

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ELEKTRONİK BURUN İLE YİYECEKLERİ PİŞME DERECELERİNE
GÖRE SINIFLANDIRMA**

YÜKSEK LİSANS TEZİ

EDA NUR USTA

Mart 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ELEKTRONİK BURUN İLE YİYECEKLERİ PİŞME DERECELERİNE
GÖRE SINIFLANDIRMA**

Eda Nur USTA

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“ELEKTRONİK YÜKSEK MÜHENDİSİ”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 16.02.2024

Tezin Savunma Tarihi : 18.03.2024

Tez Danışmanı : Prof. Dr. Ayten ATASOY

Trabzon 2024

ÖNSÖZ

“Elektronik Burun İle Yiyecekleri Pişme Derecelerine Göre Sınıflandırma” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans programı kapsamında hazırlanmıştır.

Yüksek Lisans öğrenimim ve tez çalışmam boyunca danışmanlığımı üstlenen, gerek bilimsel faaliyetlerde gerekse diğer konularda beni destekleyerek yol gösteren ve her zaman yardımcı olan sayın Prof. Dr. Ayten ATASOY’a teşekkürlerimi en içten, saygı ve minnetle sunarım.

Tez çalışmasının deney aşamasında kullanılan ankastre fırının tedariki konusunda bizlere destek sağlayan Vestel Beyaz Eşya A.Ş.’ye teşekkür ederim.

Tez çalışmasının tüm sürecinde bana her zaman destek olan ve yol gösteren değerli Öğr. Gör. Ümit ÖZSANDIKCIOĞLU’na teşekkürlerimi sunarım. Ayrıca tüm eğitim hayatım boyunca yanımda destekçim olan aileme şükranlarımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Eda Nur USTA

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Elektronik Burun İle Yiyecekleri Pişme Derecelerine Göre Sınıflandırma” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Ayten ATASOY’un sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 18/03/2024

Eda Nur USTA

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER VE KISALTMALAR DİZİNİ	XII
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Literatür Taraması	1
1.3. Tezin Amacı ve Kapsamı	3
1.4. İnsan Burnu ve Koku Algısı.....	3
1.5. Elektronik Burun	3
2. MATERYAL VE METOD.....	5
2.1. Kullanılan Veri Seti.....	5
2.2. Elektronik Burun Devresi.....	5
2.3. Sensör Birimi.....	5
2.3.1. Metal Oksit Yarıiletken Gaz Sensörü	6
2.4. Elektronik Birim.....	7
2.5. Örüntü Tanıma Birimi	8
2.5.1. Ön İşleme	8
2.5.2. Öznitelik Çıkarımı.....	9
2.5.3. Normalizasyon	9
2.5.4. Sınıflandırma.....	10
2.6. Normalizasyon Yöntemleri	10
2.6.1. Z-Skor Normalizasyonu	11
2.6.2. Maksimum Normalizasyonu	11
2.6.3. Minimum-Maksimum Normalizasyonu.....	12
2.6.4. Sigmoid Normalizasyonu.....	12
2.7. Sınıflandırma Algoritmaları	12
2.7.1. Karar Ağacı Algoritması.....	13

2.7.2. Destek Vektör Makinesi (DVM) Algoritması	14
2.7.3. K-En Yakın Komşu Algoritması.....	15
2.7.4. Ratgele Orman Algoritması	16
3. YAPILAN ÇALIŞMALAR.....	18
3.1. Elektronik Burun Denet Düzenegi	18
3.1.1. Koku İletimi	19
3.1.2. Vakum Pompası	20
3.1.3. Kontrol Arayüz Devresi: Röle Kartı	21
3.1.4. MOS Sensörler ve Sensör Haznesi	22
3.1.5. Veri Toplama Kartı (DAQ Kart).....	23
3.2. Elektronik Burun Deney Aşaması.....	24
3.3. Veriye Ön İşlem Uygulanması.....	26
3.4. Öznitelik Çıkarımı.....	29
3.5. Verilere Uygulanan Normalizasyon ve Sınıflandırma Algoritmaları	33
4. BULGULAR VE TARTIŞMA.....	34
5. SONUÇLAR.....	43
6. KAYNAKLAR.....	44
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

ELEKTRONİK BURUN İLE YİYECEKLERİ PİŞME DERECELERİNE GÖRE SINIFLANDIRMA

Eda Nur USTA

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik- Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Ayten ATASOY
2024, 46 Sayfa

Günlük hayatta en çok kullanılan pişirme yöntemlerinden biri de fırında pişirmektir. Bu yöntem ile yiyeceklerin besin değerlerini daha az kaybediyor olması ve diğer yöntemlere göre daha sağlıklı ve pratik olması sebebiyle oldukça tercih edilmektedir. Bu çalışmada ise fırında pişirilen yiyeceklerin pişme derecelerinin takibini kolaylaştırabilmek ve yiyeceklerin aşırı pişmesini önlemek adına araştırmalar yapılmıştır.

Bu tez çalışmasında; ankastre fırında pişirilen kek, börek, istavrit balığı ve somon balığı olmak üzere 4 çeşit yiyecek, 8 adet MOS Metal Oksit Yarı iletken sensör kullanılarak tasarlanan elektronik burun devresi ile pişme derecelerine göre az pişmiş, pişmiş ve çok pişmiş olmak üzere 3 sınıfta sınıflandırılmıştır. Fırında pişirilen yiyeceklerin kokusu sensörler yardımı ile algılanarak elektriksel işaretlere dönüştürülmüştür. Bu elektriksel işaretler veri toplama kartı yardımıyla kaydedilmiş ve bilgisayar ortamında sayısallaştırılmıştır. Elde edilen işaretlere ilk olarak ön işleme uygulanmış ve öznitelik çıkarımı yapılmıştır. Daha sonra öznitelik verilerine z-skor, maksimum, minimum-maksimum ve sigmoid olmak üzere 4 farklı normalizasyon yöntemi uygulanmıştır. Farklı normalizasyon yöntemlerinin sınıflandırmaya etkisini test etmek amacıyla normalizasyon uygulanmayan ve uygulanan veriler karar ağacı, k-en yakın komşu, destek vektör makineleri ve rastgele orman algoritmaları kullanılarak sınıflandırılmıştır. 5-katlı çapraz doğrulama yöntemi ile sınıflandırma doğrulukları incelenmiş ve başarı yüzdeleri karşılaştırılmıştır.

Anahtar Kelimeler: Elektronik burun, metal oksit yarı iletken gaz sensörleri, normalizasyon, sınıflandırma.

Master Thesis

SUMMARY

CLASSIFYING FOOD ACCORDING TO THEIR COOKING DEGREE WITH ELECTRONIC NOSE

Eda Nur USTA

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Ayten ATASOY
2024, 46 Pages

One of the most commonly used cooking methods in daily life is baking in the oven. This method is highly preferred because food loses less nutritional value and is healthier and more practical than other methods. In this study, research was conducted to make it easier to follow the cooking levels of oven-baked foods and to prevent overcooking of foods.

In this thesis study; 4 types of food, including cakes, pastry, horse mackerel and salmon, cooked in the built-in oven, are classified into 3 classes: undercooked, cooked and overcooked, according to their cooking degrees, with the electronic nose circuit designed using 8 MOS Metal Oxide Semiconductor sensors. The smell of the food cooked in the oven is detected with the help of sensors and converted into electrical signals. These electrical signals were recorded with the help of a data acquisition card and digitized in a computer environment. First, pre-processing was applied to the obtained signals and feature extraction was made. Then, 4 different normalization methods were applied to the feature data: z-score, maximum, minimum-maximum and sigmoid. In order to test the effect of different normalization methods on classification, data without and with normalization were classified using decision tree, k-nearest neighbors, support vector machines and random forest algorithms. Classification accuracies were examined with the 5-fold cross-validation method and success percentages were compared.

Key Words: Electronic nose, metal oxide semiconductor gas sensors, normalization, classification.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.	İnsan burnu ve elektronik burundaki koku algılama sistemleri..... 4
Şekil 2.	Çalışmada kullanılan MOS sensörlere ait temel ölçüm devresi 7
Şekil 3.	Sensörlerden elde edilen verilere uygulanan işlemler 8
Şekil 4.	Örnek karar ağacı algoritması..... 14
Şekil 5.	Örnek destek vektör makinesi algoritması 15
Şekil 6.	k-EYK algoritması kullanılarak test verisinin sınıflandırılması..... 16
Şekil 7.	Örnek rastgele orman algoritması..... 17
Şekil 8.	E-burun deney düzeneği 18
Şekil 9.	Deney düzeneğinde kullanılan selenoid valf 20
Şekil 10.	Deney düzeneğinde kullanılan vakum pompası 20
Şekil 11.	Deney düzeneğinin ve valflerin kontrolünün sağlayan röle kartı..... 21
Şekil 12.	Deney düzeneğinde kullanılan sensör haznesi. 23
Şekil 13.	Deney düzeneğinde kullanılan veri toplama kartı. 24
Şekil 14.	Bir deney süresince sensör tepkilerinin değişimi 25
Şekil 15.	Elektronik burun devresinden alınan (a) işlenmemiş gerilim verisi ve (b) referansı düzenlenmiş gerilim verisi. 26
Şekil 16.	Kullanılan sensörlere ait iletkenlik verisi 27
Şekil 17.	Börek için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri. 27
Şekil 18.	Kek için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri. 28
Şekil 19.	Somon balığı için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri 28
Şekil 20.	İstavrit balığı için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri. 29
Şekil 21.	Börek yiyeceğinin pişirilmesi süresince TGS826 ve TGS2620 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi 30
Şekil 22.	Kek yiyeceğinin pişirilmesi süresince TGS826 ve TGS2620 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi 31
Şekil 23.	Somon balığının pişirilmesi süresince TGS826 ve TGS2602 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi 31
Şekil 24.	İstavrit balığının pişirilmesi süresince TGS826 ve TGS2602 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi 32
Şekil 25.	Normalizasyon işlemi uygulanmayan börek verisinin sınıflandırma doğruluğuna ait hata matrisi 35

Şekil 26.	Z-skor normalizasyonu uygulanan börek verisinin sınıflandırma doğruluğuna ait hata matrisi.	36
Şekil 27.	Normalizasyon işlemi uygulanmayan kek verisinin sınıflandırma doğruluğuna ait hata matrisi.	37
Şekil 28.	Minimum-Maksimum normalizasyonu uygulanan kek verisinin sınıflandırma doğruluğuna ait hata matrisi	38
Şekil 29.	Normalizasyon işlemi uygulanmayan somon balığı verisinin sınıflandırma doğruluğuna ait hata matrisi	39
Şekil 30.	Sigmoid normalizasyon yöntemi uygulanan somon balığı verisinin sınıflandırma doğruluğuna ait hata matrisi	40
Şekil 31.	Normalizasyon işlemi uygulanmayan istavrit balığı verisinin sınıflandırma doğruluğuna ait hata matrisi	41
Şekil 32.	Z-skor normalizasyonu uygulanan istavrit balığı verisinin sınıflandırma doğruluğuna ait hata matrisi	42

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Gaz türlerine göre sensörlerdeki direnç değişimi	6
Tablo 2. Hata matrisi.....	13
Tablo 3. Bir deney süresince valflerin durumları	21
Tablo 4. MOS sensörlerin özellikleri	22
Tablo 5. Çalışma boyunca pişirme deneyi yapılan yiyeceklerin pişirme süreleri ve dereceleri.....	24
Tablo 6. Pişirilen börek verisine ait sınıflandırma başarılarının yüzdeleri	34
Tablo 7. Pişirilen kek verisine ait sınıflandırma başarılarının yüzdeleri	37
Tablo 8. Pişirilen somon balığı verisine ait sınıflandırma başarılarının yüzdeleri	39
Tablo 9. Pişirilen istavrit balığı verisine ait sınıflandırma başarılarının yüzdeleri	41

SEMBOLLER VE KISALTMALAR DİZİNİ

MOS	: Metal Oksit Yarıiletken
k-EYK	: K En Yakın Komşu
DVM	: Destek Vektör Makinesi
TGS	: Taguchi Gaz Sensörü
DAQ	: Veri Toplama Ünitesi
ρ	: İletkenlik
R_L	: Sensör Yük Direnci
R_S	: Sensör Direnci
V_C	: Sensör Besleme Gerilimi
V_{RL}	: Yük Direnci Gerilimi
$G_{n,s}^R$	: Sensöre ait iletkenlik verisi
μ	: Ortalama
σ	: Standart Sapma
e	: Euler Değeri
x'	: Normalize Edilmiş Veri

