

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EMLAK FOTOĞRAFLARININ KALİTE DEĞERLENDİRİLMESİ:
DERİN ÖĞRENME TABANLI BİR YAKLAŞIM**

YÜKSEK LİSANS TEZİ

Akın YAŞAR

Bilgisayar Mühendisliği Anabilim Dalı

HAZİRAN 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EMLAK FOTOĞRAFLARININ KALİTE DEĞERLENDİRİLMESİ:
DERİN ÖĞRENME TABANLI BİR YAKLAŞIM**

YÜKSEK LİSANS TEZİ

Akın YAŞAR

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Yüksel YURTAY

HAZİRAN 2025

Akın Yaşar tarafından hazırlanan “EMLAK FOTOĞRAFLARININ KALİTE DEĞERLENDİRİLMESİ: DERİN ÖĞRENME TABANLI BİR YAKLAŞIM” adlı tez çalışması 30.06.2025 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Unvan Adı SOYADI**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI (Danışman)**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
(Gerekliyse) Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
(Gerekliyse) Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “EMLAK FOTOĞRAFLARININ KALİTE DEĞERLENDİRİLMESİ: DERİN ÖĞRENME TABANLI BİR YAKLAŞIM” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(...../...../20.....).

Akın YAŞAR



TEŞEKKÜR

Bu yüksek lisans tez çalışmasının hazırlanmasında değerli katkıları ve rehberliğiyle her zaman destek olan danışmanım Doç. Dr. Yüksel Yurtay'a en içten teşekkürlerimi sunarım.

Tez sürecinde kullandığım veri setinin elde edilmesinde ve çalışmanın temellerinin oluşturulmasında önemli katkılar sağlayan Sayın Muhammed Büyükkınacı'ya özellikle teşekkür ederim.

Akademik hayatım boyunca bilgi ve tecrübeleriyle beni yönlendiren tüm Sakarya Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı öğretim üyelerine teşekkür ederim.

Bu süreçte sabırları, destekleri ve sevgileriyle her zaman yanımda olan aileme, dostlarıma ve tüm sevdiklerime sonsuz teşekkürlerimi sunarım.

Akın YAŞAR



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
TABLO LİSTESİ	xiii
ŞEKİL LİSTESİ	xv
ÖZET.....	xvii
SUMMARY	xix
1. GİRİŞ.....	1
1.1. Emlak İlanlarında Görsel Kalitenin Önemi	1
1.2. Literatür Araştırmaları.....	1
1.2.1. Görsel kalite değerlendirmesi çalışmaları.....	1
1.2.2. Emlak fotoğrafları üzerine yapılan çalışmalar	5
1.3. Çalışmanın Amacı ve Katkısı.....	7
2. YÖNTEM.....	9
2.1. Veri Seti.....	9
2.2. Veri Ön İşleme	11
2.3. Kullanılan Modeller	13
2.4. Model Eğitimi	14
2.5. Değerlendirme Metrikleri.....	16
2.5.1. Doğruluk (accuracy)	16
2.5.2. Kesinlik (precision).....	17
2.5.3. Geri çağırma (recall)	17
2.5.4. F1 skoru.....	17
2.5.5. ROC eğrisi ve AUC	18
3. BULGULAR VE DEĞERLENDİRME	19
3.1. Deneysel Sonuçlar	19
3.2. Modellerin Performans Metrikleri.....	19
3.3. ROC Eğrisi ve AUC Analizi	20
3.3.1. MobileNetV2 Roc Eğrisi	21
3.3.2. ResNet18 Roc Eğrisi.....	21
3.3.3. EfficientNetB1 Roc Eğrisi	22
3.4. Tahmin Dağılımı Analizi.....	22
3.5. Karmaşıklık Matrisi Analizi.....	23
3.6. Modellerin Genel Performans Değerlendirmesi.....	25
4. SONUÇ VE GELECEK ÇALIŞMALAR	27
KAYNAKLAR	29
ÖZGEÇMİŞ.....	31



KISALTMALAR

AI	: Artificial Intelligence
AUC	: Area Under Curve
CLAHE	: Contrast Limited Adaptive Histogram Equalization
CNN	: Convolutional Neural Network
DeepBIQ	: Deep Learning-based Blind Image Quality
DNN	: Deep Neural Networks
IAQA	: Image Aesthetic Quality Assessment
IQA	: Image Quality Assessment
MOS	: Mean Opinion Score
ROC	: Receiver Operating Characteristic
VGG16	: Visual Geometry Group 16



TABLO LİSTESİ

Sayfa

Tablo 2.1. Veri setinin sınıf dağılımı.	10
Tablo 2.2. Veri setinin küme dağılımı.....	10
Tablo 2.3. Veri artırmanın test verisi üzerindeki model performansına etkisi.....	12
Tablo 2.4. Kullanılan derin öğrenme modelleri.	13
Tablo 2.5. Model eğitimi sırasında kullanılan ortak hiperparametreler.	14
Tablo 3.1. Modellerin test verisi üzerindeki performans metrikleri.....	20



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Veri seti örnek görüntüleri.....	11
Şekil 2.2. Eğitim doğruluğu karşılaştırması.....	15
Şekil 2.3. Eğitim kayıp karşılaştırması.	15
Şekil 3.1. MobileNetV2 ROC eğrisi grafiği.	21
Şekil 3.2. ResNet18 ROC eğrisi grafiği.....	21
Şekil 3.3. EfficientNetB1 ROC eğrisi grafiği.	22
Şekil 3.4. Modellerin test veri seti üzerindeki tahmin dağılımları.....	23
Şekil 3.5 MobileNetV2 karmaşıklık matrisi.	24
Şekil 3.6 ResNet18 karmaşıklık matrisi.....	24
Şekil 3.7 EfficientNetB1 karmaşıklık matrisi.....	25



EMLAK FOTOĞRAFLARININ KALİTE DEĞERLENDİRİLMESİ: DERİN ÖĞRENME TABANLI BİR YAKLAŞIM

ÖZET

Emlak sektöründe görsellerin kalitesi, kullanıcı deneyimini ve satış süreçlerini doğrudan etkileyen kritik bir faktördür. Bu çalışmada, emlak ilanlarında kullanılan fotoğrafların kalite sınıflandırmasını yapmak amacıyla üç farklı derin öğrenme modeli, MobileNetV2, ResNet18 ve EfficientNetB1 kullanılmıştır. Bu modeller, yaygın kullanımları, farklı mimari yapıları ve hesaplama gereksinimlerinin çeşitliliği göz önünde bulundurularak seçilmiştir. Literatürde görsel kalite değerlendirme üzerine yapılan çalışmalar genellikle genel görüntü iyileştirme veya estetik değerlendirme üzerine yoğunlaşırken, bu araştırma kapsamında ise doğrudan emlak ilanlarına özel ve uygulamaya dönük bir sınıflandırma sistemi geliştirilmiştir. Çalışmada, bu modellerin eğitim ve test performansları karşılaştırılmıştır. Deneylerde kullanılan veri kümesi, Türkiye’deki bir emlak ilan platformundan toplanmış ve gerçek kullanıcılar tarafından yüklenen 6.330 emlak fotoğrafını içermektedir. Görseller manuel olarak "Good" ve "Bad" şeklinde etiketlenmiştir. Etiketleme süreci, çalışmanın yazarı ve platform çalışanlarının katkılarıyla gerçekleştirilmiş olup, 'Good' sınıfı yüksek kaliteli görüntülerden oluşurken, 'Bad' sınıfı bulanıklık, aşırı karanlık veya aydınlık olması, watermark ya da logo içermesi gibi kaliteyi düşüren faktörlere sahip görselleri içermektedir. Eğitim, doğrulama ve test aşamalarında kullanılan veri dağılımı şu şekildedir: 4.446 görüntü eğitim, 628 görüntü doğrulama ve 1.256 görüntü test için kullanılmıştır. Model karşılaştırması, aynı veri seti, hiper parametreler ve değerlendirme metrikleri altında gerçekleştirilmiş olup, metodolojik tutarlılıkla doğrudan performans kıyaslaması yapılabilmesine olanak tanımaktadır. Eğitim sürecinde modellerin kayıp fonksiyonu ve doğruluk metrikleri takip edilerek performansları analiz edilmiştir. Eğitim sürecini hızlandırmak ve genelleme yeteneğini artırmak amacıyla transfer öğrenme yaklaşımı benimsenmiştir. Bu kapsamda, önceden eğitilmiş modellerin ağırlıkları dondurulmuş ve yalnızca çıktı katmanları yeniden eğitilerek özelleştirilmiştir. Bu yöntem, sınırlı veri setleriyle yapılan çalışmalarda başarı oranını artıran etkili bir stratejidir. Test aşamasında modellerin performansını değerlendirmek için ROC eğrisi, Doğruluk-Duyarlılık (Precision-Recall) eğrisi, F1 skoru, histogram ve karmaşıklık matrisi gibi çeşitli metrikler kullanılmıştır. Deneysel sonuçlar, MobileNetV2 modelinin %89 doğruluk oranıyla en iyi performansı sergilediğini ve en düşük kayıp değerine ulaştığını ortaya koymaktadır. ResNet18 ve EfficientNetB1, belirli kalite problemlerine karşı hassasiyet gösterse de genel doğruluk açısından MobileNetV2'nin gerisinde kalmıştır. Analizler, MobileNetV2'nin düşük kaliteli görüntüleri ayırt etmede daha başarılı olduğunu göstermektedir. Bu çalışma, emlak ilan platformlarında düşük kaliteli görsellerin yüklenmesini önlemeye yönelik bir sistemin temelini oluşturmaktadır. Önerilen model, emlak ilan platformlarında kullanıcıların yükleme aşamasında rehberlik edilmesini sağlayarak kalite kontrol süreçlerini otomatik hale getirebilir. Böyle bir sistemin uygulanması, platform moderatörlerinin manuel kontrol ihtiyacını azaltabilir ve ilan kalitesinde bütünlük sağlayarak marka güvenilirliğini artırabilir. Böylece yalnızca yüksek kaliteli

görsellerin paylaşılması sağlanarak kullanıcı deneyimi iyileştirilebilir. Gelecekteki çalışmalar, modelin daha farklı kalite problemlerini tanıyabilmesi için sınıf çeşitliliğini artırmaya ve daha geniş veri setleriyle doğrulama yapılmasına odaklanabilir.



