T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KONVEYÖRLÜ ELEKTRİK FIRINLARINDA PİŞİRİLEN ÜRÜNLERİN PİŞME SEVİYELERİNE GÖRE MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE SINIFLANDIRILMASI

Hazırlayan
Kerem ARSLANGİRAY

Danışman
Dr. Öğr. Üyesi Sertaç SAVAŞ

Yüksek Lisans Tezi

Kasım 2024
KAYSERİ

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KONVEYÖRLÜ ELEKTRİK FIRINLARINDA PİŞİRİLEN ÜRÜNLERİN PİŞME SEVİYELERİNE GÖRE MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Hazırlayan
Kerem ARSLANGİRAY

Danışman
Dr. Öğr. Üyesi Sertaç SAVAŞ

Kasım 2024
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Kerem ARSLANGİRAY

İmza

“Konveyörlü Elektrik Fırınlarında Pişirilen Ürünlerin Pişme Seviyelerine Göre Makine Öğrenmesi Algoritmaları ile Sınıflandırılması” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan	**Danışman**
Kerem ARSLANGİRAY	Dr. Öğr. Üyesi Sertaç SAVAŞ
İmza	İmza

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

İmza

TEŞEKKÜR

"Konveyörlü Elektrik Fırınlarında Pişirilen Ürünlerin Pişme Seviyelerine Göre Makine Öğrenmesi Algoritmaları ile Sınıflandırılması" konulu tezin belirlenmesinde, yürütülmesinde ve sonuçlandırılmasında maddi manevi destek ve yardımlarda bulunan değerli danışman hocam Sayın Dr. Öğr. Üyesi Sertaç SAVAŞ'a teşekkür ederim.

Tez çalışması boyunca verdiği maddi, manevi destek ve gösterdiği anlayıştan dolayı eşim Kader ARSLANGİRAY'a, yine her daim yanımda olan annem, babam, abim ve ablama, ayrıca çalışmalarımın her safhasında görüş, öneri ve desteklerini esirgemeyen Arş. Gör. Mehmet Safa BİNGÖL'e teşekkür ederim.

Son olarak bu çalışmada kullanılan verileri sağlamadaki değerli katkılarından dolayı BUHARA Endüstriyel Makine San. ve Dış Tic. Ltd. Şti.'ne teşekkür ederim.

Kerem ARSLANGİRAY

Kasım 2024, KAYSERİ

KONVEYÖRLÜ ELEKTRİK FIRINLARINDA PİŞİRİLEN ÜRÜNLERİN PİŞME SEVİYELERİNE GÖRE MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE SINIFLANDIRILMASI

Kerem ARSLANGİRAY

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Kasım 2024
Danışman: Dr. Öğr. Üyesi Sertaç SAVAŞ

ÖZET

Antik çağlardan günümüze kadar kullanılan fırında pişirme tekniği, teknolojinin gelişmesiyle birlikte yapay zeka destekli akıllı özelliklerle donatılmıştır. Zamanın kritik bir faktör olduğu büyük restoran ve işletmeler için, hızlandırılmış pişirme özelliklerine, hassas kontrol kabiliyetlerine ve isteğe bağlı özelleştirme seçeneklerine sahip yeni nesil akıllı fırınlar büyük önem kazanmıştır. Bu gereksinimler, pişirme parametrelerinin (hız, sıcaklık, pişme seviyesi gibi) önceden tahmin edilmesini, dolayısıyla fırın performansının artırılmasını zorunlu kılmaktadır. Bu tez çalışmasında, konveyörlü elektrikli fırınlarda pişirilen ürünlerin pişme seviyelerini (az pişmiş, pişmiş, çok pişmiş) belirlemek için bir sınıflandırıcı geliştirilmiştir. Sınıflandırıcı tasarımında, denetimli makine öğrenmesi algoritmalarından Karar Ağaçları (İnce, Orta, Kaba Ağaç) ve K-En Yakın Komşu (İnce, Orta, Kaba KNN) yöntemleri karşılaştırmalı olarak kullanılmıştır. Altı farklı modelin eğitim ve test performansları, doğruluk yüzdesi, toplam maliyet, tahmin hızı ve eğitim süresi gibi metriklerle değerlendirilmiştir. Bunlar arasında İnce KNN, %92.7 eğitim ve %95.2 test doğruluğu ile en başarılı model olarak elde edilmiştir. Sonuçlar karışıklık matrisleri ve ROC eğrileriyle desteklenmiş olup, önerilen modelin, ürünlerin belirlenen hız ve sıcaklıkta istenen pişme seviyesine ulaşıp ulaşmadığını yüksek doğrulukla tespit edebildiği ve gerçek zamanlı uygulamalarda kullanılabilecek olduğu ortaya konmuştur.

Anahtar Kelimeler: Konveyörlü elektrik fırınları, pişme seviyesi sınıflandırması, makine öğrenmesi, karar ağaçları, k-en yakın komşu (KNN).

CLASSIFICATION OF PRODUCTS BAKED IN CONVEYOR ELECTRIC OVENS ACCORDING TO THEIR BAKING LEVELS USING MACHINE LEARNING ALGORITHMS

Kerem ARSLANGİRAY

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, November 2024
Supervisor: Assist. Prof. Dr. Sertaç SAVAŞ

ABSTRACT

The oven baking technique, which has been used from ancient times to the present day, has been equipped with smart features supported by artificial intelligence with the development of technology. For large restaurants and businesses where time is a critical factor, new generation smart ovens with accelerated baking features, precise control capabilities and optional customization options have gained great importance. These requirements necessitate the prediction of baking parameters (such as speed, temperature, baking level) in advance, thus increasing oven performance. In this thesis, a classifier is developed to determine the baking levels (underbaked, properly baked, overbaked) of products baked in conveyor electric ovens. In the design of the classifier, supervised machine learning algorithms Decision Trees (Fine, Medium, Coarse Tree) and K-Nearest Neighbors (Fine, Medium, Coarse KNN) methods are used comparatively. The training and test performances of six different models are evaluated with metrics such as accuracy percentage, total cost, prediction speed and training time. Among these, the Fine KNN is obtained as the most successful model with 92.7% training and 95.2% test accuracy. The results are supported by confusion matrices and ROC curves, and it is shown that the proposed model can detect with high accuracy whether the products reach the desired baking level at the specified speed and temperature and can be used in real-time applications.

Keywords: Conveyor electric ovens, baking level classification, machine learning, decision trees, k-nearest neighbors (KNN).

İÇİNDEKİLER

KONVEYÖRLÜ ELEKTRİK FIRINLARINDA PİŞİRİLEN ÜRÜNLERİN PİŞME SEVİYELERİNE GÖRE MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE SINIFLANDIRILMASI

BİLİMSEL ETİĞE UYGUNLUK ii

YÖNERGEYE UYGUNLUK iii

KABUL VE ONAY iv

TEŞEKKÜR v

ÖZET vi

ABSTRACT vii

İÇİNDEKİLER viii

KISALTMALAR x

TABLOLAR LİSTESİ xi

ŞEKİLLER LİSTESİ xii

GİRİŞ 1

1. BÖLÜM

TEZİN AMACI VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Amacı 3

1.2. Literatür Çalışması 3

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Konveyörlü Elektrik Fırını 9

2.1.1. Sistemin Proses Şeması, Kontrol Yapısı ve Sistem Bileşinleri 9

2.1.2. Pişirilen Ürünler ve Veri Setinin Hazırlanması 17
2.2. Sınıflandırma Algoritmaları 20
2.2.1. Karar Ağaçları Algoritması 21
2.2.2. K-En Yakın Komşu Algoritması 24

3. BÖLÜM
SİMÜLASYON ÇALIŞMALARI

3.1. Eğitim ve Test Çalışmaları 26
3.2. Karışıklık Matrisleri 28
3.3. ROC Eğrileri 35

4. BÖLÜM
SONUÇ VE ÖNERİLER

KAYNAKÇA 43
ÖZGEÇMİŞ 48

KISALTMALAR

vb.: Ve benzeri

KNN: K-Nearest Neighbors Algorithm – K-En Yakın Komşu Algoritması

ROC: Receiver Operating Characteristic – Alıcı İşletim Karakteristiği

PLC: Programmable Logic Controller – Programlanabilir Lojik Kontrolör

°C: Santigrat Derece

PID: Proportional Integral Derivative Controller – Oransal İntegral Türevsel Kontrolör

SCADA: Supervisory Control and Data Acquisition – Merkezi Kontrol ve Veri Toplama

POM-QM: Production and Operations Management - Quantitative Methods – Üretim ve Operasyon Yönetimi - Nicel Yöntemler

CART: Classification & Regression Tree – Sınıflandırma ve Regresyon Ağacı

GRNN: General Regression Neural Networks – Genelleştirilmiş Regresyon Sinir Ağı

HMI: Human Machine Interface – Operatör Panel

V: Volt

PWM: Pulse Width Modulation – Sinyal Genişlik Modülasyonu

SSR: Solid State Relay – Katı Hal Rölesi

TFT: Thin Film Transistor – İnce Film Transistör

RTC: Real Time Clock – Gerçek Zamanlı Saat

DC: Direct Current – Doğru Akım

AC: Alternating Current – Alternatif Akım

sn: Saniye

EV: Expected Value – Beklenen Değer

EVdal1: 1. dal için beklenen değer

EVdal2: 2. dal için beklenen değer

EVdalN: N. dal için beklenen değer

CPU: Central Process Unit – Merkezi İşlem Birimi

GHz: Gigahertz

GB: Gigabayt

DP: TPR-True Positive Rate – Doğru Pozitif Oranı

YN: FNR-False Negative Rate – Yanlış Negatif Oranı

AUC: Area Under the Curve – Eğri Altında Kalan Alan

TABLOLAR LİSTESİ

Tablo 2.1. Pişmiş ürünlere ait ürün türü, indis numarası, pişme süresi/hızı (sn) ve rezistans sıcaklıkları (°C) için örnek veri seti 19
Tablo 2.2. Karar Ağaçları algoritması sınıflandırma türleri 22
Tablo 2.3. Karar Ağaçları algoritmasının model hiperparametreleri 23
Tablo 2.4. K-En Yakın Komşu algoritması sınıflandırma türleri 24
Tablo 2.5. K-En Yakın Komşu algoritmasının model hiperparametreleri 25
Tablo 3.1. Eğitim ve test parametreleri 27
Tablo 3.2. Karar Ağaçları ve KNN modellerinin eğitim sonuçları 28
Tablo 3.3. Karar Ağaçları ve KNN modellerinin test sonuçları 28

ŞEKİLLER LİSTESİ

Şekil 2.1. Elektrikli fırın proses şeması 9
Şekil 2.2. Fırın kontrol blok diyagramı 10
Şekil 2.3. GMT marka PLC [34] 11
Şekil 2.4. HMI operatör paneli [35] 12
Şekil 2.5. GMT genişleme modülü [36] 13
Şekil 2.6. Katı hal rölesi (SSR) [37] 13
Şekil 2.7. SSR devresi iç yapısı [38] 14
Şekil 2.8. K tip termokupl [40] 14
Şekil 2.9. K tip termokupl çalışma prensibi [41] 14
Şekil 2.10. Motor sürücü [42] 15
Şekil 2.11. Fırının genel görünümü ve bileşenleri 15
Şekil 2.12. Fırının ısıtma paneli (rezistans) 16
Şekil 2.13. Fırın boyunca konumlandırılan ısı bölgeleri ve rezistanslar 16
Şekil 2.14. Pişirilen ürünlere ait görseller 18
Şekil 2.15. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi 20
Şekil 2.16. Makine öğrenmesi türleri ve alt kategorileri 21
Şekil 3.1. Sınıflandırıcı modelinin şematik yapısı 26
Şekil 3.2. Doğrulama Karışıklık Matrisleri: (a) İnce Ağaç ve (b) İnce KNN 29
Şekil 3.3. Test Karışıklık Matrisleri: (a) İnce Ağaç ve (b) İnce KNN 30
Şekil 3.4. Doğrulama Karışıklık Matrisleri: (a) Orta Ağaç ve (b) Orta KNN 31
Şekil 3.5. Test Karışıklık Matrisleri: (a) Orta Ağaç ve (b) Orta KNN 32
Şekil 3.6. Doğrulama Karışıklık Matrisleri: (a) Kaba Ağaç ve (b) Kaba KNN 33
Şekil 3.7. Test Karışıklık Matrisleri: (a) Kaba Ağaç ve (b) Kaba KNN 34
Şekil 3.8. Doğrulama ROC Eğrileri: (a) İnce Ağaç ve (b) İnce KNN 35
Şekil 3.9. Test ROC Eğrileri: (a) İnce Ağaç ve (b) İnce KNN 36
Şekil 3.10. Doğrulama ROC Eğrileri: (a) Orta Ağaç ve (b) Orta KNN 37
Şekil 3.11. Test ROC Eğrileri: (a) Orta Ağaç ve (b) Orta KNN 38
Şekil 3.12. Doğrulama ROC Eğrileri: (a) Kaba Ağaç ve (b) Kaba KNN 39
Şekil 3.13. Test ROC Eğrileri: (a) Kaba Ağaç ve (b) Kaba KNN 40

GİRİŞ

Değişen ve gelişen dünya ile beraber sanayi ve endüstride farklı fırın ihtiyaçları doğmuştur. İhtiyaç duyulan fırınların akıllı, sistematik ve verimli olması gerekmektedir. Bu fırınlar sanayinin farklı alanlarında kullanılabilmektedir. Demir işleme alanlarında demir eritme fırınları, cam sanayisinde temperli fırınlar, seramik alanında seramik fırınlar ve gıda endüstrisinde gıda pişirme fırınları kullanılmaktadır. Gıda endüstrisinde kullanılan fırınlar genellikle pişirme üzerine imal edilirler. Bu fırınlarda genel olarak balık, et, tavuk, pizza, lahmacun, pide, ekmek vb. yiyecek türleri pişirilmektedir.

Fırın gibi sistemlerde bazı parametrelerin önceden bilinmesi ya da tahmin edilmesi gerekmektedir. Bu bilgi ve tahmin, pişirilecek ürünün testlere tabi tutulmadan doğrudan pişirilme evresine geçmesini sağlar. Bu hızlı geçiş, zamandan, maliyetten ve iş gücünden tasarruf ettirmektedir. Yapılan tez çalışmasında ise pişirilecek ürünlerin pişirme bilgilerini önceden tahmin etmek için ürünlerin pişme seviyelerini (az pişmiş, pişmiş, çok pişmiş) belirleyecek bir sınıflandırıcı geliştirilmiştir. Sınıflandırma çalışmaları konveyörlü bir elektrik fırınından 16 farklı ürün tipi için elde edilmiş veri seti kullanılarak gerçekleştirilmiştir. Çalışmada denetimli makine öğrenmesi algoritmalarından Karar Ağaçları (Decision Trees) ve K-En Yakın Komşu (K-Nearest Neighbors - KNN) yöntemleri karşılaştırmalı olarak kullanılmış; Karar Ağaçları için İnce Ağaç (Fine Tree), Orta Ağaç (Medium Tree) ve Kaba Ağaç (Coarse Tree) modelleri, KNN için ise İnce KNN (Fine KNN), Orta KNN (Medium KNN) ve Kaba KNN (Coarse KNN) modelleri olmak üzere altı farklı model karşılaştırılmıştır. Tüm eğitim ve test çalışmaları MATLAB'da yapılmış olup, sonuçlar doğruluk yüzdesi, toplam maliyet, tahmin hızı ve eğitim süresi gibi metrikler ile karşılaştırılmalı olarak analiz edilmiştir. Ayrıca sonuçların analizi karışıklık matrisleri (confusion matrix) ve ROC (Receiver Operating Characteristic-Alıcı İşletim Karakteristiği) eğrileri ile desteklenmiştir.

Tez çalışması 4 bölümden oluşmaktadır. 1. bölümde tezin amacı açıklanmış ve literatür çalışması anlatılmıştır. “Yöntem ve Materyal” başlıklı 2. bölümde ise, sınıflandırıcı tasarımında kullanılacak veri setinin temin edildiği konveyörlü endüstriyel fırının proses şeması, kontrol yapısı ve sistem bileşenleri ile pişirilen ürünler ve veri setinin hazırlanması hakkında bilgiler verilmiştir. Ayrıca makine öğrenmesi ve alt dalları ile çalışmamıza konu olan sınıflandırma algoritmaları olan Karar Ağaçları ve K-En Yakın Komşu algoritması detaylı bir şekilde açıklanmıştır. Çalışmanın 3. bölümünde, sınıflandırma çalışmasının eğitim ve test çalışmaları iki algoritmanın da üç farklı modeli için gerçekleştirilmiş ve bulgular karışıklık matrisleri ve ROC eğrileri olarak verilmiştir. Son olarak 4. bölümde ise sonuç ve öneriler üzerinde durulmuştur.

1. BÖLÜM

TEZİN AMACI VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Amacı

Amacımız teknolojiyi kullanarak her sektörde olduğu gibi gıda sektöründe de çözümler üretmektir. Gıda ürünlerinin tüketim ihtiyacının yüksek olduğu yerlerde, küçük ve orta ölçekli elektrikli, odunlu ve gazlı fırınlar ihtiyaca cevap verememektedir. Ayrıca konveyörlü fırınlarda pişirilecek bazı ürünlerin hangi hız ve sıcaklıkta piştiğini saptamak için birçok deneme ve test yapılması gerekmektedir. Bu olay zaman ve maddi kayıplara yol açmaktadır.

Tez çalışmasında konveyörlü bir elektrik fırınından elde edilen veri seti ile makine öğrenmesi algoritmaları kullanılarak ürünün pişip pişmediği üzerine bir sınıflandırma yapılmıştır. Böylece sınıflandırma algoritmalarının kulllanımı ile zaman kaybetmeden gerekli ürünün hangi aralıkta pişebildiği tespit edilebilecektir. Bu algoritmalar aynı zamanda cam, seramik, demir-çelik eritme ve boya kurutma fırınları gibi yerlerde de uygun veri seti ile eğitilip, ardından test edilerek kullanılabilir. Sınıflandırma algoritmaları kullanımı ile büyük ve küçük işletmelerde zaman, iş gücü ve maddi kayıpların önüne geçilebilecektir.

1.2. Literatür Çalışması

Gıda ürünlerinin fırınlarda pişirilme süreci yüzyıllardır devam etmektedir. Günümüzde ise teknolojik gelişmelere paralel olarak yeni nesil fırınlar üretilmektedir. Endüstriyel kullanımdaki birçok fırın, kullanıcıya özgü program arayüzleri sunabilmektedir. Bu sayede, kullanıcılar fırınları daha kolay ve sorunsuz bir şekilde kullanabilmektedir. Kullanıcı panelleri sayesinde sıcaklık, süre, yiyecek türü ve pişirme programı gibi

ayarlamalar dokunmatik ekran üzerinden yapılabilmektedir. Ayrıca, iletişim teknolojilerindeki gelişmeler sayesinde fırınlar da dahil olmak üzere birçok cihaz uzaktan kontrol edilebilmektedir.