1. GENEL BİLGİLER

1.1. Giriş

İnsan burnundaki alıcılar, aynı kokuya farklı tepkiler gösterir; bir koku algılandığında koku molekülleri alıcılarla etkileşim göstererek beyne sinyal ilettiğinde koku tanınır yorumlanır. Beynin çok sayıdaki algılayıcı sinire sahip olması ile kimyasal moleküllerden oluşan tanımlamayı ayırt edebilme yeteneği gerçekleşir. İnsan burnu, kokuya karşı çok duyarlı olmasına rağmen bir ortamda aynı koku ile belirli bir süre geçirilince bu kokuyu ayırt etme özelliği zayıflar ve temiz hava alındıktan sonra tekrar ayırt edilebilir. İnsan burnundaki bu özellik nedeniyle, bilim insanları kokuların belirlenmesi, değerlendirilmesi ve tanımlanması işlemlerinin tekrarlanabilir ve tarafsız olabilmesi amacıyla bu işlevleri gerçekleştirecek cihazlar yapmaya yönelmiştir ve Elektronik Burunlar tasarlanmıştır (Usta vd., 2023). Elektronik burun, kokuları algılamayı amaçlayan elektronik bir algılama cihazıdır. Elektronik algılama, sensör dizileri ve örüntü tanıma sistemlerini kullanarak insan duyularını yeniden üretme kabiliyetini ifade eder. Elektronik burun devreleri sensör birimi, elektronik birim ve örüntü tanıma birimi olmak üzere üç bölümden oluşmaktadır. Sensör biriminde tanınmak istenen kokunun içerdiği kimyasal bileşenlere göre sensör tepkileri elde edilir. Elektronik birimde dönüştürücü ve osilatör devreleri ile elektriksel işaretler üretilir. Örüntü tanıma biriminde ise kokunun tanımı yapılır (Özsandıkçıoğlu vd., 2015)

Bu çalışmada, elektronik burun kullanılarak ankastre fırında pişirilen yiyeceklerin aşırı pişirme durumlarının tespit edilmesi amaçlanmıştır. Aşırı pişirme, yiyeceklerin lezzet ve besin değerini olumsuz etkileyebilir ve bu durumun önlenmesi önemlidir.

1.2. Literatür Taraması

Elektronik burun günümüzde gıda, sağlık, kozmetik ve tarım gibi birçok alanda kullanılmaktadır. En yaygın uygulama alanlarından biri olan gıda sektöründe ise et, meyve, balık gibi ürünlerin tazeliğinin testi, çeşitli gıdaların ayırımı ve analizinde kullanılmaktadır.

Yapılan bir çalışmada E-burun kullanılarak balık tazeliğini sınıflandırmak için bir sistem tasarlanmıştır. 5 Katlı Çapraz Doğrulama yöntemi kullanılmış ve maksimum başarı oranı %98,94 olarak elde edilmiştir (Özsandıkçıoğlu vd., 2015).

Yapılan bir diğer çalışmada satılan et ve balıkların tazeliğini belirlemek için E-burun sistemi tasarlanmıştır. Elektronik burun üç model sınıflandırma algoritması (yapay sinir ağı,

destek vektör makinesi ve k-en yakın komşu) kullanarak test edilmiştir ve bunlar doğruluk, hassasiyet ve özgüllük temelinde karşılaştırılmıştır. Sonuçlar, k-en yakın komşu algoritmasının en yüksek doğruluğa sahip olduğunu göstermektedir (Hasan vd., 2012).

Amerika’da yapılan bir çalışmada ise uçucu organik bileşiklerin (gıdalar, bakteriler ve bitkiler gibi çeşitli gruplar tarafından yayılan kimyasallar) tespiti ve sınıflandırılması için çoklu metal oksit gaz sensörleri ve makine öğrenimi algoritmaları kullanan, taşınabilir, pille çalışan bir elektronik burun sistemini geliştirilmiştir. Bu çalışmada dört farklı şarap örneği ve üç farklı yağ örneği sınıflandırıldı ve eğitim modeli, hata matrisi analizine göre sırasıyla %100 ve %98 doğruluk elde edildi. Eğitilmiş model yeni veri setleriyle karşılaştırıldığında, Destek Vektör Makinesi (DVM) sınıflandırıcı kullanıldığında şarap testi için sırasıyla %98.5 ve %98.6’lık, yağ testi için ve %96.3 ve %93.3’lük duyarlılık ve hassasiyet elde edildi (Huang vd., 2021).

Elektronik burun kullanılarak yapılan başka bir çalışmada tasarlanan elektronik burun ile günümüzde yaygın olarak kullanılan Arabika ve Robusta türü kahvelerin ayrımlarının yapılması hedeflenmiştir. Bu doğrultuda 7 adet MQ sensörleri kullanılarak elektronik burun tasarlanmış ve kahveler analiz edilmiştir. Çalışma sonucunda Arabika ve Robusta kahvelerinin ayrımının en iyi sınıflandırma sonucu karar ağacı algoritması ile elde edilmiştir. (İncegöl & Taşdelen, 2021).

Ekmek pişirme işleminin farklı aşamalarına özgü temel aromaların tespiti amacıyla yapılan çalışmada elektronik burun, hedef uygulama olarak seçilmiştir. Önerilen elektronik burnun, bu uçucuları, farklı pişirme adımlarını yansıtacak şekilde düzenli bir şekilde ayırmaya uygunluğunu ortaya koymak amaçlanmıştır. Çalışmada 4 adet metal oksit gaz sensörü kullanılmıştır. Çalışmada önerilen elektronik burnun, ekmek pişirme sürecindeki temel aromaları öncelikle kimyasal yapılarına bağlı olarak ayırt etme yeteneği kanıtlanmıştır (Ponzoni vd., 2008).

Bisküvilerin pişirme işlemi sırasındaki ana fiziko-kimyasal değişikliklerin farklı pişirme sürelerinde (0, 2, 4, 6, 8, 10, 12 dakika) izlendiği çalışmada bisküvilerin nem içeriği, yüzey renkleri ve dokuları ölçülmüştür. Bisküvilerin aroma salınımının algılanması, 10 metal oksit sensörüyle tasarlanan bir elektronik burun aracılığıyla gerçekleştirilmiştir. Elektronik burun, çiğ, az pişmiş, iyi pişmiş ve fazla pişmiş bisküviler arasında ayırım yapılmasına olanak sağlamıştır. Elde edilen sonuçlar, basitleştirilmiş gaz sensörü dizisine sahip bir elektronik burun kullanılarak bisküvinin aromasındaki ve pişme seviyesindeki

değişikliklerin işlem sırasında doğrudan izlenmesinin mümkün olabileceğini göstermiştir. (Romani vd., 2012)

1.3. Tezin Amacı ve Kapsamı

Yapılan araştırmalar sonucunda elektronik burun devreleri kullanılarak birçok gıdanın tazeliğinin, kalitesinin veya aynı tür gıdaların birbirinden ayrıştırılabilmesinin sağlandığı tespit edilmiştir. Ayrıca pişirilen gıdalardan alınan aromalar yardımıyla yiyeceklerin pişirme derecelerine göre sınıflandırıldığı çalışmalar da yapılmıştır. Bu tez çalışmasında ise fırında pişirilen farklı türden yiyeceklerin pişme derecelerine göre sınıflandırılması ve aşırı pişmelerinin önlenmesi amaçlanmıştır.

Çalışmada elektronik burun kullanılarak tasarlanan veri seti, bu veri setinin çalışma prensibi, verilerin elde edilmesi, analizi ve sınıflandırılması anlatılmıştır.

1.4. İnsan Burnu ve Koku Algısı


Koku algısı, insan burnunda bulunan koku soğancığındaki reseptörlerin buruna giren moleküller tarafından uyarılmasıyla başlar. Reseptörler tarafından üretilen elektriksel sinyaller nöronların uyarılmasını ve beyne bilgi aktarılmasını sağlar (Chong vd., 2020). İnsan beyninin ayırt edebilme özelliği algılayıcı sinirler ile gerçekleşir.

İnsan burnu koku algılama bakımından çok duyarlı olsa da koku algısı oluşumunda birden fazla reseptörün bulunması ve reseptörlerin farklı sıra veya zamanlama ile uyarılması aynı koku için farklı algılar oluşmasına neden olur. Bir ortamda aynı kokuya maruz kalan insan burnunun belirli bir süre sonra bu kokuyu ayırt edebilme yeteneği zayıflar ve temiz hava alındıktan sonra tekrar kokuyu ayırt edebilir. İnsan burnundaki bu özellikler nedeniyle, bilim insanları kokuların belirlenmesi, değerlendirilmesi ve tanımlanması işlemlerinin tekrarlanabilir ve tarafsız olabilmesi amacıyla bu işlevleri gerçekleştirecek cihazlar yapmaya yönelmiştir ve Elektronik Burunlar tasarlanmıştır.

1.5. Elektronik Burun

İnsan koku alma sistemini taklit ederek çalışan elektronik burunlar üç ana kısımdan oluşmaktadır. Sensör ünitesi, elektronik buruna uygulanan kimyasal bileşenlerin özelliklerine bağlı olarak elektrik sinyalleri üretir. Sisteme koku gelmesi durumunda sensör

ünitesindeki sensör tipine göre sensörlerin kapasitansları, iletkenlikleri veya frekansları değişir. Tespit edilecek uçucu organik bileşikler için en hassas sensörler seçilerek hedef gazlar daha doğru algılanabilmektedir (Pearce vd., 2002). Transformatörler, filtreler ve osilatör devrelerinden oluşan elektronik ünite, elektrik sinyallerinin elde edildiği kısımdır. Son ünite ise örüntü tanıma kısmıdır. Bu işlem, elektrik sinyallerinden belirlenen özellikler kullanılarak kokuların tanımlanması ve sınıflandırılması olarak tanımlanmaktadır. (Demir, 2021). Şekil 1’de insan koku algılama sisteminin kısımları ve buna karşılık gelen elektronik burundaki koku algılama kısımları gösterilmiştir.



Şekil 1. İnsan burnu ve elektronik burundaki koku algılama sistemleri

2. MATERYAL VE METOD

2.1. Kullanılan Veri Seti

Günlük hayatta kullanılan ankastre fırınlarda pişirilen yiyecekler diğer pişirme yöntemleri ile pişirilen yiyeceklerle kıyaslandığında bu yöntemle yiyeceklerin besin değerlerini daha az kaybetmeleri, daha lezzetli ve sağlıklı olmaları nedeniyle oldukça tercih edilmektedir. Ayrıca fırında pişirme yönteminin diğer yöntemlere göre daha kolay olduğu da söylenebilir. Bu çalışmada ise fırında pişirilen yiyeceklerin pişme derecelerinin takibini kolaylaştırabilmek ve yiyeceklerin aşırı pişmesini önlemek adına araştırmalar yapılmıştır.

Çalışma boyunca Dr. Oetker'in sade kek karışımı ile hazırlanan kek, Superfresh'in peynirli tepsi böreği, istavrit balığı ve somon balığı olmak üzere 4 farklı yiyecek kullanılmış ve Vestel ankastre fırında pişirilmiştir. Bu deneyler sonucu elde edilen veriler az pişmiş, pişmiş ve fazla pişmiş olarak 3 sınıfta sınıflandırılmıştır.

2.2. Elektronik Burun Devresi

Elektronik burun, insan burnunun algılayamadığı kokular için hassas ölçümler yapan ve kimyasal sensör dizisinden oluşan cihazdır (Saraoğlu, 2008). Elektronik burun devreleri sensör birimi, elektronik birim ve örüntü tanıma birimi olmak üzere üç bölümden oluşmaktadır. Sensör biriminde tanınmak istenen kokunun içerdiği kimyasal bileşenlere göre sensör tepkileri elde edilir. Elektronik birimde dönüştürücü ve osilatör devreleri ile elektriksel işaretler üretilir. Örüntü tanıma biriminde ise kokunun tanımı yapılır (Özsandıkçıoğlu vd., 2015)

2.3. Sensör Birimi

Elektronik burun devresi sensör biriminde koku bilgisini alıp elektriksel sinyallere dönüştüren kimyasal sensörler kullanılır. Kullanılan sensörler farklı amaçlar ve teknolojiler için çeşitli tiplerde tasarlanan gaz sensörleridir. Bu sensörlerden, kimya, tıp, gıda ve ziraat alanında yaygın olarak kullanılan ve iletkenlik ölçümüne bağlı olarak çalışan metal oksit yarı iletken gaz sensörleri (MOS); ucuz, portatif ve sağlamdır, ayrıca hızlı tepki verirler (İncegül vd., 2022). Bu tez çalışmasında 8 adet MOS Metal Oksit Yarıiletken sensör kullanılmıştır.