QUALITY ASSESSMENT OF REAL ESTATE PHOTOGRAPHS: A DEEP LEARNING-BASED APPROACH

SUMMARY

In the digital era, where first impressions are often formed through online visuals, the quality of real estate photographs plays a crucial role in influencing prospective buyers' decisions and shaping their perception of properties. Visual presentation in real estate listings is no longer a supplementary feature but a vital determinant of user engagement and transaction success. Numerous studies have revealed that high-quality images can significantly increase the perceived value of a property and drive user interactions, while low-quality visuals may reduce trust and interest.

This study proposes an automated system for real estate image quality assessment using deep learning methodologies. While previous research in image quality evaluation has focused primarily on aesthetic judgments, generic image enhancement, or low-level perceptual metrics, the present study addresses a specific and practical need: assessing and filtering real estate photographs based on their visual adequacy for online listing platforms. The work is rooted in the recognition that the manual moderation of thousands of user-uploaded images is labor-intensive, subjective, and unsustainable for large-scale real estate platforms. Hence, automation in quality control using artificial intelligence (AI) provides a scalable and consistent alternative.

To this end, three convolutional neural network (CNN) models—MobileNetV2, ResNet18, and EfficientNetB1—were selected for comparative analysis based on their architectural diversity, computational complexity, and prior success in vision-based tasks. These models represent different design philosophies: MobileNetV2 emphasizes lightweight design and efficiency, ResNet18 utilizes residual connections for deeper feature extraction, and EfficientNetB1 introduces compound scaling to balance model accuracy and complexity.

The dataset for this study comprises 6,330 images collected from a major real estate platform in Turkey, representing real user uploads. Each image was manually labeled as either "Good" or "Bad" based on clear criteria such as sharpness, lighting, absence of watermarks, and visual clarity. The "Good" class includes professionally appropriate photographs, while the "Bad" class includes blurry, poorly lit, overexposed, or logo-marked images. The dataset was split into training (4,446), validation (628), and testing (1,256) subsets. This manual labeling process was meticulously carried out by the author and real estate platform employees to ensure objectivity and reliability in model training.

Preprocessing steps included image resizing to 224x224 pixels and pixel normalization to the [0,1] range. Additionally, data augmentation techniques—such as random flipping, cropping, and brightness adjustments—were applied during training to enhance the model's generalization capability. However, experimental results showed marginal performance improvements with augmentation; hence, models were primarily trained without these enhancements for optimal efficiency.

A transfer learning strategy was adopted to leverage the pretrained knowledge embedded in ImageNet-based architectures. The convolutional base of each model was frozen, and only the classification head was fine-tuned on the custom real estate dataset. This approach significantly reduced training time and prevented overfitting, making it especially suitable for domain-specific tasks with moderate-sized datasets.

Performance evaluation was conducted using accuracy, precision, recall, F1-score, ROC-AUC, and confusion matrices. Among the three models, MobileNetV2 consistently outperformed its counterparts across multiple metrics. It achieved an accuracy of 89.17%, an AUC of 0.9435, a precision of 0.9424, a recall of 0.8344, and an F1-score of 0.8851. These results underscore MobileNetV2's capability to balance computational efficiency and classification performance, making it the most suitable model for real-time applications on listing platforms. The confusion matrix analysis revealed that MobileNetV2 had the lowest false positive and false negative rates, especially in identifying low-quality images.

On the other hand, ResNet18 demonstrated robust recall and moderately high precision but suffered from slightly lower accuracy and higher training time. EfficientNetB1, while maintaining good precision and F1-scores, exhibited lower recall in detecting poor-quality images. This suggests that while it is effective in identifying good images, it is less sensitive to problematic visual attributes.

The findings from this research provide concrete evidence that lightweight CNN architectures such as MobileNetV2 can be effectively integrated into the upload pipelines of real estate platforms. By embedding such models at the point of content submission, platforms can guide users in real-time to upload only acceptable quality visuals. This not only improves the aesthetic and informational quality of listings but also reduces the need for manual moderation. Moreover, maintaining consistent visual standards contributes to brand credibility and user trust, ultimately enhancing the platform's competitiveness in the market.

In practical deployment scenarios, a simplified variant of the best-performing model was developed to classify single image inputs as either "High Quality" or "Low Quality." This enables instant feedback to users, streamlining the content validation process and preventing the publication of substandard visuals.

Beyond the immediate benefits to listing platforms, the implementation of such an automated system also opens avenues for broader applications within the real estate industry. For example, quality assessment models can be integrated into agent-facing tools to help realtors curate their portfolios more effectively or to suggest optimal photo-taking practices. Additionally, these models can contribute to market analytics by enabling large-scale analysis of photo quality trends over time and across regions, offering insights into how visual presentation correlates with sales velocity and pricing strategies.

Furthermore, incorporating explainable AI techniques into the quality assessment pipeline represents an exciting direction for future research. By providing interpretable feedback—such as highlighting blurry areas or poorly lit regions—users can gain actionable insights into how to improve their photographs. This transparency fosters user trust and facilitates educational opportunities, encouraging users to adhere to best practices while also enhancing the model's acceptance and effectiveness within real-world workflows.

Future work could explore the inclusion of additional quality dimensions, such as composition, color harmony, or presence of human subjects, to refine classification granularity. Furthermore, expanding the dataset to include international listings and multilingual interfaces could enable cross-cultural model training, enhancing generalizability. Lastly, an end-to-end quality control framework combining deep learning with explainable AI techniques could help platform moderators understand model decisions and ensure transparency in automated evaluations.

In conclusion, this thesis demonstrates that real estate photo quality assessment can be reliably and efficiently automated using deep learning, specifically with MobileNetV2. The proposed approach offers a foundational step toward integrating AI-based visual quality control mechanisms into digital real estate ecosystems, promising enhanced user experience, operational efficiency, and market competitiveness.





1. GİRİŞ

1.1. Emlak İlanlarında Görsel Kalitenin Önemi

Günümüzde emlak sektöründe dijitalleşmenin hızla yaygınlaşmasıyla birlikte, potansiyel müşterilere ulaşmanın temel yollarından biri çevrim içi ilan platformları olmuştur. Bu platformlardaki görseller, kullanıcıların bir mülkle ilgili ilk izlenimlerini oluşturmalarında kritik bir rol oynamaktadır. Görsel kalitesinin, kullanıcı algısı ve emlak satış başarısı üzerindeki belirleyici rolü, son yıllarda yapılan derin öğrenme tabanlı çalışmalarla da desteklenmiştir [1].

Elde edilen bulgular, düşük kaliteli fotoğrafların (örneğin bulanık, aşırı karanlık veya ışık dengesizliği olan görseller) kullanıcıların ilana olan ilgisini azalttığını göstermektedir. Bu yalnızca kullanıcı etkileşimini değil, aynı zamanda satış başarısını da doğrudan etkilemektedir. Nase ve arkadaşlarının çalışmasında, kalite odaklı tasarım özelliklerinin emlak değerini artırdığı belirlenmiştir [2]. Yang ve Tian ise, görsel kalitesi yüksek olan ve yaşam alanlarını net şekilde gösteren ilan görsellerinin kullanıcıların güven algısını artırarak rezervasyon kararlarını olumlu yönde etkilediğini ortaya koymuştur [1]. Dolayısıyla, görsel kalite yalnızca kullanıcı deneyimini değil, aynı zamanda mülkün ticari değerine ve satış başarısına doğrudan etki eden çok boyutlu bir unsur hâline gelmiştir.

1.2. Literatür Araştırmaları

1.2.1. Görsel kalite değerlendirmesi çalışmaları

Literatürdeki pek çok çalışma, manuel görsel kalite kontrol süreçlerinin büyük ölçekli platformlar için sürdürülemez olduğunu ve otomatik sistemlerin geliştirilmesine duyulan ihtiyacı vurgulamaktadır. Son yıllarda yapay zekâ ve özellikle derin öğrenme (deep learning) teknikleri, görsel verilerin değerlendirilmesinde etkin araçlar hâline gelmiştir. Evrişimli sinir ağları (CNN), görsellerdeki karmaşık örüntüleri öğrenebilme kabiliyetiyle birçok görsel sınıflandırma probleminde başarılı sonuçlar ortaya koymuştur [3–5].

