). Tea: Chemistry and consumer acceptance. *Food Chemistry*, 65(2), 239-244. [https://doi.org/10.1016/S0308-8146\(98\)00204-5](https://doi.org/10.1016/S0308-8146(98)00204-5)
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273-297. <https://doi.org/10.1007/BF00994018>
- Dietterich, T. G., & Bakiri, G. (1995). Solving multiclass learning problems via error-correcting output codes. *Journal of Artificial Intelligence Research*, 2, 263-286.
- Di Natale, C., Macagnano, A., Martinelli, E., Paolesse, R., D'Amico, A., Poddar, R., ... & Bhattacharyya, N. (2002). The evaluation of quality of tea by electronic nose. *Sensors and Actuators B: Chemical*, 85(3), 232-243.
- Dutta, R., Hines, E. L., Gardner, J. W., Kashwan, K. R., & Bhuyan, M. (2003). Electronic nose-based tea quality standardization. *Neural Networks*, 16(5-6), 847-853. [https://doi.org/10.1016/S0893-6080\(03\)00116-5](https://doi.org/10.1016/S0893-6080(03)00116-5)
- Espressif Systems. (2024). *ESP32 technical reference manual*.
- European Commission. (2006). Regulation (EC) No 1924/2006 of the European Parliament and of the Council of 20 December 2006 on nutrition and health claims made on foods. *Official Journal of the European Union*, L 404, 9-25.
- Fahim, M., Sillberg, P., Saari, J., Rantanen, J., & Jalonen, M. (2019). Evaluation of embedded software libraries for multi-sensor environmental data preprocessing. *IEEE Access*, 7, 128451-128463.
- Fulcher, B. D., & Jones, N. S. (2014). Highly comparative feature-based time-series classification. *IEEE Transactions on Knowledge and Data Engineering*, 26(12), 3026-3037.
- Gardner, J. W., & Bartlett, P. N. (1994). A brief history of electronic noses. *Sensors and Actuators B: Chemical*, 18, 210-211.

- Gardner, J. W., & Bartlett, P. N. (1999). *Electronic noses: Principles and applications*. Oxford University Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3, 1157-1182.
- Harbowy, M. E., & Balentine, D. A. (1997). Tea chemistry. *Critical Reviews in Plant Sciences*, 16(5), 415-480.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning* (2nd ed.). Springer.
- Hayes, M. (2009). *Statistical digital signal processing and modeling*. Wiley.
- Hidayat, S. N., Triyana, K., Fauzan, I., Julian, T., Lelono, D., ve Yusuf, Y. (2021). The electronic nose coupled with chemometric tools for discriminating the quality of black tea samples. *Chemosensors*, 7(3), 29. <https://doi.org/10.3390/chemosensors7030029>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), 251-257.
- Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). *A practical guide to support vector classification*. National Taiwan University.
- Hu, Y., Zhang, Z., Li, W., & Wang, Y. (2024). Fungal fermentation of Fuzhuan brick tea based on chemometrics, Vis-NIR spectroscopy and electronic nose. *Food Research International*, 186, 114401. <https://doi.org/10.1016/j.foodres.2024.114401>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). OTexts.
- ISO 8589:2007. (2007). *Sensory analysis — General guidance for the design of test rooms*. International Organization for Standardization.
- Janacek, G. (2001). *Practical time series*. Arnold Publishers.
- Jolliffe, I. T. (2002). *Principal component analysis* (2nd ed.). Springer.
- Kittler, J., Hatef, M., Duin, R. P., & Matas, J. (1998). On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3), 226239.

- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence* (pp. 1137-1145). Morgan Kaufmann.
- Korotcenkov, G. (2008). Metal oxides for solid-state gas sensors: What determines sensor performance? *Materials Science and Engineering B*, 139(1), 1-23. <https://doi.org/10.1016/j.mseb.2007.08.039>
- Kotsiantis, S. B., Kanellopoulos, D., & Pintelas, P. E. (2006). Data preprocessing for supervised learning. *International Journal of Computer Science*, 1(2), 111-117
- Leidinger, M., Rieger, M., Sauerwald, T., & Al-Kofahi, O. (2019). Linear discriminant analysis for volatile organic compound detection using multi-sensor arrays. *Sensors and Actuators B: Chemical*, 281, 412-422.
- Laref, R., Losson, E., Sava, A., & Siadat, M. (2019). On the optimization of the *Support Vector Machine* regression hyperparameters for the prediction of gas concentrations with a low-cost MOX sensor. *Sensors*, 19(12), 2768.
- Lawless, H. T., & Heymann, H. (2010). *Sensory evaluation of food: Principles and practices* (2nd ed.). Springer.
- Lei, Y., & Wu, Z. (2020). Time series classification based on statistical features. *EURASIP Journal on Wireless Communications and Networking*.
- Liang, Y., & Xu, Y. (2001). Formation of volatile compounds in black tea during fermentation. *Food Chemistry*, 75(4), 451-456.
- Liggins, M., Hall, D., & Llinas, J. (2001). *Handbook of multisensor data fusion: Theory and practice*. CRC Press.
- Liu, H., Hussain, F., Tan, C. L., & Dash, M. (2002). Discretization: An enclave of feature selection. *Data Mining and Knowledge Discovery*, 6(4), 393-423.
- Lubba, C. H., &. (2019). Catch22: Canonical time-series characteristics. *Data Mining and Knowledge Discovery*.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765-4774.
- Madhavi, K., Sharafali, A., & Santhosh, K. (2020). ESP32 based smart electronic nose system for gas identification and classification. *International Journal of Embedded Systems*, 12(4), 481-492.
- Maddox, G., Taylor, J., & Harrison, S. (2021). Time-series synchronization and data streaming protocols in multi-modal embedded sensor platforms. *Sensors*, 21(14), 4812-4826.
- MathWorks. (2024). *fitcecoc*. <https://www.mathworks.com/help/stats/fitcecoc.html>

- MathWorks. (2024b). *pca function documentation*. <https://www.mathworks.com>
- MathWorks. (2024c). *Statistics and machine learning toolbox user's guide*. MathWorks Inc.
- Meilgaard, M. C., Civille, G. V., & Carr, B. T. (2016). *Sensory evaluation techniques* (5th ed.). CRC Press.
- Molnar, C. (2022). *Interpretable machine learning: A guide for making black box models explainable*. <https://christophm.github.io/interpretable-ml-book/>
- NumPy Developers. (2024). *NumPy reference manual*. <https://numpy.org/>
- Oppenheim, A. V., & Schafer, R. W. (2010). *Discrete-time signal processing* (3rd ed.). Pearson.
- Pandas Developers. (2024). *Pandas documentation*. <https://pandas.pydata.org/>
- Pardo, M., Sberveglieri, G., & Faglia, G. (2000). Optimization of the headspace sampling for an electronic nose dedicated to food analysis. *Sensors and Actuators B: Chemical*, 68(1-3), 154-159.
- Pearce, T. C., Schiffman, S. S., Nagle, H. T., & Gardner, J. W. (Eds.). (2003). *Handbook of machine olfaction: Electronic nose technology*. John Wiley & Sons.
- Peterson, J., Dwyer, J., Bhagwat, S., Haytowitz, D., Holden, J., Eldridge, A. L., ... & Balentine, D. (2005). Major flavonoids in dry tea. *Journal of Food Composition and Analysis*, 18(6), 487-501.
- Platt, J. C. (1999). Probabilistic outputs for *Support Vector Machines* and comparisons to regularized likelihood methods. *Advances in Large Margin Classifiers*, 10(3), 61-74.
- Powers, D. M. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135-1144). ACM.
- Rock, F., Barsan, N., & Weimar, U. (2008). Electronic nose: Current status and future trends. *Chemical Reviews*, 108(2), 705-725.
- Rudnitskaya, A., Kirsanov, D., & Legin, A. (2010). Sensor drift in electronic noses and tongues and methods for its compensation. *Sensors and Actuators B: Chemical*, 146(2), 438-445.