2.3.1. Metal Oksit Yarıiletken Gaz Sensörü

Metal oksit yarı iletken sensörleri (MOS); elektronik, optik, fiziksel ve kimyasal özelliklerinden dolayı çok tercih edilmektedir. MOS sensörler maliyetlerinin düşük olması, basit yapıda olmaları, yüksek hassasiyete sahip olmaları ve modern elektronik cihazlara uyum sağlamaları nedeniyle sensör alanında yaygın bir kullanım sahasına sahiptirler (İncegöl vd., 2022). Yaygın olarak kullanılan bu gaz sensörlerin duyarlılıklarının nem, sıcaklık, kimyasal kompozisyon gibi dış etmenlerden etkilenmeleri dezavantajlarındanır (Kazdal, 2022).


MOS yapıdaki sensörler, herhangi bir gaz ile oksidasyon veya indirgemeye uğrayarak tepkime veren yapılar olarak tasarlanır (Kazdal, 2022). MOS sensörlerde oksitin iletkenliğinin değişimi sensör içerisindeki oksit materyallerin, oksijen tiplerini kimyasal olarak yüzeye çekmesi ve bunun sonucunda oksitlerin metaloksit yüzeydeki gaz molekülleri ile tepkimeye girmesiyle gerçekleşir. Direnç değişimi ise, sıcaklığa, metal oksit granülün büyüklüğüne ve yarıiletken yüzeydeki oksijen ile tepkimeye giren uçucu gazlara bağlıdır. (Beyhan & Çetin, 2019). MOS sensörler elektriksel direnç tepkilerine göre n-tipi ve p-tipi olmak üzere iki gruba ayrılır (Arshak vd., 2004). Okside edici gaz olan kükürt dioksit ve oksijen p-tipi sensörlerde rezistansta azalışa, n-tipinde ise artışa neden olur. İndirgeyici gaz olan karbon monoksit, etanol ve hidrojen ise rezistansın p-tipi sensörlerde artışına, n-tipi sensörlerde azalışına neden olur (Gao & Zhang, 2018). İlgili gazların sensör tipleri üzerindeki dirençlere etkisi Tablo 1’de verilmiştir.

Tablo 1. Gaz türlerine göre sensörlerdeki direnç değişimi

<i>Gaz Türü</i>	<i>N-tipi yarı iletken sensör (ZnO, SnO₂, TiO₂, WO₃, In₂O₃)</i>	<i>P-tipi yarı iletken sensör (Cu₂O, Co₃O₄, Cr₂O₃, Mn₃O₄, NiO)</i>
<i>İndirgeyici gazlar (H₂, CO, CH₄, etanol, aseton)</i>	Azalır	Artar
<i>Okside edici gazlar (O₂, O₃, NO_x, SO₂)</i>	Artar	Azalır

2.4. Elektronik Birim

Elektronik birimde MOS sensörler ile elde edilen veriler dönüştürücü ve osilatör devreleri ile elektriksel işaretlere dönüştürülür. Sensörlerde algılanan gaz, sensörde bir değişikliğe neden olur. Bu değişiklik, sensörün çalışma prensibine bağlı olarak direnç, gerilim, akım veya diğer elektriksel özelliklerde bir değişiklik olabilir. Sensördeki bu fiziksel değişiklik, elektriksel bir sinyale dönüştürülür. Bu çalışmada kullanılan MOS sensörde, gazın etkileşimiyle sensör direncinde bir değişiklik meydana gelir ve bu direnç değişikliği bir gerilim sinyaline dönüştürülerek okunur. Çalışmada kullanılan MOS sensörlere ait temel ölçüm devresi Şekil 2’de gösterilmiştir.



Şekil 2. Çalışmada kullanılan MOS sensörlere ait temel ölçüm devresi (Figaro TGS 2620 Sensör Kataloğu, 2024)


Şekil 2’ de verilen temel ölçüm devresine V_C sensör besleme gerilimi uygulanır. V_H sensör ısıtıcı gerilimi ile sensör ısınır ve çalışması için belirli bir sıcaklığa ulaşır, R_H sensör içinde bulunan dahili ısıtıcı direncini temsil etmektedir. R_S uygulanan kokunun yoğunluğuna ve kokuya ne kadar maruz kaldığına bağlı olarak değişen sensör direncidir. R_S direncinin artıp azalmasına bağlı olarak sensörlere seri bağlı yük direnci olan R_L ve bu yük direnci üzerinde oluşan gerilim olan V_{RL} değişir. Bu değişim kokunun yoğunluğu hakkındaki bilgiyi verir. Sensöre ait iletkenlik ve R_L yük direnci üzerinde oluşan gerilim değerlerinin hesabı eşitlik 1 ve 2 de verilmiştir.

$$\rho = \frac{1}{R_L} = \frac{I_S}{V_S} = \frac{V_{RL}/R_L}{V_C - V_{RL}} \quad (1)$$

$$V_{RL} = \frac{(V_C - V_{RL})}{V_{RL}} \times R_L \quad (2)$$

2.5. Örüntü Tanıma Birimi

Elektronik birimde elde edilen elektriksel sinyaller daha sonra örüntü tanıma birimine iletilir. Bu birim, algılanan sinyalleri analiz eder, desenleri tanır ve belirli gaz veya kimyasalları tanımlamak için kullanılan algoritmaları uygular. Özetle elde edilen elektriksel sinyallerin sayısal işaretlere dönüştüğü ve bilgisayarda işlendiği birimdir. Sensörler tarafından algılanan kokunun tanınması için ilk olarak kokulara ait özellikler ile sistem eğitilir. Bir koku için verilen çeşitli tepkiler o kokuya ait işaret sınıfını oluşturur. Bu özelliklerin ortaya çıkarılması ve kokunun tanınması için bu tez çalışmasında koku verilerinin geçeceği bazı aşamalar Şekil 3’te verilmiştir.



Şekil 3. Sensörlerden elde edilen verilere uygulanan işlemler

Şekilde de gösterildiği gibi örüntü tanıma biriminde sırasıyla ön işleme işlemleri, öznitelik çıkarımı, normalizasyon işlemi ve sınıflandırma yapılmaktadır. Tüm bu işlemler sonucunda alınan kokunun az pişmiş, pişmiş ve fazla pişmiş olarak sınıflandırması yapılmış olacaktır.

2.5.1. Ön İşleme

Elektronik burun devresinde MOS sensörler ile elde edilen ve sayısal işarete dönüştürülen verilerinden öznitelikler çıkarılmadan önce sınıflandırma başarısını artırmak ve verilerin daha iyi yorumlanabilmesi sağlamak için referans düzeltme işlemi uygulanır. Bu yöntemle birlikte sensörlere yemek kokusunun gönderilmeye başlandığı andaki gerilim değeri eşitlik (3) kullanılarak sıfır eksenine çekilir ve veri görsel olarak düzenlenir.

$$v_{n,s,r}(t) = v_{n,s}(t) - v_{n,s}(0) \quad (3)$$

(3) eşitliğinde $v_{n,s}(t)$ ham sensör verilerini, $v_{n,s}(0)$ sensörlere yemek kokusu iletildiği ilk anda elde edilen sensör verilerini ve $v_{n,s,r}(t)$ referansı düzeltilmiş sensör verilerini ifade etmektedir. Elde edilen gerilim verileri sensörlere seri bağlı yük direnci üzerindeki gerilim olduğundan veri işleme ve veri sınıflandırma açısından sensörlerle doğrudan ilgili bilgileri kullanmak elektronik burun çalışmaları konusunda çalışanlara daha doğru bilgi sağlamaktadır. Bu nedenle bu çalışma kapsamında da gerilim verisi literatürde sıklıkla kullanılan (4) eşitliği ile sensör iletkenlik verisine dönüştürülmüştür.

$$G_{n,s}^R(t) = \frac{v_{n,s,r}(t)}{(V_c - v_{n,s,r}(t))R_{L,s}} \quad (4)$$

(4) eşitliğinde V_c sensörlerin besleme gerilimini, $R_{L,s}$ MOS sensörlere seri bağlı direnç değerlerini ve $G_{n,s}^R(t)$ sensörlere ait iletkenlik verisini göstermektedir.

2.5.2. Öznitelik Çıkarımı

Öznitelik çıkarımı veri setlerindeki bilgiyi daha anlamlı ve işlenebilir hale getirerek, model eğitimi ve analiz süreçlerini geliştirmeye yardımcı olur. Ön işleme aşamasından geçen koku verilerinden öznitelik çıkarma işlemi yapılır. Öznitelik çıkarımının iyi olması farklı kokuların birbirinden ayrılmasının yani sınıflandırma başarısının da iyi olmasını sağlar (Kazdal, 2022). Yani her farklı koku için farklı özniteliklerin tespiti önemlidir. Sayısal işaretlerin maksimum, ortalama, varyans, eğrilik, alan gibi birçok özelliği öznitelik çıkarımı olarak kullanılabilir. Öznitelik seçiminde, çalışmada işlenen her bir koku verisi için bu özelliklerden sınıflandırma aşamasında belirleyici nitelik taşıyanlar tercih edilir.

2.5.3. Normalizasyon

Normalizasyonun amacı büyük boyutlu verilerde veri tekrarlarının ortadan kaldırılması, verinin doğruluğunun artırılması ve böylece verilerin eğitime uygun hale getirilmesidir. Veri seti içerisinde boyutları birbirinden farklı birçok özellik bulunur. Burada boyutu büyük olan özellikler sınıflandırma adımı daha büyük ağırlığa sahip olurken daha küçük boyutlu özellikler daha küçük ağırlığa sahip olabilir. Buna istinaden gerçek doğru

sınıf hatalı belirlenebilir. Veri setindeki her bir özelliğin yaklaşık olarak aynı boyutta ve etkiye olması bu hatanın ortadan kalmasını sağlar. Bunların dışında kullanılan veri setinden özellik çıkarımı yapıldıktan sonra elde edilen verinin boyutu da büyük olabilir. Yani veri seti içerisinde gürültülü, ilgisiz ve fazla özellikler de olabilir. Bu durumda sınıflandırma işleminde sınıflama performansı azalabilir, hesaplama maliyetini artabilir ve sonuçların doğruluk değeri düşebilir (Yüce & Özkan, 2021). Bu nedenle normalizasyon, ilk seçilen aralıktaki özelliklerin değerlerini belirli aralıklara getirmek için faydalı bir yöntemdir. Veri normalizasyonunun literatürde kullanılan Z-Skor, Minimum-Maksimum, Maksimum, Ondalık Ölçekleme gibi birçok yöntemi bulunmaktadır.

2.5.4. Sınıflandırma

Veri sınıflandırma, veri noktalarını farklı sınıflara ayırarak veri setinin yapısını anlamayı ve veri noktalarının ait olduğu sınıfı belirlemeyi sağlar. Ön işleme, öznitelik çıkarımı ve normalizasyon adımlarından sonra elde edilen veriler son olarak sınıflandırma adımıyla tanınır. Böylece pişirilen yiyeceklerin sensörler yardımı ile alınan kokularından hangi pişme aşamasında oldukları tespit edilir.

2.6. Normalizasyon Yöntemleri

Normalizasyon ile belirli bir boyuttaki veri seti bir uzaydan başka bir uzaya taşınır. Bu taşıma işleminde veri setinin boyutu değişmezken maksimum ve minimum noktalarının değerleri değişir (Akdemir, 2009). Burada normalize edilen veri ile sınıflandırıcının kararlılığı ve doğruluğu artabilir (Yüce & Özkan, 2021). Her veri seti için normalizasyon yöntemlerinin uygulanması gerekli değildir. Veri seti içinde kullanılan özelliklerin farklı aralıklara sahip olması durumunda normalizasyon işlemi uygulanır.

Normalizasyonun işleminin uygulanmasına karar verildikten sonra önemli olan bir diğer konu ise hangi normalizasyon yönteminin kullanılması gerektiğidir. Kullanılan veri setlerindeki özelliklerin ölçüt değerlerinin birimleri birbirinden farklı olabilir veya içerisinde sayısal olarak ifade edilemeyen özellikler bulunabilir. Örneğin; az-çok, iyi-kötü ya da (+) ve (-) gibi. Böyle durumlarda bu özelliklerin de sayısal olarak ifade edilmesi gerekir (Akdemir, 2009).