Mai çalışmasında, fotoğraf kalitesini değerlendirmek için derin öğrenme ve geleneksel görsel özellikler kullanarak, kullanıcıların bir fotoğrafı nasıl değerlendirdiğini tahmin etmek amacıyla regresyon yöntemini kullanmıştır [6]. Araştırma, fotoğraf kalitesini subjektif değerlendirmelerle ve istatistiksel verilerle modelleyerek, görsel estetik ve kaliteyi tahmin etmede yenilikçi bir yaklaşım sunmuştur. Çalışma, fotoğrafın kalite değerlendirmesini yalnızca düşük ya da yüksek kaliteyle sınıflandırmaktan daha öteye taşımış ve görsel kalite algısını kullanıcı gruplarına göre nasıl tahmin edebileceğimizi göstermiştir. Bununla birlikte, çalışmanın sınırlılıkları arasında, bazı fotoğraf türlerinin subjektif değerlendirilmesinin zor olduğu ve veri setinin sınırlı olması gibi unsurlar yer almaktadır. Bu tezde de benzer şekilde, görsel kalite üzerine yapılan diğer çalışmalarla kıyaslandığında, daha geniş kalite ölçütleri ve derinlemesine analizler kullanılacaktır.

Çakır ve Sofu, görsel kalite değerlendirmesi (IQA) alanında derin öğrenme tabanlı özellik çıkarımı yöntemini geliştirmiştir [7]. Çalışmada, geleneksel elle yapılmış özellik çıkarım teknikleri yerine, önceden eğitilmiş derin sinir ağları (DNN) kullanılarak otomatik özellik çıkarımı yapılmıştır. Bu yöntem, görsellerden özelliklerin çıkarılmasını ve bu özelliklerin subjektif puanlarla eşleştirilmesini amaçlamaktadır. Çalışma, derin öğrenme mimarilerinin genelleme kapasitesinden faydalanarak IQA problemini çözmekte başarılı sonuçlar elde etmiştir. Ancak, bu çalışma yalnızca özellik çıkarımı ve havuzlama aşamalarına odaklanırken, görsel algılama ve kullanıcı etkileşimi gibi subjektif faktörlere odaklanmamaktadır. Bu tezde ise, görsel kalite değerlendirmesinde hem teknik ölçütler hem de kullanıcı algısı gibi daha fazla kalite faktörü ele alınarak daha kapsamlı bir değerlendirme yapılacaktır.

Lin, Jin ve Yang çalışmasında, derin konvolüsyonel sinir ağları (CNN) kullanarak görsellerin sınıflandırılmasını daha etkili hale getirmek amacıyla bir çift sütunlu ağ yapısı önermiştir [8]. Bu yaklaşımda, her bir görselin yerel ve küresel temsilleri iki paralel sütunda işlenerek daha verimli sonuçlar elde edilmiştir. Çift sütunlu yapının her iki sütunu, görsel temsillerin daha ayrıntılı öğrenilmesi için tam bağlantılı katmanlar ile birleşmiştir. Çalışma, bu derin öğrenme yaklaşımının diğer geleneksel sınıflandırma yöntemlerine kıyasla daha yüksek doğruluk sağladığını göstermiştir. Ancak, çalışmanın sınırlılığı, yalnızca görsel özelliklerin teknik analizini yapması ve görsel algı ya da kullanıcı etkileşimi gibi subjektif faktörlere odaklanmamasıdır. Bu

tezde ise, görsel kaliteyi hem teknik hem de subjektif faktörleri birleştirerek ele alacak şekilde daha kapsamlı bir değerlendirme yapılacaktır.

Daryanavard Chouchenani ve arkadaşları, görsel estetik kalite değerlendirmesi (IAQA) alanında derin öğrenme yaklaşımlarını inceleyen kapsamlı bir literatür çalışması sunmuşlardır [9]. Çalışma, derin öğrenme tabanlı IAQA modellerini giriş, süreç ve çıktı aşamaları üzerinden üç ana fazda ele alır. Özellikle, görüntülerin estetik kalitesinin değerlendirilmesinde, giriş aşaması verinin seçiminden ve ön işleme adımlarından oluşmakta olup, burada hem genel hem de göreve özgü metodolojiler kullanılarak farklı veri setleri seçilmiştir. İşlem aşamasında, CNN mimarileri ve özellik çıkarımı yöntemleri gibi ağ yapıları tartışılmış, sonrasında çıktı aşaması ile estetik skorlaması ve dağılımlarına yönelik çeşitli metrikler ele alınmıştır. Ayrıca, araştırma çevresel faktörlerin estetik üzerine etkilerini de vurgulayarak, bu alandaki zorluklar ve gelecekteki araştırmalar için öneriler sunmuştur.

Liang ve Xue çalışmasında, derin öğrenme tabanlı özellik çıkarımı ve görüntü kalitesi değerlendirmesi üzerine önemli bir model geliştirmiştir [10]. Bu çalışmada, görüntü özellikleri, VGG16 ağ yapısı kullanılarak derin öğrenme yöntemiyle çıkarılmıştır ve bu özellikler, görsel algılama özellikleriyle birleştirilerek daha doğru kalite skorları elde edilmiştir. Görüntü sınıflandırma, geleneksel yöntemlere kıyasla önemli bir doğruluk artışı sağlanarak test edilmiştir. Ayrıca, görsel kalite değerlendirmesi için önerilen derin ve sığ özelliklerin birleşimi yöntemi, farklı bozulma türleriyle test edilerek, bu tür sistemlerin sağladığı iyileşme performanslarını ortaya koymuştur. Çalışma, görsel kalite değerlendirme süreçlerinde daha kapsamlı, daha doğru ve genelleştirilebilir sonuçlar elde edilmesine katkı sağlamaktadır.

Bouzerdoun, Havstad ve Beghdadi çalışmasında, görsel kalite değerlendirmesi için sinir ağları tabanlı bir yaklaşım önermiştir [11]. Bu çalışma, görsellerin ortalama görüş puanını (MOS) tahmin etmek için, derin öğrenme yöntemlerini kullanarak görsel özelliklerin çıkarılmasına odaklanmıştır. Çalışma, 352 JPEG ve JPEG2000 sıkıştırılmış görseli kullanarak, görsel kaliteyi öngörmede yapay sinir ağlarının yüksek doğruluk sağladığını göstermiştir. Ayrıca, araştırmada derin öğrenme ağları kullanılarak, görsellerin insan algısına yakın kalite ölçütleriyle değerlendirilmesi yapılmıştır. Bununla birlikte, çalışma yalnızca görüntülerin teknik özelliklerine odaklanırken, kullanıcı algısı ve görsel estetik gibi diğer faktörleri kapsamamaktadır.

Bu tezde ise, teknik ölçütlerle birlikte görsel algı da dikkate alınarak kapsamlı bir değerlendirme yapılacaktır.

Bianco ve arkadaşları, derin öğrenme tabanlı bir yöntemle görsel kalite değerlendirmesi yapmıştır [12]. Çalışmalarında, önceden eğitilmiş bir CNN'den çıkarılan özelliklerin görsel kalite ile ilişkilendirilmesi hedeflenmiştir. Yöntem, görüntülerin alt bölgelerindeki kaliteyi tahmin etmek için ortalama havuzlama yöntemi kullanarak çeşitli CNN yapılarını incelemiştir. DeepBIQ adı verilen bu yöntem, yapılan denemelerde, insan değerlendirmeleri ile yüksek uyum sağladığı ve mevcut yöntemleri geride bıraktığı gösterilmiştir. Bununla birlikte, bu çalışma sadece genel kalite değerlendirmesini değil, görsel bozulmaların etkilerini de hesaba katarak daha kapsamlı bir kalite tahmini yapılmasını sağlamıştır. Bu tezde ise, aynı zamanda kullanıcı algısı ve derin öğrenme yöntemleriyle kalite tespiti yapılarak daha sistematik bir değerlendirme yapılmaktadır.

Feng ve arkadaşları, karmaşık veri setlerini kullanarak, görsel kalite değerlendirmesi için monotonic bir yapay sinir ağı modeli geliştirmiştir [13]. Bu model, farklı veri setlerinin kalite anotasyonlarını uyumlu hale getirmek için kullanılmakta olup, her bir veri seti için görsel kaliteyi doğru şekilde tahmin etmek adına dataset-specific quality transformers kullanmaktadır. Model, derin öğrenme tabanlı özellik çıkarımını kullanarak görsellerin perseptüel kalitesini tahmin etmekte ve ardından, görsel kaliteyi görsel bozulma oranlarına göre sıralamaktadır. Sonuçlar, önerilen modelin, mevcut görsel kalite değerlendirmesi yöntemleri ile karşılaştırıldığında daha iyi performans sergilediğini göstermektedir. Çalışma, görsel kalite değerlendirmesi için veri seti çeşitliliğiyle çalışan derin öğrenme tabanlı bir yöntem geliştirilmesi gerektiğine dikkat çekmektedir. Bu tezde de benzer şekilde, görsel kaliteyi tahmin etmek için derin öğrenme yöntemlerine dayalı görsel analiz kullanılacaktır.

