

**İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

YÜKSEK LİSANS TEZİ

**YAPAY ZEKÂ İLE YEMEĞİN OTOMATİK PİŞMESİNİ RENK TAKİBİ İLE YAPAN SİSTEMİN
GELİŞTİRİLMESİ**

**DEVELOPMENT OF AN AUTOMATED COOKING SYSTEM USING ARTİFİCİAL
İNTELLİGENCE AND COLOR TRACKİNG**

Fırat KOÇYİĞİT

Y220246005

Tez Danışmanı:

Prof. Dr. Ayşegül ALAYBEYOĞLU

İzmir, 2025

ÖZ

Bu çalışmanın temel amacı, günümüzün en etkili tahmin yöntemlerinden biri olan Evrişimli Sinir Ağı'nın tahmin gücünü yemeğin pişme durumu tahmininde ortaya koymak ve bu bağlamda CNN'nin sağladığı avantajları kapsamlı bir şekilde incelemektir. Evrişimli Sinir Ağı, biyolojik sinir sistemlerinden esinlenerek geliştirilmiş, karmaşık veri setlerinden öğrenerek genelleme yapabilen güçlü bir hesaplama tekniğidir. Son yıllarda, CNN'nin tahmin yetenekleri birçok alanda büyük başarılar elde etmiştir ve özellikle görüntü işleme, sınıflandırma, öngörü modelleri ve karar destek sistemlerinde etkin bir şekilde kullanılmaktadır. Gıda teknolojisi ve gastronomi alanında da bu tür yöntemlerin kullanımı giderek artmaktadır, çünkü gıda maddelerinin fiziksel ve kimyasal özelliklerini analiz etmek, gıda güvenliği ve kalite kontrolü açısından büyük bir öneme sahiptir.

Bu bağlamda, yemeğin pişme durumu tahmin edilerek hem mutfakta daha verimli bir süreç sağlanması hem de gıda güvenliğinin artırılması amaçlanmaktadır. Pişirme sürecinin analizi, geleneksel olarak deneme-yanılma yöntemi, manuel ölçümler veya aşçılık tecrübesine dayalı tahminlerle yapılmaktadır. Ancak bu yöntemler, hem zaman kaybına neden olmakta hem de sübjektif değerlendirmeler içerdiğinden hataya açık olabilmektedir. Son yıllarda gelişen yapay zeka ve makine öğrenimi yöntemleri, bu süreci daha objektif hale getirerek daha doğru tahminler yapmaya imkan sağlamaktadır. Özellikle CNN'nin öğrenme kapasitesi, çoklu değişkenleri aynı anda işleyebilme kabiliyeti ve doğrusal olmayan ilişkileri öğrenebilme yeteneği sayesinde pişme sürecine dair daha doğru sonuçlar elde edilmesi mümkün olmaktadır.

Bu çalışmada, pişme sürecinin belirlenmesi için renk değişimlerine dayalı analizler gerçekleştirilmiştir. Pişme sürecinin her aşamasında meydana gelen renk değişiklikleri, gıdaların iç sıcaklık seviyeleri ve pişme dereceleri hakkında önemli bilgiler içermektedir. Gıdaların pişme süreçlerini belirlemek için geleneksel sıcaklık ölçümleri, doku analizleri veya kimyasal yöntemler kullanılabilir. Ancak, bu yöntemler genellikle zaman alıcı ve maliyetli olup pratik mutfak uygulamaları için uygun değildir. Yapay zeka ve görüntü işleme yöntemleri sayesinde, bu sürecin daha hızlı ve otomatik bir şekilde analiz edilmesi mümkün hale gelmektedir. Bu çalışmada

geliştirilen modelde, pişme sürecine ilişkin renk değişimlerinin analiz edilmesi için görüntü işleme özelinde optimize edilmiş bir CNN kullanılmıştır.

Bu analizler kapsamında, pişme sürecini en iyi tahmin eden Evrişimli Sinir Ağı modeli belirlenmiş ve farklı model konfigürasyonlarının performansları karşılaştırılmıştır. Çalışmanın temel hedeflerinden biri, bu süreçte en uygun tahmin yöntemini belirlemek ve modelin doğruluk oranlarını iyileştirerek hata payını en aza indirmektir. Pişme sürecinin belirlenmesi için farklı aktivasyon fonksiyonları, öğrenme oranları ve veri artırma yöntemleri değerlendirilmiş; modelin en iyi tahmin gücüne ulaşması için çeşitli parametre optimizasyonları gerçekleştirilmiştir. Bu çalışmanın ortaya koyduğu sonuçlar, hem gıda endüstrisinde hem de akıllı mutfak teknolojileri geliştirilmesinde önemli bir referans niteliği taşıyacaktır. Özellikle ev otomasyonu ve endüstriyel mutfak sistemleri için geliştirilecek akıllı pişirme sistemlerinde, bu tür bir yapay zeka modelinin entegre edilmesi pişirme sürecinin daha verimli ve hassas bir şekilde yönetilmesine olanak sağlayacaktır.

Sonuç olarak, bu çalışmada CNN'nin pişirme süreçlerinin analizi ve tahmini üzerindeki başarısı incelenmiş, renk değişimlerine dayalı analizler için geliştirilen Evrişimli Sinir Ağı modellerinin performansı değerlendirilmiş ve elde edilen sonuçlar ışığında en uygun tahmin yöntemi belirlenmeye çalışılmıştır. Çalışma kapsamında geliştirilen modelin, gıda teknolojisi ve yapay zeka uygulamalarının kesişim noktasında önemli bir katkı sağlaması hedeflenmektedir.

Anahtar Kelimeler: Yapay Zeka, Evriřimli Sinir Ađı, Otomatik Yemek Piřirme, Grnt İřleme, Fırın Yemekleri, Makine ğrenmesi, Piřme Durumu Tahmini, Optik Sensrler



ABSTRACT

The aim of this study is to show the prediction power of Convolutional Neural Networks, one of the best prediction methods today, in predicting the cooking status of food. The CNN results specific to image processing developed for the analysis based on color changes of the application and the most appropriate prediction method and result for this study were tried to be found.