Tüm normalizasyon yöntemlerinde veri setinde bulunan farklı özellikler birbirinden bağımsız olarak normalize edilir ancak hepsi birbirinden ayrı olarak normalize edildiği için maksimum ve minimum değerleri aynı olur ve aynı aralıkta normalize edilmiş olur.

Bu tez çalışması kapsamında kullanılan normalizasyon yöntemleri; Z-Skor Normalizasyonu, Maksimum Normalizasyonu, Minimum-Maksimum Normalizasyonu ve Sigmoid Normalizasyonudur.

2.6.1. Z-Skor Normalizasyonu

Veri setindeki değişkenlik ile varyansın düzenlenmesi ve dengeye getirilmesi için uygulanan yöntemdir. Z-skor istatistik değerlendirilmelerde yaygın kullanılan bir normalizasyon yöntemidir. Bu yöntemin kullanılabilmesi için ilk olarak ortalama ve standart sapma değerlerinin hesaplanması gerekir. Z-skor normalizasyon yönteminde veriye ait hesaplanan ortalama değeri ile bu verinin ortalama değere uzaklığı kullanılarak yeni değerler hesaplanır (Standard score, 2024). Bu yöntem ile bir özelliğin ortalama değere ne kadar uzak olduğunu standart sapma birimiyle ifade eder ve eşitlik (5) ile hesaplanır.

$$x' = \frac{x - \mu}{\sigma} \quad (5)$$

Burada x' normalize edilen veriyi, x veri değerini, μ özelliğin ortalamasını ve σ standart sapmayı verir. Z-skorları hesaplandığında, her özellik aynı ortalamaya (0) ve aynı standart sapmaya (1) sahip olur.

2.6.2. Maksimum Normalizasyonu

Maksimum normalizasyon yöntemi (6) nolu eşitlik ile gerçekleştirilmektedir.

$$x' = \frac{x_i}{x_{max}}, x_{max} = \max x_i \quad (1 \leq i \leq N) \quad (6)$$

Burada x' normalize edilen veriyi, x_i veri değerini ve x_{max} maksimum değeri verir. Maksimum pozitif değer ile minimum negatif değer çok küçük olduğunda ((-10,0.1) gibi), farkı artırmak mümkündür ve normalize edilmiş değer aralığı daha büyük olabilir (Li & Liu, 2011).

2.6.3. Minimum-Maksimum Normalizasyonu

Minimum-Maksimum yöntemi, verileri doğrusal olarak normalize eden bir algoritmadır. Minimum; girdi verisinin alabileceği en düşük değer iken, maksimum; girdi verisinin alabileceği en yüksek değeri ifade eder. Bir veriyi Min-Max yöntemi ile belirli bir aralığa indirmek için (7) nolu eşitlik kullanılır (Yavuz & Deveci, 2012).

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (7)$$

Burada x' normalize edilen veriyi, x_i veri değerini, x_{min} minimum değeri ve x_{max} maksimum değeri verir. Min-max normalizasyonu uygulandığında her özellik yeni değer aralığında yer alacak ve aynı kalacaktır (Jayalakshmi & Santhakumaran, 2011).

2.6.4. Sigmoid Normalizasyonu

Sigmoid normalizasyon fonksiyonu, örnekleri 0 ile 1 veya -1 ile +1 aralığında ölçeklendirmek için kullanılır. Doğrusal olmayan sigmoid fonksiyonların çeşitli türleri mevcuttur. Bu yönteme ait denklem (8) nolu eşitlikte verilmiştir.

$$x' = \frac{e^{x_i} - e^{-x_i}}{e^{x_i} + e^{-x_i}} \quad (8)$$

Burada x' normalize edilen veriyi, x_i veri değerini vermektedir.

2.7. Sınıflandırma Algoritmaları

Veri madenciliğinin temel yöntemlerinden biri olan sınıflandırma yöntemi, öğrenme algoritmasına dayanmaktadır. Büyük ölçekli veri setlerinde gizli olan örüntü yapısını bulmak için kullanılır. Örüntü kavramı veri içerisinde gözlemlenebilir, ölçülebilir ve tekrar edilebilir bir bilgidir. Sınıflandırma algoritmaları ulaşılması gereken sonucu hedefleyerek, veri setini belirlenen özellikler doğrultusunda belirli sınıflara ayırmaktır (Özlüer Başer vd., 2021). Bu ayrımın yapılması için ilk olarak veriler eğitim ve test verileri olarak bölünür. Sınıfları bilinen eğitim verileri ile sınıflandırma modeli oluşur. Sınıflandırma işlemi yapılarak sınıfı belirlenen eğitim verileri ile sınıflandırma modeli oluşturulur. Elde edilen bu

model test verisine uygulanarak belirlenen sınıfların bu veri seti içerisindeki varlığı araştırılır ve verilerin sınıfı tahmin edilir (Özlüer vd., 2021). Bu tahminler sonucu test verisinin sınıfları doğru veya yanlış tahmin edilir. Sınıflandırma modelinin başarısının ölçülmesi için doğru ve yanlış sınıflara atılan verilerin sayıları dikkate alınır. Bu değerlendirmenin yapılabilmesi için ise Tablo 2’de bir örneği verilen hata matrisleri oluşturulur.

Tablo 2. Hata matrisi

<i>Hata Matrisi</i>		<i>Tahmin Edilen Sınıf</i>	
		Doğru	Yanlış
<i>Gerçek Sınıf</i>	Doğru	DP	YN
	Yanlış	YP	DN

DP: Gerçekte doğru olan sınıfın doğru tahmin edilmesi

DN: Gerçekte yanlış olan sınıfın yanlış tahmin edilmesi

YP: Gerçekte yanlış olan sınıfın doğru tahmin edilmesi

YN: Gerçekte doğru olan sınıfın yanlış tahmin edilmesi

Verilen hata matrisinde satırlar gerçek sınıfı sütunlar ise tahmin edilen sınıfı ifade etmektedir. Hata matrisindeki değerler ile sınıflandırma işleminin doğruluğu (9) nolu eşitlik ile elde edilir.


$$\text{Sınıflandırma Doğruluğu} = \frac{DP+DN}{DP+YP+DN+YN} \times 100 \quad (9)$$

Yapılan bu tez çalışmasında fırında pişirilen 4 farklı yiyecek az pişmiş, pişmiş ve fazla pişmiş olarak üç farklı sınıfta sınıflandırılması amaçlanmıştır. Bu sınıflandırma işlemi için 4 farklı sınıflandırma algoritması kullanılmış olup farklı algoritmaların sınıflandırma üzerindeki etkisi test edilmiştir. Çalışmada kullanılan algoritmalar aşağıda verilmektedir.

2.7.1. Karar Ağacı Algoritması

Karar Ağacı algoritması, bir dizi karar kuralı kullanarak birçok özelliğe sahip olan veri kümesini daha küçük birimlere ayırır (Yüce & Özkan, 2021). Bir ağaç yapısı gibi kök, dal ve yapraklardan oluşmaktadır. Karar ağacı, sınıflama, özellik ve hedefe göre karar düğümleri

ve yaprak düğümlerinden oluşur. Ağaç yapısı formunda bir model oluşturan sınıflandırma yöntemidir. (Özlüer Başer vd., 2021). Şekil 4’te örnek bir karar ağacı yapısı verilmiştir.




Şekil 4. Örnek karar ağacı algoritması (Medium, 2024)

Bu yapıda her bir düğüm bir öznelilik üzerindeki test koşulunu ve buna bağlı olarak her bir dal, test koşulunun sonucunu temsil eder. Her bir yaprakta ise düğüme bir sınıf etiketi atanır. En üstteki düğüm kök düğümdür. Karar ağacı böl ve yönet yaklaşımıyla oluşturulmuştur. Karar ağacındaki her yol bir karar kuralı oluşturur (Jadhav & Channe, 2013). Karar ağaçlarının düşük maliyetli ve güvenilir olmakla birlikte oluşturulmasının ve yorumlanmasının kolay olması avantajlarındandır.

2.7.2. Destek Vektör Makinesi (DVM) Algoritması

Denetimli makine öğrenmesi tekniklerinden biri olan ve istatistiksel öğrenme teorisi ile yapısal risk minimasyonu teknikleri üzerine kurulmuş olan destek vektör makineleri regresyon ve sınıflandırma için yaygın olarak kullanılır (Harman, 2021). Algoritmanın amacı iki farklı sınıf arasındaki uzaklığın en fazla olduğu durumun bulunmasıdır. Verileri iki sınıfta ayıracak çok fazla sayıda düzlem bulunur. Bu düzlemlerden biri olan optimum ayırıcı düzlem, her iki sınıfın en uzak verileri arasındaki mesafenin maksimum olduğu durumu sağlayan düzlemdir. Şekil 5’te optimum ayırıcı düzleme ait örnek verilmiştir. Algoritmanın, uygun çekirdek fonksiyonlarının seçimi ile karmaşık ve düzgün olmayan verileri modelleme başarısı sıklıkla tercih edilme sebeplerindendir. Bu özelliği ile büyük

boyutlu veri uzaylarında doğrusal olmayan ilişkilerin, doğrusal olarak ifade edilebilmesini sağlar (Tuncer & Bolat, 2022).



Şekil 5. Örnek destek vektör makinesi algoritması (Kavzoğlu & Çölkesen, 2010)


2.7.3. K-En Yakın Komşu (k-EYK) Algoritması

K-En yakın komşu algoritması hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılır. Bu yöntem basit ve uygulaması kolay bir denetimli öğrenme algoritmasıdır. Bu algoritmanın amacı test veri setinde bulunan ve sınıfı bilinmeyen bir özelliğin eğitim veri setindeki özelliklere olan uzaklığının ölçülerek sınıflandırılmasıdır (Akmaz, 2022). Burada k adet en yakın komşuların sınıflarına göre sınıflandırma yapılır. Sınıfı belirlenmek istenen örnek, eğitim verisindeki sınıfı bilinen her bir örnek ile tek tek değerlendirilir. Test edilen örneğin hangi sınıfa ait olduğunu belirlemek için eğitim veri setindeki bu örneğe en yakın k adet örnek seçilir (Karakoyun & Hacıbeyoğlu, 2014). Seçilen k adet örneğin oluşturduğu kümede en çok hangi sınıf varsa test edilen örneğin de o sınıfa ait olduğu yorumlanır. Algoritmada örnekler arasındaki uzaklıklar Eşitlik (10)'daki Öklid uzaklığı denklemi ile hesaplanır.

$$d(x, y) = \sqrt{\sum_i^n (X_i - Y_i)^2} \quad (10)$$

Şekil 6'da k-EYK algoritması ile iki sınıfı olan bir veri setinde, test verisinin en yakın komşularına bakılarak sınıfının belirlenmesine bir örnek verilmiştir. Bu örnekte yıldız test

verisini, üçgen 1. sınıfı ve kare 2. sınıfı ifade etmektedir. Burada k değeri 5 seçilmiş olup test verisine en yakın 5 örnek daire içine alınmıştır. Bu durumda şekil üzerinde görüldüğü üzere daire içerisinde üçgen sayısının fazla olması nedeniyle test verisinin 1. sınıfa ait olduğu yorumlanır.



Şekil 6. k-EYK algoritması kullanılarak test verisinin sınıflandırılması


Burada belirlenen k parametresi k-EYK algoritmasının başarısı üzerinde etkilidir. Genelde tek sayı olarak seçilen k parametresi için küçük bir değer belirlenmesi hatalı olmasına neden olabilirken büyük bir değer seçilmesi de işlem yükünü artırır. Bu çalışmada ise k-EYK algoritması kullanılırken k değeri 1,3,5 ve 7 seçilerek sınıflandırma doğrulukları test edilmiştir.

2.7.4. Rastgele Orman Algoritması

Rastgele orman içinde birçok karar ağacı bulunduran, genellikle sınıflandırma ve regresyon için kullanılan algoritmadır. Her bir karar ağacı oluşturulurken rastgele özellikler seçilir ve her ağaç birbirinden farklı olur. Bu karar ağaçlarındaki özellikler üzerinde sınıflandırma veya regresyon işlemleri yapılır. Bu ağaçların çıktısı, sınıflandırma problemleri için ağaçların çoğunluğunun kararına göre ve regresyon problemleri için ağaçların tahminlerinin ortalaması alınarak tek bir çıktı halinde toplanır (Rigatti, 2017). Algoritma girdi değeri büyük olan verilerde iyi bir performans gösterirken eksik verilerde de iyi tahminlerde bulunması nedeniyle kolaylık sağlar. Bu algoritma ile dengesiz sınıf

dağılımına sahip verilerde model geliştirilirken, dengesizlik probleminin aşılmasına ve modelin performansının artırılmasına da yardımcı olmaktadır (Özlüer vd., 2021).