Li ve arkadaşları, derin konvolüsyonel sinir ağları (CNN) kullanarak görsel kalite değerlendirmesi yapmışlardır [14]. Çalışmalarında, görsel kaliteyi belirlemek amacıyla derin öğrenme tabanlı ağ yapıları kullanılmış ve görüntülerin kalite tahminlerini yaparken, CNN tabanlı özellik çıkarım teknikleri uygulanmıştır. Çalışma, farklı bozulma türleriyle görselleri test ederek, derin öğrenme yöntemlerinin, geleneksel yöntemlere kıyasla daha yüksek doğruluk sağladığını göstermektedir. Ayrıca, araştırma, görsel kaliteyi sınıflandırırken özellik çıkarımı ve havuzlama adımlarını kullanarak, bu tür sistemlerin sağladığı iyileşme performanslarını da

vurgulamaktadır. Bu tezde ise, aynı zamanda görsel kaliteyi değerlendirmek için derin öğrenme ile birlikte kullanıcı algısı gibi daha fazla faktör göz önünde bulundurulacaktır.

1.2.2. Emlak fotoğrafları üzerine yapılan çalışmalar

Kang ve arkadaşları, düşük kaliteli emlak fotoğraflarının sınıflandırılmasına yönelik derin öğrenme tabanlı bir yaklaşım geliştirmiştir [15]. Çalışmalarında, kullanıcılar tarafından yüklenen fotoğrafların kalite düzeylerini otomatik olarak belirlemek amacıyla özelleştirilmiş bir CNN mimarisi tasarlanmıştır. Bu yapı, görüntü netliği, parlaklık, kontrast gibi temel kalite ölçütlerine dayalı olarak eğitilmiş ve sınıflandırma başarısı %85'in üzerinde raporlanmıştır. Araştırmacılar, sistemin özellikle büyük ölçekli emlak platformlarında manuel moderasyon ihtiyacını azaltabileceğini vurgulamışlardır. Ancak model, transfer öğrenme yerine sıfırdan (from scratch) eğitilmiş olup, farklı mimari yapıların kıyaslanmasına yönelik bir analiz yapılmamıştır. Bu çalışmada ise farklı CNN mimarilerinin (MobileNetV2, ResNet18 ve EfficientNetB1) karşılaştırmalı olarak test edilmesiyle, hangi yapının emlak görsellerinde daha iyi performans sunduğu ortaya konmuştur. Ayrıca bu tez çalışmasında transfer öğrenme yaklaşımı kullanılarak modelin daha kısa sürede ve daha az veriyle yüksek doğrulukla öğrenmesi sağlanmıştır.

Kumari, Maan ve Dhiraj çalışmasında, emlak verilerindeki fotoğrafların doğru şekilde sınıflandırılabilmesi için derin öğrenme tabanlı bir yaklaşım kullanmışlardır [16]. Çalışmada, evin farklı bölümlerine ait fotoğrafların sınıflandırılabilmesi için CNN mimarisi kullanılmıştır. Bu sınıflandırma algoritması, fotoğrafların kalitesini iyileştirmek amacıyla kontrast sınırlı adaptif histogram eşitlemesi (CLAHE) ön işleme tekniği ile desteklenmiştir. Araştırma, kullanılan CNN tabanlı mimarinin geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları sağladığını ortaya koymuştur. Çalışmanın sınırlılığı, yalnızca görsel kaliteyi artırmaya yönelik kullanılan bir yöntemle sınırlı kalması ve kullanıcı etkileşimi ya da görsel algı gibi subjektif faktörlerin analiz edilmemesidir. Bu tezde ise, görsel kalite değerlendirmeleri yalnızca teknik ölçütlerle değil, aynı zamanda kullanıcı algısı gibi daha geniş ölçütlerle yapılacaktır.

Kiyota çalışmasında, derin öğrenme teknolojilerinin görsel kalite değerlendirmesi (IQA) üzerindeki etkisini incelemiştir [17]. Çalışmada, emlak fotoğraflarının derin öğrenme tabanlı sınıflandırılması kullanılarak, fotoğrafların kalite iyileştirme

sürecinde nasıl değerlendirilebileceği ele alınmıştır. Görsel işleme teknolojilerinin, derin öğrenme ile birleşerek, emlak fotoğraflarının sınıflandırma doğruluğunu artırması sağlanmıştır. Çalışmada ayrıca, floorplan (kat planı) görüntüleriyle birlikte görsel analiz yapılarak, görsel bilgilerin akademik topluluklara veri seti olarak sağlanması gerektiği vurgulanmıştır. Ancak çalışma, görsel algılama ve kullanıcı etkileşimi gibi subjektif faktörlere odaklanmamış ve yalnızca görsel işleme yöntemlerine dayanmıştır. Bu tezde ise, görsel kalite değerlendirmesi, yalnızca teknik faktörlerle değil, aynı zamanda kullanıcı algısı gibi daha kapsamlı faktörlerle birlikte ele alınacaktır.

Florea ve arkadaşları, emlak verilerindeki görsellerin otomatik analizini yaparak, bu verilerin geri getirilmesi ve sınıflandırılması süreçlerine katkı sağlamışlardır [18]. Çalışmalarında, görsel özellik çıkarımı kullanarak, emlak ilanlarında yer alan görsellerin cvasi-duplicate (yaklaşık kopya) olarak tanımlanan görüntülerini izole etme amacıyla özellik tabanlı analiz yöntemleri geliştirilmiştir. Görsel etiketleme ve görsel benzerlik ölçümü gibi konularda derin öğrenme tabanlı yöntemlerin etkinliğini değerlendirmiştir. Ayrıca, bu çalışmada emlak fotoğraflarının daha verimli bir şekilde sınıflandırılabilmesi için etiketleme ve görsel tanıma teknolojilerinin kullanılması gerektiği vurgulanmıştır. Bu tezde de benzer şekilde, görsel analiz ve görsel benzerlik tespiti konularında derin öğrenme yöntemlerinin kullanımı ele alınacaktır.

Literatürde incelenen çalışmaların büyük çoğunluğunda kullanılan veri kümelerine ilişkin detaylı bilgi verilmediği görülmektedir. Sadece Bouzerdoum ve arkadaşları [11] çalışmasında, 352 adet JPEG/JPEG2000 formatında görselin kullanıldığı açıkça belirtilmiştir. Ayrıca Kang ve arkadaşları [15] çalışmasında ise, kullanıcılar tarafından yüklenen emlak fotoğraflarının kullanıldığı ifade edilmiştir. Diğer çalışmalarda ise veri kümesi bilgisi ya hiç verilmemiş ya da “kendi derlenen görseller” veya “çeşitli karmaşık veri setleri” gibi genel ifadelerle geçilmiştir. Bu durum, çalışmaların yöntemlerinin karşılaştırılabilirliğini kısıtlamakta ve sonuçların genellenebilirliği üzerinde belirsizlik yaratmaktadır. Literatür araştırmaları bu çerçevede değerlendirildiğinde, çalışmamızın özgünlüğü ve katkısı daha açık bir şekilde ortaya konmaktadır.

1.3. Çalışmanın Amacı ve Katkısı

Bu tez çalışmasının temel amacı, emlak ilan platformlarına yüklenen görsellerin kalitesini derin öğrenme modelleri aracılığıyla değerlendirmek ve düşük kaliteli görsellerin otomatik olarak ayıklanmasını sağlayacak bir sınıflandırma sistemi geliştirmektir. Bu doğrultuda, yaygın kullanımı ve mimari çeşitliliği ile bilinen MobileNetV2 [3], ResNet18 [4] ve EfficientNetB1 [5] mimarileri seçilerek detaylı bir karşılaştırmalı analiz gerçekleştirilmiştir. Modeller, aynı veri seti üzerinde eğitilmiş ve çeşitli performans metrikleri kullanılarak değerlendirilmiştir.

Çalışmada kullanılan veri seti, Türkiye'deki büyük bir emlak ilan platformundan toplanmış ve gerçek kullanıcılar tarafından yüklenen 6.330 emlak görselinden oluşmaktadır. Görseller, kalite kriterleri doğrultusunda manuel olarak etiketlenmiş ve bu yönüyle çalışmaya özgünlük kazandırılmıştır. Literatürde görsel kalite değerlendirmesi üzerine yapılan çalışmalar genellikle genel görüntü estetiğine odaklanırken, bu çalışmada emlak bağlamına özgü bir uygulama gerçekleştirilmiştir. Ayrıca, elde edilen en başarılı modelin sadeleştirilmiş bir versiyonu geliştirilerek, sistemin gerçek zamanlı uygulamalara entegrasyonu test edilmiştir.

MobileNetV2 modeli, düşük hesaplama maliyeti ve hafif yapısı sayesinde mobil sistemlere entegre edilebilirliği ile öne çıkarken; ResNet18, derin yapısı sayesinde karmaşık görsel örüntüleri başarılı şekilde öğrenebilmesiyle tercih edilmiştir. EfficientNetB1 ise doğruluk ve verimlilik arasında optimal denge kurması nedeniyle çalışmaya dahil edilmiştir.