The main purpose of this study is to demonstrate the predictive power of Convolutional Neural Networks, one of the most effective prediction methods of today, in predicting the cooking status of food and to examine the advantages provided by CNN in this context in a comprehensive manner. Convolutional Neural Networks are a powerful computational technique inspired by biological nervous systems and capable of generalizing by learning from complex data sets. In recent years, CNN's predictive capabilities have achieved great success in many areas and are effectively used especially in image processing, classification, predictive models and decision support systems. The use of such methods is also increasing in the field of food technology and gastronomy, because analyzing the physical and chemical properties of food materials is of great importance in terms of food safety and quality control. In this context, it is aimed to provide a more efficient process in the kitchen and increase food safety by predicting the cooking status of food. The analysis of the cooking process is traditionally done with the trial-and-error method, manual measurements or estimations based on cooking experience. However, these methods both cause loss of time and can be prone to error since they involve subjective evaluations. In recent years, developing artificial intelligence and machine learning methods make this process more objective and allow for more accurate predictions. In particular, thanks to the learning capacity of CNN, its ability to process multiple variables simultaneously, and its ability to learn nonlinear relationships, it is possible to obtain more accurate results regarding the cooking process.

In this study, analyzes based on color changes were performed to determine the cooking process. Color changes that occur at each stage of the cooking process contain important information about the internal temperature levels and cooking degrees of foods. Traditional temperature measurements, texture analyzes, or chemical methods

can be used to determine the cooking processes of foods. However, these methods are usually time-consuming and costly and are not suitable for practical kitchen applications. Thanks to artificial intelligence and image processing methods, it is possible to analyze this process more quickly and automatically. In the model developed in this study, an CNN optimized for image processing was used to analyze color changes related to the cooking process.

Within the scope of these analyzes, the convolutional neural network model that best predicts the cooking process was determined and the performances of different model configurations were compared. One of the main objectives of the study is to determine the most appropriate prediction method in this process and to minimize the margin of error by improving the accuracy rates of the model. Different activation functions, learning rates and data augmentation methods were evaluated to determine the cooking process; various parameter optimizations were performed to achieve the best prediction power of the model. The results of this study will be an important reference both in the food industry and in the development of smart kitchen technologies. Integrating such an artificial intelligence model, especially in smart cooking systems to be developed for home automation and industrial kitchen systems, will allow the cooking process to be managed more efficiently and precisely. As a result, in this study, the success of CNN in the analysis and prediction of cooking processes was examined, the performance of convolutional neural network models developed for color change-based analyses was evaluated and the most appropriate prediction method was tried to be determined in the light of the obtained results. The model developed within the scope of the study is aimed to make a significant contribution at the intersection of food technology and artificial intelligence applications.

Keywords: Artificial Intelligence, Convolutional Neural Networks, Automatic Cooking, Color Tracking, Image Processing, Oven Dishes, Machine Learning, Cooking Status Estimation, Optical Sensors

ÖNSÖZ

İnsanların, kendileri gibi düşünen, hareket eden ve etkileşime giren sistemler oluşturma arzusu antik çağlardan beri var olmuştur. Bu merak, Yapay Zeka'nın gelişimine zemin hazırlamış ve insan beyninin işleyişini matematiksel modellerle taklit eden teknolojilerin ortaya çıkmasına yol açmıştır. Yapay zeka teknolojilerinden biri olan Evrişimli Sinir Ağı, günümüzde pek çok alanda yaygın olarak kullanılan güçlü bir tahmin ve modelleme tekniğidir.

CNN, doğrusal olmayan yapılarda üstün tahmin yetenekleri, esneklikleri ve farklı problem türlerinde (sınıflandırma, kümeleme, optimizasyon vb.) elde ettikleri başarılı sonuçlar ile öne çıkmaktadır. Bu özellikleri sayesinde savunmadan sağlığa, finanstan endüstriye kadar birçok sektörde yaygın olarak kullanılmaktadır. Bu çalışmada, CNN yöntemi kullanılarak, yemeğin pişmesini renk takibi ile yapan bir akıllı sistem geliştirilmiştir.

Bu çalışmam esnasında, bana her zaman destek olan ailem başta olmak üzere, beni her zaman cesaretlendiren ve destek olan Danışman Hocam Prof. Dr. Ayşegül ALAYBEYOĞLU'na, tezin yazım aşamasında destek aldığım hocalarıma ve eğitim hayatı boyunca ders aldığım bütün hocalarıma çok teşekkür ederim.

İÇİNDEKİLER

ÖZ	ii
ABSTRACT	v
ÖNSÖZ	viii
İÇİNDEKİLER	ix
TABLO LİSTESİ	x
KISALTMA LİSTESİ	xi
GİRİŞ	11
2. LİTERATÜR TARAMASI	14
3. EVRİŞİMLİ SİNİR AĞI TASARIMI VE KULLANILAN YÖNTEMLER	17
3.1 Eğitim ve Test Kümelerinin Seçimi:	17
3.2 Katman ve Nöron Sayısının Seçimi	19
3.3 Girdilerin Ölçeklendirilmesi	20
3.4 Fonksiyon Seçimi	20
3.5 Performans Fonksiyonunun Belirlenmesi	20
3.7 Ağın Devir (Epoch) Sayısı	22
3.8 Lojistik Regresyon	22
4. YAPAY ZEKA İLE YEMEĞİN OTOMATİK PİŞMESİNİ RENK TAKİBİ İLE YAPAN SİSTEM	
4.1 Veri Seti	26
4.2 Evrişimli Sinir Ağı Analiz Sonuçları	29
4.3 Ara Katmandaki En Uygun Nöron Sayısının Bulunması	32
4.4 En Uygun Öğrenme Oranı ve Momentum Katsayısının Belirlenmesi	33
4.5 En Uygun Aktivasyon Fonksiyonunun Bulunması	35
4.6 İki Ara Katmanlı Ağ Yapısı Denemesi	37
4.7 Lojistik Regresyon Modeli	38
4.8 Modelin Anlamlılık Testi	40
5. SONUÇLAR VE DEĞERLENDİRME	41
6. REFERANSLAR	444
7. EK	46