Şekil 7’de rastgele orman algoritmasının sınıflandırma yöntemine dair bir örneği verilmiştir.



Şekil 7. Örnek rastgele orman algoritması

Burada N_1 , N_2 , N_3 ve N_4 olmak üzere 4 farklı özellik seçilmiştir. Seçilen bu farklı özellikler ise 4 farklı karar ağacı oluşturularak sınıflandırılmıştır. 4 farklı karar ağacının tahminleri sonucu oluşan sınıflar göz önüne alınarak oy çokluğu ile en çok tahmin edilen sınıf belirlenir. Bu örnekte ise özelliğin en çok Sınıf 1 olarak tahmin edildiği ve sonuç olarak bu özelliğin sınıfının Sınıf 1 olduğuna karar verildiği görülmektedir.


3. YAPILAN ÇALIŞMALAR

Bu çalışmada Dr. Oetker'in sade kek karışımı ile hazırlanan kek, Superfresh'in peynirli tepsi böreği, istavrit balığı ve somon balığı olmak üzere 4 farklı yiyecek kullanılmış olup yiyeceklerin ankastre fırında pişirilmesi sırasında ortaya çıkan kokuların elektronik burun sensörleri ile analiz edilmesi amaçlanmıştır. Her bir yiyeceğin deney çalışması ayrı yürütülmüş ve bu 4 yiyecek için toplamda 59 deney gerçekleştirilmiştir.

Deney verilerinin elde edilmesi amacıyla 8 adet MOS Metal Oksit Yarı İletken sensörler (TGS826, TGS816, TGS825, TGS813, TGS2610, TGS2602, TGS2620, TGS2611) kullanılmıştır. Elde edilen veriler bilgisayar ortamında sayısallaştırılmış ve referans düzeltme, öznitelik çıkarma, normalizasyon gibi ön işlemlerden geçirilmiştir. Tüm işlemleri tamamlanan veriler Karar Ağacı, Destek Vektör Makinesi, k-EYK ve Rasgele Orman Algoritmaları ile az pişmiş, pişmiş, çok pişmiş olmak üzere 3 farklı sınıfta sınıflandırılmıştır. Elde edilen sınıflandırma sonuçları her bir yiyecek için karşılaştırılmış ve doğruluğu en yüksek olan algoritmalar belirlenmiştir.

3.1. Elektronik Burun Deney Düzeneği

Yapılan bu tez çalışmasında, ankastre fırında pişirilen yiyeceklerin aşırı pişme durumunu önlemek için 8 adet MOS Metal Oksit Yarı İletken sensör kullanılarak e-burun deney düzeneği geliştirildi. Geliştirilen bu düzenek Şekil 8'de verilmiştir.



Şekil 8. E-burun deney düzeneği.

Şekil 8 üzerinde görüldüğü üzere deney düzeneğinde fırın, valfler, vakum pompası, MOS sensörler, sensör arayüz devresi, veri toplama kartı ve bilgisayar kullanılmıştır. Fırın

içerisinde pişirilen 4 farklı yiyeceğin kokuları MOS sensörler ile algılanır ve algılanan koku verileri elektriksel işaret dönüştürülür. Sensörlerden gelen verileri bilgisayar ortamında sayısallaştırmak amacıyla Şekil 8’de de gösterilen DAQ veri toplama kartı kullanılmıştır. Bilgisayara bağlı olan bu veri toplama kartına kaydedilen veriler bilgisayarda görüntülenir ve MATLAB üzerinde işlenir. Veri üzerinde gerekli düzenlemeler yapıldıktan sonra veriye 4 farklı normalizasyon yöntemi uygulanmış ve 4 farklı sınıflandırma algoritması ile sınıflandırılmıştır. Böylelikle farklı normalizasyon ve sınıflandırma yöntemlerinin sınıflandırma doğruluğuna etkisi incelenmiştir.

3.1.1. Koku İletimi

Bu tez çalışmasında kullanılan e-burun deney düzeneğinde pişirilen yiyeceklerin kokusunu iletmek için teflon borular kullanılmıştır. Teflon malzeme ısıya, kimyevî maddelere, neme, sürtünmeye dayanıklıdır (Teflon, 2024). Bu özellikleri sayesinde kimyasal maddeler ile tepkimeye girmemesi, deney düzeneğinde kullanılma nedenlerindendir. Ayrıca teflon boru, içerisinde iletilen kokuyu hammaddesi farklı olan borulara göre daha az tutar. Bu deney çalışmasında da iletilen kokunun saf olması sınıflandırma anlamında önemli olduğundan bu özelliği nedeniyle tercih edilmiştir.

Şekil 8’de görüldüğü gibi pişirilen yiyeceklerin kokusunun fırının içerisinden alınıp sensörlere iletilmesi için teflon boru, fırının içerisinden başlayarak fırın kapağının sağ üst kısmından dışarı çıkarılmıştır. Teflon borular yerleştirilirken fırın kapağı tamamen kapatılabilmiş fırına ve kapağa herhangi bir zarar verilmemiştir. Şekil 8’de koku iletimini sağlayan boruların bağlantıları görünmektedir.


Bu deney düzeneği üzerinde teflon borular ile iletilen kokunun iletim yönünün belirlenmesi ve belirli noktalarda hapsedilmesinin sağlanması için selenoid valfler kullanılmıştır. Belirli noktalara koyulan bu valflerin anahtar görevi görmesi ile bu işlemler gerçekleşir. Valfler enerjilendirildiğinde, elektrik enerjisi mekanik enerjiye dönüştürülür ve fiziksel olarak bir bariyeri hareket ettirerek koku akışını engeller veya akışa izin verir (Solenoid Valve, 2024). Tasarlanan e-burun deney düzeneğinde kullanılan valf ise Şekil 9’da gösterilmiştir.



Şekil 9. Deney düzeneğinde kullanılan selenoid valf

3.1.2. Vakum Pompası

Fırın içerisinde pişirilen yiyeceklerin kokularının alınıp sensörlere iletilmesi için vakum pompası kullanılmıştır. Vakum pompası, kapalı bir ortam içerisindeki gaz moleküllerini vakumlayarak gaz moleküllerinin transferini sağlamaktadır. Gaz transfer prensibine dayalı çalışan vakum pompaları, gazları pompa içinde hareket ettirerek vakum oluşturur (Vakum Pompası, 2024).



Şekil 10. Deney düzeneğinde kullanılan vakum pompası


3.1.3. Kontrol Arayüz Devresi: Röle Kartı

E-burun deney düzeneğinde bulunan 3 adet valf kontrol arayüz devresi ile kontrol edilmektedir. Bu kontrole ait programlama MATLAB üzerinden yapılmıştır. Şekil 8’de gösterilen bu 3 valfin deneyin hangi aşamalarında hangi durumda oldukları Tablo 3’te verilmiştir.

Tablo 3. Bir deney süresince valflerin durumları

Yapılan İşlemler ve Süreleri	Valfler ve Durumları (Açık-Kapalı)		
	V1	V2	V3
Deney Öncesi Ön Temizleme (130sn)	Açık	Kapalı	Açık
Yiyecek Kokularının Sensörlere Gönderilmesi (40sn)	Kapalı	Açık	Kapalı
Yiyecek Kokularının Sensör Haznelerinde Hapsedilmesi (30sn)	Kapalı	Kapalı	Kapalı
Sistemin Son Temizlenmesi (130sn)	Açık	Kapalı	Açık

E-burun deney düzeneğinin ve valflerin kontrolünün sağlayan röle kartı Şekil 11’de verilmiştir.



Şekil 11. Deney düzeneğinin ve valflerin kontrolünün sağlayan röle kartı


3.1.4. MOS Sensörler ve Sensör Haznesi

Yapılan bu tez çalışmasında 8 adet MOS Metal Oksit Yarı iletken sensör kullanılmıştır. Kullanılan bu sensörler TGS826, TGS816, TGS825, TGS813, TGS2610, TGS2602, TGS2620 ve TGS2611'dir. Figaro marka bu sensörlerin katalogları (URL-1, 2024) incelenmiş olup V_C sensör besleme gerilimi, V_H sensör ısıtıcı gerilimi, R_H sensör içinde bulunan dahili ısıtıcı direnci, R_L sensörlere seri bağlı yük direncinin değerleri ve bu sensörlerin hassasiyet gösterdiği gazlar Tablo 4'te verilmiştir.

Tablo 4. MOS sensörlerin özellikleri

Özellikler Sensörler	Sensörün hassasiyet gösterdiği gazlar	Sensör besleme gerilimi (V_C)	Sensör ısıtıcı gerilimi (V_H)	Yük direnci (R_L)($k\Omega$)
TGS826	Amonyak	5 V	5 V	1
TGS816	Metan, Propan, Bütan			3
TGS825	Hidrojen sülfid			6
TGS813	Metan, Propan, Bütan			2
TGS2610	Bütan, Propan			1
TGS2602	Amonyak, H_2S , VOCs			4,7
TGS2620	Alkoller, Çözeltiler			2
TGS2611	Metan			2

Fırın içerisinde pişirilen yiyeceklerin kokularının hapsedilip sensörler tarafından algılanabilmesi için alüminyum malzemeden yapılan bir sensör haznesi tasarlanmıştır. Deneyde kullanılan 8 adet MOS sensör kartına yerleştirilerek bu hazne içine konulmuş ve ortamdaki hava ile temasının kesilmesi için deney süresince kutunun kapağı kapalı tutulmuştur. Böylelikle sensörler yalnızca o an fırında pişirilen kokuyu algılayacaktır. Tasarlanan bu sensör haznesine ait görsel Şekil 12'de verilmiştir.



Şekil 12. Deney düzeneğinde kullanılan sensör haznesi

Tasarlanan bu sensör haznesinin karşılıklı iki kenarına teflon boruların giriş ve çıkışı için delikler açılmıştır. Fırın içerisinden alınıp fırın kapağının üst kısmından dışarı çıkarılan teflon boru sensör haznesinin bir kenarına bağlanarak kokunun hazne içerisine girmesini sağlamaktadır. Karşı tarafa ise sensör içerisine hapsedilen kokunun dış ortama atılmasını sağlayacak teflon boru yerleştirilmiştir. Sensör haznesinin bir kenarında ise sensör kartı ile sensör dirençlerinin üzerinde bulunduğu sensör arayüz kartı arasındaki bağlantıyı sağlayan kabloların çıkışlarını sağlayan konnektörler yerleştirilmiştir.

3.1.5. Veri Toplama Kartı (DAQ Kart)

Veri toplama kartları fiziksel olarak elde edilen işaretleri sayısal işaretlere dönüştürür. Bu çalışmada ise sensörler üzerinde oluşan gerilim değeri sayısal işaretlere dönüştürülür. Sensörlerden alınan veriler The National Instruments™ Model 6218 USB veri elde etme kartıyla 10 Hz örnekleme frekansı ile kaydedilip bilgisayara aktarılmıştır. DAQ kart ile elde edilen sayısal işaretler bilgisayar ortamında MATLAB programı ile işlenmiştir. Deney düzeneğinde kullanılan karta ait görsel Şekil 13'te verilmiştir.



Şekil 13. Deney düzeneğinde kullanılan veri toplama kartı

3.2. Elektronik Burun Deney Aşaması

Yapılan bu tez çalışmasında Dr. Oetker'in sade kek karışımı ile hazırlanan kek, Superfresh'in peynirli tepsi böreği, istavrit balığı ve somon balığı ankastre fırında pişirilmiştir. Bu 4 farklı yiyeceğe ait pişirme süreleri ve dereceleri Tablo 5'te verilmiştir.

Tablo 5. Çalışma boyunca pişirme deneyi yapılan yiyeceklerin pişirme süreleri ve dereceleri

Yiyecek Çeşitleri	Pişirme Süresi (Dakika)	Pişirme Derecesi (C^0)
Börek	70	170
Kek	70	170
Somon Balığı	70	170
İstavrit Balığı	70	170

Tabloda belirtilen süre ve derecelerde börek için 16, kek için 15, somon balığı için 14 ve istavrit balığı için 14 olmak üzere toplamda 59 deney yapılmıştır. Yapılan 59 deneyden koku verilerinin elde edilmesi için fırından kokunun alınma aşamaları her bir deney için aşağıdaki gibi tekrarlanmıştır.