Tüm bu yönleriyle çalışma, hem akademik hem de sektörel açıdan katkı sunmayı hedeflemekte; gerçek veri seti, derin öğrenme temelli değerlendirme süreci ve uygulamaya dönük model önerisiyle literatürdeki benzer çalışmalardan ayrılmaktadır.

Takip eden bölümlerde veri setinin yapısı, modellerin eğitimi, deneysel süreç ve elde edilen sonuçlar detaylı olarak sunulacaktır



2. YÖNTEM

2.1. Veri Seti

Bu çalışmada kullanılan veri seti, Türkiye’de aktif olarak faaliyet gösteren, yüksek hacimli bir emlak ilan platformundan toplanmıştır. Veri kümesi, platform kullanıcıları tarafından sisteme yüklenen toplam 6.330 adet emlak fotoğrafından oluşmaktadır. Fotoğraflar, herhangi bir ön filtreleme uygulanmaksızın rastgele seçilerek alınmış, bu sayede saha koşullarındaki gerçek kullanıcı davranışları doğrudan yansıtılmıştır.

Veri seti, ilgili emlak platformundan gerekli izinler alınarak elde edilmiştir. Çalışmada yer alan veriler, kullanıcılar tarafından paylaşılan ancak kişisel bilgi içermeyen görsellerden oluşmaktadır. Bu veriler yalnızca bu çalışmada model eğitimi ve performans değerlendirme sürecinde kullanılmış olup, görseller doğrudan hiçbir şekilde çalışma kapsamında paylaşılmamıştır.

Veri setindeki tüm görseller kalite düzeyine göre manuel olarak etiketlenmiş ve iki ana kategoriye ayrılmıştır: “Good” (İyi) ve “Bad” (Kötü). Değerlendirme sürecinde görüntü netliği, ışık dengesi, çözünürlük seviyesi ve dikkat dağıtıcı unsurların (örneğin watermark, logo veya yazı gibi) varlığı gibi ölçütler dikkate alınmıştır.

“Good” sınıfında yer alan fotoğraflar net, dengeli ışıklandırılmış ve profesyonel görünüm taşıyan görselleri içerirken; “Bad” kategorisindeki görseller genellikle bulanık, aşırı karanlık ya da aydınlık, düşük çözünürlüklü veya üzerinde dikkat dağıtan logolar ve yazılar barındıran örneklerden oluşmaktadır.

Etiketleme işlemi, araştırmacı ve emlak platformu çalışanlarının katkılarıyla yapılmış olup, değerlendirmelerin öznel olma riski en aza indirgenmiştir. Gelecekteki çalışmalarda, daha fazla etiketleyici katılımcı ile etiketleme sürecinin çeşitlendirilmesi veya oy çokluğuna dayalı sistemlerin kullanılması önerilmektedir. Sınıf bazlı örnek dağılım Tablo 2.1’de sunulmuştur.

Tablo 2.1. Veri setinin sınıf dağılımı.

Sınıf	Tanım	Görüntü Sayısı
Good	Net, ışık dengesi sağlanmış, watermark veya logo içermeyen görseller	3165
Bad	Bulanık, aşırı karanlık veya aydınlık, watermark veya logo içeren görseller	3165

Veri seti, modelin performansını değerlendirmek amacıyla eğitim, doğrulama ve test olmak üzere üç alt kümeye ayrılmıştır. Bu ayrım yapılırken, literatürde yaygın olarak kullanılan %70 eğitim, %10 doğrulama ve %20 test oranlarına yakın bir dağılım tercih edilmiştir. Bu kümelere ilişkin sayısal dağılım Tablo 2.2’de sunulmaktadır.

Tablo 2.2. Veri setinin küme dağılımı.

Bölüm	Görüntü Sayısı	Yüzdelik Dağılım (%)
Eğitim	4.446	70%
Doğrulama	628	10%
Test	1256	20%

Eğitim kümesi, modelin temel örüntüleri öğrenmesi için kullanılırken; doğrulama kümesi, hiperparametre optimizasyonu ve aşırı öğrenme risklerinin kontrolü amacıyla kullanılmıştır. Test kümesi ise eğitim sürecinden tamamen bağımsız tutularak, modelin gerçek dünya verileri üzerindeki genellenebilir başarısını değerlendirmek için ayrılmıştır.

Bu yapının sağladığı kontrollü ayrım sayesinde, modelin hem öğrenme sürecindeki gelişimi hem de dış veri üzerindeki performansı ayrı ayrı izlenebilmekte, böylece geliştirilen sistemin güvenilirliği daha sistematik şekilde ölçülebilmektedir.

Veri setinin manuel olarak etiketlenmiş olması, etiketleme kriterlerinin istikrarlı biçimde uygulanmasına olanak sağlamıştır. Etiketleme sürecinde kullanılan kalite ölçütlerinin önceden tanımlanması ve tutarlı bir şekilde uygulanması, veri bütünlüğünü destekleyen önemli bir etkidir. Sürecin araştırmacı ve emlak platformu

alıřanları tarafından yrtlmesi, deęerlendirmelerin znel risklerini minimize etmiřtir. Belirlenen kriterlerin sistematik olarak takip edilmesi, sınıflandırma doęruluęunu desteklemiř ve model eęitimi iin gvenilir bir temel oluřturmuřtur.

Veri setindeki grsellerin sınıflandırma kriterlerini daha iyi aıklayabilmek amacıyla, “Good” ve “Bad” sınıflarına benzer zellikler tařıyan temsili rnekler řekil 2.1’de sunulmuřtur. Sol tarafta yer alan grseller; netlik, dengeli ıřıklandırma ve temiz ierik gibi zellikleriyle “Good” sınıfının karakteristiklerini yansıtırken, saę taraftaki rnekler ise bulanıklık, ıřık sorunu veya dikkat daęıtıcı unsurlar gibi niteliklerle “Bad” sınıfının genel zelliklerini temsil etmektedir.

Bu grseller, sınıflandırma ltlerinin kavramsal olarak anlařılmasını desteklemek amacıyla kullanılmıř olup, veri setinden alınmamıřtır.



řekil 2.1. Veri seti rnek grntleri.

2.2. Veri n İřleme

alıřmada kullanılan emlak grselleri, derin ęrenme modellerinin giriř boyutlarına uygun hale getirilerek iřlenmiřtir. İlk olarak tm grseller, eęitimde kullanılan mimarilerle uyumlu olacak řekilde 224x224 piksel boyutuna yeniden leklendirilmiřtir. Ardından, piksel deęerleri 0 ile 255 aralıęından [0,1] aralıęına normalize edilerek modelin ęrenme srecine katkı saęlayacak biimde dnřtrlmřtir. Bu tr grnt boyutlandırma ve normalizasyon iřlemleri, derin ęrenme tabanlı grsel kalite sınıflandırmalarında yaygın olarak kullanılmakta olup, model performansını artıran temel n iřleme adımlarındandır [19].

Modelin genelleme yeteneğini artırmak ve aşırı öğrenme (overfitting) riskini azaltmak amacıyla, eğitim aşamasında çeşitli veri artırma (data augmentation) teknikleri uygulanmıştır. Bu kapsamda kullanılan yöntemler arasında rastgele döndürme, parlaklık düzeyinin değiştirilmesi, kırpma (cropping) ve yatay aynalama (horizontal flipping) gibi yaygın yaklaşımlar yer almaktadır.

Ancak gerçekleştirilen deneysel gözlemler, bu tekniklerin test veri seti üzerindeki model başarımına anlamlı bir katkı sağlamadığını ortaya koymuştur. Veri artırma işlemi modelin eğitim sırasında daha çeşitli örneklerle karşılaşmasına neden olmuşsa da, test aşamasındaki doğruluk, AUC ve kayıp (loss) değerlerinde kayda değer bir iyileşme gözlenmemiştir. Bu sonuçlar, veri setinin zaten doğal olarak yeterince çeşitli olması ve kullanılan derin öğrenme modellerinin belirli türdeki dönüşümlere karşı duyarsız kalabilmesi gibi olasılıklarla açıklanabilir. Ayrıca, veri artırma uygulandığında eğitim sürecinin uzadığı ve hesaplama maliyetinin arttığı da gözlemlenmiştir.

Aşağıda sunulan Tablo 2.3, veri artırma tekniklerinin uygulanıp uygulanmaması durumunda modellerin test veri seti üzerindeki performans karşılaştırmalarını içermektedir. MobileNetV2, ResNet18 ve EfficientNetB1 mimarileri için doğruluk (%), AUC ve kayıp (loss) değerleri ayrı ayrı raporlanmıştır.

Tablo 2.3. Veri artırmanın test verisi üzerindeki model performansına etkisi.

Model	Veri Artırma Uygulanmadı			Veri Artırma Uygulandı		
	Doğruluk (%)	AUC	Kayıp (Loss)	Doğruluk (%)	AUC	Kayıp (Loss)
MobileNetV2	89.17	0.9435	0.2720	89.33	0.9427	0.2702
ResNet18	85.90	0.9271	0.3356	86.14	0.9290	0.3325
EfficientNetB1	86.38	0.9206	0.3373	86.06	0.9199	0.3342

Tablo, veri artırmanın bazı modellerde küçük değişiklikler yarattığını gösterse de, genel anlamda test performansında anlamlı bir iyileşme sağlamadığını ve eğitim süresine ek yük getirdiğini ortaya koymaktadır. Bu nedenle, performansa olumlu bir katkı sunmadığı tespit edilen veri artırma teknikleri eğitim sürecinden çıkarılmıştır.