TABLO LİSTESİ

Tablo 4.1: Aktivasyon Sonuçları.....	35
Tablo 4.2: İki Ara Katmanlı Yapılandırmanın Sonuçları	37
Tablo 4.3:Lojistik Regresyon Modeli Sonuçlarının Değerlendirilmesi	38
Tablo 4.4: ROC Eğrisi ve AUC Analizi.....	38
Tablo 4.5: Performans Karşılaştırması.....	39
Tablo 4.6: Lojistik Regresyon Modeli Anlamlılık Testi Sonuçları.....	40

ŞEKİL LİSTESİ

Şekil 3.1 Eğitim Kümesi ve Onaylama Kümelerinin Hatalarının Karşılaştırılması.....	16
Şekil 4.0 Sistem Çalışma Şeması.....	25
Şekil 4.1 Fırın İçerisinden Toplanan Veri Setleri Örnekleri.....	26
Şekil 4.2 Fırın İçerisinden Toplanan Yemeğin Pişmemiş Görüntülerinin Veri Seti.....	27
Şekil 4.3 Fırın İçerisinden Toplanan Yemeğin Orta Pişmiş Görüntülerinin Veri Seti.....	27
Şekil 4.4 Fırın İçerisinden Toplanan Yemeğin Tam Pişmiş Görüntülerinin Veri Seti.....	27
Şekil 4.5 Pişme durumu tahmini yapan Evrişimli Sınır Ağı görseli.....	30

KISALTMA LİSTESİ

- **LR** - Lojistik Regresyon
- **ROC** - Receiver Operating Characteristic
- **MSE** - Mean Square Error
- **ME** - Mean Error
- **MAE** - Mean Absolute Error
- **RMSE** - Root Mean Square Error
- **CNN** - Convolutional Neural Networks
- **AI** – Artificial Intelligence

GİRİŞ

Günümüzde yapay zeka teknolojileri hızla gelişmekte ve hayatımızın pek çok alanında önemli çözümler sunmaktadır. Özellikle tahmin ve sınıflandırma problemleri için geliştirilen Evrişimli Sinir Ağı, birçok disiplinde büyük başarılar elde etmiş ve geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları sunan modeller geliştirilmesine olanak tanımıştır. CNN'nin en önemli özelliklerinden biri, öğrenme kapasitesi sayesinde karmaşık veri setleri üzerinde genelleme yapabilme yeteneğidir. Bu özellik, özellikle görüntü işleme ve analiz süreçlerinde, verinin yapısını öğrenerek doğru tahminler yapabilmesine imkan tanımaktadır. Bu çalışmada, CNN'nin tahmin gücü, gıda endüstrisi için kritik bir süreç olan yemeğin pişme durumunun belirlenmesi bağlamında ele alınmaktadır.

Yemeğin pişme sürecinin doğru bir şekilde belirlenmesi, hem endüstriyel gıda üretiminde hem de ev mutfaklarında büyük önem taşımaktadır. Geleneksel olarak pişme süresi genellikle deneyime dayalı olarak belirlenmekte, ancak sıcaklık, nem, malzeme yoğunluğu gibi faktörlerin değişkenliği nedeniyle bu yöntemler her zaman güvenilir sonuçlar vermemektedir. Ayrıca, yemeğin iç sıcaklığı ve dış yüzeyde oluşan fiziksel değişiklikler göz önünde bulundurularak yapılan değerlendirmeler, subjektif faktörlere bağlı olarak değişiklik gösterebilmektedir. Bunun yerine, nesnel ve ölçülebilir parametreler ile desteklenen bir tahmin modeli oluşturmak, özellikle büyük ölçekli üretim yapan gıda fabrikaları için kalite standartlarını iyileştirmeye yönelik önemli bir adım olacaktır.

Bu çalışmada, yemeğin pişme sürecinin analiz edilmesi için renk değişimlerine dayalı bir görüntü işleme modeli geliştirilmiştir. Renk değişimi, pişme sürecinin kritik bir göstergesidir ve birçok gıda ürünüde, pişme durumu ile doğrudan ilişkilendirilebilmektedir. Özellikle et ve hamur bazlı ürünlerde, sıcaklık değişimiyle birlikte meydana gelen Maillard reaksiyonu gibi kimyasal süreçler, yiyeceklerin yüzey renklerinde belirgin farklılıklar oluşturmakta ve bu değişimler, görüntü işleme teknikleri ile analiz edilerek anlamlı bilgiler çıkarılabilmektedir.

Evrişimli Sinir Ağı, büyük miktardaki veriden öğrenme yeteneği sayesinde, karmaşık ilişkileri modelleyerek pişme sürecinin otomatik olarak belirlenmesini sağlamaktadır.

Ađı modeli tasarımında izlenmesi gereken yol ve önemli bazı parametrelerden bahsedilmiştir. Dördüncü bölümde geliştirilen sistem hakkında detaylı bilgi verilmiştir. Renk analizi ve görüntü işleme tekniklerine değinilmiştir. Farklı yemek türlerinin pişme durumları CNN ile incelenmiş; sonuçlar karşılaştırılarak, en iyi tahmin yöntemi belirlenmeye çalışılmıştır. Beşinci bölümde yapılan çalışmanın sonuçları değerlendirilmiştir.



2. LİTERATÜR TARAMASI

Yapay zekanın (YZ) gıda biliminde, özellikle pişirme koşullarını tahmin etmede uygulanması, son yıllarda ortaya çıkan bir araştırma alanı olmuştur. Çeşitli çalışmalar, YZ ve makine öğrenme tekniklerinin gıda kalite kontrolünü nasıl geliştirebileceğini, pişirme parametrelerini nasıl optimize edebileceğini ve gıda güvenliğini nasıl iyileştirebileceğini göstermiştir.