Fırından Valf 2'ye ulaşan boru ile pişirilen yiyeceğin kokusu vakum pompası yardımıyla çekilerek sensör haznesine iletilmektedir. Valf 1'in ucundaki boru ise dış

ortamdan temiz havayı alıp sensörlerin temizlenmesini sağlamaktadır. Sensör haznesindeki koku ise Valf 3 ile ortama atılmaktadır.

E-burun kullanılarak verilerin elde edilmesi için 4 aşama gerçekleşmektedir. İlk olarak Valf 1 ve Valf 3 açık, Valf 2 kapalı durumda iken sistem 130 saniye boyunca ortamdaki hava ile temizlenir. 2. aşamada yalnızca Valf 2 açılır ve fırın içindeki koku 40 saniye boyunca MOS sensör haznelerine aktarılır. 3. aşamada tüm Valfler kapatılır ve 30 saniye boyunca sensörlerin, sensör haznelerindeki kokuya tepki vermeleri sağlanır. Son olarak tekrar Valf 1 ve Valf 3 açık, Valf 2 kapalı konuma getirilir ve 130 saniye boyunca sistemin temizlenmesi sağlanır. Böylelikle bir deney ortalama 5,5 dakikada tamamlanmaktadır.

Bir yiyeceğin 70 dakikalık pişirme süresi boyunca her 10 dakikada bir ise deney düzeneği çalıştırılmış ve 5,5 dakikalık deneyler tekrarlanmıştır. Yani 70 dakikalık deney boyunca sensörlerin tepkileri 7 kez ölçülmüş ve sayısallaştırılmıştır. Bir yiyeceğin pişirilme süresinin yaklaşık 55 dakikasında deney düzeneği çalışır durumdadır.

Her bir deney sonucunda elde edilen veriler DAQ kart yardımıyla sayısallaştırılmış ve bilgisayar ortamında MATLAB programında kaydedilmiştir. Bu deneyler sonucunda oluşan 8 farklı sensöre ait gerilim değişimleri Şekil 14’te verilmektedir. Şekil 14’te verilen grafikten de görüleceği gibi son temizleme bölümünde sensörler olması gerektiği gibi temizlenebilmektedir.




Şekil 14. Bir deney süresince sensör tepkilerinin değişimi

3.3. Veriye Ön İşlem Uygulanması


Sensörlerden elde edilen ham verilerin daha iyi yorumlanabilmesi ve sınıflandırma başarısını arttırmak için bazı sayısal yöntemler kullanılarak grafikler görsel olarak daha düzgün hale getirilir. Bu çalışmada kullanılan ön işlemler ise referans düzeltme yöntemi ve iletkenlik dönüşümüdür.

Referans düzeltme işlemi ile birlikte sensörlere yemek kokusunun gönderilmeye başlandığı andaki gerilim değeri sıfır eksenine çekilerek veri görsel olarak düzenlenir. Şekil 15'te (a) ve (b) ile sırasıyla elektronik burun devresinden alınan işlenmemiş gerilim verisini ve referansı düzenlenmiş gerilim verisi gösterilmektedir.




Şekil 15. Elektronik burun devresinden alınan (a) işlenmemiş gerilim verisi ve (b) referansı düzenlenmiş gerilim verisi

Elde edilen verileri uygulanan ikinci ön işlem ise iletkenlik dönüşümüdür. Şekil 15 (b) de verilen gerilim verisinin iletkenlik verisine dönüştürülmüş hali Şekil 16'da verilmektedir.




Şekil 16. Kullanılan sensörlere ait iletkenlik verisi

Piştirilen yiyecekler için 10 dakika aralıklarla gerçekleştirilen deneyler sonucu elde edilen sensör iletkenlik değişimleri incelenmiş ve fazla pişmiş yiyecekleri az pişmiş yiyeceklerden ayıracak sensör özellikleri belirlenmiştir. Örnek olarak 70 dakika boyunca piştirilen bir somon balığı, peynirli tepsi böreği, kek ve istavrit balığının piştirme süresince 10 dakika aralıkla gerçekleştirilen deneyler sonucu elde edilen sensör iletkenlik değişimleri Şekil 17, Şekil 18, Şekil 19 ve Şekil 20’de verilmiştir.




Şekil 17. Börek için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri

Şekil 17’de böreğe ait iletkenlik değişimleri incelendiğinde TGS826 ve TGS2620 sensörlerinin iletkenlik değerlerinin tepe değerleri arasındaki farkın pişirme süresinin ilerleyen dakikalarında belirgin şekilde değiştiği görülmektedir.




Şekil 18. Kek için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri

Şekil 18’de keke ait iletkenlik değişimleri incelendiğinde TGS826 ve TGS2620 sensörlerinin iletkenlik değerlerinin tepe değerleri arasındaki farkın börek verilerinde olduğu gibi pişirme süresinin ilerleyen dakikalarında belirgin şekilde değiştiği görülmektedir.



Şekil 19. Somon balığı için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri

Şekil 19'daki somon balığının iletkenlik değişimleri incelendiğinde TGS826 ve TGS2602 sensörlerinin iletkenlik değerlerinin pişirme süresinin ilerleyen dakikalarında belirgin şekilde yükseldiği görülmektedir.



Şekil 20. İstavrit balığı için 10 dakika aralıklarla gerçekleştirilen deney sonuçlarının iletkenlik değerleri

Şekil 20'deki istavrit balığının iletkenlik değişimleri incelendiğinde TGS826 ve TGS2602 sensörlerinin iletkenlik değerlerinin somon balığında olduğu gibi pişirme süresinin ilerleyen dakikalarında belirgin şekilde yükseldiği görülmektedir.

3.4. Öznitelik Çıkarımı


Bu tez çalışmasında gerçekleştirilen deneyler sonucunda elde edilen veriler kullanılarak yiyeceklerin pişirilme derecelerine göre sınıflandırılabilmesi için sensör verilerinden aşağıdaki öznitelikler çıkarılmıştır.

Sensör verilerinin;

- 130 saniye-210 saniyeler arasındaki maksimum, ortalama, varyans, basıklık (kurtosis), eğrilik (skewness) değerleri,
- 130 saniye-210 saniyeler arasında sensör verileri arasında kalan alan,
- 130 saniye-170 saniyeler arasında elde edilen verilerin eğrilik ve basıklık değerleri,
- 130 saniye-170 saniyeler arasında sensör verilerine ait, ortalama, varyans, eğrilik ve basıklık değerleri kullanılmıştır.

Bu özniteliklerin kullanılmasıyla oluşturulan öznitelik matrisi (59x241) boyutunda oluşmuştur. Özellik çıkarma ve sınıflandırma aşamasında tüm sensörlerin kullanılması ve seçilen öznitelik sayısının fazla olması sınıflandırma başarısını artırmaktadır ancak bu durum hem veri işleme süresini hem de sistem maliyetini artırmaktadır. Yapılan deneyler sonucunda elde edilen veriler içerisinde tüm sensörler tek tek incelenmiş ve en ayırt edici sensör ve özellik belirlenmiştir.


Peynirli tepsi böreği için yapılan deneyler sonucunda elde edilen verilerin incelenmesi sonucu TGS826 ve TGS2620 sensörlerinin iletkenlik değişiminin en büyük değerlerinin ve bu değerlerin farkının kullanılmasına karar verilmiştir. 50, 60 ve 70. dakikalarda yapılan deneyler sonucu elde edilen iletkenlik değerlerinin maksimum değerleri arasındaki fark 10, 20, 30 ve 40. dakikalarda elde edilen farklardan önemli ölçüde ayrılmaktadır. Börek deneyleri için Şekil 21’de bu iki sensörün pişirme süresine göre iletkenliklerinin değişimi verilmektedir.



Şekil 21. Börek yiyeceğinin pişirilmesi süresince TGS826 ve TGS2620 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi


Şekil 21’de verilen grafikten de görülebileceği üzere pişirme süresinin ilerleyen bölümünde TGS826 ve TGS2620 sensörlerinin tepe noktaları arasındaki fark belirgin şekilde değişmektedir.

Kek ile yapılan deneylere ilişkin veriler incelendiğinde börek verilerinde kullanılan özniteliklerin aynısı bu verilerde de kullanılmasının uygun olacağı belirlenmiştir. Kek deneyleri için Şekil 22’de bu iki sensörün pişirme süresine göre iletkenliklerinin değişimi verilmektedir.



Şekil 22. Kek yiyeceğinin pişirilmesi süresince TGS826 ve TGS2620 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi


Bu tez çalışmasında gerçekleştirilen bir sonraki deneyler somon balığıyla gerçekleştirilmiştir. Somon balığı deneyleri sonucu oluşan sensör iletkenlikleri değişimi incelendiğinde TGS826 ve TGS2602 sensörlerinin iletkenliklerinin maksimum değerlerinin kullanılması somon balığının pişirme süresinin değişimleri hakkında anlamlı bilgiler vermektedir. Bu iki sensörün pişirme süresi ilerledikçe oluşturdukları iletkenlik değişimi Şekil 23'te verilmektedir.



Şekil 23. Somon balığının pişirilmesi süresince TGS826 ve TGS2602 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi

Somon balığı ile yapılan deneyler sonrasında somon balığından daha küçük bir balık türü olan istavrit balığı ile deneyler gerçekleştirilmiştir. Sensör iletkenliklerinin incelenmesi sonucu istavrit balığının da fazla pişirilmesinin önlenmesi için TGS826 ve TGS2602 sensörlerinin iletkenlik değişiminin maksimum değerlerinin kullanılmasının olumlu sonuçlar vereceği kararlaştırılmıştır.

İstavrit balığı için TGS826 ve TGS2602 sensörlerinin pişirme süresi ilerledikçe oluşturdukları iletkenlik değişimi Şekil 24’te verilmektedir.



Şekil 24. İstavrit balığının pişirilmesi süresince TGS826 ve TGS2602 sensörlerinin 10 dakika aralıklarla iletkenliklerinin değişimi

Şekil 24’te verilen iletkenlik değişimi incelendiğinde TGS826 ve TGS2602 sensörlerinin iletkenlik değişimlerinin maksimum değeri pişirme süresinin fazla olduğu durumlarda pişirme süresinin az olduğu durumlara göre oldukça farklıdır.

3.5. Verilere Uygulanan Normalizasyon ve Sınıflandırma Algoritmaları

Yapılan bu çalışmada pişirilen yiyeceklerin sınıflandırma doğruluğuna farklı normalizasyon yöntemlerinin ve sınıflandırma algoritmalarının etkisi test edilmiştir. İlk olarak her bir yiyecek normalizasyon uygulanmadan sınıflandırılmıştır. Sonrasında kek, börek, istavrit balığı ve somon balığının pişirme verilerine sırasıyla Z-skor, maksimum, minimum maksimum ve sigmoid normalizasyon yöntemleri uygulanmıştır. Uygulanan normalizasyon yöntemlerinden sonra karar ağacı, destek vektör makineleri (doğrusal, karesel, kübik olmak üzere 3 farklı çeşidi), k-EYK ($k=1$, $k=3$, $k=5$, $k=7$ olmak üzere 4 farklı çeşidi) ve rastgele orman algoritması olmak üzere toplamda 9 farklı sınıflandırma algoritması uygulanarak her birinin sınıflandırma doğrulukları gözlemlenmiştir.

Elde edilen yiyecek kokularına ait veriler MATLAB programında işlenmiş ve sınıflandırma işlemleri MATLAB programının Classification Learner Toolbox arayüzünde gerçekleştirilmiştir.