2.3. Kullanılan Modeller

Bu çalışmada, emlak ilanlarında kullanılan görsellerin kalite düzeyini belirleyebilmek amacıyla üç farklı derin öğrenme tabanlı mimari tercih edilmiştir: MobileNetV2, ResNet18 ve EfficientNetB1. Bu modellerin seçilme gerekçesi; farklı mimari yapılar, parametre boyutları ve hesaplama gereksinimleri açısından çeşitlilik sunmalarıdır. Tablo 2.4'te bu mimarilerin temel özellikleri ve sağladığı avantajlar özetlenmiştir.

Tablo 2.4. Kullanılan derin öğrenme modelleri.

Model	Özellikleri	Avantajları
MobileNetV2	Hafif yapı, düşük parametre sayısı	Mobil ve düşük güç gerektiren uygulamalara uygun
ResNet18	Derin ağ yapısı, daha yüksek parametre sayısı	Karmaşık desenleri tanıma başarısı yüksek
EfficientNetB1	Model boyutu ile doğruluk arasında en iyi denge	Daha düşük hesaplama maliyeti ile yüksek doğruluk

MobileNetV2, düşük parametre sayısı ve hafif yapısıyla özellikle mobil ve gömülü sistemlerde tercih edilen mimariler arasında yer almaktadır [3]. Bu model, sınırlı donanım kaynaklarında yüksek hız ve yeterli doğruluk sağlaması nedeniyle bu çalışmada değerlendirilmiştir. Mimarisi, standart konvolüsyonların yerine daha az hesaplama gerektiren derin ayrılabilir konvolüsyonlar ve ters artık bloklar üzerine kuruludur. Bu yapı, hem parametre sayısını düşürür hem de doğruluk kaybını en aza indirir.

ResNet18, daha derin katman yapısına sahip olması sayesinde görsellerdeki karmaşık örüntüleri tanımada etkin bir performans sunmaktadır [4]. Art arda gelen katmanlarda bilgi kaybını azaltan ve öğrenmeyi kolaylaştıran artık bağlantı (atlama bağlantısı) yapısı sayesinde yüksek doğruluk oranlarına ulaşabilmektedir. Bu mimari, daha derin ağlarda ortaya çıkan kaybolan gradyan (vanishing gradient) problemini çözmek amacıyla geliştirilmiştir.

EfficientNetB1, parametrik verimlilik açısından öne çıkan bir mimaridir. Model boyutu, işlem süresi ve doğruluk oranı arasında en iyi dengeyi kurmayı amaçlar [5]. Bunu, genişlik, derinlik ve çözünürlük boyutlarında eşzamanlı olarak ölçekleme yapan

birleşik ölçekleme stratejisi ile gerçekleştirir. Ayrıca, mimarisinde yer alan sıkıştırma ve uyarma blokları sayesinde daha iyi özellik haritaları öğrenir ve daha az parametreyle yüksek doğruluk sağlar.

Bu üç model, eğitim süreçlerinde aynı veri seti ve parametre yapısıyla eğitilerek karşılaştırmalı şekilde değerlendirilmiştir. Elde edilen sonuçlar, bölüm 3'te detaylı biçimde sunulmaktadır.

2.4. Model Eğitimi

Bu çalışmada kullanılan tüm derin öğrenme modelleri, aynı hiperparametre ayarları altında eğitilmiştir. Böylece modeller arasında adil ve karşılaştırılabilir bir değerlendirme yapılması amaçlanmıştır. Aşağıda sunulan Tablo 2.5, eğitim sürecinde kullanılan ortak hiperparametreleri özetlemektedir.

Tablo 2.5. Model eğitimi sırasında kullanılan ortak hiperparametreler.

Parametre	Değer
Optimizasyon Algoritması	Adam
Öğrenme Oranı	0.0001
Batch Size	64
Epoch Sayısı	50
Kayıp Fonksiyonu	Binary Cross-Entropy


Model eğitimi sırasında doğruluk (accuracy) ve kayıp (loss) metrikleri epok bazında sürekli olarak izlenmiş ve erken durdurma (early stopping) tekniği uygulanmıştır. Bu yaklaşım, modelin eğitim verisine aşırı uyum göstermesini (aşırı öğrenme / overfitting) önlemek amacıyla tercih edilmiştir.

Erken durdurma mekanizması doğrulama verisinde iyileşme gözlemlenmediği durumlarda modelin eğitiminin otomatik olarak sonlandırılmasını sağlayarak, gereksiz hesaplama maliyetini azaltır ve genelleme performansını korur.


Eğitim sürecinde MobileNetV2 modeli, diğer mimarilere kıyasla daha hızlı bir öğrenme eğrisi göstermiştir. Bu modelde doğruluk değeri erken epoklarda hızla

yükselmiş ve doğrulama kaybı sabitlenmeye başladığında 14. epokta eğitim durdurulmuştur.

Aşağıda sunulan Şekil 2.2 ve Şekil 2.3, her bir modelin eğitim süreci boyunca doğruluk (accuracy) ve kayıp (loss) değerlerinin epok bazında değişimini göstermektedir.



Şekil 2.2. Eğitim doğruluğu karşılaştırması.



Şekil 2.3. Eğitim kayıp karşılaştırması.

Şekil 2.2 incelendiğinde, MobileNetV2 modelinin erken epoklardan itibaren daha hızlı bir doğruluk artışı gösterdiği ve 10. epok sonrasında nispeten sabit bir eğri çizdiği

gözlemlenmektedir. ResNet18 ve EfficientNetB1 modelleri ise doğruluk değerlerini daha kademeli olarak artırmıştır. Şekil 2.3'te ise MobileNetV2'nin eğitim kaybının daha hızlı düştüğü ve süreç boyunca daha düşük seviyelerde seyrettiği görülmektedir. Diğer modellerde ise kayıp değerlerinin daha yavaş azaldığı ve belirli epoklarda dalgalanmalar gösterdiği dikkat çekmektedir. Bu grafikler, her modelin eğitim verisi üzerindeki öğrenme dinamiklerini görsel olarak karşılaştırma imkânı sunmaktadır.

2.5. Değerlendirme Metrikleri

Derin öğrenme modellerinin sınıflandırma başarısını yalnızca genel doğruluk oranıyla değerlendirmek, özellikle dengesiz ya da farklı sınıflar arasında önemli ayrımlar olan veri kümelerinde yetersiz kalabilmektedir. Bu nedenle, her bir modelin performansını daha ayrıntılı bir biçimde değerlendirebilmek adına çeşitli metrikler kullanılmıştır.

Bu bölümde, çalışmada kullanılan değerlendirme metrikleri kısa ve anlaşılır biçimde açıklanmıştır. Her bir metriğin neyi ölçtüğü, nasıl yorumlandığı ve model değerlendirmesindeki önemi özgün ifadelerle sunulmuştur. Böylece ilerleyen bölümlerde yapılacak karşılaştırmalar için kavramsal bir temel oluşturulması hedeflenmiştir.

2.5.1. Doğruluk (accuracy)

Doğruluk, modelin sınıflandırma görevindeki genel başarısını yüzdesel olarak ifade eden temel ölçütlerden biridir. Modelin doğru tahmin ettiği tüm örneklerin, toplam örnek sayısına oranı olarak hesaplanır. Her ne kadar sık kullanılsa da, sınıflar arasında dengesizlik olması durumunda tek başına yeterli bilgi sunamayabilir.

$$\text{Doğruluk} = ((TP + TN)) / (TP + TN + FP + FN) \quad (2.1)$$

Denklem 2.1'de kullanılan terimler şunlardır: TP (True Positive), modelin pozitif bir örneği doğru şekilde pozitif olarak tahmin ettiği durumlardır. TN (True Negative), negatif bir örneğin doğru biçimde negatif olarak tahmin edilmesini ifade eder. FP (False Positive), negatif bir örneğin yanlışlıkla pozitif olarak sınıflandırılması; FN (False Negative) ise pozitif bir örneğin hatalı biçimde negatif olarak sınıflandırılması durumudur. Doğruluk, bu dört temel değeri kullanarak, modelin toplamda ne kadar doğru tahmin yaptığını gösterir ve en yaygın kullanılan performans göstergelerinden biridir.

2.5.2. Kesinlik (precision)

Kesinlik, modelin pozitif sınıf olarak tahmin ettiği örnekler içerisinde gerçekten pozitif olanların oranını ifade eder. Bu metrik, özellikle modelin hatalı pozitif tahminlerinin (false positive) ne ölçüde sınırlı tutulduğunu değerlendirmek açısından önemlidir. Pozitif sınıfın hedeflenmesi gereken durumlarda, yüksek kesinlik modeli güvenilir kılar.

$$Kesinlik = TP / TP + FP \quad (2.2)$$

Denklem 2.2’de kullanılan TP (True Positive), modelin doğru şekilde pozitif olarak tahmin ettiği örnek sayısını; FP (False Positive) ise negatif bir örneğin yanlışlıkla pozitif olarak sınıflandırılmasını ifade eder. Kesinlik, modelin pozitif tahminlerinde ne kadar güvenilir olduğunu ortaya koyar. Bu çalışmada, kesinlik metriği test aşamasında analiz edilmiş ve modellerin yanlış pozitif üretme eğilimlerini karşılaştırmak için kullanılmıştır.