Bu alana önemli bir katkı, bilgisayar görüşü ve YZ kullanarak gıda rengini ve pişirme koşullarını değerlendirmek için otomatik sistemler geliştirilmiştir [1-4]. Çalışmaları, pişirme sırasında gıda rengindeki değişiklikleri izlemede gerçek zamanlı görüntü işleminin verimliliğini vurgulamıştır. HSV renk alanı dönüşümü ve segmentasyon algoritmalarını kullanarak, sistem pişirmenin farklı aşamalarını başarıyla belirlemiş ve gıdanın hazır olup olmadığı konusunda doğru tahminler sağlamıştır. Bu yaklaşım, makine öğrenme modelleri kullanılarak renk tabanlı gıda analizinin etkinliğini doğruladığı için çalışmamız için özellikle önemlidir.

Annamalai ve diğerleri (2004) tarafından yapılan bir diğer önemli çalışma, gıda işleme uygulamalarına genişletilebilen narenciye verimi tahmininde renk görme sistemlerinin kullanımını araştırmıştır [5-7]. Yapay zeka tabanlı renk analizinin gıda kalitesini değerlendirmek ve olgunluk seviyelerini tahmin etmek için kullanılabilirliğini gösterdiler. Benzer şekilde, Rodríguez-Pulido ve diğerleri gıda görünüm özelliklerini analiz etmek için bilgisayarlı görüş tekniklerini uyguladılar ve gıda sınıflandırması ve kalite kontrolünde görüntü tabanlı analiz potansiyelini ortaya koydular [8-10]. Bu çalışmalar toplu olarak makine görüşünün ve derin öğrenme modellerinin gıda değerlendirme görevlerini otomatikleştirmede önemli bir rol oynayabileceğini öne sürüyor.

Ayrıca, derin öğrenme alanında Yang ve diğerleri (2018), gıda analizinde evrişimli sinir ağlarının (CNN'ler) uygulanabilirliğini vurgulayarak sebze görüntülerinin alınması için ince ayarlı VGG modelleri kullanmıştır [11-13]. Araştırmaları, farklı pişirme aşamalarını belirten ince renk değişimlerini belirlemede özellik çıkarma ve

süreçlerinin otomasyonunu geliştirmeyi ve akıllı pişirme sistemlerinin geliştirilmesine katkıda bulunmayı amaçlamaktadır.



3. EVRİŞİMLİ SİNİR AĞI TASARIMI VE KULLANILAN YÖNTEMLER

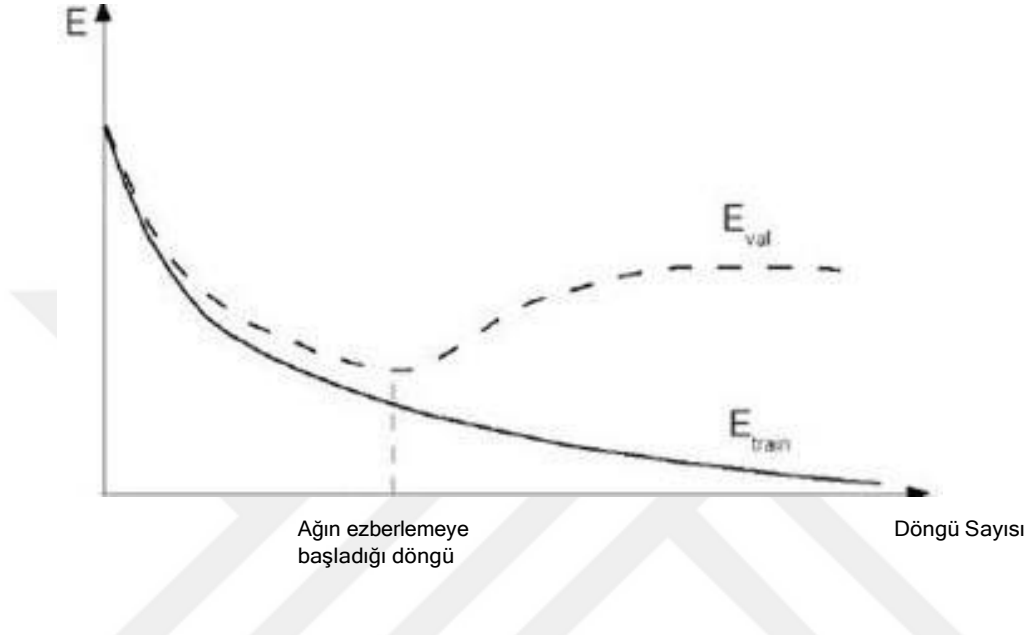
Evrışimli Sinir Ağları, görüntü işleme, nesne tanıma ve derin öğrenme tabanlı diğer görevler için tasarlanmış özel bir yapay sinir ağı modelidir. CNN'ler, geleneksel yapay sinir ağlarından farklı olarak, veriyi doğrudan ham haliyle (örneğin piksel verisi) işleyerek anlamlı özellikleri otomatik olarak çıkarma yeteneğine sahiptir. Bir CNN modeli, genellikle evrişim katmanları (convolutional layers), aktivasyon fonksiyonları, havuzlama katmanları (pooling layers), tam bağlı katmanlar (fully connected layers) ve sınıflandırıcıdan oluşur. Evrişim katmanları, görüntü üzerindeki yerel özellikleri yakalamak için filtreler (kernels) kullanarak giriş verisini işler ve daha yüksek seviyeli özellikler oluşturur. Havuzlama katmanları, modelin ölçek değişmezliğini artırarak hesaplama maliyetini düşürürken, tam bağlı katmanlar sınıflandırma gibi işlemleri gerçekleştirir. CNN'lerin tasarımında, katman sayısı, filtre boyutları, aktivasyon fonksiyonları ve optimizasyon teknikleri gibi birçok parametre modelin başarısını etkileyen faktörlerdir. Derin öğrenme alanında CNN'ler, özellikle görüntü tabanlı tahmin modellerinde yüksek doğruluk elde etmek için tercih edilmektedir.