4. BULGULAR VE TARTIŞMA

Yapılan bu tez çalışmasında, e-burun deney düzeneğinde pişirilen yiyeceklerden elde edilen veriler analiz edilerek MATLAB programında işlenmiştir. İşlenen verilere uygulanan farklı normalizasyon yöntemleri ve sınıflandırma algoritmaları sonucunda sınıflandırma işlemleri tamamlanmıştır. Sınıflandırma sonucunda her bir yiyecek türü özelinde sınıflandırma başarılarının yüzdeleri incelenmiş ve hata matrisleri oluşturulmuştur. 4 çeşit yiyecek için uygulanan 4 farklı normalizasyon yöntemi sonucu elde edilen veriler 9 farklı sınıflandırma algoritması ile sınıflandırılmıştır. Sınıflandırma yapılırken 10 ve 20. dakikalarda yapılan deneylere ait veriler az pişmiş, 30 ve 40. dakikalarda yapılan deneylere ait veriler pişmiş, 50, 60 ve 70. dakikalarda yapılan deneylere ait veriler fazla pişmiş olarak sınıflandırılmıştır. Bu işlemler yapılırken her bir yiyecek için normalizasyon ve sınıflandırma işlemleri 10'ar kez tekrarlanmıştır. Her bir sınıflandırma algoritmasında, sınıflandırma başarısını değerlendirmek amacıyla 5 katlı çapraz doğrulama yöntemi uygulanmıştır. Elde edilen 10'ar sınıflandırma sonuçlarının ortalaması alınarak her bir yiyecek için sınıflandırma doğruluklarını içeren tablolar oluşturulmuştur.

Tablo 6. Pişirilen Börek verisine ait sınıflandırma başarılarının yüzdeleri

BÖREK		Normalizasyon Yöntemi				
		Normalizasyon Kullanılmadan	Z-Skor	Maksimum	Minimum-Maksimum	Sigmoid
Sınıflandırma Yöntemi	<i>Karar Ağacı</i>	64,17	57,95	64,90	64,12	65,82
	<i>Doğrusal DVM</i>	77,18	78,75	78,45	77,18	76,46
	<i>Karesel DVM</i>	79,2	83,3	78,22	79,06	75,64
	<i>Kübik DVM</i>	76,07	77,29	76,66	76,07	73,43
	<i>k-EYK-1</i>	68,43	68,95	68,86	68,43	65,74
	<i>k-EYK-3</i>	67,61	67,42	68,03	67,51	64,91
	<i>k-EYK-5</i>	66,26	68,13	68,66	66,26	63,24
	<i>k-EYK-7</i>	65,22	66,25	66,89	65,22	63,12
	<i>Rastgele Orman</i>	75,22	75,64	76,33	75,22	74,26

Tablo 6 incelendiğinde böreğin pişme derecesinin sınıflandırılmasında normalizasyonun etkisi görülmektedir. Pişirilen börek verilerinin normalizasyon

uygulanmadan ve 4 farklı normalizasyon yöntemi uygulanarak sınıflandırılması sonucu elde edilen sınıflandırma doğrulukları verilmiştir. Bu veriler her bir sınıflandırma algoritmasının 10 kez tekrarlanması sonucu ortalama alınarak elde edilmiştir. Pişirilen börek verilerinin sınıflandırılması sonucu en yüksek doğruluk z-skor normalizasyon yöntemi uygulanarak ve karesel destek vektör makineleri sınıflandırma algoritması kullanılarak %83,3 olarak elde edilmiştir. Sınıflandırma doğruluğunun normalizasyon uygulanmayan veriye göre en çok artışı da z-skor normalizasyon uygulanarak ve karesel DVM ile sınıflandırıldığında gösterdiği tabloda görülmektedir.

Normalizasyon uygulanmayan ve z-skor normalizasyon uygulanan verilerin karesel DVM algoritması ile sınıflandırma doğruluklarının detaylarını içeren, 10 sınıflandırma sonucunun ortalama değerine ait hata matrisleri Şekil 25 ve Şekil 26’da gösterilmiştir.

Sınıflandırma Sonuçları
Karesel Destek Vektör Makinesi Algoritması - %79.2

Gerçek Sınıf	Az Pişmiş	10 62.5%	5 31.3%	1 6.3%
	Pişmiş	1 3.1%	25 78.1%	6 18.8%
	Fazla Pişmiş	0 0.0%	7 14.6%	41 85.4%
		Az Pişmiş	Pişmiş	Fazla Pişmiş
		Tahmin Edilen Sınıf		

Şekil 25. Normalizasyon işlemi uygulanmayan börek verisinin sınıflandırma doğruluğuna ait hata matrisi

Sınıflandırma Sonuçları
Karesel Destek Vektör Makinesi Algoritması - %83.3

Gerçek Sınıf	Az Pişmiş	11 68.8%	5 31.3%	0 0.0%
	Pişmiş	3 9.4%	24 75.0%	5 15.6%
	Fazla Pişmiş	0 0.0%	3 6.3%	45 93.8%
		Az Pişmiş	Pişmiş	Fazla Pişmiş
		Tahmin Edilen Sınıf		

Şekil 26. Z-skor normalizasyonu uygulanan börek verisinin sınıflandırma doğruluğuna ait hata matrisi


Şekil 25 ve Şekil 26 incelendiğinde börek verilerinin az pişmiş, pişmiş ve fazla pişmiş olarak 3 sınıfta sınıflandırılması sonuçları görülmektedir. Normalizasyon uygulanan veride az pişmiş ve fazla pişmiş sınıfları normalizasyon uygulanmayan veriye göre daha iyi sınıflandırılmıştır.

Kek verisine ait sınıflandırma doğruluğu değerlerini içeren Tablo 7 incelendiğinde sınıflandırma doğruluğunun, normalizasyon uygulanmayan veriye göre en çok artışı minimum-maksimum normalizasyon yöntemi uygulanarak k-EYK algoritması ile sınıflandırıldığında gösterdiği görülmektedir. Ancak en yüksek sınıflandırma doğruluğu minimum-maksimum normalizasyon yöntemi uygulanarak ve rastgele orman algoritması ile sınıflandırıldığında %82,20 olarak elde edilmiştir.

Tablo 7. Pişirilen kek verisine ait sınıflandırma başarılarının yüzdeleri

KEK		Normalizasyon Yöntemi				
		Normalizasyon Kullanılmadan	Z-Skor	Maksimum	Minimum-Maksimum	Sigmoid
Sınıflandırma Yöntemi	<i>Karar Ağacı</i>	67,79	66,90	68,56	67,23	68,68
	<i>Doğrusal DVM</i>	74,98	75,46	76,12	76,02	72,10
	<i>Karesel DVM</i>	77,01	77,55	76,79	78,22	78,11
	<i>Kübik DVM</i>	74,99	75,44	77,35	77,90	78,11
	<i>k-EYK-1</i>	69,22	71,32	71,32	73,00	68,56
	<i>k-EYK-3</i>	66,90	68,27	68,00	68,01	67,90
	<i>k-EYK-5</i>	69,67	71,78	71,09	71,22	69,89
	<i>k-EYK-7</i>	74,11	75,46	74,90	74,87	69,45
	<i>Rastgele Orman</i>	80,01	81,09	81,43	82,20	81,54

Normalizasyon uygulanmayan ve minimum-maksimum normalizasyon uygulanan kek verilerinin rastgele orman algoritması ile sınıflandırma doğruluklarının detaylarını içeren, 10 sınıflandırma sonucunun ortalama değerine ait hata matrisleri Şekil 27 ve Şekil 28’de gösterilmiştir.



Şekil 27. Normalizasyon işlemi uygulanmayan kek verisinin sınıflandırma doğruluğuna ait hata matrisi

Sınıflandırma Sonuçları
Rastgele Orman Algoritması - %82.2

Gerçek Sınıf	Az Pişmiş	10 66.7%	5 33.3%	0 0.0%
	Pişmiş	1 3.3%	23 76.7%	6 20.0%
	Fazla Pişmiş	0 0.0%	4 8.9%	41 91.1%
		Az Pişmiş	Pişmiş	Fazla Pişmiş
		Tahmin Edilen Sınıf		

Şekil 28. Minimum-Maksimum normalizasyonu uygulanan kek verisinin sınıflandırma doğruluğuna ait hata matrisi


Şekil 27 ve Şekil 28 incelendiğinde kek verilerinin az pişmiş, pişmiş ve fazla pişmiş olarak 3 sınıfta sınıflandırılması sonuçları görünmektedir. Normalizasyon uygulanan veride pişmiş ve fazla pişmiş sınıfları normalizasyon uygulanmayan veriye göre daha iyi sınıflandırılmıştır.

Piştirilen somon balığının sınıflandırılmasına ait sınıflandırma doğruluklarını içeren Tablo 8 incelendiğinde ise hem sınıflandırma doğruluğunun normalizasyon uygulanmayan veriye göre en çok artışı sigmoid normalizasyon yöntemi uygulanarak ve k-EYK-3 algoritması ile sınıflandırıldığında gösterdiği hem de en yüksek sınıflandırma doğruluğunun bu algoritmalarla %77,4 olarak elde edildiği görünmektedir.

Tablo 8. Pişirilen somon balığı verisine ait sınıflandırma başarılarının yüzdeleri

SOMON BALIĞI		Normalizasyon Yöntemi				
		Normalizasyon Kullanılmadan	Z-Skor	Maksimum	Minimum-Maksimum	Sigmoid
Sınıflandırma Yöntemi	<i>Karar Ağacı</i>	67,34	66,18	66,07	67,97	67,87
	<i>Doğrusal DVM</i>	71,89	71,29	69,89	69,51	72,40
	<i>Karesel DVM</i>	73,57	75,00	72,61	73,80	73,80
	<i>Kübik DVM</i>	69,40	71,17	68,44	70,34	75,60
	<i>k-EYK-1</i>	70,35	73,21	70,46	71,30	75,24
	<i>k-EYK-3</i>	68,81	69,04	68,32	68,46	77,40
	<i>k-EYK-5</i>	69,51	69,05	69,75	69,39	76,56
	<i>k-EYK-7</i>	68,82	69,98	68,34	68,21	75,12
	<i>Rastgele Orman</i>	75,48	75,84	74,40	75,84	75,24

Normalizasyon uygulanmayan ve sigmoid normalizasyonu uygulanan somon balığı verilerinin k-EYK-3 algoritması ile sınıflandırma doğruluklarının detaylarını içeren, 10 sınıflandırma sonucunun ortalama değerine ait hata matrisleri Şekil 29 ve Şekil 30'da gösterilmiştir.



Şekil 29. Normalizasyon işlemi uygulanmayan somon balığı verisinin sınıflandırma doğruluğuna ait hata matrisi

Sınıflandırma Sonuçları
k-En Yakın Komşu Algoritması - %77.4

Gerçek Sınıf	Az Pişmiş	5 35.7%	7 50.0%	2 14.3%
	Pişmiş	2 7.1%	20 71.4%	6 21.4%
	Fazla Pişmiş	0 0.0%	2 4.8%	40 95.2%
		Tahmin Edilen Sınıf		
		Az Pişmiş	Pişmiş	Fazla Pişmiş

Şekil 30. Sigmoid normalizasyon yöntemi uygulanan somon balığı verisinin sınıflandırma doğruluğuna ait hata matrisi


Şekil 29 ve Şekil 30 incelendiğinde somon balığı verilerinin az pişmiş, pişmiş ve fazla pişmiş olarak 3 sınıfta sınıflandırılması sonuçları görülmektedir. Normalizasyon uygulanan veride pişmiş ve fazla pişmiş sınıfları normalizasyon uygulanmayan veriye göre daha iyi sınıflandırılmıştır.

Piştirilen istavrit balığının pişirme derecelerine göre sınıflandırılması sonucu oluşturulan Tablo 9 incelendiğinde sınıflandırma doğruluğunun, normalizasyon uygulanmayan veriye göre en çok artışı maksimum normalizasyon yöntemi uygulanarak ve k-EYK-3 algoritması ile sınıflandırıldığında gösterdiği görülmektedir. Ancak en yüksek sınıflandırma doğruluğu z-skor normalizasyonu ve rastgele orman algoritması ile %83,3 olarak elde edilmiştir.

Tablo 9. Pişirilen istavrit balığı verisine ait sınıflandırma başarılarının yüzdeleri

İSTAVRİT BALIĞI		Normalizasyon Yöntemi				
		Normalizasyon Kullanılmadan	Z-Skor	Maksimum	Minimum-Maksimum	Sigmoid
Sınıflandırma Yöntemi	Karar Ağacı	74,29	72,96	73,92	72,60	72,61
	Doğrusal DVM	81,31	80,74	81,91	79,44	79,77
	Karesel DVM	76,92	77,87	78,35	77,52	77,10
	Kübik DVM	73,80	74,04	74,16	73,56	76,44
	k-EYK-1	76,19	76,32	76,08	74,41	74,64
	k-EYK-3	72,13	72,37	75,84	72,49	74,64
	k-EYK-5	75,60	76,56	76,92	75,00	76,20
	k-EYK-7	75,72	76,16	76,20	74,64	77,16
	Rastgele Orman	80,95	83,3	81,19	80,50	80,59

Normalizasyon uygulanmayan ve z-skor normalizasyonu uygulanan istavrit balığı verilerinin rastgele orman algoritması ile sınıflandırma doğruluklarının detaylarını içeren, 10 sınıflandırma sonucunun ortalama değerine ait hata matrisleri Şekil 31 ve Şekil 32’de gösterilmiştir.