Gıda ürünlerinin pişirme süreçleri ile ilgili birçok çalışma yapılmıştır. Abdulazim Hansu [1] tarafından yapılan çalışmada, PLC ile bir akıllı fırın tasarımı için gerekli teknolojik gelişmeler incelenmiş ve pişirmenin çoğunlukla yemeğin türüne göre yapıldığı belirlenmiştir. Gıda türlerini balık, et, tavuk, pizza ve ekmek gibi başlıklar altında sınıflandırmıştır. Çalışmada kullanıcılar otomatik olarak yemek pişirilebilmekte veya sadece sıcaklık ve süreyi seçerek pişirme işlemini yapabilmektedir. Thorvaldsson ve Skjöldebrand [2] tarafından yapılan ekmekte ısı ve su taşınımı araştırmalarında ekmeğin 225°C'de 35 dakika pişirilmesi gözlemlenmiştir. Unun pişme sırasındaki sıcaklığı ölçülmüştür. Sonuç olarak 70±5°C'ye kadar olan sıcaklıklarda ekmeğin yapısının ve ekmeğin içindeki su oranının değiştiği gözlemlenmiştir. Bu sıcaklığın üzerindeki değerlerde su parçacıklarının kademeli olarak buharlaşmaya başladığı gözlemlenmiştir. Purlis ve Salvadori [3] tarafından yapılan çalışmada, pişirme sırasında yaklaşık 100°C'de kabuk ile iç kısım arasındaki buharlaşma etkisinden kaynaklanan sıcaklık ve nem değişikliklerini gösteren fenomenolojik bir model oluştuğu gözlemlenmiştir. Buharlaşma etkisiyle ekmekte iç kısım ve kabuk kısmı olmak üzere iki bölge oluştuğu görülmüştür. Kabukta nem oranının düşük seviyelerde olduğu ve kabuk sıcaklığının fırının iç sıcaklığına yakın olduğu görülmüştür. Kabuk içinde kalan kısımda nemin sabit ve iç sıcaklığın 100°C olduğu gözlemlenmiştir. Mankan [4] tarafından yapılan çalışmada, ekmek hamuru yapımında farklı çavdar unları kullanılmış ve sekiz farklı hamur elde edilmiştir. Bu hamurlar Farinograph, Extensograph ve Amylograph cihazlarıyla karşılaştırılmıştır. Karşılaştırma sonucunda çavdar oranının elde edilen ekmeğin kalitesini etkilediği gözlemlenmiştir. Çavdarın oranı ekmeğin ağırlığını ve hacmini de etkilemektedir. Yapılan deneyler, çavdar unu oranının ekmek içi rengini, kabuk rengini, dokusunu, elastikiyetini ve lezzetini etkilediğini göstermiştir.

Fırın tasarımları ve kontrolü üzerine de literatürde birçok çalışma yer almaktadır. Astrom ve Hagglund [5] tarafından yapılan çalışmada, fırının sıcaklık kontrolü, sıcaklık kontrol uygulamaları için önerilen PID (oransal-integral-türevsel) kontrolör kullanılarak yapılmıştır. Kantaş [6] tarafından yapılan çalışmada, ev tipi elektrikli fırınların yüksek verimde çalışması için bir hava dağıtım kanalı yapılmıştır. Fırın verimliliği için enerji

sarfiyatı ve ürünün pişme kalitesi önemli bir yer tutmaktadır. Hava dağıtım kanalının fırın performansı üzerindeki olumlu etkisi fark edilmiş ve bir hava kanalı tasarımı için planlamalar yapılmıştır. Yapılan hava kanalı fırın üzerine konulup fırın iç sıcaklığı baz alınarak teste tabi tutulmuştur. Hava dağıtım kanalının son hali testlerde elde edilen verilere dayandırılarak tasarlanmıştır. Tasarlanan hava kanalı, son haliyle bir ürün haline getirilmiş, bu ürün kullanılarak da fırın içindeki sıcaklıklar ölçülmüştür. Bu sıcaklıklar tablo haline getirilmiş ve elde edilen verilerle çeşitli pişirme deneyleri yapılmıştır. Bu deneylerde pişme süreleri, pişme kalitesi ve ısı dağılımları karşılaştırılmıştır. Yapılan deneyler sonucunda hava dağıtım kanalı kullanıldığında ve kullanılmadığında elde edilen sonuçlar mukayese edildiğinde, toplam akışta %15,1'lik bir fark görülmüştür. Yılmaz [7] tarafından yapılan çalışmada, PLC ile ekmek üretimi süreçleri denetlenmiştir. PLC kontrollü otomatik ekmek üretim hattı hamurdan pişirmeye kadar her şeyi kapsamaktadır. Pişme süreci üç aşamadan oluşmaktadır. Bu adımlar hamurun yoğrulmasını, şekillendirilmesini ve son olarak pişirilmesini içerir. 3 adet PLC tarafından kontrol edilen üretim hattı yaklaşık 100 giriş ve çıkışa sahiptir. PLC tarafından alınan ve analiz edilen veriler sayesinde sistemde hata olup olmadığı tespit edilmektedir. Böylece üretim hattı arıza oranları azaltılmıştır. Çalışan sayısı azaltılmış, ekmeğin maliyeti düşmüş, kalite iyileşmiş ve hijyen koşulları sağlanmıştır. Edwards ve Spurgeon [8] tarafından yapılan çalışmada, numune bir seramik fırın tasarımı planlanmıştır. Fırında önce kontaktör kullanılarak, daha sonra da PID kontrolör kullanılarak ısı kontrolü yapılmıştır. Fırın verimiyle alakalı test sonuçlarının karşılaştırılması sonucunda PID kontrolörün daha verimli çalıştığı görülmüştür.

Usalan [9] tarafından yapılan çalışmada, endüstriyel fırınların gıda, çelik, seramik, cam gibi alanlarda kullanımı geniş bir şekilde araştırılmıştır. Elektrikli fırınlar birçok avantajı olduğundan tercih edilmektedir. Çevreci, kontrol edilebilir, güvenli, ekonomik ve herhangi bir yere depo edilme ihtiyacının olmaması gibi avantajları sebebiyle elektrikli fırınların sıcaklık kontrolü daha kolay hale gelmektedir. Bu değerlendirmelerden sonra PLC kontrollü bir SCADA sistemi tasarlamıştır. Bu sistemle beraber fırının sıcaklık set değerleri uzaktan kontrolle ayarlanabilmektedir. Operatör panel üzerinden sıcaklık set değerleri görülebilmekte, ihtiyaç dahilinde de değiştirilebilmektedir. Fırının çalışma periyodu süresince sıcaklıklar sensörler vasıtasıyla ölçülüp set değeri ile karşılaştırılmıştır. Fırının set edilen değere en kısa sürede ulaşması için gerekli veriler

işlenmiştir. Tao ve arkadaşları [10] tarafından yapılan çalışmada, sanayide kok fırını iç basınç kontrolü uygulamasında PID kontrolör ile analitik tabanlı matris kontrol modeli karşılaştırılmıştır. Karşılaştırma sonucunda PID kontrolörün daha iyi sonuç verdiği gözlemlenmiştir. Boisvert ve Runstedther [11] tarafından yapılan çalışmada, sanayi fırınları yakıt ilavesi işlemi için hesaplamalı akışkan dinamiği modeli konusunda çalışılmıştır. Yapılan çalışma test edildiğinde, akışkan kontrolünün hassas olması sebebiyle yakıt aktarımının gecikmeli bir şekilde olduğu görülmüştür.

Makine öğrenimi, görevlerin başarılı bir şekilde yerine getirilmesi için veri setlerini, algoritmaları ve istatistiksel öğrenme tekniklerini kullanan bir yapay zekâ dalıdır [12]. Makine öğrenmesinin alt dalı olan sınıflandırma konusunda da birçok çalışma yapılmıştır. Beşkardeş ve Özdemir [13], yaptıkları araştırmada sinterleme makinesinin verimliliğini artıracak, böylece makine yönetiminin operatörden alınarak otomatik olarak gerçekleştirilmesini sağlayacak bir model tanıma sistemi tasarlamışlardır. Tasarlanan bu sistemde doğrusal sınıflandırıcı, destek vektör makinesi ve yapay sinir ağı algoritmaları kullanılmıştır. Bu sınıflandırıcılar 4212 adet bağımsız veri seti üzerinde test edilmiş ve birbirleriyle karşılaştırılmıştır. Böylece algoritmaları kullanarak daha verimli bir fırın elde etmişlerdir. Kaşıkçı ve Gökçen [14], bir web sitesinin e-ticaret sitesi olup olmadığının tahmin edilmesi durumunu tek etiketleme yaparak sınıflandırma algoritmaları ile gerçekleştirmişlerdir. Çelik ve Koç [15], sınıflandırma algoritmalarını kullanarak Türkçe televizyon haberlerini finans, kültür vb. alanlarda çok etiketli bir yapı ile sınıflandırmışlardır. Göçgün ve Onan [16] yaptıkları çalışmada, bir alışveriş sitesindeki İngilizce ürün incelemelerini olumlu/olumsuz olarak sınıflandırmışlardır. Eryılmaz ve arkadaşları [17], e-posta kutularına gelen Türkçe e-postaların spam olup olmadığını araştırmışlardır. Safalı [18], bazı sosyal medya alanlarından topladığı mesajları, insanların siyasi koalisyonu destekleyip desteklememelerine göre sınıflandırmıştır. Çılgın ve arkadaşları [19], öncelikle kripto para birimleri hakkında paylaşılan İngilizce tweet paylaşımlarını duygulara göre sınıflandırmışlar, daha sonra bu duygular ile kripto para birimlerinin değeri arasındaki ilişkiyi araştırmışlardır. Makine öğreniminde kümeleme ve sınıflandırma yöntemlerinin bir kombinasyonunu kullanan Edwards ve arkadaşları [20], bir barajın pompa istasyonunda gerçekleştirilen bakımların planlı mı yoksa plansız mı olduğunu 12 yıl boyunca tutulan arıza kayıtlarından tahmin etmek için bir çalışma yürütmüşlerdir.

Karar Ağaçları ve K-En Yakın Komşu algoritmaları, sınıflandırma uygulamalarında sıklıkla kullanılmaktadır [21-24]. Özcan ve Külahlı [25], bir lastik üretim fabrikasının kalite bölümünde hatalı lastik tespiti sürecini incelemişlerdir. POM-QM paket programı yardımıyla belirsizlik ve risk altındaki karar verme süreçleri için Karar Ağaçları yöntemi uygulanmıştır. Uygulanan Karar Ağaçları yöntemi sonucunda, bölgenin gözden geçirilmesi lehine bir sonuç ortaya çıkmıştır. Onan [26] ise şirket iflaslarının tahmini üzerine bir çalışma yapmıştır. Bu amaçla, 240 farklı şirketin finansal özelliklerinden oluşan bir veri seti kullanılmıştır. Sınıflandırmada önemli yöntemlerden biri olan Karar Ağaçları yöntemine ait yedi farklı algoritma veri setine uygulanmış; doğru sınıflandırma yüzdesi, karekök ortalama hata, ortalama mutlak hata, doğruluk, geri çağırma ve F-skoru gibi kriterler değerlendirilmiştir. Sonuçlar analiz edildiğinde, Karar Ağaçları algoritmasının şirket iflaslarını tahmin etmek için kullanılabileceği görülmüştür. Yılmaz ve arkadaşları [27] ise Eskişehir ilindeki havayolu yolcu potansiyelini incelemiştir. Havayolu şirketleri uçuş hatlarını planlarken öncelikle o hattın kârlılığı ortaya konulmalıdır. Bunun için hattın potansiyel yolcu talebinin bilinmesi gerekmektedir. Bu amaçla çalışmada Karar Ağaçları yöntemi kullanılmıştır. Böylece, havayolu ile seyahat potansiyeli yüksek hatların belirlenmesi amaçlanmıştır. Özcan ve Özer [28], tarım sektöründe Karar Ağaçları kullanımını araştırmışlardır. Tarım sektöründe karşılaşılan sorunların belirsizlik ve risk içermesi, sektörde karar analizi kullanımını mümkün kılmıştır. Çalışmada durumlar belirsizlik ve risk altında değerlendirilmiş ve Karar Ağaçları çizilerek sonuçlar yorumlanmıştır. Çalışma, çiftçiye karar durumuna bağlı olarak uygun seçeneği sunmayı ve tarım sektöründe karar analizini uygulamayı hedeflemektedir. Karar Ağaçlarında olasılık atama yöntemi değişse de her iki durumda da zeytinin en uygun faaliyet olduğu kararlaştırılmıştır. Bilenler ve Özgüven [29], sahte para kontrolü üzerine bir araştırma yapmışlardır. Çevrimiçi platformdan alınan hazır veri seti kullanılarak sınıflandırma yapılmış, Karar Ağaçları algoritmalarından biri olan CART algoritması uygulanmıştır. Sınıflandırma sürecini incelemek ve algoritmik iyileştirmeler yapmak amaçlanmıştır. Çapraz doğrulama aşaması, özellikle sahtecilik denetimlerinde algoritmanın daha verimli kullanılabilmesi için ağaç yapısını daha doğru şekilde eğitmeyi hedeflemiştir.

Gül ve Kalyoncu [30], kullanıcı kaynaklı piston segman aşınması durumunda hava kompresörlerinde yağ konveksiyon hatasını incelemiştir. Ayrıca bu durumun kompresör

üzerindeki etkisini değerlendirmişlerdir. Çalışmada, K-En Yakın Komşu (KNN) yöntemini kullanmışlardır. Veri elde etmek için test sistemindeki sensörden veri kaydetmişlerdir. En yakın 30 komşuya göre Manhattan uzaklık ölçütü, test verisinde en başarılı sonuçları vermiştir. Oral ve arkadaşları [31] ise KNN ve genelleştirilmiş sinir ağlarının (GRNN) kalıp, döşeme ve duvar ekiplerinin 3 farklı özelliğe sahip verileri üzerindeki performansını incelemiştir. KNN, tüm veri setlerinde genelleştirilmiş sinir ağından daha iyi sonuç vermiştir. Hacıbeyoğlu ve arkadaşları [32] ise enerji verimliliğini artırma amacıyla binalarda enerji verimliliği üzerine bir çalışma yapmışlardır. Çalışmada doğrusal regresyon ve KNN algoritması kullanılmış; k parametre değeri optimize edilerek KNN algoritmasının performansı artırılmaya çalışılmıştır. Elde edilen sonuçlar, enerji verimliliğini artırmaya yönelik politikalar geliştirilmesinde kullanılabilecektir.

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Konveyörlü Elektrik Fırını

2.1.1. Sistemin Proses Şeması, Kontrol Yapısı ve Sistem Bileşinleri

Çalışmanın veri setinin temin edildiği, sanayi ve büyük lokantalarda kullanılacak konveyörlü fırının tasarım ve üretimi, PLC kontrol sistemi kullanılarak gerçekleştirilmiştir. Fırını kullanan yetkili kişi program ve pişirme süresi gibi kullanıcı ayarlarını bir dokunmatik ekranı aracılığıyla yapabilmektedir. PLC'deki tüm sensör verileri işlenir ve gerekli bilgiler dokunmatik ekrana aktarılır. Bu bilgiler sayesinde fırın için gerekli olan program, sıcaklık set değerleri, hız ve süreler dokunmatik ekran üzerinden girilerek fırın çalıştırma işlemi başlatılabilir. Bahsi geçen elektrikli fırının proses şeması Şekil 2.1'de, fırının kontrol blok diyagramı Şekil 2.2'de verilmiştir. Proses şemasında, fırın tasarımında kullanılan PLC modülü, sıcaklık modülü, güç kaynağı ve diğer bileşenler gösterilmiştir.