3.1 Eğitim ve Test Kümelerinin Seçimi:

Ağa sunulacak eğitim ve test kümelerindeki örnekler, ağın performansını büyük ölçüde etkiler. Eğitim kümesindeki örneklerin, ağın çözeceği problem alanını iyi bir şekilde temsil etmesi gerekir. Çünkü ağ, kendisine gösterilen örneklerden yola çıkarak genellemeler yapar. Eğer test kümesindeki örnekler, eğitim kümesinde yer almayan ve ilişkisiz örneklerden oluşursa, ağdan doğru tahminler yapması beklenemez.

Bunun yanı sıra, eğitim setindeki örnek sayısı ne kadar fazla olursa, ağın öğrenmesi o kadar kapsamlı ve doğru olur. Eğitim sürecinde daha fazla örnekle karşılaşan ağ, fonksiyonun daha fazla noktasını öğrenir ve bu da doğru tahmin yapma yeteneğini artırır.

Veri setinde, eğitim ve test kümelerine ek olarak, bir de doğrulama (cross validation) kümesi seçilebilir. Doğrulama kümesi, modelin aşırı öğrenmeye (overfitting) başlamadan önce eğitimini durdurmak amacıyla kullanılır. Şekil 3.1’de x ekseninin temsil ettiği doğrulama kümesi hatası düşüştün sonra artmaya başlamadan önceki durum, en iyi genel çözüm bulunduğu kabul edilir ve eğitim süreci durdurulur [18].



Şekil 3.1 Eğitim Kümesi ve Onaylama Kümelerinin Hatalarının Karşılaştırılması[18]

Veri setinin hangi oranlarda bölüneceğine dair kesin bir kural yoktur. Fakat genellikle eldeki verilerin %70'i eğitim, %20'si onaylama ve %10'u test için ayrılır.

3.2 Katman ve Nöron Sayısının Seçimi

Evrişimli Sinir Ağı'nda, ağın katman sayısı ve katmanlardaki nöron sayısı için kesin bir kural yoktur. En uygun yapı, genellikle deneme yanılma yöntemiyle bulunur. Başlangıçta belirli bir ağ yapısı seçilir ve zamanla bu yapı, ağın büyütülmesi veya küçültülmesi yoluyla optimize edilir. Bu süreçte tasarımcının deneyimi, en uygun ağ yapısını belirlemede önemli bir rol oynar.

Katman sayısı ve katmanlardaki nöron sayısı arttıkça, Evrişimli Sinir Ağının işlem ve öğrenme kapasitesi azalarak ağın ezberlemesine (memorization) neden olabilir. Gereğinden az sayıda katman veya nöron kullanımı ise, ağın örneklerden yeterince iyi genellemeler yapamamasına yol açabilir.

Giriş katmanındaki nöron sayısı, ağın aldığı bağımsız değişkenlerin sayısı ile orantılıdır. Giriş katmanında her bir değişken için bir nöron bulunur. Çıkış katmanındaki nöron sayısı ise hedeflenen çıktı sayısına bağlıdır. Genellikle tek bir çıktı hedeflendiğinden, bu sayı genellikle 1'dir.

Gizli katman sayısı, probleme ve veri setine bağlı olarak değişir. Genellikle bir veya iki gizli katman (ara katman) yeterli olur. Daha fazla gizli katman kullanımı, ağın hızını düşürür ve ezberlemesine yol açabilir [1]. Eğer üç katmanlı bir yapı istenilen sonucu vermezse, ara katman sayısı dört katmana kadar artırılabilir. Ancak, önceki çalışmalara göre, dörtten fazla ara katman kullanmak genellikle ağın performansını olumsuz etkiler. Ara katmanlardaki nöron sayısı için de kesin bir kural bulunmamakla birlikte, daha önce yapılan çalışmalara dayanarak bazı genellemeler yapılabilir.

3.5 Performans Fonksiyonunun Belirlenmesi

Performans fonksiyonları, Evrişimli Sinir Ağının ürettiği çıktılar ile istenilen çıktı değerleri arasındaki farkın kümülatif değerlerini hesaplar. Bu performans değerleri, ağın eğitim kümesinin gerçeği ne kadar doğru temsil ettiğini ve hatayı ne ölçüde minimize ettiğini gözlemlemeye olanak tanır. Ağırlıklar, bu performans değerlerine göre ayarlanarak ağın doğruluğu artırılır. Evrişimli Sinir Ağında hatayı minimize etmek için en yaygın kullanılan yöntem, Hata Karelerinin Ortalaması (Mean Square Error, MSE) yöntemidir. Bunun yanı sıra, Ortalama Hata (Mean Error, ME), Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error, RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error, MAE) gibi performans kriterleri de sıklıkla kullanılır [19-20]. Bu yöntemler, pişme durumunun tahmininde kullanılan sistemin doğruluğunu ve güvenilirliğini artırmak için kritik öneme sahiptir.

3.6 Öğrenme Oranı ve Momentum Katsayısının Belirlenmesi

Öğrenme oranı, Evrişimli Sinir Ağındaki ağırlıkların ne kadar değişeceğini belirler. Öğrenme oranının büyük seçilmesi, ağın salınım (oscillation) yapmasına ve stabil bir sonuca ulaşmasını zorlaştırmasına neden olabilir [21]. Öte yandan, öğrenme oranının küçük seçilmesi, öğrenme süresinin uzamasına ve ağın yerel çözümlere takılmasına yol açabilir. Bu durum, pişme durumunun doğru şekilde tahmin edilmesi için gerekli olan genel çözümü bulmayı zorlaştırabilir.

Bir problemin çözümünde, en az hatayı veren mutlak minimum çözüme ulaşmak her zaman mümkün olmayabilir. Evrişimli Sinir Ağı, eğitimi sırasında bu çözüme ulaşmaya çalışsa da, bazen yerel bir minimumda takılabilir ve daha fazla iyileştirme sağlanamayabilir.