Şekil 31. Normalizasyon işlemi uygulanmayan istavrit balığı verisinin sınıflandırma doğruluğuna ait hata matrisi

Sınıflandırma Sonuçları
Rastgele Orman Algoritması - %83.3

Gerçek Sınıf	Az Pişmiş	10 71.4%	4 28.6%	0 0.0%
	Pişmiş	5 17.9%	21 75.0%	2 7.1%
	Fazla Pişmiş	0 0.0%	3 7.1%	39 92.9%
		Tahmin Edilen Sınıf		
		Az Pişmiş	Pişmiş	Fazla Pişmiş

Şekil 32. Z-skor normalizasyonu uygulanan istavrit balığı verisinin sınıflandırma doğruluğuna ait hata matrisi

Şekil 31 ve Şekil 32 incelendiğinde istavrit balığı verilerinin az pişmiş, pişmiş ve fazla pişmiş olarak 3 sınıfta sınıflandırılması sonuçları görünmektedir. Normalizasyon uygulanan veride az pişmiş ve pişmiş sınıfları normalizasyon uygulanmayan veriye göre daha iyi sınıflandırılmıştır.

5. SONUÇLAR

Bu tez çalışmasında, 4 farklı yiyeceğin Vestel ankastre fırında pişirilmesi sonucu, koku verileri MOS sensörler ile tasarlanan elektronik burun deney düzeneği sayesinde pişme derecelerine göre sınıflandırılmıştır. Bilgisayara kaydedilen koku verilerine ait grafikler ayrı ayrı incelenerek pişme sürelerini birbirinden ayıracak en iyi ve en az sayıda sensör elde edilmeye çalışılmıştır. Bu bağlamda kullanılan 3 adet sensörün (TGS826, TGS2602 ve TGS2620), deneyleri gerçekleştirilen yiyecekleri pişme sürelerine göre ayırt edici tepkilere sahip olduğu görülmüştür. TGS826 ve TGS2620 sensör verilerinin börek ve kek yiyeceklerini ayırt etmede, TGS826 ve TGS2602 sensörlerinin ise istavrit ve somon balığı yiyeceklerini ayırt etmede başarılı olduğu görülmüştür. Bu şekilde sensör sayısı optimize edilmiştir.

Piştirilen her bir yiyecek için sınıflandırma sonuçları ayrı ayrı incelendiğinde böreğin sınıflandırma doğruluğunun z-skor normalizasyon yöntemi uygulanarak ve karesel DVM ile sınıflandırıldığında %83,3 olarak en yüksek değere ulaştığı belirlenmiştir. Keke ait en yüksek sınıflandırma doğruluğu minimum-maksimum normalizasyon yöntemi uygulanarak rastgele orman algoritması ile sınıflandırıldığında %82,2 olarak hesaplanmıştır. Somon balığı sınıflandırma sonuçlarında ise en yüksek başarı %77,4 olarak hesaplanmış ve sigmoid normalizasyon yöntemi uygulanarak ve k-EYK-3 algoritması ile sınıflandırıldığında elde edilmiştir. Son olarak istavrit balığına ait sınıflandırma başarısı ise %83,3 olarak hesaplanmış ve z-skor normalizasyonu ve rastgele orman algoritması ile elde edilmiştir. Tüm yiyeceklerin sınıflandırma doğruluklarına ait hata matrisleri incelendiğinde ise hepsinde fazla pişmiş sınıfının sınıflandırma başarısının %90'ın üzerinde olduğu görülmektedir. Elde edilen sonuçlar neticesinde; kullanılan gıdalar için en uygun sensörlerin, normalizasyon yönteminin ve sınıflandırma algoritmasının seçiminin sınıflandırma doğruluğu başarısında ne kadar önemli olduğu anlaşılmıştır.

Bu tez çalışmasında kullanılan tüm yiyeceklerin fazla pişmiş sınıfının iyi bir şekilde sınıflandırılabilmesi, ankastre fırınlarda aşırı pişme durumunun önlenmesi amacıyla elektronik burun kullanmanın bu amaca uygun bir yöntem olduğunu göstermiştir.

6. KAYNAKLAR

- Akdemir, B. (2009). Tahmin Uygulamalarında Performans Geliştirmek İçin Kullanılan Normalizasyon Metodlarına Yeni Bir Yaklaşım. *Doktora Tezi*. Selçuk Üniversitesi, Konya.
- Akmaz, D. (2022). Güç Kalitesi Olaylarının Dalgacık Dönüşümü, K-En Yakın Komşu Algoritması Ve Kazanç Oranı Özellik Seçme Yöntemi Kullanılarak Tanınması. *International Journal of Innovative Engineering Applications*.
- Arshak, K., Moore, E., Lyons, G., Harris, S., & Clifford, S. (2004). A review of gas sensors employed in electronic nose applications. *Sensor Review*, 181-198.
- Beyhan, S., & Çetin, M. (2019). Elektronik Burun Tasarımı ve Literatür Araştırması. *Otomatik Kontrol Türk Milli Komitesi 2019 Ulusal Toplantısı*. Muğla.
- Chong, E., Moroni, M., Wilson, C., Shoham, S., Panzeri, S., & Rinberg, D. (2020). Manipulating synthetic optogenetic odors reveals the coding logic of olfactory perception. *Science*.
- Demir, F. (2021). L1-Norm DVM ve Ki-Kare Tabanlı Öznitelik Seçme Algoritmaları ile Parkinson Hastalığının Konuşma Sinyalleri Üzerinden Saptanması. *International Journal of Pure and Applied Sciences*, 32-40.
- Figaro TGS 2620 Sensör Kataloğu. (2024). Figaro: https://www.figarosensor.com/product/docs/tgs2620_product%20information%28fusa%29_rev04.pdf adresinden alındı
- Gao, X., & Zhang, T. (2018). An overview: Facet-dependent metal oxide semiconductor gas sensors. *Sensors and Actuators B: Chemical*, 604-633.
- Harman, G. (2021). Destek Vektör Makineleri ve Naive Bayes Sınıflandırma Algoritmalarını Kullanarak Diabetes Mellitus Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 7-13.
- Hasan, N., Ejaz, N., Ejaz, W., & Kim, H. S. (2012). Meat and Fish Freshness Inspection System Based on Odor Sensing. *Sensors*, 15542-15557.
- Huang, Y., Doh, I.-J., & Bae, E. (2021). Design and Validation of a Portable Machine Learning-Based Electronic Nose. *Sensors*.
- İncegöl, A., & Taşdelen, K. (2021). Elektronik Burun Kullanılarak Arabika (*Coffea arabica*) ve Robusta (*Coffea canephora*) Kahvelerinin Ayırıştırılması. *Bilge International Journal of Science and Technology Research*, 101-106.
- İncegöl, Y., Özkan, G., İncegöl, A., & Taşdelen, K. (2022). Elektronik Burun Metal Oksit Yarı İletken Sensörlerin Gıda Analizlerinde Kullanımı. *Akademik Gıda*, 454-473.

- Jadhav, S., & Channe, H. (2013). Comparative Study of K-NN, Naive Bayes and Decision Tree Classification Techniques. *International Journal of Science and Research (IJSR)*.
- Jayalakshmi, T., & Santhakumaran, A. (2011). Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*.
- Karakoyun, M., & Hacıbeyoğlu, M. (2014). Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 30-41.
- Kavzoğlu, T., & Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 73-82.
- Kazdal, E. (2022). E-Burun Kullanılarak Aynı Ve Ayır Hasat Dönemindeki Farklı Kalitelere Sahip Siyah Çayların Sınıflandırılması. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- Li, W., & Liu, Z. (2011). A method of SVM with Normalization in Intrusion Detection. *Procedia Environmental Sciences*, 256-262.
- Medium. (2024). Makine Öğrenimi Bölüm-5 (Karar Ağaçları): <https://medium.com/@k.ulgen90/makine-%C3%B6%C4%9Frenimi-b%C3%B6l%C3%BCm-5-karar-a%C4%9Fa%C3%A7lar%C4%B1-c90bd7593010> adresinden alındı
- Özlüer Başer, B., Yangın, M., & Sarıdaş, E. (2021). Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 112-120.
- Özsandıkciğlu, Ü., Atasoy, A., & Güney, S. (2015). Classification of Different Objects with Artificial Neural Networks Using Electronic Nose. *23th IEEE Signal Processing and Communications Applications Conference (SIU)*, 815-818.
- Özsandıkciğlu, Ü., Atasoy, A., & Güney, S. (2015). Fish Freshness Testing with Artificial Neural Networks. *9th International Conference on Electrical and Electronics Engineering (ELECO)* (s. 700-704). Bursa: IEEE.
- Pearce, T., Schiffman, S., Nagle, H., & Gardner, J. (2002). *Handbook of Machine Olfaction: Electronic Nose Technology*. Almany: Wiley-VCH Verlag GmbH & Co. KGaA.
- Ponzoni, A., Depari, A., Falasconi, M., Comini, E., Flammini, A., Marioli, D., . . . Sberveglieri, G. (2008). Bread baking aromas detection by low-cost electronic nose. *Sensors and Actuators B: Chemical*, 100-104.
- Rigatti, S. (2017). Random Forest. *Journal of Insurance Medicine*, 31-39.

- Romani, S., Balestra, F., Angioloni, A., Rocculi, P., & Rosa, M. (2012). PHYSICO-CHEMICAL AND ELECTRONIC NOSE MEASUREMENTS ON THE STUDY OF BISCUIT BAKING KINETICS. *Italian Journal of Food Science*, 32-40.
- Saraoğlu, H. M. (2008). Elektronik burun teknolojisi ve uygulama alanları. *Akademik Bilişim*.
- Solenoid Valve. (2024). Wikipedia: https://en.wikipedia.org/wiki/Solenoid_valve adresinden alındı
- Standard score. (2024). Wikipedia: https://en.wikipedia.org/wiki/Standard_score adresinden alındı
- Teflon. (2024). Vikipedi: <https://tr.wikipedia.org/wiki/Teflon> adresinden alındı
- Tuncer, E., & Bolat, E. (2022). Destek Vektör Makineleri ile EEG Sinyallerinden Epileptik Nöbet Sınıflandırması. *Politeknik Dergisi*, 239-249.
- URL-1. (2024, Ocak 15). *Figaro*. <https://www.figarosensor.com/> adresinden alındı
- Usta, E. N., Atasoy, A., & Özsandıkçıoğlu, Ü. (2023). Elektronik Burun ile Yiyecekleri Pişme Derecelerine Göre Sınıflandırma. *Ege 9. Uluslararası Uygulamalı Bilimler Kongresi* (s. 527-536). İzmir: Academy Global Publishing House.
- Vakum Pompası. (2024). Salmastraburada: <https://salmastraburada.com/vakum-pompasi/> adresinden alındı
- Yavuz, S., & Deveci, M. (2012). İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 167-187.
- Yüce, H., & Özkan, A. O. (2021). Normalizasyon Yöntemlerinin Biyomedikal Verilerde Sınıflandırma Performansına Etkisi. *Avrupa Bilim ve Teknoloji Dergisi*, 35-43.

ÖZGEÇMİŞ

Eda Nur USTA, ilköğrenimini Gazi İlköğretim Okulu'nda bitirdikten sonra lise eğitimini 2014 yılında Beşikdüzü İMKB Anadolu Öğretmen Lisesi'nde tamamladı. 2014-2015 eğitim öğretim yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde lisans eğitimine başladı. 2017-2018 eğitim öğretim yılı bahar dönemini Erasmus+ Öğrenim Hareketliliği kapsamında AGH University of Science and Technology, Krakov, Polonya'da tamamladı. 2019 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden mezun oldu. 2020 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim dalında tezli yüksek lisans programına başladı. 2022 Temmuz ayından itibaren Aksa Karadeniz Doğal Gaz Dağıtım A.Ş.'de Tarife ve Raporlama Uzmanı olarak görev yapmaktadır.

Usta, E.N., Atasoy, A., ve Özsandıkçıoğlu, Ü. (2023). Elektronik Burun ile Yiyecekleri Pişme Derecelerine Göre Sınıflandırma. *Ege 9. Uluslararası Uygulamalı Bilimler Kongresi*, s. 527-536. İzmir.