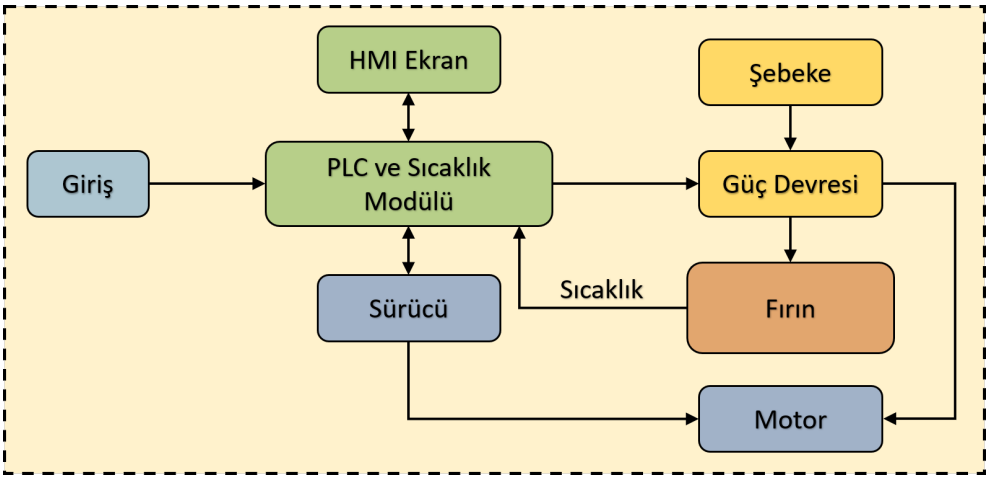

Şekil 2.1. Elektrikli fırın proses şeması

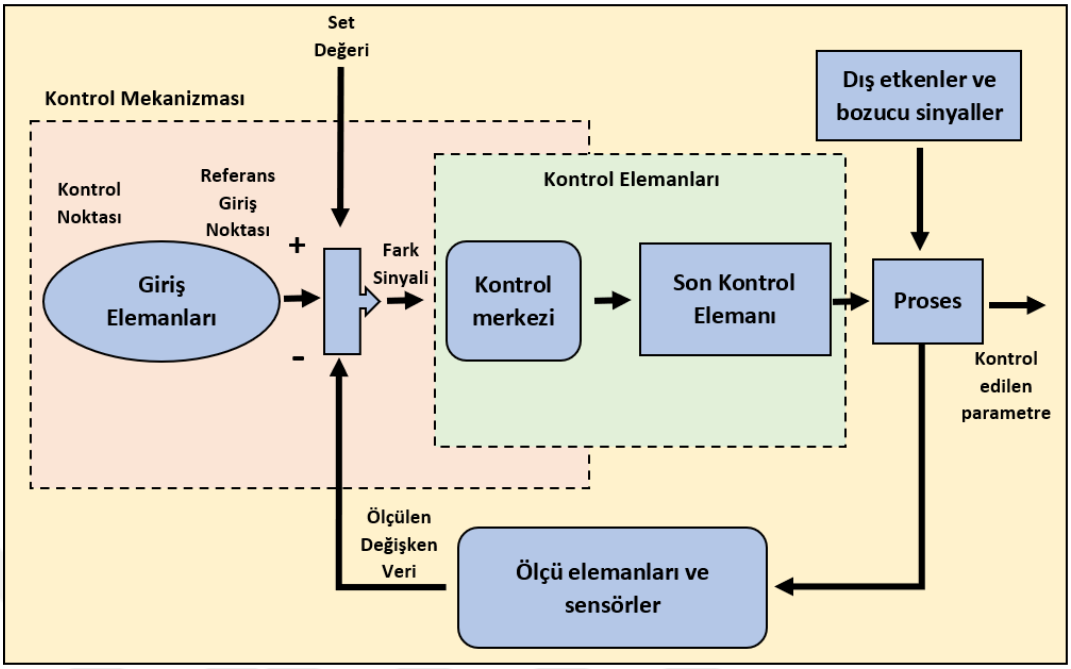

Şekil 2.2. Fırın kontrol blok diyagramı

Fırının çalışma prensibi, temelde bir PLC kontrolöre dayanır. PLC (GMT), RS232 protokolüyle HMI (TSG070)'a bağlanır. Aynı şekilde RS485 protokolüyle konveyör motorunu süren invertere bağlanmaktadır. Fırının iç sıcaklığını ölçmek için k tip termokupl kullanılmıştır. Yetkili kişi fırını çalıştırmak istediğinde önce ana sigortaları açmaktadır. Sigortalar açıldıktan sonra HMI (TSG070) ekran açılacaktır. Açılan ekranda yetkili kişi giriş şifresini girerek ana sayfaya gitmektedir. Ana sayfada İngilizce ve Türkçe olmak üzere iki dil seçeneği mevcuttur. Dil seçiminden sonra ürün ekleme ekranına gidilir. Burada pişirilecek ürün, hız ve sıcaklık set değerlerinin bilgileri girilir ve ürün ekle (ürün kayıt) tuşuna basılır (bu kayıt işlemi fırın ilk kurulduğunda yapılır). Pişirmek istediği tüm ürünleri ilgili bilgileriyle beraber listeye ekler. Daha sonra ürün pişirme sayfasına gider, burada daha önce kaydettiği ürünlerden birinin ismini ya da liste numarasını yazarak ekrana çağırır. Ekranda, çağrılan ürüne ait sıcaklık set değerleri, konveyör hız limiti vb. parametreler görünmektedir. Değerlerde herhangi bir sorun yoksa yetkili kişi Start (başlatma) tuşuna basıp fırını çalıştırır. Start tuşundan basıldıktan sonra PLC, giriş çıkışları denetlemeye başlar. Motor sürücü üzerinden motora enerji verir ve konveyörü çalıştırır. Daha sonra termokupldan aldığı sıcaklık değerlerine göre analog çıkışlar üretir. Bu analog çıkışlar 0-24 V arasında PWM şeklindedir. Sıcaklık değerleri PLC ile algılanıp PID kontrolör ile çıkışlar üretilir. Bu parametreler katı hal rölelerinin (SSR) ne kadar açılıp kapanması gerektiğini belirler. PLC, PID kontrolcü ile beraber

rezistansları açıp kapatmaktadır. Set edilen değere yaklaştığında PID kontrolör ısıtıcıları daha az açarak set değerlerini geçmesini engellemektedir. Fırın, sıcaklık set değerine geldiğinde ürün pişirmeye hazır hale gelmiştir. Girişten verilen ürün konveyör hattıyla beraber fırının içinden geçip çıkışa pişmiş halde ulaşmaktadır.

Ayrıca sistem çalışmadığı durumlarda fırın kendini beklemeye almaktadır. Bekleme zamanlarında fırın yarım yükte çalışmaktadır. Bu da fırının yeniden açıldığında harcadığı enerjiyi minimuma düşürür. Fırın aşırı ısınma durumunda ekrana uyarı vererek alarm vermektedir. Fırın çalışırken yeni bir ürün pişirmek istenildiğinde ekrana gidip durdur tuşuna basılması, sonra ürün isminin girilmesi veya liste numarasının seçilmesi, bunlar yapıldıktan sora da Start tuşuna basılması gerekmektedir.

Sistem bileşenlerinden en önemlisi olan PLC, “Programmable Logic Controller” teriminin baş harflerinin kısaltılmasından oluşturulmuştur. Sistemindeki ileri düzey otomatik kontrol ekipmanları PLC tarafından kontrol edilmektedir. PLC, kontrol aygıtlarından gelen bilgiye göre çıkışlarına bağlı olan elemanları aktif hale getirir. Yapılan programda zaman hesaplaması veya herhangi bir hesaplama işlemi varsa PLC bu işlemleri matematiksel hesaplar kullanarak çözmektedir [33]. Fırın otomasyonunda Şekil 2.3’te görülen GMT (496t) marka PLC kullanılmıştır [34].



Şekil 2.3. GMT marka PLC [34]

Fırın GMTSuite PLC Editör programı (versiyon 1.0.1.6) kullanılarak programlanmıştır. Programlama aşamasında ladder (merdiven) diyagramlar kullanılmıştır. Programlama aşamasında ek modüller, motor sürücüler ve dokunmatik ekran girdileri de dikkate alınmıştır. Kullanımı kolaylaştırmak için ana programlar ve ana programlara ait alt programlar oluşturulmuştur. Bu programlarda manuel veya otomatik pişirme seçenekleri vardır. Programda tüm girdiler ekran üzerinde gruplandırılarak düzenlenmiştir. Örneğin yiyecekler manuel pişirmek isteniyorsa manuel adı verilen alt program kullanılmalıdır.

Aynı zamanda fırında Şekil 2.4'te görülen GTM firmasına ait TSG-070 model operatör panel (HMI) kullanılmaktadır. TSG serisi panel, iletişim protokollerini barındıran, internete bağlanabilen, mail atabilen ve sanayi alanında yaygın olarak kullanılan TFT dokunmatik bir operatör panelidir. Operatör panelde gerçek zaman saati (RTC) mevcuttur. Kullanıcı dostu yazılımı ile geniş bir kütüphaneye sahip olan bu operatör panelin kullanımı kolay olup, piyasadaki tüm PLC'leri desteklemektedir [35].



Şekil 2.4. HMI operatör paneli [35]

GMT-GXM40U genişleme modülü fırının içinde bulunan termokupllardan gelen değişken sıcaklık bilgisini alıp PLC'ye yollayan bir ek modüldür. 2 adet ve 4 adet girişi olan modüller mevcuttur. Bu fırın otomasyonunda 4 adet girişi olan modül kullanılmaktadır [36]. GMT genişleme modülü Şekil 2.5'te görülmektedir.



Şekil 2.5. GMT genişleme modülü [36]

Katı hal röleleri (Solid State Relay-SSR) (Şekil 2.6) fırında bulunan yüksek güçteki rezistansları kontrol etmek için kullanılmaktadır. Girişlerine 0-10V DC gerilim verilerek çalıştırılır. Bu gerilim analog bir değerdir ve PID parametrelerine göre röleleri açıp kapatır. Bu rölelerin hareketli veya mekanik parçaları yoktur. Yarı iletkenin elektriksel ve optik özelliklerini kullanarak giriş ve çıkış arasındaki dönüşümü gerçekleştirirler. Çok düşük akımlarla, çok büyük akımları kontrol edebilirler. Enerji giriş uçları harici AC veya DC gerilim uygulandığında elektriği ileten ve kesen bir sisteme dönüşür.

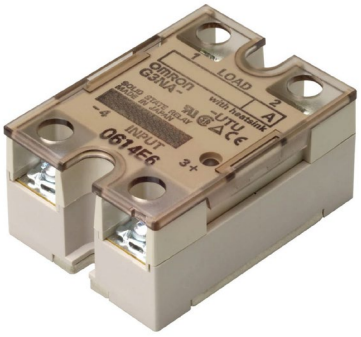

Şekil 2.6. Katı hal rölesi (SSR) [37]

SSR'lar hareketli kontaklar gibi mekanik bir yapıya sahip değildir. Mekanik röleye benzer yapıda çalışır, ancak SSR Şekil 2.7'de görüldüğü gibi, tristör, triyak, diyot ve transistör gibi katı hal anahtarlama elemanlarını içerisinde barındırır [38].



Şekil 2.7. SSR devresi iç yapısı [38]

Elektrikli fırının sıcaklığı yaklaşık 800°C sıcaklığı ulaşmaktadır. Dolayısıyla yüksek sıcaklık ölçebilen bir K tip termokupl kullanılmaktadır. K tipi termokupllar yaygın kullanılan termokupl türlerinden biridir. K tipi termokupl yüksek ölçüm hassasiyetine ve geniş sıcaklık aralığına sahiptir. K tipinde kullanılan iletken malzeme diğer termokupl türlerinde kullanılan iletken malzemelerden daha kalitedir. Seçilen termokuplun çalışma aralığı -200°C ile 1250°C'dir. Dolayısıyla diğer termokupl türlerine göre daha geniş bir ölçüm aralığı sunmaktadır. Nikel-krom veya nikel-alüminyum malzemelerden imal edilirler [39]. K tipi bir termokupl örneği Şekil 2.8'de, çalışma prensibi ise Şekil 2.9'da gösterilmiştir.

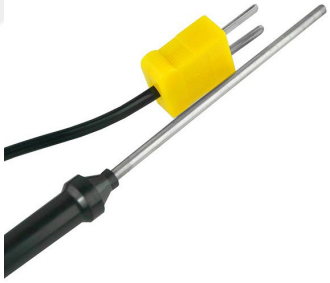

Şekil 2.8. K tip termokupl [40]

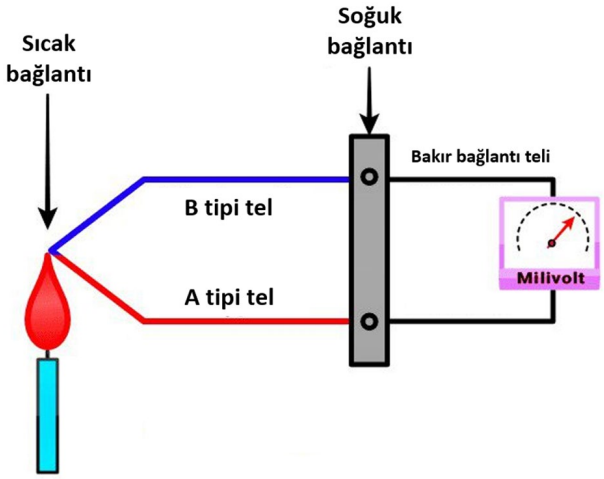

Şekil 2.9. K tip termokupl çalışma prensibi [41]

Asenkron motorlarda hız kontrolü için motor sürücüler (inverter) kullanılmaktadır. Fırın otomasyonunda Delta VFD004EL21W-1 el serisi sürücü (Şekil 2.10) kullanılmaktadır. Bu sürücü PLC ile RS485 hattı üzerinden bağlanmaktadır. Operatör panelden girilen değerlere göre motorun hızını kontrol etmektedir [42].



Şekil 2.10. Motor sürücü [42]

Konveyörlü elektrikli fırının genel görünümü ve bileşenleri Şekil 2.11'de gösterilmiştir.

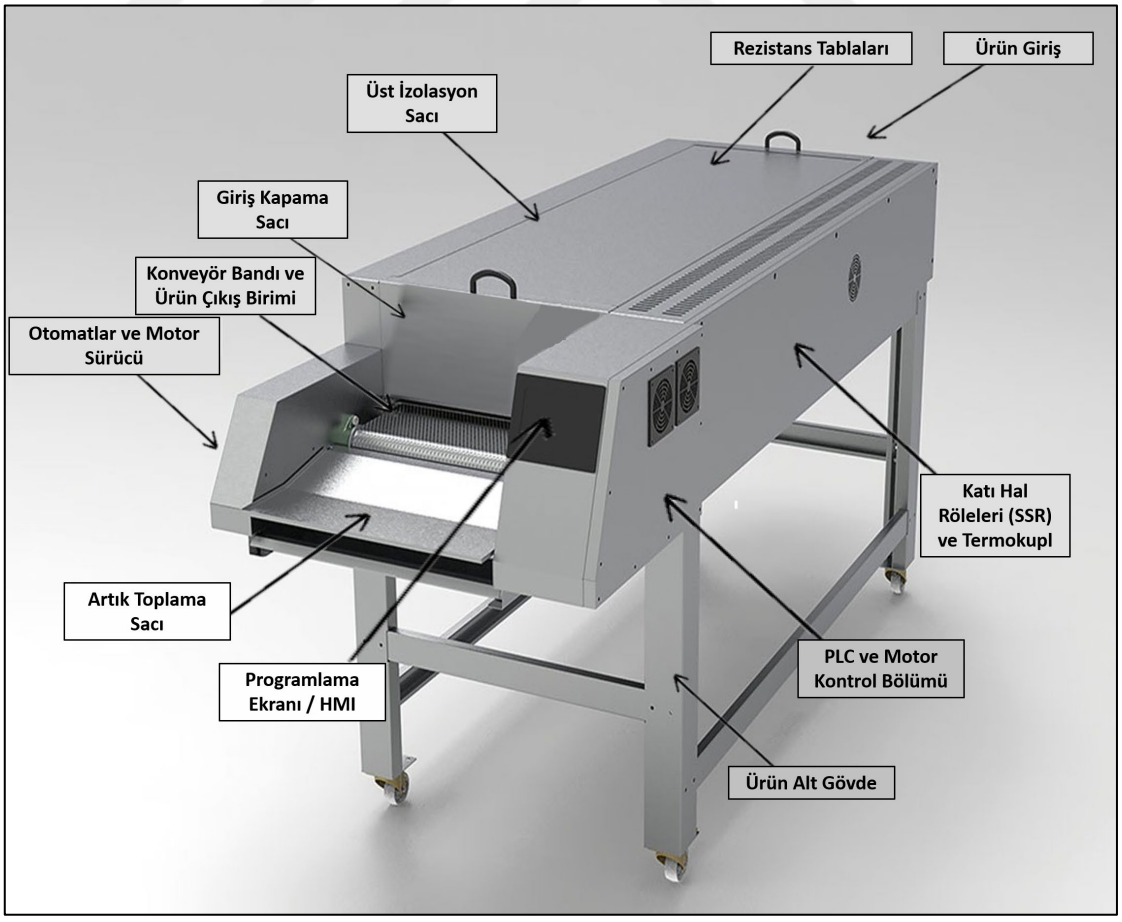

Şekil 2.11. Fırının genel görünümü ve bileşenleri

Kızılötesi ısıtma panelleri (rezistanslar) fırının üst ve alt kısımlarına yerleştirilmiştir. Bu paneller radyant ısı dalgası yayar. Radyant ısı üzerindeki ısıyı sadece altına konulan obje veya ürünlere bırakır, havada ısı kaybına uğramazlar. Dolayısıyla bu ısı dalgaları sayesinde ürün etrafından başlayarak ortasına doğru düzgünce pişmeye başlamaktadır. Kullanılan rezistans örneği Şekil 2.12'de, konveyörlü fırın boyunca konumlandırılan ısı bölgeleri ve rezistanslar ise Şekil 2.13'te görülmektedir.

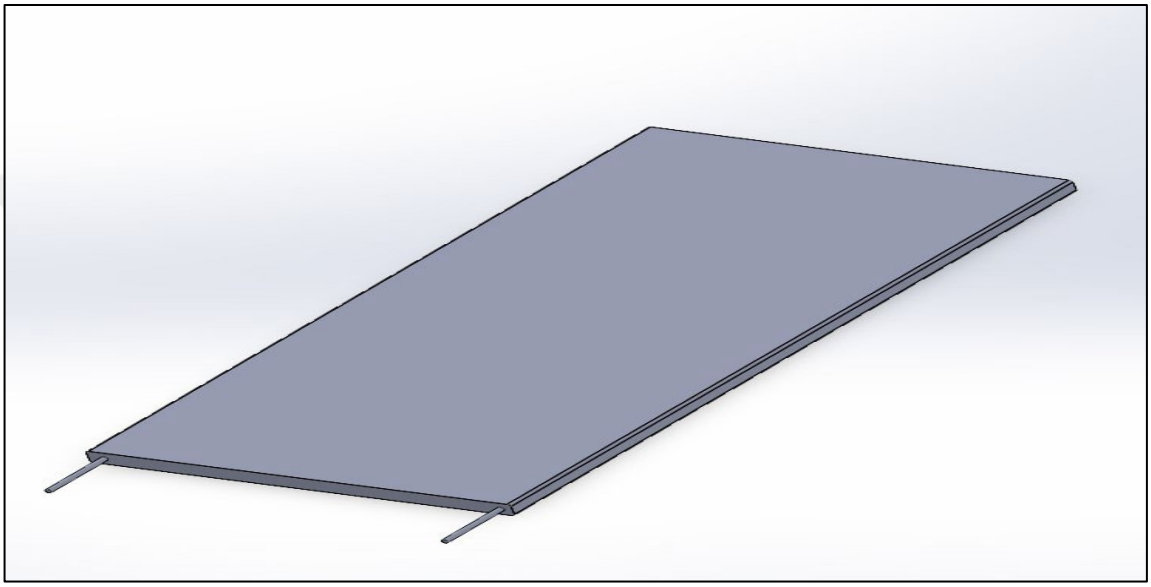

Şekil 2.12. Fırının ısıtma paneli (rezistans)

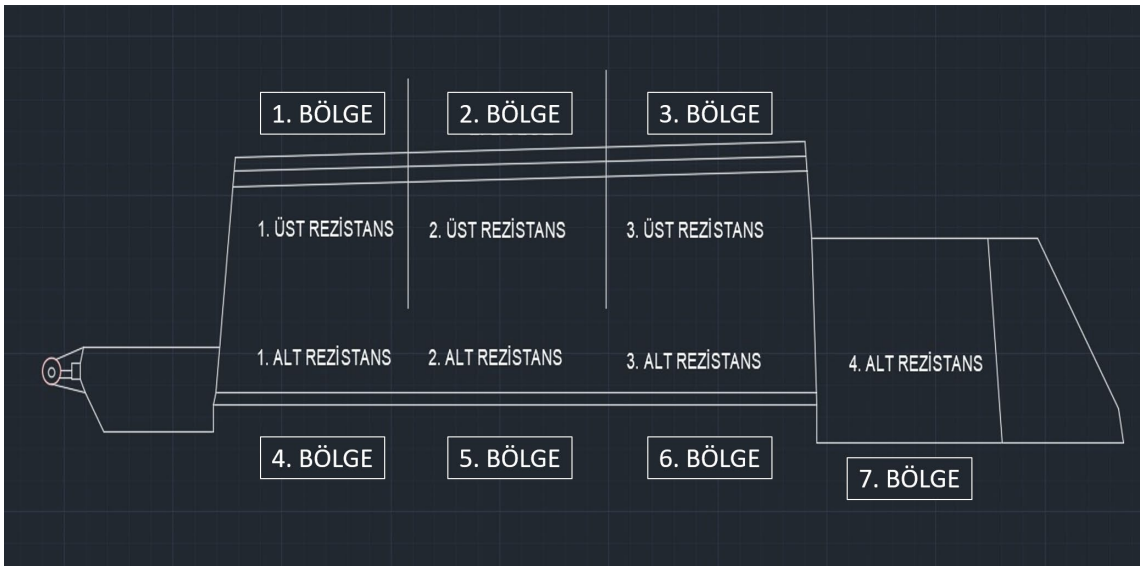

Şekil 2.13. Fırın boyunca konumlandırılan ısı bölgeleri ve rezistanslar

Fırın Şekil 2.13'te görüldüğü gibi 7 adet ısıtma bölgesinden oluşmaktadır. 1, 2, 3. ısı bölgelerinde sırası ile 1, 2 ve 3. üst rezistanslar; 4, 5, 6, 7. ısı bölgelerinde sırası ile 1, 2, 3 ve 4. alt rezistanslar yer almaktadır.