Momentum katsayısı ise, önceki ağırlık değişimlerinin mevcut ağırlık değişimlerini nasıl etkileyeceğini belirler. Eğer momentum terimi kullanılmazsa, ağın düşük öğrenme oranı ile yerel minimuma ulaşması uzun zaman alabilir ve yüksek öğrenme oranında ise salınımlar nedeniyle yerel minimuma ulaşmak zorlaşabilir [22]. Ancak momentum kullanıldığında, yerel minimuma daha hızlı bir şekilde ulaşmak mümkün olur.

Özetle, momentum katsayısı, özellikle yerel çözümlere takılan ağların bir sıçrama yaparak daha iyi sonuçlar bulmasını ve ağı daha hızlı bir sonuca ulaşmasını sağlar. Ancak, momentum katsayısının çok küçük olması yerel çözümlerden kurtulmayı, çok büyük olması ise tek bir çözüme ulaşmayı zorlaştırabilir. Bu nedenle, doğru öğrenme ve momentum katsayılarının seçimi, pişme durumunu doğru tahmin etmek için kritik öneme sahiptir.

3.7 Ağın Devir (Epoch) Sayısı

Eğitim setinin Evrişimli Sinir Ağı içinde bir kez işleminden geçirilmesine devir (epoch) denir. Devir sayısı, ağı öğrenme sürecini doğrudan etkilediğinden, dikkatli bir şekilde belirlenmelidir. Eğitim sürecinde çok fazla ya da çok az sayıda iterasyon kullanmaktan kaçınılmalıdır. Gerekenden az sayıda iterasyon, yetersiz bir eğitimle sonuçlanacak ve ağı, pişme durumu gibi karmaşık problemleri doğru şekilde öğrenemeyecektir. Öte yandan, gereğinden fazla iterasyon kullanılması, ağı eğitimi için gerekli süreyi uzatmanın yanı sıra aşırı uygunluk (overfitting) problemine yol açabilir. Bu durumda ağı, eğitim verileri üzerinde iyi sonuçlar verirken, test seti üzerinde yeterli performansı gösteremeyebilir. Bu nedenle, uygun devir sayısının belirlenmesi, ağı genel performansını optimize etmek için kritik bir faktördür [23].

3.8 Lojistik Regresyon


LR analizi, bağımlı değişkenin kategorik olduğu durumlarda kullanılan bir regresyon modelidir. LR analizinin temel amacı, diğer regresyon yöntemlerinde olduğu gibi bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi incelemektir. Başka bir deyişle, minimum sayıda değişken kullanarak sonuç değişkeni ile açıklayıcı değişkenler arasındaki ilişkiyi tanımlayan kabul edilebilir bir model oluşturmaktır [24]. LR yönteminde, bağımlı değişkenin sürekli olması gibi bir varsayım bulunmaz; bu yöntem özellikle bağımlı değişkenin iki veya daha fazla değer aldığı durumlarda kullanılır.

Lojistik modelin biyolojik deneylerin analizinde kullanımı ilk olarak Berkson (1944)



4.1 Veri Seti

Bu çalışmada, fırın yemeklerinin pişme sürecini analiz etmek ve renk değişimlerine dayalı bir tahmin sistemi geliştirmek amacıyla özel olarak oluşturulmuş bir veri seti kullanılmıştır. Veri seti, farklı yemek türlerinin pişme süreçleri boyunca alınan görüntülerden oluşmaktadır. Her bir görüntü, yemeklerin pişme durumunu yansıtan renk değişikliklerini kaydetmektedir.



Şekil 4.1 Fırın İçerisinden Toplanan Veri Setleri Örnekleri

4.1.1 Veri Toplama Süreci

Veri seti, gerçek mutfak ortamında pişirilen çeşitli fırın yemeklerinden elde edilen görüntülerin toplanmasıyla oluşturulmuştur. Farklı yemek türleri (et yemekleri, sebze yemekleri, tatlılar vb.) kullanılarak geniş bir yelpazede veri elde edilmiştir. Pişirme işlemi sırasında belirli aralıklarla alınan yüksek çözünürlüklü görüntüler, pişme süresince meydana gelen renk değişimlerini yakalamak için kullanılmıştır. Şekil 4.2 de Fırın içerisinden toplanan yemeğin pişmemiş görüntüsü verileri sunulmaktadır. Şekil 4.3, fırın içerisinden toplanan orta pişmiş yemeğin görüntü veri setlerini içermektedir. Şekil 4.4 de fırın içerisinden toplanan tam pişmiş yemeğin görüntü veri setlerini temsil etmektedir.

bir şekilde tahmin etmekle kalmamış, aynı zamanda yemeğin ideal pişme durumuna ulaştığı noktayı da başarılı bir şekilde belirleyebilmiştir.

Bu analizler, yapay zeka ve Evrişimli Sinir Ağı teknolojilerinin gıda pişirme süreçlerinde nasıl uygulanabileceğini gösteren önemli bir adım olmuştur. Geliştirilen sistem, hem ev kullanıcıları hem de profesyonel mutfaklar için pişirme sürecinin daha iyi kontrol edilmesini sağlayacak yenilikçi bir çözüm sunmaktadır.

4.3 Ara Katmandaki En Uygun Nöron Sayısının Bulunması

Evrişimli Sinir Ağı modelinin performansını optimize etmek için, ara katmanlardaki nöron sayısının doğru bir şekilde belirlenmesi kritik bir öneme sahiptir. Nöron sayısı, modelin öğrenme kapasitesini ve genel performansını doğrudan etkileyen bir faktördür. Çok az sayıda nöron kullanılması, modelin yetersiz öğrenmesine (underfitting) neden olabilirken, çok fazla sayıda nöron kullanılması aşırı öğrenmeye (overfitting) yol açabilir. Bu nedenle, en uygun nöron sayısının bulunması için sistematik bir yaklaşım izlenmiştir.