2.5.3. Geri çağırma (recall)

Geri çağırma, pozitif sınıfa ait gerçek örneklerin model tarafından ne oranda doğru şekilde tahmin edilebildiğini gösterir. Yanlış negatiflerin (false negative) sayısını minimize etmek hedeflendiğinde geri çağırma öne çıkan bir başarı ölçütü hâline gelir. Pozitif sınıfın kapsamlı şekilde yakalanması bu metriğin güçlü olmasını gerektirir.

$$Geri \text{ Çağırma} = TP / TP + FN \quad (2.3)$$

Denklem 2.3’te yer alan TP (True Positive), modelin doğru şekilde pozitif olarak sınıflandırdığı örnek sayısını; FN (False Negative) ise pozitif olan fakat model tarafından yanlışlıkla negatif tahmin edilen örnekleri ifade eder. Geri çağırma, modelin gerçekten pozitif olan verileri ne ölçüde doğru ve eksiksiz yakalayabildiğini gösterir. Yüksek geri çağırma değeri, modelin pozitif örnekleri gözden kaçırma olasılığının düşük olduğunu ve kapsayıcılığının güçlü olduğunu ortaya koyar.

2.5.4. F1 skoru

F1 skoru, kesinlik ve geri çağırma metriklerini ortak bir ölçü altında birleştiren dengeli bir başarı ölçütüdür. Bu iki değer harmonik ortalaması olarak hesaplanır. Modelin hem isabetli hem de kapsamlı sonuçlar üretmesi gereken durumlarda doğruluktan daha gerçekçi bir performans göstergesi olabilir.

$$F1 - Skor = 2.TP / (2.TP + FP + FN) \quad (2.4)$$

Denklem 2.4'te yer alan TP (True Positive), modelin doğru şekilde pozitif olarak sınıflandırdığı örnekleri; FP (False Positive), negatif olduğu halde yanlışlıkla pozitif tahmin edilenleri; FN (False Negative) ise pozitif olduğu halde yanlışlıkla negatif olarak sınıflandırılan örnekleri ifade eder. F1 skoru, kesinlik ve geri çağırma değerlerini birlikte değerlendirerek modelin hem isabetli hem de kapsayıcı sonuç üretme yeteneğini yansıtır. Bu çalışmada, geliştirilen derin öğrenme modellerinin sınıflandırma performansı yalnızca doğruluk oranına göre değil, F1 skoru ile de analiz edilmiş ve modellerin genel dengesini değerlendirmek için kullanılmıştır.

2.5.5. ROC eğrisi ve AUC

ROC (Receiver Operating Characteristic) eğrisi, modelin farklı eşik değerleri altındaki duyarlılık (true positive rate) ve yanlış pozitif oranı (false positive rate) arasındaki ilişkiyi görselleştirir. Eğri altında kalan alan olan AUC (Area Under Curve), modelin genel sınıflandırma başarısını özetleyen güçlü bir metriktir. AUC değeri 1'e yaklaştıkça modelin sınıflar arası ayrım yapabilme yeteneği artmaktadır.

3. BULGULAR VE DEĞERLENDİRME

3.1. Deneysel Sonuçlar

Bu çalışmada, emlak ilanlarında kullanılan görsellerin kalite düzeylerini otomatik olarak sınıflandırmak amacıyla üç farklı derin öğrenme modeli (MobileNetV2, ResNet18 ve EfficientNetB1) kullanılarak deneysel analizler gerçekleştirilmiştir. Modellerin performansları; eğitim, doğrulama ve test veri kümeleri üzerinde çeşitli değerlendirme metrikleri aracılığıyla ölçülmüştür. Uygulanan başlıca performans göstergeleri doğruluk (accuracy), kesinlik (precision), geri çağırma (recall), F1 skoru ve ROC eğrisi altında toplanmıştır.

Deneylerin temel amacı, bu modeller arasından en yüksek doğruluk ve genelleme başarısına sahip olanı belirleyerek, gerçek dünyadaki uygulamalara entegre edilebilecek bir yapı ortaya koymaktır. Bu doğrultuda, en başarılı model kullanılarak, görsellerin "Yüksek Kalite" veya "Düşük Kalite" olarak anında sınıflandırılabilirdiği bir varyasyon geliştirilmiştir. Bu sistem sayesinde, bir emlak ilan platformunda kullanıcılar görsel yüklerken anlık kalite analizi yapılarak düşük kaliteli görsellerin önlenmesi hedeflenmiş; böylece kullanıcı deneyimi ve platform güvenilirliğinin artırılması amaçlanmıştır.

3.2. Modellerin Performans Metrikleri

Modellerin test veri seti üzerindeki performanslarına ilişkin temel metrikler, aşağıdaki Tablo 3.1'de özetlenmiştir. Değerlendirme sırasında doğruluk (accuracy), eğri altı alan (AUC), kesinlik (precision), geri çağırma (recall) ve F1 skoru olmak üzere beş farklı ölçüt kullanılmıştır. Tüm değerlendirmeler, 0.5 eşik değeri baz alınarak gerçekleştirilmiştir.

Tablo 3.1. Modellerin test verisi üzerindeki performans metrikleri

Model	Doğruluk (%)	AUC	Precision	Recall	F1 Skoru
MobileNetV2	89.17	0.9435	0.9424	0.8344	0.8851
ResNet18	85.90	0.9271	0.9020	0.8057	0.8511
EfficientNetB1	86.38	0.9206	0.9271	0.7898	0.8530


Tablo 3.1’de sunulan performans çıktıları incelendiğinde, MobileNetV2 modelinin %89.17 doğruluk oranı ve 0.9435 AUC skoru ile diğer modellere kıyasla yüksek bir başarı sergilediği gözlemlenmektedir. Bununla birlikte, ResNet18 modeli %85.90 doğruluk ve 0.9271 AUC skoru ile tatmin edici bir performans ortaya koyarken, EfficientNetB1 modeli %86.38 doğruluk oranına ve 0.9206 AUC değerine ulaşmıştır. Modellerin Precision ve Recall değerleri karşılaştırıldığında ise MobileNetV2 modelinin yüksek precision (0.9424) ve dengeli recall (0.8344) skorları ile dikkat çektiği, diğer modellerin ise belirli metriklerde daha düşük oranlar sunduğu görülmektedir. Ancak, modellerin genel başarılarının kesin bir şekilde değerlendirilebilmesi için, ilerleyen bölümlerde ROC eğrileri ve karmaşıklık matrisleri gibi ek analizler yapılacak ve bu bulgular bütüncül bir şekilde yorumlanacaktır.

3.3. ROC Eğrisi ve AUC Analizi

ROC eğrileri, modellerin sınıflandırma performansını farklı eşik değerleri üzerinden değerlendirmek için kullanılmıştır. AUC (Area Under the Curve) skorları, modellerin genel ayırt edici yeteneklerini sayısal olarak ifade etmektedir. Bu bölümde her bir model için ROC eğrisi ayrı ayrı sunulurken, performansları ayrıntılı şekilde analiz edilmiştir.

3.3.1. MobileNetV2 Roc Eğrisi

Aşağıdaki Şekil 3.1'de MobileNetV2 modelinin ROC eğrisi gösterilmektedir.




Şekil 3.1. MobileNetV2 ROC eğrisi grafiği.

MobileNetV2 modeli, AUC değeri 0.9435 ile diğer modellere kıyasla en yüksek ayırt etme başarısını sergilemiştir. ROC eğrisi neredeyse üst köşeye yakın seyretmekte olup, bu durum modelin hem düşük yanlış pozitif oranına hem de yüksek doğru pozitif oranına sahip olduğunu göstermektedir. Elde edilen bu sonuç, MobileNetV2'nin emlak ilanları görsellerinin kalitesini yüksek doğrulukla ayırt edebildiğini ortaya koymaktadır.

3.3.2. ResNet18 Roc Eğrisi

Aşağıdaki Şekil 3.2'de ResNet18 modelinin ROC eğrisi sunulmaktadır.




Şekil 3.2. ResNet18 ROC eğrisi grafiği.

ResNet18 modeli, AUC değeri 0.9271 ile MobileNetV2'nin ardından ikinci sırada yer almıştır. ROC eğrisi, doğru sınıflandırma oranının genel olarak yüksek olduğunu, ancak MobileNetV2'ye kıyasla biraz daha fazla yanlış pozitif ürettiğini göstermektedir. Bu durum, ResNet18'in sınıflandırma performansında güçlü olmakla birlikte, MobileNetV2 kadar hassas bir ayırt edicilik sunamadığını göstermektedir.

3.3.3. EfficientNetB1 Roc Eğrisi

Aşağıdaki Şekil 3.3'te EfficientNetB1 modeline ait ROC eğrisi verilmiştir.