Fırının işlevleri PLC tarafından denetlenmektedir. Fırın önceden programlanarak çalıştırılır. Fırında şu modlar bulunmaktadır.

- Program sayfası (ilk kez çalıştırıldığında programların girileceği sayfadır)
- Pişirme sayfası (pişirme ekranının görüldüğü sayfadır burada listeden ürünler seçilerek çalıştırılır)
- Yardımcı programlar (burada manuel program, temizleme, bekleme ve kapatma modları bulunmaktadır)
- Kullanım kılavuzu (burada İngilizce ve Türkçe kullanım kılavuzu vardır)

2.1.2. Pişirilen Ürünler ve Veri Setinin Hazırlanması

Fırında pişirilebilen ürünlerin bazıları aşağıdaki gibi listelenebilir:

- Balık ve Deniz Mahsulleri
- Istakoz Kuyruk
- Karides
- Yengeç
- Beyaz Etli Balık Filetosu
- Bütün Alabalık
- Pizza
- Dondurulmuş Pizza
- Kalın Hamur
- İnce Hamur
- Lahmacun
- Kümes Hayvanları
- Tavuk Cordon Blue
- Tavuk Parçaları
- Yarım Tavuk
- Bütün Tavuk
- Kahvaltı Yiyecekleri

- Dana Pastırması
- Bisküvi
- Yumurtalı Börek
- Kızarmış Yumurta
- Kabarık Omlet
- Sucuk, Sosis
- Sosisli Börek
- Güveç
- Lazanya
- Makarna ve Peynir
- Makarna ve Sos
- Kurabiye
- Kek
- Çikolata
- Makaron
- Yulaf Ezmesi (Yulaf Lapası)
- Tatlılar
- Elma Tatlısı
- Pişmiş Muhallebi
- Kremalı Pasta

Pişirilen ürünlere ait örnek görseller ise Şekil 2.14'te verilmiştir.



Şekil 2.14. Pişirilen ürünlere ait görseller

Tez çalışmasında kullanılan veri seti 16 ürün çeşitinden oluşmaktadır. Herbir ürün için, farklı pişirme şartlarında, fırının 7 ısıtma bölgesinden alınan sıcaklık değerleri ve ürünün konveyörden çıkışa ulaşma süresi verileri toplanmıştır. Elde edilen veriler ürünlerin pişme seviyelerine göre (az pişmiş, pişmiş ve çok pişmiş şeklinde) etiketlenmiştir. Ürün tipleri ise veri seti içerisinde indis ile ifade edilmiştir. Dolayısıyla sınıflandırma çalışmasında modellere uygulanacak veri seti, tahminci olarak ifade edilen 9 girdiden oluşmaktadır; indis (ürün tipini ifade eder), süre (pişirme süreçlerinde hız olarak da ifade edilmektedir) ve 7 rezistans sıcaklığı. Model çıkışı (yanıt) ise tek olacak ve az pişmiş, pişmiş veya çok pişmiş yanıtlarından birisini verecektir. Daha doğru sonuçlara ulaşmak için 3 sınıftan eşit örnek sayısı alınarak veri seti oluşturulmuştur. Veri seti içerisinden pişmiş ürünlere ait verilerden bir kısmı, ürün türü, ürün indis numarası, pişme süresi (hızı) ve toplamda 7 rezistans sıcaklığı olmak üzere örnek olarak Tablo 2.1'de verilmiştir.

Tablo 2.1. Pişmiş ürünlere ait ürün türü, indis numarası, pişme süresi/hızı (sn) ve rezistans sıcaklıkları (°C) için örnek veri seti

Ürün Türü	İndis	Süre/Hız (sn)	1. Üst Rezistans	2. Üst Rezistans	3. Üst Rezistans	1. Alt Rezistans	2. Alt Rezistans	3. Alt Rezistans	4. Alt Rezistans
Lahmacun1	1	130	455	465	475	355	365	375	375
Lahmacun2	2	140	460	470	480	360	370	380	380
Lahmacun3	3	150	470	480	482	370	380	382	382
Lahmacun4	4	165	475	480	485	375	380	385	385
Pide/Pizza1	5	360	320	340	360	315	280	315	315
Pide/Pizza2	6	420	455	465	475	355	365	375	375
Pide/Pizza3	7	480	200	200	200	200	200	200	200
Pide/Pizza4	8	480	290	290	290	200	200	200	200
İstakoz Kuyruk	9	130	454	426	426	315	287	260	260
Karides	10	140	454	426	426	260	287	315	315
Yengeç	11	150	454	426	426	260	287	315	260
Beyaz Etli Balık Filetosu	12	180	454	426	426	315	287	260	260
Bütün Alabalık	13	360	454	426	426	260	287	315	315
Tırnak/Tombik	14	420	455	465	475	355	365	375	375
Poğaça	15	480	290	290	290	200	200	200	200
Börek	16	480	200	200	200	200	200	200	200

2.2. Sınıflandırma Algoritmaları

Makine öğrenimi, yapay zekanın bir alt dalı olarak, verilerdeki kalıpları tanımlamak ve bu kalıplardan öğrenmek için çeşitli algoritmalar ve yöntemler kullanır. Bu süreç, verilerdeki etiketli örneklerin incelenmesiyle başlar ve sistemin akıl yürütebilme yeteneği kazanmasını sağlar. Algoritmalar, matematiksel ve istatistiksel yöntemlerle veri setindeki örnek olayları analiz eder, bu olayların oluşum mekanizmalarını öğrenir ve genelleme yaparak yeni durumları tahmin edebilir. Büyük veri yığınlarında gizli kalmış yapıları açığa çıkaran bu yöntemler, olayları etkileyen faktörleri belirleyip bunların etkisini değerlendirerek, henüz gerçekleşmemiş olaylara ilişkin öngörüler sunar. Örneğin, bir yıl sonraki enerji ihtiyacını tahmin etmek, bir uçağın rötar süresini öngörmek ya da gün içinde yağmur yağıp yağmayacağını kestirmek gibi sorunlara çözüm sunabilir [43]. Şekil 2.15'te bahsedilen makine öğrenmesinin, yapa zeka disiplini içerisinde yeri gösterilmiştir.

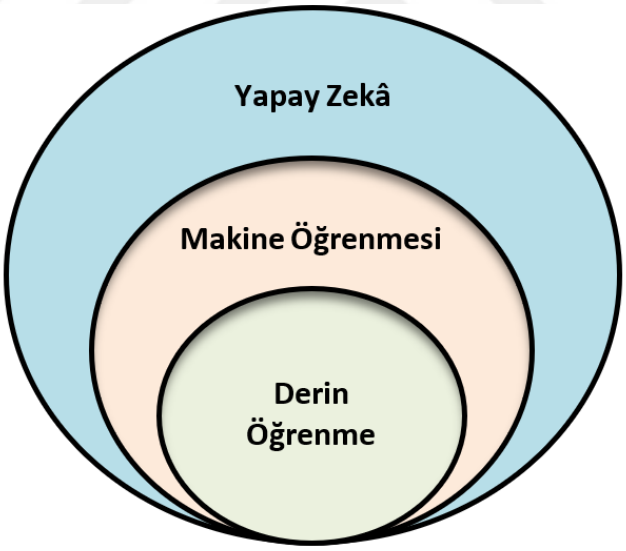

Şekil 2.15. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi

Makine öğrenmesi yöntemleri genel olarak üç kategoriye ayrılır: denetimli, denetimsiz ve takviyeli öğrenme. Karar Ağaçları ve KNN algoritmaları da denetimli öğrenme sınıfına aittir. Sınıflandırma problemlerinde hem Karar Ağaçları, hem de KNN algoritmaları sıklıkla kullanılmaktadırlar. Şekil 2.16'da makine öğrenmesi türleri ve alt kategorileri şematik olarak görülmektedir.

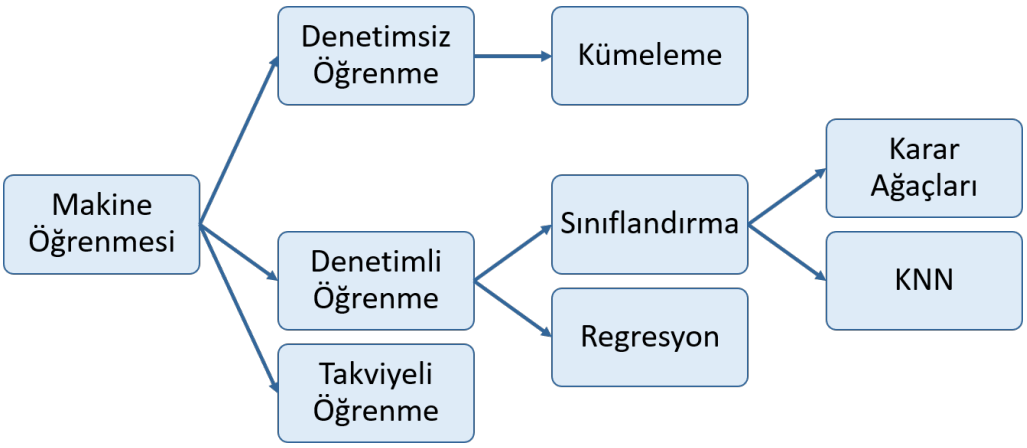

Şekil 2.16. Makine öğrenmesi türleri ve alt kategorileri

2.2.1. Karar Ağaçları Algoritması

Önceki bölümde de ifade edildiği gibi Karar Ağaçları, literatürde yaygın olarak kullanılan bir sınıflandırma algoritmasıdır. Karar Ağaçlarının yaygın kullanılmasının en önemli nedeni, ağaç yapılarının oluşturulmasında kullanılan kuralların anlaşılır ve basit olmasıdır. Karar Ağaçları, sınıflandırma sürecini gerçekleştirmek için sıralı veya çok aşamalı bir yaklaşım kullanır [44-45]. Bir Karar Ağacı üç temel kısımdan oluşur: dal, yaprak ve düğüm. Bu ağaç yapısında her bir özellik bir düğüm ile temsil edilir. Yapraklar ve dallar, ağacın diğer unsurlarıdır. Kök ile yapraklar arasındaki kısımlar dallar olarak adlandırılırken, ağacın son kısmı yaprak, üst kısmı ise kök olarak adlandırılır [45]. Karar Ağaçlarında hesaplamalar, aşağıda verilen adımlarla gerçekleştirilir [46-47]:

- Bir karar düğümüne bağlı son dal için beklenen değer (EV), sonucun kendisine eşittir.
  EV = Sonuç

- Bir olasılık düğümüne bağlı bir son dal için beklenen değer, o dalın sonucu ile olasılığının çarpımına eşittir.
  EV = Sonuç x Olasılık

- Bir olasılık düğümünün beklenen değeri, her bir olasılık dalının sonucunun ve karşılık gelen olasılığının çarpımlarının toplamıdır.
  EV = [EVdal1+ EVdal2+...+ EVdalN]

- Bir karar düğümü için beklenen değer, o düğümdeki tüm karar dalları arasında en yüksek getirisi olan değerdir (kâr odaklı problemler için en yüksek, maliyet odaklı problemler için en düşük değer).
  EV = Karar düğümünden tüm karar dalları arasında beklenen en yüksek değer

- Herhangi bir düğümün beklenen değeri, başlangıç düğümüne doğru bağlantılı olduğu önceki düğümün sonuç değeridir.

Karar Ağaçları modelini tasarlarken maksimum dal sayısı dikkate alınmalıdır. Bu değerle, Karar Ağaçlarının öngörü gücü ile basitliği arasında bir optimizasyon sağlanabilir. Düğümlerin ne zaman bölüneceğine karar vermek için bölme ölçütü kullanılır. Eksik veri olduğunda yerine geçen karar bölmeleri kullanılır. Ancak çalışmamızda eksik veri bulunmadığından bu parametre kullanılmamıştır.

Karar Ağaçları, kolay anlaşılabilir yapısı, hızlı uyum ve tahmin süreci ile düşük bellek kullanımı avantajları sunar, ancak düşük tahmin doğruluğuna sahip olabilirler. Aşırı uyumu (overfitting) önlemek için daha basit ağaçlar oluşturmaya çalışılmalıdır. Ağacın derinliği maksimum dal sayısı ayarı ile kontrol edilebilir. Maksimum dal sayısı arttıkça model esnekliği de artar [48]. Karar Ağaçları algoritması sınıflandırma türleri Tablo 2.2'de verilmiştir.

Tablo 2.2. Karar Ağaçları algoritması sınıflandırma türleri

Sınıflandırma türü	**Yorumlanabilirlik**	**Model Esnekliği**
İnce Ağaç	Kolay	Yüksek Sınıflar arasında çok sayıda ayrım yapmak için birçok dal (maksimum dal sayısı 100)
Orta Ağaç	Kolay	Orta Sınıflar arasında daha hassas ayrımlar için orta sayıda dal (maksimum dal sayısı 20)
Kaba Ağaç	Kolay	Düşük: Az sayıda dal ile sınıflar arasında kaba ayrımlar yapılır (maksimum dal sayısı 4)

Karar Ağaçları algoritmasının hiperparametre seçenekleri aşağıdaki gibidir:

- **Maksimum dal sayısı:** Ağacın derinliğini kontrol etmek için maksimum dal veya dallanma noktasını belirlenir. Ağacı büyütürken basitlik ve tahmin gücü dikkate alınmalıdır. Çok sayıda dala sahip ince bir ağaç, eğitim verisi üzerinde genellikle yüksek doğruluğa sahiptir. Ancak, bağımsız bir test setinde benzer doğruluğu göstermeyebilir. Dallı ağaçlar aşırı uyuma meyillidir ve doğrulama doğruluğu çoğunlukla eğitim doğruluğundan düşüktür. Kaba bir ağaç ise yüksek eğitim doğruluğu elde etmez ancak daha dayanıklıdır, eğitim doğruluğu genellikle temsil edici bir test setine yaklaşabilir. Ayrıca, kaba ağaçlar daha kolay anlaşılır.

- **Bölme ölçütü:** Düğümleri bölerken karar vermek için kullanılan ölçüttür. Veriler ile model performansını artırabilecek üç ayar vardır. Bölme ölçütü seçenekleri: Gini'nin çeşitlilik indeksi, Twoing kuralı veya Maksimum sapma indirgeme (çapraz entropi olarak da bilinir). Karar Ağaçları, yalnızca tek bir sınıf içeren saf düğümler elde etmeye çalışır. Gini'nin çeşitlilik indeksi sapma kriteri düğüm saflığını ölçerken, twoing kuralı düğüm saflığını artırmaya yönelik farklı bir ölçü sunar.

- **Yerine geçen karar bölmeleri:** Sadece eksik veriler için kullanılır. Eksik veri içeren verilerde tahmin doğruluğunu artırmak için yerine geçen bölmeler belirlenir. Yerine geçen karar bölmeleri "Açık" olarak ayarlandığında, her dallanma noktasında en fazla 10 yerine geçen bölme bulunur. "Hepsini Bul" ayarında ise her dallanma noktasında tüm yerine geçen bölmeler bulunur, ancak bu ayar fazladan zaman ve bellek kullanabilir.

Çalışmada kullanılan Karar Ağaçları algoritmasının model hiperparametreleri Tablo 2.3'te verilmiştir.

Tablo 2.3. Karar Ağaçları algoritmasının model hiperparametreleri

Hiperparametre	Değer
Ön Ayar (Preset)	İnce Ağaç / Orta Ağaç / Kaba Ağaç (Fine Tree / Medium Tree / Coarse Tree)
Maksimum dal sayısı (Maximum number of splits)	100 / 20 / 4
Bölme ölçütü (Split criterion)	Gini'nin çeşitlilik indeksi (Gini's diversity index)
Yerine geçen karar bölmeleri (Surrogate decision splits)	Kapalı

2.2.2. K-En Yakın Komşu Algoritması

Sınıflandırma problemlerinde yaygın olarak kullanılan diğer bir yöntem KNN'dir. KNN'nin tercih edilme nedenlerinden biri uygulama kolaylığıdır. KNN, daha az sınıfa sahip problemlerde daha yüksek doğruluk oranları ile sonuç verir. Yinelemeli bölme işlemi, veriyi içeren kümelere olan mesafeyi azaltarak en az kare hatasına sahip K kümesini bulmaya çalışır. Bu yinelemeli yaklaşım, veriler sabitlenene kadar tekrarlanır. KNN'de hesaplamalar aşağıdaki adımlarla gerçekleştirilir [49-50]:

1. Kümeleri temsil eden merkezler atanır.
2. Küme merkezlerinin dışındaki veriler için yeni mesafeler hesaplanır ve veriler kümelere atanır.
3. Veriler yeni kümelere atandıktan sonra yeni küme merkezleri hesaplanır.
4. Küme merkezleri değişmeyene kadar önceki iki adım tekrarlanır.

Bir KNN modeli tasarlanırken, komşu sayısı değeri ayarlanmalıdır. Komşu sayısı arttıkça işlem süresinin de arttığı dikkate alınmalıdır. Minkowski, manhattan ve öklid gibi çeşitli metrikler mesafe ölçütü olarak kullanılabilir. Bu çalışmada, öklid metriği tercih edilmiştir. Mesafeler için çeşitli ağırlıklar tanımlanabilir; ancak bu çalışmada ağırlıklar eşit alınmıştır.