- Saha, P., Ghorai, S., Tudu, B., Bandyopadhyay, R., ve Bhattacharyya, N. (2012). Multi-class SVM for quality estimation of black tea using electronic nose. *IEEE Sensors Journal*, 12(5), 1421-1428.
- Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support Vector Machines, regularization, optimization, and beyond*. MIT Press.
- Schuh, C., & Schieberle, P. (2006). Characterization of the key aroma compounds in the beverage prepared from Darjeeling black tea. *Journal of Agricultural and Food Chemistry*, 54(3), 916-924.
- Schütze, A., Baur, T., Leidinger, M., Reimringer, W., Jung, R., Conrad, T., ve Sauerwald, T. (2017). Highly sensitive and selective VOC sensor systems based on semiconductor gas sensors: How to? *Sensors*, 17(12), 2784.
- Sensortec, B. (2021). BME688 gas sensor with AI: Operating and calibration guidelines. Bosch Sensortec GmbH.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.
- Sohn, J. H., Atzeni, M., Janni, K., & Bacon, R. (2008). Quantification of odour and greenhouse gas emissions from pig barns using an electronic nose system. *Biosystems Engineering*, 101(4), 433-441.
- TE Connectivity. (2020). *Vacuum chamber engineering guidelines*.
- Tudu, B., Bhattacharyya, N., Bhuyan, M., Shaw, L., Bandyopadhyay, R., & Chatterjee, E. (2005). Multiclass classification of electronic nose data using support vector machine for tea quality evaluation. *IEEE Sensors Journal*, 5(6), 1350-1359.
- Theodoridis, S., & Koutroumbas, K. (2009). *Pattern recognition* (4th ed.). Academic Press.
- Van Boekel, M. A. J. S. (2008). Kinetic modeling of food quality: A critical review. *Comprehensive Reviews in Food Science and Food Safety*, 7(1), 144-158.
- Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer.
- Wang, C., Yang, J., & Wu, Q. (2022). GE-ELM combined with electronic nose for tea gas identification. *Measurement and Control*, 55(7-8), 746-756.
- Wang, L., & Fu, J. (2018). Chapter 5: Gas sensor calibration and drift compensation. In *Advanced gas sensing* (pp. 105-128). Woodhead Publishing.
- Wang, L. F., Lee, J. Y., Chung, J. O., Baik, J. H., So, S., & Park, S. K. (2008). Discrimination of teas with different degrees of fermentation by SPME-GC

- analysis of the characteristic volatile flavour compounds. *Food Chemistry*, 109(1), 196-206.
- Wang, X., Smith, K., & Hyndman, R. J. (2006). Characteristic-based clustering for time series data. *Data Mining and Knowledge Discovery*, 13(3), 335-364.
- Wang, Y., & Fu, J. (2018). Drift compensation in metal oxide gas sensors using dynamic subspace projection. *Sensors and Actuators B: Chemical*, 255, 2412-2423.
- Webb, A. R., & Copsey, K. D. (2011). *Statistical pattern recognition* (3rd ed.). Wiley.
- Wilson, A. D., & Baietto, M. (2009). Applications and advances in electronic-nose technologies. *Sensors*, 9(7), 5099-5148.
- Wright, L. P., & de Silva, H. N. (2018). Flavour chemistry of tea and coffee. In *Springer handbook of odor* (pp. 101-102). Springer.
- Wright, L. P., Mphangwe, N. I., Nyirenda, H. E., & Apostolides, Z. (2002). Analysis of the theaflavin composition in black tea by HPLC and correlation with quality tea tasters. *Journal of the Science of Food and Agriculture*, 82(5), 517-525.
- Yamazoe, N., & Shimanoe, K. (2008). New perspectives of gas sensor technology. *Sensors and Actuators B: Chemical*, 128(2), 566-573.
- Yang, Z., Baldermann, S., & Watanabe, N. (2013). Recent studies of the volatile compounds in tea. *Food Research International*, 53(2), 585-599.
- Yao, L., Jiang, Y., Caffin, N., D'Arcy, B., Datta, N., Liu, X., Singanusong, R., & Xu, Y. (2006). Phenolic compounds in tea from Australian supermarkets. *Food Chemistry*, 96(4), 614-620.
- Yu, H., & Wang, J. (2007). Discrimination of LongJing green tea grade by electronic nose. *Sensors and Actuators B: Chemical*, 122(1), 134-140.
- Yu, Y., Li, Q., Hua, Z., Yin, C., & Shi, Y. (2025). Global and local feature fusion network for tea quality identification. *Measurement*, 243, 116452.
- Zhou, Y., Chen, H., & Jiang, H. (2018). Aroma formation in black tea: Chemical composition and influence of processing. *Critical Reviews in Food Science and Nutrition*, 58(5), 865-879.