4.3.1. Deneysel Yaklaşım

Ara katmandaki nöron sayısının belirlenmesi için, farklı nöron sayılarıyla çeşitli model yapılandırmaları test edilmiştir. Başlangıç olarak, küçük bir nöron sayısı ile model eğitilmiş ve elde edilen sonuçlar analiz edilmiştir. Daha sonra, nöron sayısı kademeli olarak artırılmış ve her seferinde modelin performansı gözlemlenmiştir.

Performans değerlendirmesi, modelin eğitim verileri üzerindeki doğruluğu, doğrulama seti üzerindeki doğruluğu ve genel hata oranı dikkate alınarak yapılmıştır. Özellikle doğrulama seti üzerindeki performans, modelin genelleme kabiliyetini değerlendirmek için kritik bir rol oynamıştır.

4.3.2. Performans Kriterleri

Nöron sayısının belirlenmesinde kullanılan performans kriterleri şunlardır:

Eğitim Hatası: Modelin eğitim verileri üzerinde yaptığı hataların ortalaması.
Doğrulama Hatası: Modelin doğrulama seti üzerindeki performansını gösteren hata oranı.
Genel Doğruluk: Modelin tüm veri seti üzerindeki genel doğruluk oranı.
Aşırı Öğrenme Kontrolü: Modelin doğrulama hatasında önemli bir artış gözlemlendiğinde,

öğrenebilirken, çok yüksek bir momentum değeri modelin dengesiz öğrenmesine yol açabilir. Bu nedenle, uygun bir denge bulunması önemlidir.

4.4.3. Öğrenme Oranı Ve Momentum Katsayısının En Uygun Değerlerini Belirlemek İçin Deneysel Yaklaşım

Bu aşamada, öğrenme oranı ve momentum katsayısının en uygun değerlerini belirlemek için sistematik bir deneysel yaklaşım izlenmiştir:

Öğrenme Oranı Denemeleri: Farklı öğrenme oranları kullanılarak model eğitilmiş ve her bir durumda eğitim hızı, doğrulama hatası ve genel doğruluk oranı değerlendirilmiştir. Öğrenme oranının çok düşük olduğu durumlarda modelin öğrenme süresi uzamış, çok yüksek olduğu durumlarda ise dengesiz sonuçlar elde edilmiştir.

Momentum Katsayısı Denemeleri: Benzer şekilde, farklı momentum katsayıları kullanılarak model eğitilmiş ve sonuçlar analiz edilmiştir. Momentum katsayısının çok düşük olması durumunda modelin kararlılığı azalmış, çok yüksek olması durumunda ise öğrenme sürecinde aşırı dalgalanmalar (oscillations) gözlemlenmiştir.

Yapılan denemeler sonucunda, hem öğrenme oranı hem de momentum katsayısı için en uygun değerler belirlenmiştir. Bu değerler, modelin hızlı ve dengeli bir şekilde optimum sonuçlara ulaşmasını sağlamıştır. Optimum öğrenme oranı ve momentum katsayısı, modelin pişme durumu tahminlerinde yüksek doğruluk oranları elde etmesine olanak tanımış ve genel olarak daha verimli bir eğitim süreci sunmuştur.

Aşağıda, farklı aktivasyon fonksiyonlarının performansını gösteren örnek bir test tablosu sunulmuştur:

Tablo4.1: Aktivasyon Sonuçları

Aktivasyon Fonksiyonu	Eğitim Süresi (dakika)	Doğruluk Oranı (%)	Hata Oranı (%)	Genel Performans
Sigmoid	120	85	15	Orta
Tanh	100	88	12	İyi
ReLU	80	90	10	Çok İyi
Leaky ReLU	85	89	11	İyi

Yapılan testler sonucunda, ReLU aktivasyon fonksiyonu, pişme durumu tahminlerinde en iyi performansı göstermiştir. Bu fonksiyon, hızlı öğrenme sağlaması ve doğruluk oranının yüksek olması nedeniyle tercih edilmiştir. Ancak, Leaky ReLU fonksiyonu da benzer sonuçlar verdiği için alternatif bir seçenek olarak değerlendirilebilir. Sigmoid ve Tanh fonksiyonları, doğruluk oranı ve hata oranı açısından yeterli performansı göstermiş ancak eğitim süresi açısından daha yavaş kalmıştır.

Bu sonuçlar, pişme durumu tahmininde kullanılacak Evrişimli Sinir Ağı modelinde ReLU aktivasyon fonksiyonunun en uygun seçenek olduğunu göstermektedir. Bu fonksiyon, modelin doğrusal olmayan ilişkileri etkin bir şekilde öğrenmesine ve pişme süreci boyunca doğru tahminlerde bulunmasına olanak tanımıştır.

CNN modeli ve LR modeli karşılaştırıldığında, CNN modelinin daha yüksek bir doğruluk oranı ve daha düşük bir hata oranı sunduğu görülmüştür. Bununla birlikte, LR modelinin basitliği ve hesaplama verimliliği, özellikle daha az karmaşık problemlerde veya doğrusal ilişkilere dayalı sistemlerde hala güçlü bir alternatif olabileceğini göstermektedir. Aşağıda, iki modelin karşılaştırmalı sonuçları özetlenmiştir:

Tablo4.5: Performans Karşılaştırması

Model	Doğruluk Oranı (%)	Hata Oranı (%)	AUC Değeri
Yapay Sinir Ağı (YSA)	92	8	0,92
Lojistik Regresyon	85	15	0,85

Sonuç olarak, LR, pişme durumu tahmininde makul bir performans göstermiş, ancak Evrişimli Sinir Ağı modeli, doğrusal olmayan ilişkileri daha iyi öğrenme kabiliyeti sayesinde daha üstün sonuçlar elde etmiştir.