K-En Yakın Komşu sınıflandırıcıları, düşük boyutlarda genellikle iyi bir tahmin doğruluğuna sahiptir, ancak yüksek boyutlarda bu durum azalabilir. Bu sınıflandırıcıların bellek kullanımı yüksektir ve yorumlanması kolay değildir. Komşu sayısı arttıkça model esnekliği azalır [48]. KNN algoritması sınıflandırma türleri Tablo 2.4'te verilmiştir.

Tablo 2.4. K-En Yakın Komşu algoritması sınıflandırma türleri

Sınıflandıma türü	**Yorumlanabilirlik**	**Model Esnekliği**
İnce KNN	Zor	Sınıflar arasında ayrıntılı farklılıklar (Komşu sayısı: 1)
Orta KNN	Zor	Orta düzeyde farklılıklar (Komşu sayısı: 10)
Kaba KNN	Zor	Sınıflar arasında genel farklılıklar (Komşu sayısı: 100)

KNN algoritmasının hiperparametre seçenekleri aşağıdaki gibidir:

- **Komşu Sayısı:** Her nokta için sınıflandırma yaparken bulunacak en yakın komşu sayısını belirtir. Komşu sayısını değiştirerek ince (düşük sayıda) veya kaba (yüksek sayıda) bir sınıflandırıcı seçilebilir. Örneğin, ince KNN bir komşu kullanırken, kaba KNN 100 komşu kullanır. Yüksek komşu sayısı hesaplama süresini artırabilir.

- **Mesafe Ölçütü:** Noktalara olan mesafeyi belirlemek için farklı metrikler kullanılabilir (minkowski, manhattan ve öklid).

- **Mesafe Ağırlığı:** Mesafe ağırlıklandırma fonksiyonunu belirler. Eşit (ağırlık yok), Ters (ağırlık: 1/mesafe) veya Kare Ters (ağırlık: 1/mesafe^2) olarak seçilebilir.

- **Verileri Standartlaştırma:** Her koordinat mesafesini ölçeklendirme seçeneğidir. Eğer öngörücüler farklı ölçeklere sahipse, standartlaştırma uyumu artırabilir.

Çalışmada kullanılan K-En Yakın Komşu algoritmasının model hiperparametreleri Tablo 2.5'te verilmiştir.

Tablo 2.5. K-En Yakın Komşu algoritmasının model hiperparametreleri

Hiperparametre	Değer
Ön Ayar (Preset)	İnce KNN / Orta KNN / Kaba KNN (Fine KNN / Medium KNN / Coarse KNN)
Komşu sayısı	1 / 10 / 100
Mesafe ölçütü	Öklid (Euclidean)
Mesafe ağırlığı	Eşit
Verileri standartlaştır	Evet

3. BÖLÜM

SİMÜLASYON ÇALIŞMALARI

3.1. Eğitim ve Test Çalışmaları

Tez çalışmasında, konveyörlü elektrik fırınında pişirilmiş 16 farklı ürün kullanılmıştır. Veri setinin yakın değerlerden oluşması ve bu algoritmalara uygun olduğu düşüncesiyle, Karar Ağaçları ve K-En Yakın Komşu (KNN) algoritmaları kullanılarak ürünler 3 sınıfa ayrılmıştır. Sınıflandırmada tahminci girişler; ürün tipini temsil eden indis değerleri, pişme süresi (konveyör hattından çıkış zamanı) ve 7 ısı bölgesine ait rezistans sıcaklıklarından oluşmaktadır. Bu 9 girişe karşılık sınıflandırıcının çıktısı, "az pişmiş", "pişmiş" veya "çok pişmiş" sınıflarından biri olacaktır. Bölüm 2.1.2'de veri setinin oluşturulması detaylı bir şekilde açıklanmıştır. Ayrıca sınıflandırıcı modelinin şematik yapısı Şekil 3.1'de görülmektedir. Çalışma, MATLAB programında gerçekleştirilmiş ve Windows 10 (64-bit) işletim sistemi, Intel Core i7-7700HQ CPU @ 2.80GHz işlemci ve 16 GB RAM'e sahip bir bilgisayarda yürütülmüştür.

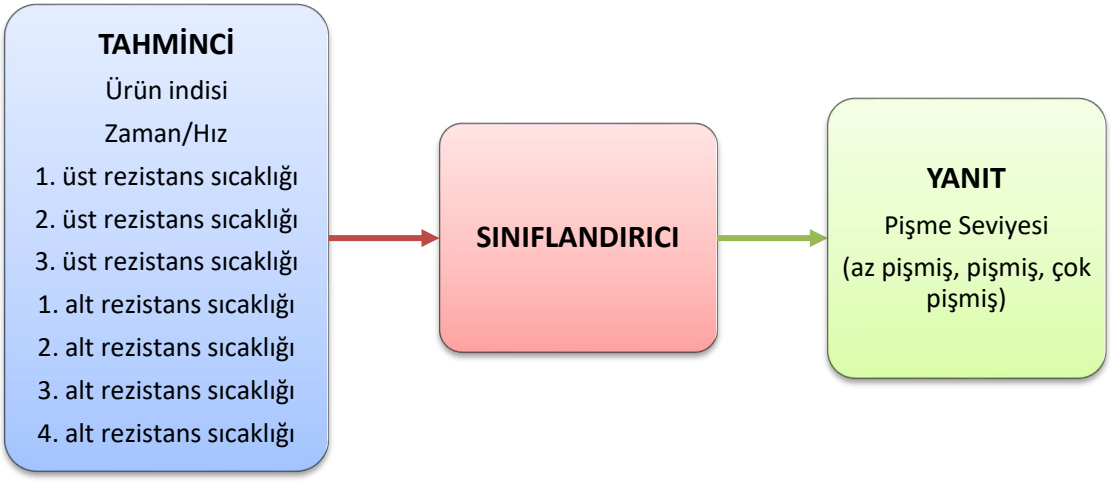

Şekil 3.1. Sınıflandırıcı modelinin şematik yapısı

Kullanılan her iki sınıflandırma algoritması için farklı hiperparametreler belirlenmiştir. Bu hiperparametreler Tablo 2.3 ve Tablo 2.4'te detaylı bir şekilde verilmiştir. Tablolardan hatırlanacağı üzere Karar Ağaçlarının farklı modellerinde maksimum dal sayısı değeri (maximum number of splits) 100, 20 ve 4 olarak alınırken; KNN'nin farklı modelleri için komşu sayısı değeri ise 1, 10 ve 100 olarak alınmıştır. Çalışmada sınıflandırma için 6 farklı model kullanılmıştır: İnce Ağaç (Fine Tree), Orta Ağaç (Medium Tree), Kaba Ağaç (Coarse Tree), İnce KNN (Fine KNN), Orta KNN (Medium KNN) ve Kaba KNN (Coarse KNN). Eğitim ve test parametreleri Tablo 3.1'de verilmiştir. Eğitim sonuçları, doğruluk (doğrulama/validation), toplam maliyet (doğrulama/validation), tahmin hızı (saniye başına gözlem sayısı, gözlem/sn) ve eğitim süresi (saniye, sn) olarak Tablo 3.2'de verilmiştir. Test verileri için doğruluk ve toplam maliyet değerleri ise Tablo 3.3'te sunulmaktadır. Doğruluk, veri setindeki doğru tahmin edilen örneklerin yüzdesi olarak ifade edilir; doğru tahmin edilen gözlem sayısının toplam tahmin sayısına bölünmesi ve bu oranın 100 ile çarpılmasıyla hesaplanır. Toplam maliyet, modelin doğrulama veri setinde yaptığı yanlış sınıflandırmaların toplam maliyetini temsil eder ve genellikle hata sayısı olarak ifade edilir. Tahmin hızı, modelin saniyede tahmin edebildiği gözlem sayısını gösterirken; eğitim süresi, modelin eğitim sürecinin süresini ifade eder.

Tablo 3.1. Eğitim ve test parametreleri

Parametre	**Değer**
Doğrulama şeması (aşırı öğrenmeyi önlemek için)	Çapraz doğrulama
Çapraz doğrulama kat sayısı	5
Test seti için ayrılan yüzde	15
Veri seti değişken boyutu	144x10
Yanıt	Az pişmiş Pişmiş Çok pişmiş
Tahminciler	Fırında pişirilmiş farklı ürünlerin indisleri: 1 .. 16 Zaman/Hız: 130 .. 480 1. üst rezistans sıcaklığı: 175 .. 500 2. üst rezistans sıcaklığı: 175 .. 505 3. üst rezistans sıcaklığı: 175 .. 510 1. alt rezistans sıcaklığı: 175 .. 400 2. alt rezistans sıcaklığı: 175 .. 405 3. alt rezistans sıcaklığı: 175 .. 410 4. alt rezistans sıcaklığı: 175 .. 410

Tablo 3.2. Karar Ağaçları ve KNN modellerinin eğitim sonuçları

Numara	Model	Doğruluk (Doğrulama) (%)	Toplam Maliyet (Doğrulama)	Tahmin Hızı (gözlem/sn)	Eğitim Süresi (sn)
1	İnce Ağaç	83.7	20	~910	3.6904
2	Orta Ağaç	83.7	20	~1300	11.485
3	Kaba Ağaç	68.3	39	~1000	10.592
4	İnce KNN	92.7	9	~1500	9.4976
5	Orta KNN	58.5	51	~1300	9.2515
6	Kaba KNN	32.5	83	~2000	8.8904

Tablo 3.3. Karar Ağaçları ve KNN modellerinin test sonuçları

Numara	Model	Doğruluk (Test) (%)	Toplam Maliyet (Test)
1	İnce Ağaç	90.5	2
2	Orta Ağaç	90.5	2
3	Kaba Ağaç	71.4	6
4	İnce KNN	95.2	1
5	Orta KNN	42.9	12
6	Kaba KNN	33.3	14

Tablo 3.2'de görüldüğü üzere, en yüksek doğrulama doğruluk oranı %92.7 ile İnce KNN algoritmasına aittir. Aynı şekilde Tablo 3.3'te görüldüğü üzere, en yüksek test doğruluk oranı da %95.2 ile İnce KNN algoritmasında elde edilmiştir. En düşük doğrulama doğruluk oranı ise %32.5 ile Kaba KNN algoritmasında bulunmuştur. Benzer şekilde, en düşük test doğruluk oranı %33.3 ile yine Kaba KNN algoritmasına aittir. Bu sonuçlar, İnce tipteki modellerin en iyi performansı sağladığını, Kaba tipteki modellerin ise en kötü sonuçları ürettiğini açıkça göstermektedir. İnce KNN algoritması, doğrulama ve test doğruluk oranlarında en yüksek değerlere ulaşmıştır.

3.2. Karışıklık Matrisleri

Bir sınıflandırma modelinin doğruluğunu gösteren karışıklık matrisi (confusion matrix), yanlış pozitif, yanlış negatif, doğru pozitif ve doğru negatif miktarlarını sunar. En iyi performans gösteren sınıflandırmalar olan İnce Ağaç ve İnce KNN modellerine ait doğrulama karışıklık matrisleri sırasıyla Şekil 3.2'de, test karışıklık matrisleri ise Şekil 3.3'te verilmiştir. Şekil 3.2'den 3.7'ye kadar, DP (TPR-True Positive Rate) Doğru Pozitif Oranını, YN (FNR-False Negative Rate) ise Yanlış Negatif Oranını temsil etmektedir.

Şekil 3.2(a)'da görüldüğü üzere, İnce Ağaç modeli ile az pişmişlerin %82.9'u, pişmişlerin %80.5'i ve çok pişmişlerin %87.8'i doğru sınıflandırılmıştır. Şekil 3.2(b), İnce KNN modeli ile az pişmişler ile pişmişlerin %95.1'i ve çok pişmişlerin %87.8'inin doğru sınıflandırıldığını göstermektedir. Şekil 3.3(a), test verisinde İnce Ağaç modeli ile az pişmiş ve pişmişlerin %100'ünün, çok pişmişlerin ise %71.4'ünün doğru sınıflandırıldığını göstermektedir. Şekil 3.3(b) ise İnce KNN modeli ile az pişmiş ve pişmişlerin %100'ünün, çok pişmişlerin %85.7'sinin doğru sınıflandırıldığını göstermektedir. Bu sonuçlar, İnce KNN modelinin doğrulama ve test veri setlerinde daha iyi metrikler sergilediğini ortaya koymaktadır.

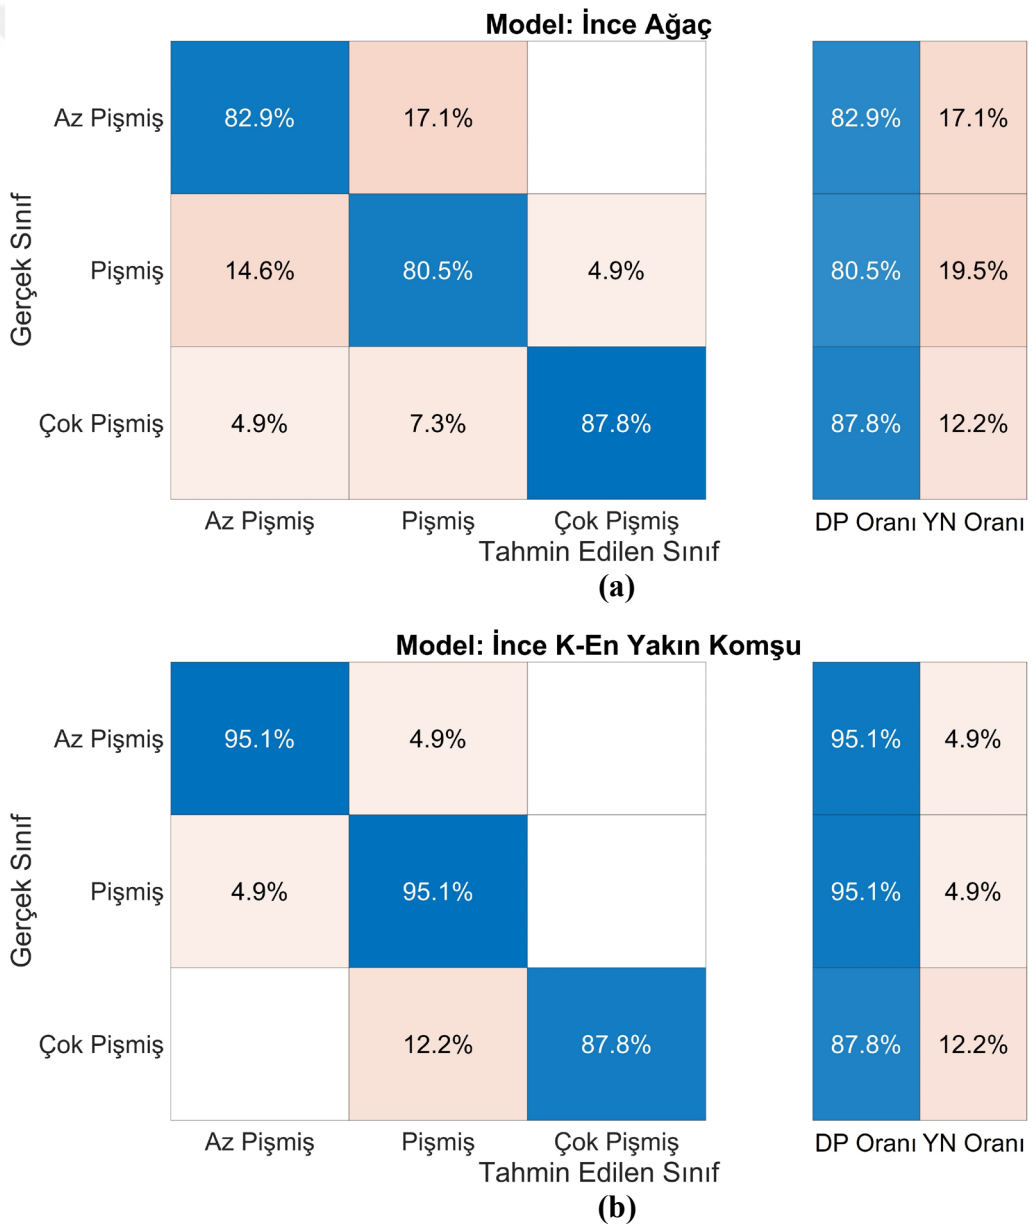

Şekil 3.2. Doğrulama Karışıklık Matrisleri: (a) İnce Ağaç ve (b) İnce KNN

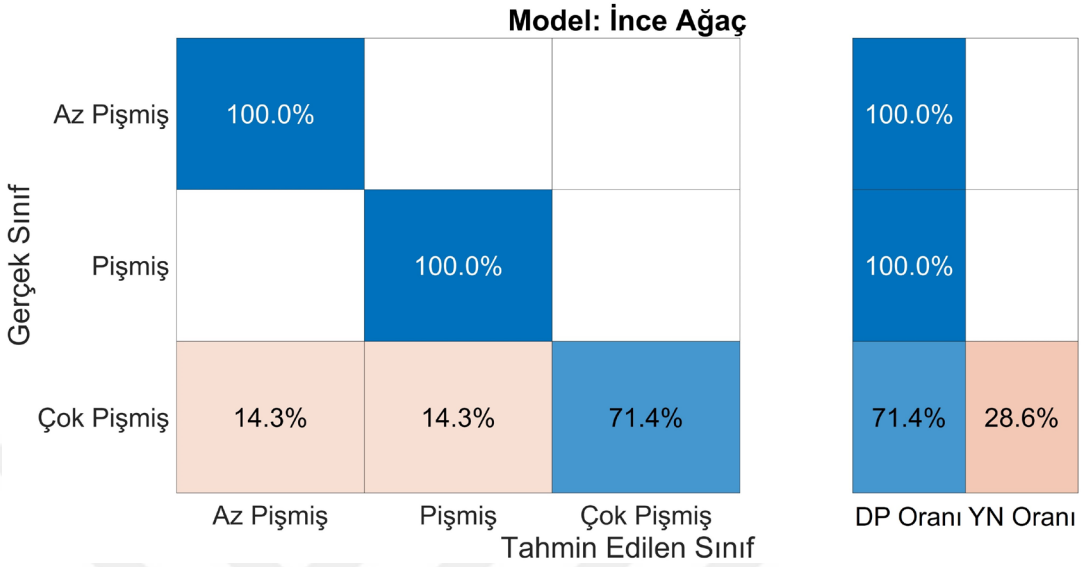

(a)

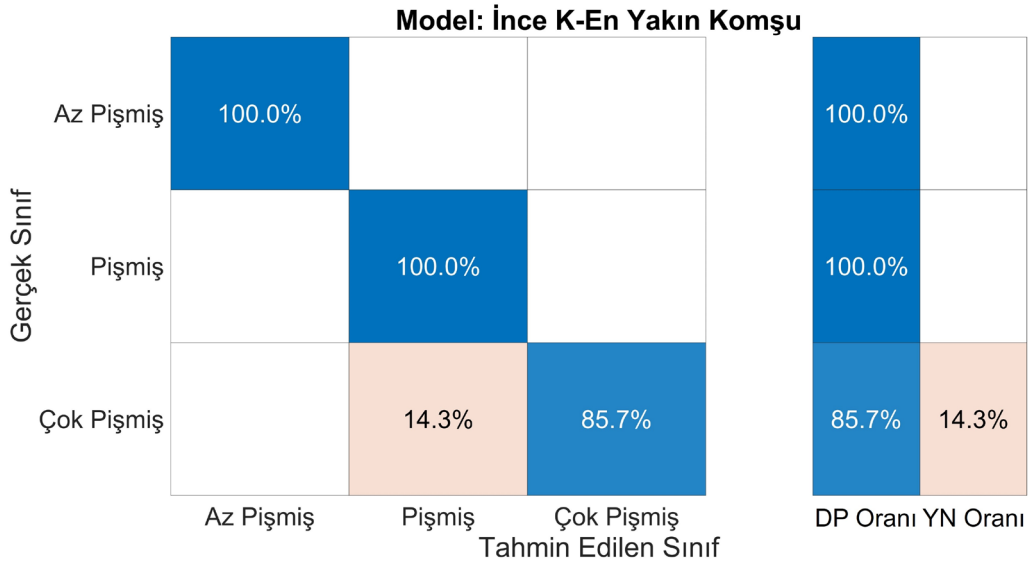

(b)

Şekil 3.3. Test Karışıklık Matrisleri: (a) İnce Ağaç ve (b) İnce KNN

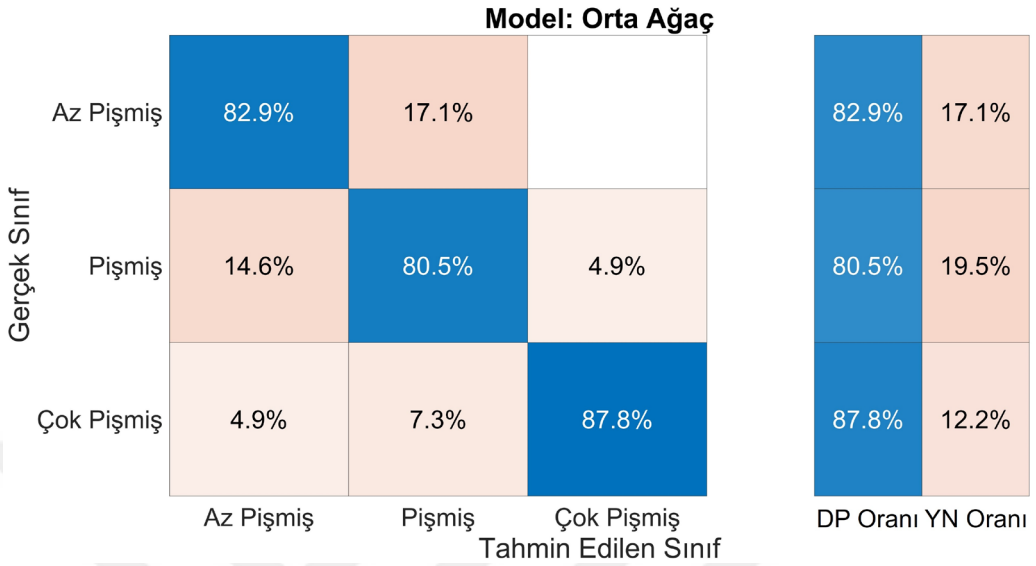

(a)

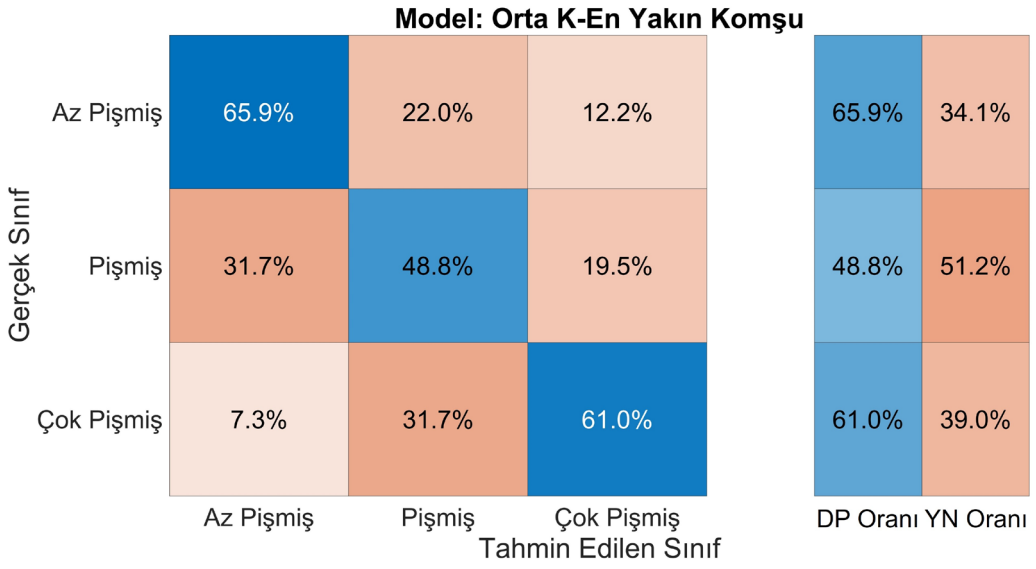

(b)

Şekil 3.4. Doğrulama Karışıklık Matrisleri: (a) Orta Ağaç ve (b) Orta KNN

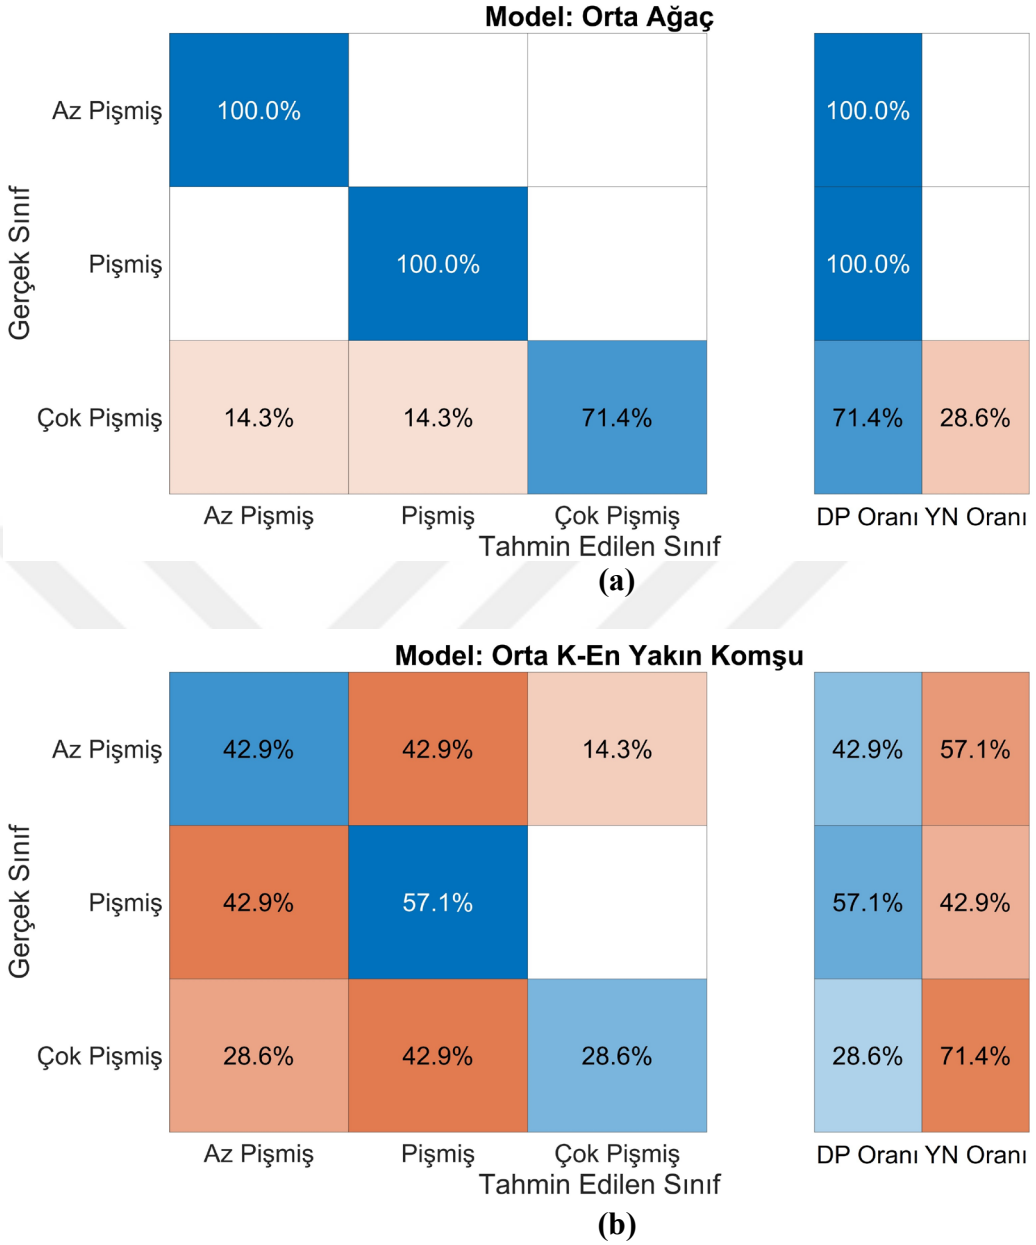

Şekil 3.5. Test Karışıklık Matrisleri: (a) Orta Ağaç ve (b) Orta KNN

Şekil 3.4(a)'da görüldüğü üzere, Orta Ağaç modeli ile az pişmişlerin %82.9'u, pişmişlerin %80.5'i ve çok pişmişlerin %87.8'i doğru sınıflandırılmıştır. Şekil 3.4(b), Orta KNN modeli ile az pişmişlerin %65.9'u, pişmişlerin %48.8'i ve çok pişmişlerin %61.0'ının doğru sınıflandırıldığını göstermektedir. Şekil 3.5(a), test verisinde Orta Ağaç modeli ile az pişmiş ve pişmişlerin %100'ünün, çok pişmişlerin ise %71.4'ünün doğru sınıflandırıldığını göstermektedir. Şekil 3.5(b) ise Orta KNN modeli ile az pişmişlerin %42.9'u, pişmişlerin %57.1'i ve çok pişmişlerin %28.6'sının doğru sınıflandırıldığını göstermektedir.

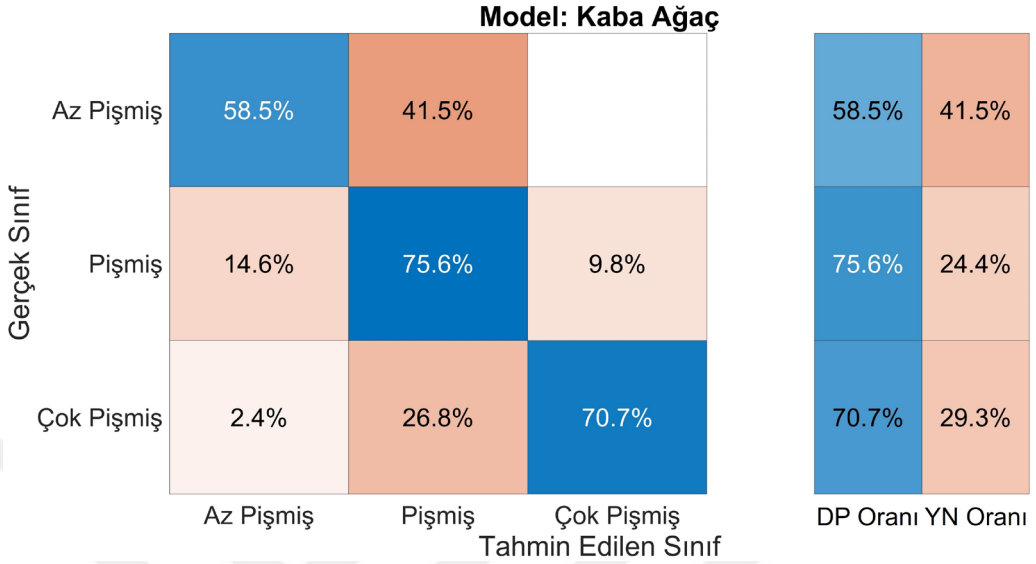

(a)

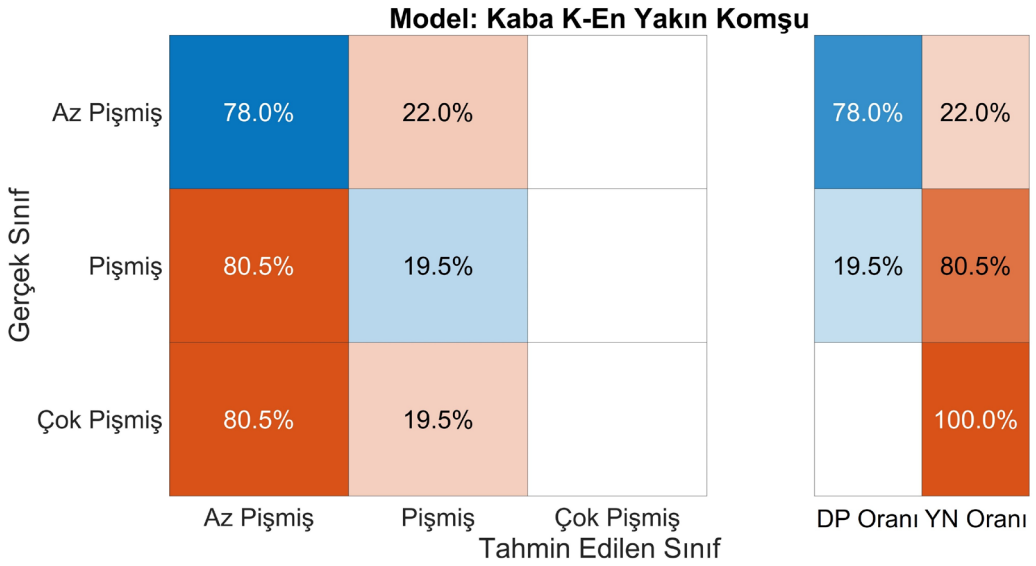

(b)

Şekil 3.6. Doğrulama Karışıklık Matrisleri: (a) Kaba Ağaç ve (b) Kaba KNN

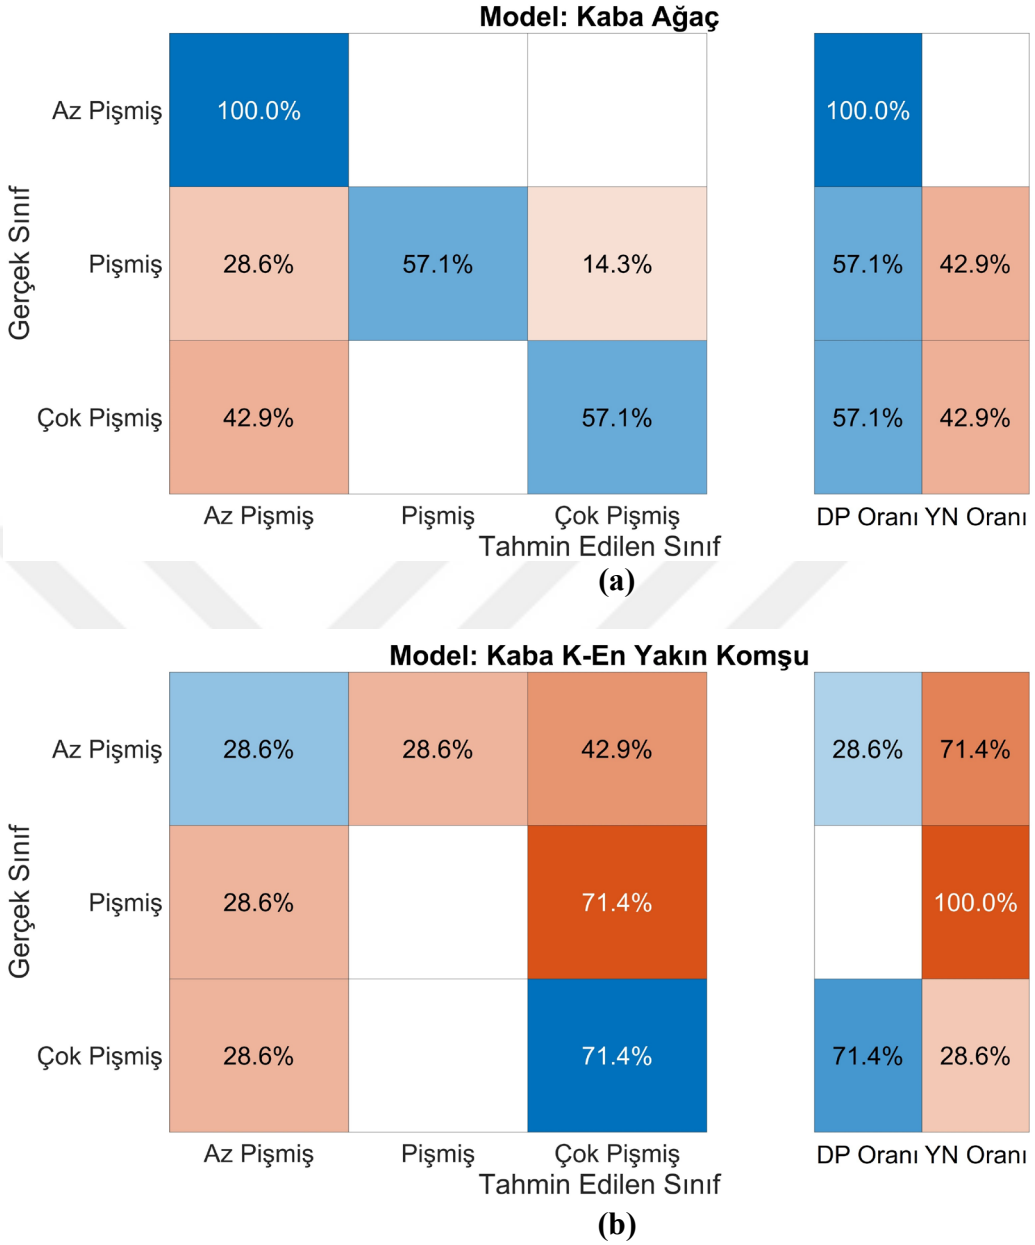

Şekil 3.7. Test Karışıklık Matrisleri: (a) Kaba Ağaç ve (b) Kaba KNN

Şekil 3.6(a)'da görüldüğü üzere, Kaba Ağaç modeli ile az pişmişlerin %58.5'i, pişmişlerin %75.6'sı ve çok pişmişlerin %70.7'si doğru sınıflandırılmıştır. Şekil 3.6(b), Kaba KNN modeli ile az pişmişlerin %78.0'ı, pişmişlerin %19.5'i ve çok pişmişlerin %00.0'ının doğru sınıflandırıldığını göstermektedir. Şekil 3.7(a), test verisinde Kaba Ağaç modeli ile az pişmişlerin %100.0'ü, pişmişlerin %57.1'inin, çok pişmişlerin ise %57.1'inin doğru sınıflandırıldığını göstermektedir. Şekil 3.7(b) ise Kaba KNN modeli ile az pişmişlerin %28.6'sı, pişmişlerin %00.0'ının ve çok pişmişlerin %71.4'ünün doğru sınıflandırıldığını göstermektedir.