4.8 Modelin Anlamlılık Testi

LR modeli, bağımlı değişken olan pişme durumu ile bağımsız değişkenler (örneğin, renk değişimi, pişirme süresi vb.) arasındaki ilişkinin doğruluğunu ve geçerliliğini değerlendirmek için kullanılmaktadır. Modelin güvenilir sonuçlar üretebilmesi için, bağımsız değişkenlerin modelde anlamlı bir etkisi olup olmadığının test edilmesi gerekmektedir. Bu süreçte modelin genel anlamlılığını değerlendirmek için çeşitli istatistiksel testler uygulanır.

4.8.1. Ki-Kare Testi

Modelin anlamlılığını test etmek için ilk adım, modelin genel uygunluğunu değerlendiren Ki-Kare testinin (Chi-Square Test) uygulanmasıdır. Bu test, modelin bağımsız değişkenlerle tahmin edilen pişme durumu sonuçları ile gerçek gözlemler arasında istatistiksel olarak anlamlı bir ilişki olup olmadığını belirler. Ki-Kare testinin p-değeri, modelin anlamlılığını gösterir. P-değeri 0.05'in altında ise modelin anlamlı olduğu kabul edilir.

4.8.2. Wald Testi

Her bir bağımsız değişkenin model üzerindeki etkisini değerlendirmek için Wald testi uygulanır. Wald testi, bağımsız değişkenlerin katsayılarının sıfırdan farklı olup olmadığını test eder. Wald testi sonucunda elde edilen p-değerleri, her bir değişkenin model için anlamlı olup olmadığını belirler. P-değeri 0.05'in altında olan değişkenler, modelde anlamlı kabul edilir ve pişme durumunun tahmin edilmesinde önemli bir rol oynar.

4.8.3. Model Uyum İyiliği (Goodness of Fit)

seçimi konusunda kapsamlı değerlendirmeler yapılmasına olanak tanıyabilir. Bununla birlikte, Grad-CAM (Gradient-weighted Class Activation Mapping) gibi görselleştirme yöntemleri ile modelin hangi görüntü alanlarına odaklandığının analiz edilmesi, sistemin açıklanabilirliğini artırarak özellikle endüstriyel kullanımlar için önemli bir avantaj sağlayabilir.

Modelin genelleme yeteneğini artırmak ve farklı pişirme koşullarına uyum sağlamak amacıyla daha geniş veri setleri üzerinde çalışmalar yapılabilir. Ayrıca, renk takibi dışında farklı sensör teknolojileri (örneğin, sıcaklık veya nem sensörleri) entegre edilerek sistemin doğruluğu ve güvenilirliği daha da artırılabilir.

5.6. Genel Değerlendirme

Sonuç olarak, bu çalışma, Evrişimli Sinir Ağı ve lojistik regresyon gibi yapay zeka tekniklerinin, fırın yemeklerinin pişme durumu tahmininde etkin bir şekilde kullanılabileceğini ortaya koymuştur. CNN modelinin üstün performansı, bu tür karmaşık süreçlerde daha doğru ve güvenilir sonuçlar elde edilmesini sağlamıştır. Geliştirilen sistem, pişirme sürecinin otomatik hale getirilmesi ve pişirme kalitesinin standartlaştırılması açısından önemli bir adım olarak değerlendirilebilir.

6. REFERANSLAR

1. Lin, C.-S., et al. (2021). "A Study of Automatic Judgment of Food Color and Cooking Conditions with Artificial Intelligence Technology." *Processes*, 9(1128), MDPI.
2. Li, H.; Lee, W.S.; Wang, K. Identifying blueberry fruit of different growth stages using natural outdoor color images. *Comput. Electron. Agric.* **2014**
3. Annamalai, P.; Lee, W.S.; Burks, T.F. Color Vision Systems for Estimating Citrus Yield in Real-time. In *Agricultural and Biological Engineering*; University of Florida: Gainesville, FL, USA, 2004
4. Arzate-Vázquez, I.; Chanona-Pérez, J.J.; de Jesús Perea-Flores, M.; Calderón-Domínguez, G.; Moreno-Armendáriz, M.A.; Calvo, H.; Godoy-Calderón, S.; Quevedo, R.; Gutiérrez-López, G. Image Processing Applied to Classification of Avocado Variety Hass (*Persea americana* Mill.) During the Ripening Process. *Food Bioprocess Technol.* **2011**
5. Annamalai, P., et al. (2004). "Color Vision Systems for Estimating Citrus Yield in Real-time." *Agricultural and Biological Engineering*.
6. Shaik, K.B.; Ganesan, P.; Kalist, V.; Sathish, B.S.; Jenitha, J.M.M. Comparative Study of Skin Color Detection and Segmentation in HSV and YCbCr Color Space. *Procedia Comput. Sci.* **2015**
7. Soriano, M.; Martinkauppi, B.; Huovinen, S.; Laaksonen, M. Skin Detection in Video under Changing Illumination Conditions. In Proceedings of the 15th International Conference on Pattern Recognition, ICPR-2000, Barcelona, Spain, 3–7 September 2000
8. Rodríguez-Pulido, F.J., et al. (2013). "Analysis of Food Appearance Properties by Computer Vision Applying Ellipsoids to Color Data." *Comput. Electron. Agric.*
9. Lin, C.S.; Chen, S.H.; Chang, C.M.; Shen, T.S. The Crack Detection of the Retaining Wall with an Innovative Ensemble Learning Method in a Dynamic Imaging System. *Sensors* **2019**
10. Lin, C.S.; Huang, Y.C.; Chen, S.H.; Hsu, Y.L.; Lin, T.C. The Application of Deep Learning and Image Processing Technology in Laser Positioning. *Appl. Sci.* **2018**
11. Yang, Z., et al. (2018). "Vegetable Image Retrieval with Fine-tuning VGG Model and Image Hash." *IFAC-PapersOnLine*.
12. Chang, C.M.; Lin, C.S.; Chen, W.C.; Chen, C.T.; Hsu, Y.L. Development and Application of a Human-Machine Interface Using Head Control and Flexible Numeric Tables for Severely Disabled. *Appl. Sci.* **2020**