3.3. ROC Eğrileri

Sınıflandırma problemleri için önemli bir performans göstergesi olan ROC (Receiver Operating Characteristic-Alıcı İşletim Karakteristiği) eğrisi, AUC (area under the curve-eğri altında kalan alan) ile ifade edilen bir olasılık eğrisidir. Şekil 3.8, İnce Ağaç ve İnce KNN sınıflandırmalarına ait doğrulama ROC eğrilerini; Şekil 3.9 ise aynı sınıflandırmalara ait test ROC eğrilerini göstermektedir.

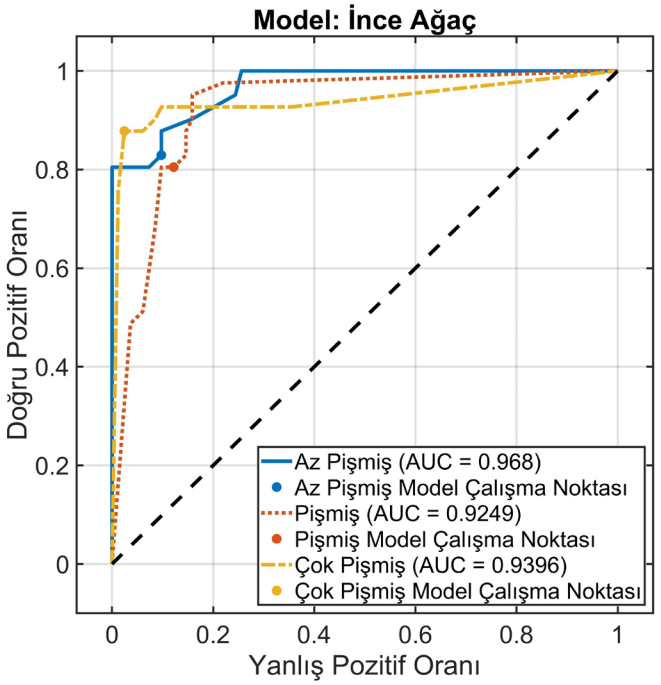

(a)

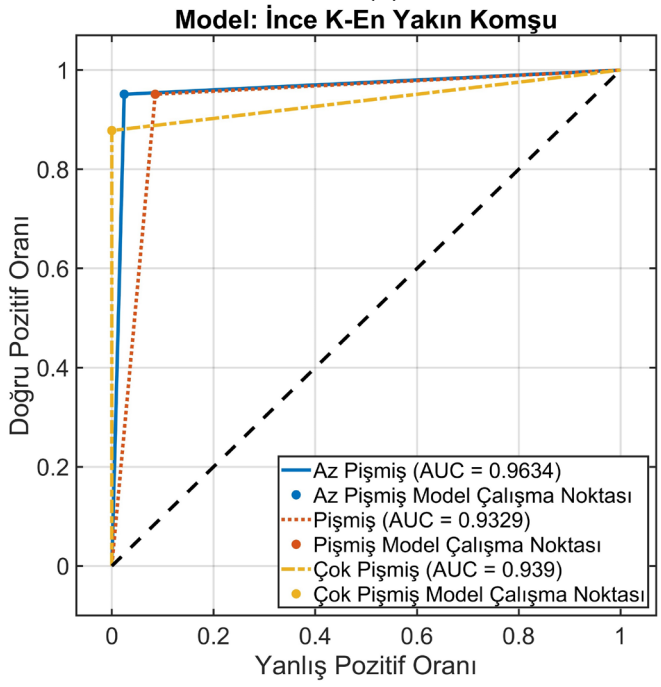

(b)

Şekil 3.8. Doğrulama ROC Eğrileri: (a) İnce Ağaç ve (b) İnce KNN

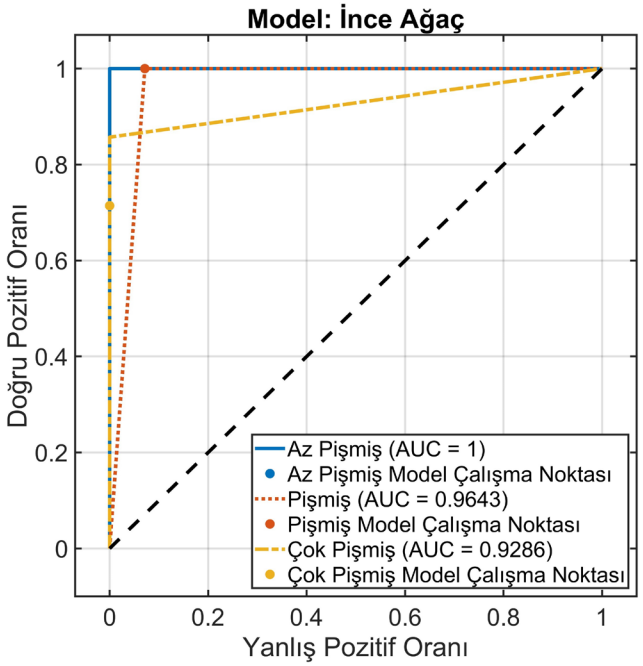

(a)

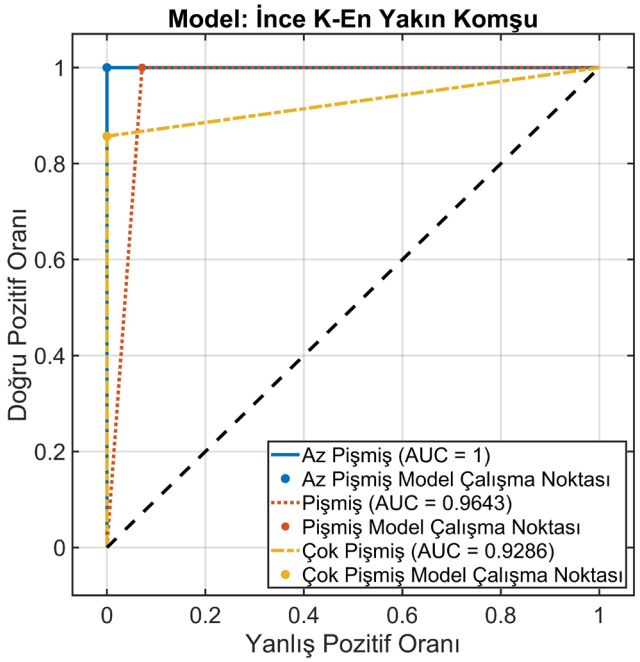

(b)

Şekil 3.9. Test ROC Eğrileri: (a) İnce Ağaç ve (b) İnce KNN

ROC eğrisi, modelin doğru pozitif oranını yanlış pozitif oranına karşı çizer ve modelin ayrıştırma kabiliyetini görsel olarak sunar. AUC değeri ise ROC eğrisinin altındaki alanı ifade eder ve bir sınıflandırma modelinin performansını ölçmek için kullanılır. Bu değer 0.5 ile 1.0 arasında değişir ve yüksek değerler modelin daha iyi performans gösterdiğini

belirtir. Şekil 3.8(a)'daki doğrulama ROC eğrilerinde görüldüğü üzere, en yüksek AUC değeri 0.968 ile az pişmiş sınıfına aittir. Şekil 3.8(b) ise en yüksek AUC değerinin 0.9634 ile yine az pişmiş sınıfında olduğunu göstermektedir. Şekil 3.9(a) ve 3.9(b)'de görüldüğü gibi, test ROC eğrilerinde en yüksek AUC değeri 1 ile az pişmiş sınıfına aittir. Şekil 3.10, Orta Ağaç ve Orta KNN sınıflandırmalarına ait doğrulama ROC eğrilerini; Şekil 3.11 ise aynı sınıflandırmalara ait test ROC eğrilerini göstermektedir.

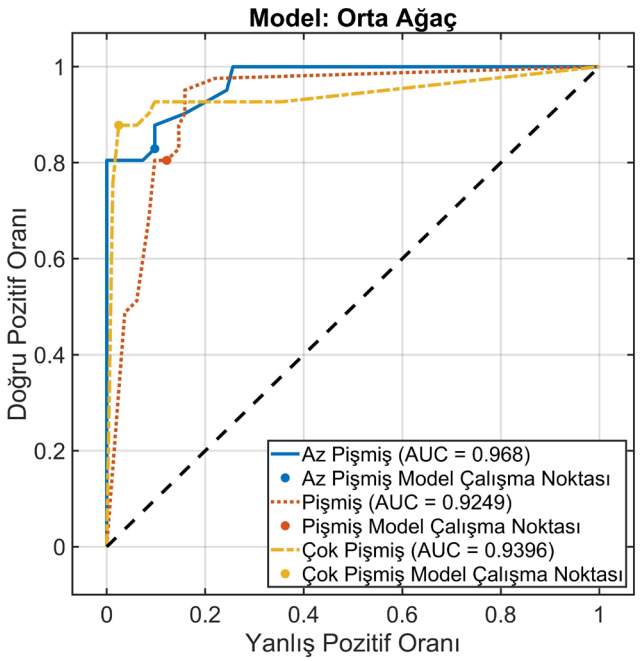

(a)

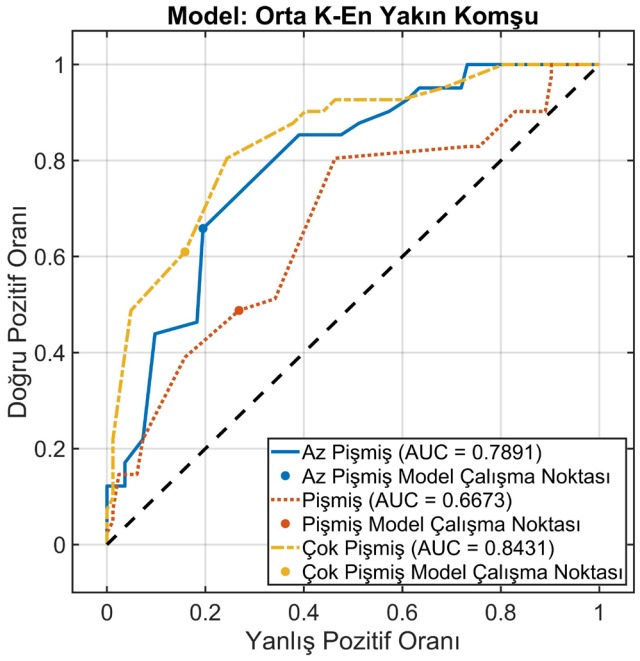

(b)

Şekil 3.10. Doğrulama ROC Eğrileri: (a) Orta Ağaç ve (b) Orta KNN

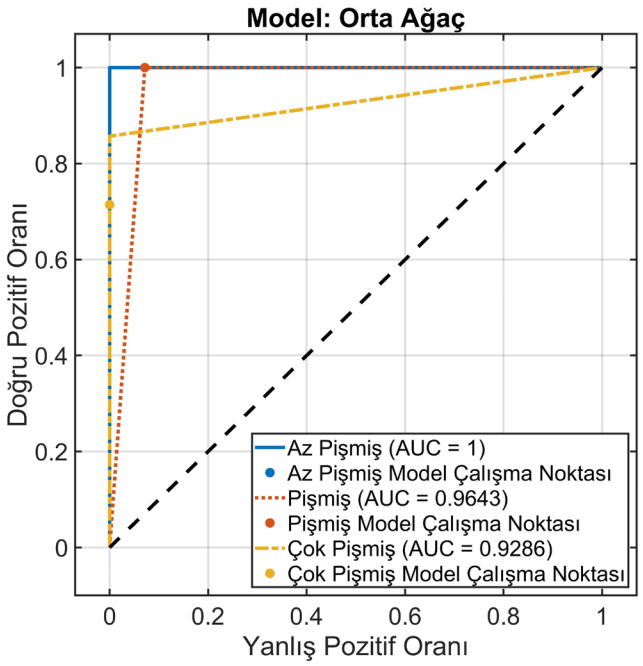

(a)

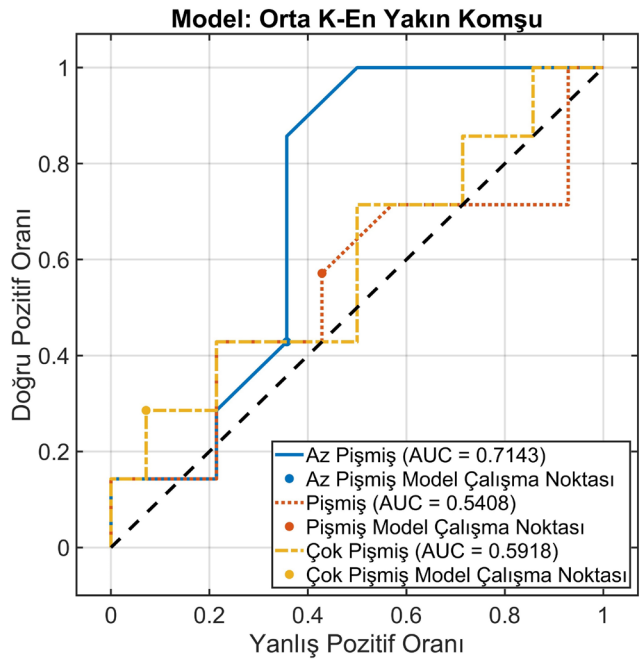

(b)

Şekil 3.11. Test ROC Eğrileri: (a) Orta Ağaç ve (b) Orta KNN

Şekil 3.10(a)'daki doğrulama ROC eğrilerinde görüldüğü üzere, en yüksek AUC değeri 0.968 ile az pişmiş sınıfına aittir. Şekil 3.10(b) ise en yüksek AUC değerinin 0.8431 ile çok pişmiş sınıfında olduğunu göstermektedir. Şekil 3.11(a)'da test ROC eğrilerinde en yüksek AUC değeri 1 ile az pişmiş sınıfına, 3.11(b)'de ise 0.7143 ile yine az pişmiş

sınıfına aittir. Şekil 3.12, Kaba Ağaç ve Kaba KNN sınıflandırmalarına ait doğrulama ROC eğrilerini; Şekil 3.13 ise aynı sınıflandırmalara ait test ROC eğrilerini göstermektedir.

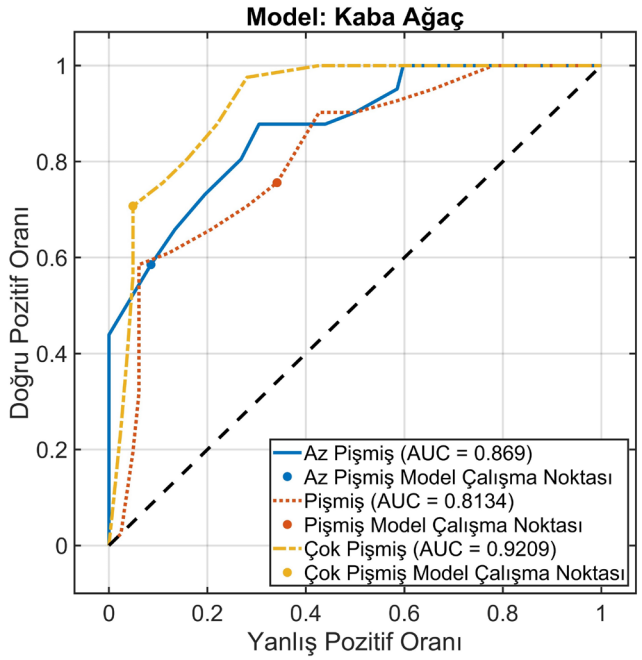

(a)

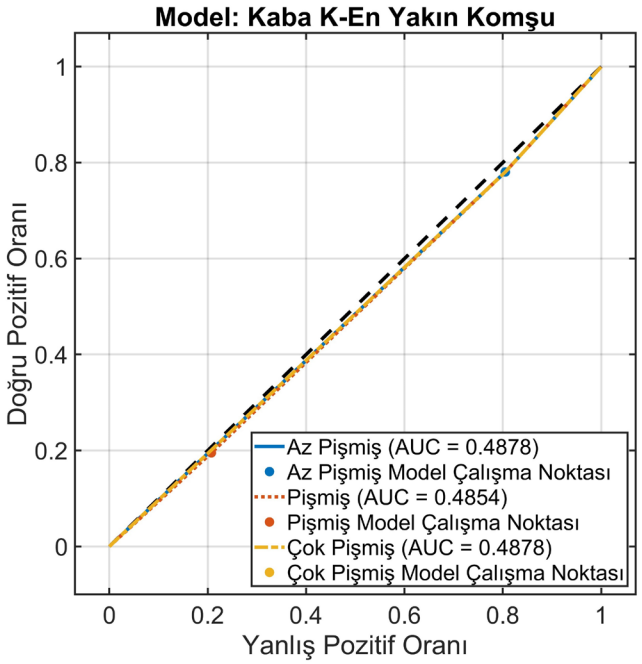

(b)

Şekil 3.12. Doğrulama ROC Eğrileri: (a) Kaba Ağaç ve (b) Kaba KNN

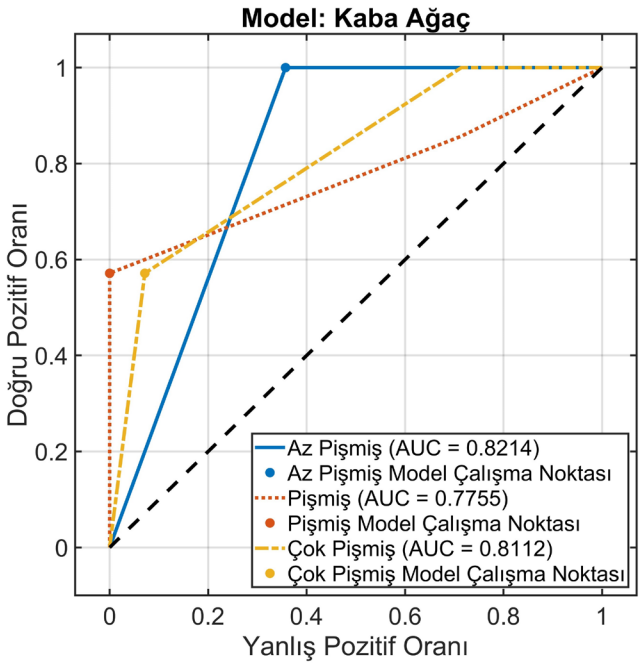

(a)

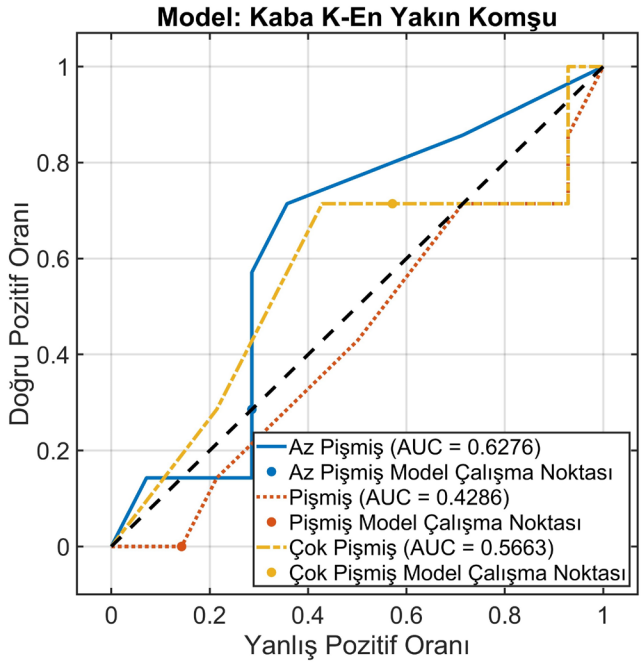

(b)

Şekil 3.13. Test ROC Eğrileri: (a) Kaba Ağaç ve (b) Kaba KNN

Şekil 3.12(a)'daki doğrulama ROC eğrilerinde görüldüğü üzere, en yüksek AUC değeri 0.9209 ile çok pişmiş sınıfına aittir. Şekil 3.12(b) ise en yüksek AUC değerinin 0.4878 ile hem az, hem çok pişmiş sınıfında olduğunu göstermektedir. Şekil 3.13(a)'da test ROC eğrilerinde en yüksek AUC değeri 0.8214 ile az pişmiş sınıfına, 3.13(b)'de ise 0.6276 ile yine az pişmiş sınıfına aittir.

4. BÖLÜM

SONUÇ VE ÖNERİLER

Bu tez çalışmasında, konveyörlü elektrikli fırınlarda ürünlerin pişme seviyelerini (az pişmiş, pişmiş, çok pişmiş) belirlemek için denetimli makine öğrenmesi algoritmalarına dayalı bir sınıflandırıcı geliştirilmiştir. Karar Ağaçları ve K-En Yakın Komşu yöntemlerinin İnce, Orta ve Kaba modellerinin karşılaştırıldığı çalışma için gerçek konveyörlü fırından alınan ürün tipi, pişme süresi, rezistans sıcaklıkları gibi değerler ile veri seti oluşturulmuş, MATLAB çalışma ortamında eğitim ve test çalışmaları yürütülmüştür.

Elde edilen bulgulara göre, en yüksek doğrulama doğruluk oranı %92.7 ile İnce KNN algoritmasına aittir. Ayrıca bu model en düşük maliyet (9) ile de öne çıkmaktadır ve eğitim süresi de 9.5 saniye ile makul bir süredir. Test sonuçlarında ise İnce KNN, %95.2 doğruluk oranıyla bir kez daha en başarılı model olmuştur. Ayrıca test sonuçlarında toplam maliyeti (1) en düşük olan model yine İnce KNN olmuştur. En düşük doğrulama doğruluk oranı %32.5 ile Kaba KNN algoritmasında bulunurken, tahmin hızı da (2000 gözlem/saniye) oldukça yüksek elde edilmiştir. En düşük test doğruluk oranı (%33.3) ve en yüksek toplam maliyet (14) yine Kaba KNN algoritmasına aittir. Karar Ağaçları modellerinden İnce Ağaç ve Orta Ağaç ise, %83.7 doğrulama doğruluk oranlarıyla başarılı sayılabilecek olmakla birlikte, toplam maliyetleri (20) İnce KNN'e göre oldukça yüksek çıkmıştır. Tahmin hızı ve bilhassa da eğitim süresi açısından İnce Ağaç, Orta Ağaç'a göre çok daha iyi değerlere sahiptir. İki model de %90.5 test doğruluk oranlarıyla doğrulama metrikleri ile istikrarlı sonuçlar ortaya koymuştur.

En iyi iki sonucu veren İnce Ağaç ve İnce KNN modellerinin doğrulama karışıklık matrisleri incelendiğinde, İnce KNN modelinin doğru pozitif oranlarının bariz bir şekilde

yüksek değerlere sahip olduğu görülmüştür. Test karışıklık matrislerine baktığımızda iki modelin de sınıfları ayırt etmede oldukça başarılı oldukları, yalnız çok pişmiş sınıfın tahminlerinde yine İnce KNN modelinin çok daha iyi sonuçlar verdiği görülmüştür. Her iki model az pişmiş ve pişmiş ürünlerde %100 doğru pozitif oranına sahip iken, İnce KNN modeli fazla pişmiş ürünlerde %85.7, İnce Ağaç modeli %71.4 doğru pozitif oranına sahiptir. Diğer modellerin (Orta ve Kaba KNN, Kaba Ağaç) doğruluk oranları ise hem doğrulama hem test setlerinde ciddi şekilde düşmektedir. ROC eğrilerini incelediğimizde, İnce KNN ve İnce Ağaç için doğrulama ve test setlerinde AUC değerlerinin genellikle yüksek olduğu (0.93-1) ve bu modellerin tutarlı şekilde iyi performans sergilediği görülmüştür. Kaba modellerin ROC eğrileri ve AUC değerleri düşük olduğundan (örneğin Kaba KNN için AUC 0.43-0.63), bu modeller sınıfları iyi ayırt edememektedir.

Sonuç olarak İnce ayar değerine sahip Karar Ağaçları ve KNN algoritmalarının en iyi sonuçları verdiği görülmektedir. Bununla birlikte özellikle İnce KNN algoritması, en yüksek doğrulama ve test doğruluk oranlarına da sahiptir. Kullanılan veri setinin yakın, iç içe geçmiş ve karmaşık değerler içermesi nedeniyle, İnce ayar değerine sahip algoritmalar daha yüksek doğruluk oranları elde etmiştir. Bu durumla tutarlı olarak Kaba modeller, her iki algoritma için de en düşük doğruluk ve AUC değerlerini sergilemektedir. Bu da karmaşık sınıflandırma problemleri için uygun olmadıklarını göstermektedir. Yapılan çalışmalar İnce ayar değerine sahip sınıflandırıcıların akıllı fırın tasarımında kullanılabileceğini göstermektedir. İki model içerisinde de özellikle İnce KNN modelinin tüm pişme seviyesi sınıflarında yüksek performans gösterdiği görülmektedir.

Bu çalışma ile pişirme parametrelerinin akıllı sınıflandırmayla dinamik ayarlanmasına imkan tanıyarak, endüstriyel fırın otomasyon verimliliğini artırmaya katkı sağlanması amaçlanmıştır. Çalışma, Karar Ağaçları ve KNN algoritmalarını karşılaştırmalı olarak değerlendirerek makine öğrenmesi uygulamalarının endüstriyel bağlamdaki potansiyelini de ortaya koymaktadır. Gelecek çalışmalarda hiperparametre optimizasyonu ile modellerin doğruluğunu arttırmak hedeflenebilir ve gerçek sistem entegrasyonunda IoT ve bulut teknolojileri kullanılarak modelin endüstriyel uygulamaları artırılabilir. Bu öneriler ile çalışma, akademik ve pratik kullanım alanlarını genişleterek ısı kontrollü sistemler ve akıllı fırın tasarımı gibi endüstriyel uygulamalara rehberlik edecektir.

KAYNAKÇA

1. Hansu, A., 2019. Ağırlığa Duyarlı Sıcaklık Kontrollü Fırın Tasarımı ve Gerçekleştirilmesi. Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, Konya, 94.
2. Thorvaldsson, K., Skjöldebrand, C., 1998. Water diffusion in bread during baking. **Lwt - Food Science and Technology, 31**: 658-663.
3. Purlis, E., Salvadori, V. O., 2009. Bread baking as a moving boundary problem. **Journal of Food Engineering, 91** (3), 428-433.
4. Mankan, E., 2008. Hamurun Fiziksel Özelliklerinin Çavdar Ekmeğinin Kalitesi Üzerine Etkisi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Gıda Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul, 69.
5. Astrom, K. J., Hagglund, T., 1995. Advanced PID control. **Energy and Power Engineering, 9** (4), 1-5.
6. Kantaş, M., 2007. Ev Tipi Elektrikli Fırınların Performansının Sayısal ve Deneysel İncelenmesi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Makina Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul, 76.
7. Yılmaz, H., 2005. Ekmek Üretiminde Programlanabilir Mantıksal Kontrol Cihazlarının Kullanılması. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, Ankara, 105.
8. Edwards, C., Spurgeon, S. K., 1994. Application of sliding modes to the control of industrial furnaces, 1443-1448. *Proceedings of IECON'94 - 20th Annual Conference of IEEE Industrial Electronics,* 05-09 September, Bologna, Italy.
9. Usalan, M. A. S., 2015. Bir Endüstriyel Fırın Otomasyonu. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Ankara, 85.
10. Tao, J., Yu, Z., Zhu, Y., 2014. PFC based PID design using genetic algorithm for chamber pressure in a coke furnace. **Chemometrics and Intelligent Laboratory Systems, 137** (3): 155-161.

11. Boisvert, P., Runstedther, A., 2014. Fuel sparing: Control of industrial furnaces using process gas as supplemental fuel. **Applied Thermal Engineering, 65** (1-2): 293-298.
12. Mohammed, M., Khan, M.B., Bashier, E.B.M., 2016. Machine Learning: Algorithms and Applications (1st ed.). CRC Press, Boca Raton, pp.226.
13. Beşkardeş, A., Özdemir, M. E., 2017. Sinter makinesinin örüntü tanıma tabanlı otomatik hız kontrolü. **Journal of Science and Engineering, 19** (57): 816-818.
14. Kaşıkçı, T., Gökçen, H., 2014. Metin madenciliği ile e-ticaret sitelerinin belirlenmesi. **Bilişim Teknolojileri Dergisi, 7** (1): 25-32.
15. Çelik, Ö., Koç, B. C., 2021. TF-IDF, Word2vec ve Fasttext vektör model yöntemleri ile Türkçe haber metinlerinin sınıflandırılması. **Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 23** (67): 121-127.
16. Göçgün, Ö. F., Onan, A., 2021. Amazon ürün değerlendirmeleri üzerinde derin öğrenme/makine öğrenmesi tabanlı duygu analizi yapılması. **Avrupa Bilim ve Teknoloji Dergisi, 1** (24): 445-448.
17. Eryılmaz, E. E., Şahin, D. Ö., Kılıç, E., 2020. Türkçe istenmeyen e-postaların farklı öznitelik seçim yöntemleri kullanılarak makine öğrenmesi algoritmaları ile tespit edilmesi. **Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 13** (2): 57-77.
18. Safalı, Y., 2020. Sosyal medya kullanıcılarının Cumhur İttifakı hakkındaki görüşlerinin veri madenciliği teknikleri ile sınıflandırılması. **Bilgisayar Bilimleri ve Teknolojileri Dergisi, 1** (2): 51-57.
19. Çılgın, C., Ünal, C., Alıcı, S., Akkol, E., Gökşen, Y., 2020. Metin sınıflandırmada yapay sinir ağları ile bitcoin fiyatları ve sosyal medyadaki beklentilerin analizi. **Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi, 4** (1):106-126.
20. Edwards, B., Zatorsky, M., Nayak, R., 2008. Clustering and classification of maintenance logs using text data mining, 193-199. *Proceedings of the Seventh Australasian Data Mining Conference (AusDM 2008)*, 27-28 November, Australia.
21. Ertaban, C., Albey, E., 2024. Simulation based resource optimization using a decision tree clearing function. **IEEE Access, 12**: 60425-60435.
22. Pan, H. (2024). The construction and application of library intelligent acquisition decision model based on decision tree algorithm. **International Journal of Advanced Computer Science and Applications(IJACSA), 15** (1): 168-178.

23. Muja, M., Lowe, D. G., 2014. Scalable nearest neighbor algorithms for high dimensional data. **IEEE Transactions on Pattern Analysis and Machine Intelligence, 36** (11), 2227-2240.
24. Cunningham, P., Delany, S. J., 2021. K-nearest neighbour classifiers-a tutorial. **ACM Computing Surveys (CSUR), 54** (6), 1-25.
25. Özcan, B., Külahlı, F., 2020. Lastik sektöründe karar analizi uygulaması. **UMUFED International Journal of Western Black Sea Engineering and Science, 2** (2), 28-54.
26. Onan, A., 2015. Comparative performance analysis of decision tree algorithms in the corporate bankruptcy prediction. **Journal of Information Technologies, 8** (1), 9-19.
27. Yılmaz, A. K., Durak, M. Ş., Özdemir, E., Kiracı, K., Tanrıverdi, G., 2017. Eskişehir ilinde havayolu yolcu potansiyelinin belirlenmesi üzerine bir karar ağacı uygulaması. **Anadolu University of Sciences & Technology-B: Theoretical Sciences, 5** (1), 22-33.
28. Özcan, B., Özer, E. H., 2021. Decision theory ımplementation in agricultural sector. **International Journal of Eastern Anatolia Science Engineering and Design, 3** (1), 257-281.
29. Bilenler, B., Özgüven, K., 2020. Methods to increase effectiveness of decision trees in counterfeit detection in banking. **TIDE AcademIA Research, 2** (1), 71-89.
30. Gül, E., & Kalyoncu, M., 2020. Investigation of classification performance of k nearest neighbor algorithm in cases of heavy vehicle air compressor piston ring wear. **European Journal of Science and Technology, Special Issue,** 78-90.
31. Oral, O., Oral, E. L., Andaç, M. S., 2021. Comparison of the performance of k-nearest neighbours and generalized neural network in construction crew productivity prediction. **Cukurova University Journal of the Faculty of Engineering, 36** (1), 131-140.
32. Hacıbeyoglu, M., Çelik, M., Çiçek, Ö. E., 2023. Energy efficiency estimation in buildings with k nearest neighbor algorithm. **Necmettin Erbakan University Journal of Science and Engineering, 5** (2), 65-74.
33. Çetin, R., 2010. S7-200 PLC'lerle Otomasyon Temel Seviye. Seçkin Yayıncılık, Ankara, Türkiye, pp.364.
34. GMT, PLC özellikleri (Web sitesi: **https://gmtcontrol.com/portfolio-item/glc-496t-plc-cpu-modulu/**), (Erişim tarihi: Haziran 2024).

35. GMT, Operatör panel özellikleri (Web sitesi: **https://gmtcontrol.com/portfolio-item/ghs-070e-2/**), (Erişim tarihi: Haziran 2024).
36. GMT, Genişleme modülü özellikleri (Web sitesi: **https://gmtcontrol.com/portfolio-item/gxm-40ua-genisleme-modulu/**), (Erişim tarihi: Haziran 2024).
37. Omron Endüstriyel Otomasyon, Solid state relay (Web sitesi: **https://industrial.omron.com.tr/tr/products/G3NA-475B-UTU-2-5-24VDC**), (Erişim tarihi: Kasım 2024).
38. Ürper, F., Solid state röle (SSR) nedir? Nasıl çalışır? (Web sitesi: **https://blog.direnc.net/solid-state-role-ssr-nedir-nasil-calisir/**), (Erişim tarihi: Haziran 2024).
39. VFA Elektronik, Termokupl Çeşitleri Nelerdir?, K tip termocupl (Web sitesi: **https://www.vfaelektronik.com/urunler/termokupllar/75**), (Erişim tarihi: Haziran 2024).
40. K tip termocupl (Web sitesi: **https://www.sanayimalzemeleri.com/lyk-3409-k-tipi-termokupl-77mm-prob-uzunlugu-50c-250c**), (Erişim tarihi: Haziran 2024).
41. Thermocouple (Web sitesi: **https://theinstrumentguru.com/thermocouple/**), (Erişim tarihi: Kasım 2024).
42. Meon Otomasyon, Delta Sürücü İnverter özellikleri (Web sitesi: **https://www.meonotomasyon.com/urun/delta-vfd004el21w-1-0-4-kw-ac-surucu-inverter-vfd004l21a**), (Erişim tarihi: Haziran 2024).
43. Shalev-Shwartz, S., Ben-David, S., 2014. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press, Cambridge, UK, pp.410.
44. Kavzoğlu, T., Çölkesen, İ., 2010. Classification of satellite images using decision trees: Kocaeli case. **Electronic Journal of Map Technologies, 2** (1), 36-45.
45. Quinlan, J. R., 2014. C4. 5: Programs for Machine Learning. Elsevier, pp.312.
46. Lezki, Ş., 2014. Çok kriterli karar verme problemlerinde karar ağacı kullanımı. **Journal of Economic Innovation, 2** (1), 16-31.
47. Clemen, R. T., 1996. Making Hard Decision: An Introduction to Decision Analysis (2nd Edition). Duxbury Press, USA, pp.664.
48. The MathWorks Help Center, Choose Classifier Options, (Web sitesi: **https://www.mathworks.com/help/stats/choose-a-classifier.html**), (Erişim tarihi: Kasım 2024).

49. Karataş, F., Sarıışık, A., Coşkun, G., 2021. Evaluation of the safety coefficients of floor coverings used in wet and dry environments by k-means and decision tree methods. **Dicle University Journal of Engineering, 12** (5), 865-873.
50. Efeoğlu, E., Tuna, G., 2021. Analysis of the parameters that affect the measurements of reflection coefficients and evaluation of the effects of parameters for k nearest neighbors-based liquid classification. **Journal of Intelligent Systems: Theory and Applications, 4** (2), 155-167.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Kerem ARSLANGİRAY
Uyruğu: Türkiye (T.C)
Doğum Tarihi ve Yeri:
Medeni Durum:
e-mail:
Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Karabük Üniversitesi, Mekatronik Mühendisliği	2016
Lise	Muş Endüstri Meslek Lisesi, Muş	2011

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2021-2023	Buhara Endüstriyel Makine	3
2017-2021	Bugass Kızılötesi Teknolojileri	5

YABANCI DİL

İngilizce

YAYINLAR

1. Arslangiray, K., Savaş, S., Bingöl, M. S., 2024. Classification of oven-baked products based on baking levels using decision tree and nearest neighbor algorithms, 220-233. *Latin America 9th International Conference on Scientific Researches,* August 9-11, Mexico City, ISBN: 978-625-6283-58-9.