Şekil 3.3. EfficientNetB1 ROC eğrisi grafiği.


EfficientNetB1 modeli, AUC değeri 0.9206 ile ResNet18'in hemen arkasında yer almıştır. ROC eğrisinde doğru pozitif oranı yüksek olmasına karşın, düşük eşik değerlerinde yanlış sınıflandırma oranı nispeten artmıştır. Bu sonuç, modelin genel performansının güçlü olduğunu ancak sınıflandırmada MobileNetV2 kadar dengeli bir başarı sunamadığını göstermektedir.

3.4. Tahmin Dağılımı Analizi

Bu bölümde, her bir modelin test veri seti üzerinde yaptığı tahminlerin dağılımı incelenmiştir. Tahmin dağılım grafikleri, modelin tahmin ettiği olasılık değerlerinin hangi aralıklarda yoğunlaştığını göstererek sınıflandırma performansının daha derinlemesine analiz edilmesine olanak tanımaktadır. Bu grafikler aynı zamanda karar eşiklerinin belirlenmesi için önemli bir referans sağlamaktadır. Grafiklerde x-ekseni tahmin olasılıklarını, y-ekseni ise bu olasılıkta kaç görselin tahmin edildiğini göstermektedir.

Aşağıdaki Şekil 3.4'de, MobileNetV2, ResNet18 ve EfficientNetB1 modellerinin test veri seti üzerindeki tahmin dağılımı histogramları gösterilmektedir. Grafiklerde "0" değeri, modelin

görseli "Bad" (düşük kaliteli) sınıfına; "1" değeri ise "Good" (yüksek kaliteli) sınıfına atadığını temsil etmektedir.




Şekil 3.4. Modellerin test veri seti üzerindeki tahmin dağılımları.

Histogramlar incelendiğinde, her üç modelde de tahminlerin büyük çoğunluğunun 0 (Bad) ve 1 (Good) uçlarında yoğunlaştığı gözlemlenmiştir. Bu durum, modellerin çoğu örnekte net sınıflandırma yapabildiğini ve karar vermede yüksek güven sergilediğini göstermektedir. Ayrıca, tahminlerin 0.5 civarında çok az yoğunluk göstermesi, modellerin kararsız tahminlerden kaçındığını ve öğrenme sürecinde etkili bir ayırım kabiliyeti geliştirdiğini ortaya koymaktadır.


Bu analiz, eşik değeri belirlenirken modellerin genel eğilimini ve güven seviyesini anlamaya katkı sağlamaktadır. Tahminlerin uç değerlere (0 veya 1) yoğunlaşması, kullanılan 0.5 eşik değerinin optimal olduğunu desteklemektedir.

3.5. Karmaşıklık Matrisi Analizi


Aşağıdaki Şekil 3.5, Şekil 3.6 ve Şekil 3.7’de, sırasıyla modellerin test veri setindeki gerçek ve tahmin edilen değerlerini içeren karmaşıklık matrisleri gösterilmiştir.



Şekil 3.5 MobileNetV2 karmaşıklık matrisi.



Şekil 3.6 ResNet18 karmaşıklık matrisi.



Şekil 3.7 EfficientNetB1 karmaşıklık matrisi.

Karmaşıklık matrisleri incelendiğinde, MobileNetV2 modelinin hem iyi (Good) hem de kötü (Bad) kalitedeki fotoğrafları doğru sınıflandırmada diğer modellere göre daha başarılı olduğu gözlemlenmiştir. MobileNetV2 modeli, "Good" sınıfında 628 fotoğraftan 596 tanesini doğru sınıflandırmış ve yalnızca 32 hata yapmıştır. "Bad" sınıfında ise 628 fotoğraftan 524 tanesini doğru sınıflandırırken 104 yanlış sınıflandırma gerçekleştirmiştir. ResNet18 modeli, MobileNetV2'ye kıyasla biraz daha yüksek hata oranıyla toplamda daha fazla yanlış sınıflandırma yapmıştır. EfficientNetB1 ise özellikle "Bad" sınıfındaki doğru tahmin sayısının düşük olması nedeniyle diğer iki modelin gerisinde kalmıştır. Bu sonuçlar, MobileNetV2'nin hem düşük kaliteli hem de yüksek kaliteli görselleri ayırt etmede diğer modellere göre daha dengeli bir performans sergilediğini göstermektedir. Modeller arasındaki genel başarı değerlendirmesi, takip eden bölümde ayrıntılı olarak ele alınacaktır.

3.6. Modellerin Genel Performans Değerlendirmesi

Bu çalışmada gerçekleştirilen deneysel analizler sonucunda elde edilen performans çıktıları, ROC eğrileri ve karmaşıklık matrisi incelemeleri doğrultusunda, MobileNetV2 modelinin diğer iki modele kıyasla daha üstün bir genel başarı gösterdiği belirlenmiştir. Tablo 7'de sunulan doğruluk, kesinlik, geri çağırma ve F1 skoru değerleri MobileNetV2'nin dengeli ve güçlü bir performans sergilediğini ortaya koyarken, ROC eğrisi analizlerinde de bu modelin daha yüksek AUC skoruna ulaştığı gözlemlenmiştir. Ayrıca karmaşıklık matrislerinin incelenmesi,

MobileNetV2'nin hem iyi hem de kötü kalitedeki görselleri doğru sınıflandırma konusunda diğer modellere göre daha düşük hata oranlarına sahip olduğunu desteklemektedir.

Hafif mimarisi, düşük parametre sayısı ve hızlı öğrenme yetenekleri sayesinde MobileNetV2, emlak ilan platformları gibi gerçek zamanlı kalite kontrolü gerektiren uygulamalarda kullanıma en uygun model olarak öne çıkmıştır. Tüm bu bulgular, MobileNetV2 modelinin bu çalışmanın amacına en uygun çözümü sunduğunu ve pratik uygulamalar açısından doğrudan kullanılabilir bir model ortaya koyduğunu göstermektedir.



4. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışma, emlak ilanlarında kullanılan görsellerin kalitesini değerlendirmek ve düşük kaliteli fotoğrafları tespit etmek amacıyla MobileNetV2, ResNet18 ve EfficientNetB1 olmak üzere üç farklı derin öğrenme modelinin karşılaştırmalı analizini gerçekleştirmiştir. Yapılan deneysel çalışmalar sonucunda, MobileNetV2 modelinin %89.17 doğruluk oranı ile en iyi performansı sergilediği belirlenmiştir. Hafif yapısı ve düşük hesaplama maliyeti sayesinde MobileNetV2, diğer modellere kıyasla daha verimli bir çözüm sunmuştur. ResNet18 modeli, derin mimarisiyle karmaşık desenleri öğrenmede başarılı olurken, işlem süresi ve kaynak tüketimi bakımından daha maliyetli kalmıştır. EfficientNetB1 modeli ise parametre verimliliği açısından avantaj sağlamasına rağmen genel doğruluk oranı bakımından MobileNetV2'nin gerisinde kalmıştır.

Ayrıca, çalışma kapsamında MobileNetV2 tabanlı bir varyasyon geliştirilmiş ve modele tek bir görsel girdisi verilerek “Yüksek Kalite” veya “Düşük Kalite” sınıflandırması yapılması sağlanmıştır. Bu yaklaşım sayesinde, modelin bir emlak ilan platformunun ilan yükleme sürecine entegre edilmesi ve gerçek zamanlı kalite değerlendirmesi gerçekleştirilmesi mümkün hâle gelmiştir. Bu çalışmayla, emlak ilan platformlarında düşük kaliteli görsellerin otomatik olarak tespit edilmesini sağlayabilecek sistemlerin geliştirilmesine yönelik bir temel oluşturulmuştur.

Gelecek çalışmalarda, daha büyük ve çeşitli veri setleri kullanılarak modelin genelleme yeteneği artırılabilir. Özellikle yalnızca emlak sektörüyle sınırlı kalmayıp, farklı alanlardaki (örneğin motorlu taşıt ilanları gibi) görseller üzerinde de kalite değerlendirmesi yapılarak sistemin farklı kullanım senaryolarına uyarlanabilirliği test edilebilir. Ayrıca, kullanıcı deneyimini güçlendirmek amacıyla bu tür derin öğrenme tabanlı sistemlerin mobil ve web tabanlı uygulamalara entegrasyonu da araştırılabilir. Bu doğrultuda geliştirilecek sistemler, emlak ve diğer sektörlerde dijital kalite standartlarının yükseltilmesine önemli katkılar sağlayabilecektir.



KAYNAKLAR

- [1] Yang, X., & Tian, M. (2022). To see and then to believe: How image affect tenant decision-making and satisfaction on short-term rental platform. *Electronic Commerce Research*, 24, 2877–2901. <https://doi.org/10.1007/s10660-022-09622-z>
- [2] Nase, I., Berry, J., & Adair, A. (2016). Impact of quality-led design on real estate value: A spatiotemporal analysis of city centre apartments. *Journal of Property Research*, 33(4), 309–331. <https://doi.org/10.1080/09599916.2016.1258588>
- [3] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. arXiv. <https://arxiv.org/abs/1704.04861>
- [4] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778). IEEE.
- [5] Tan, M., & Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the International Conference on Machine Learning* (pp. 6105–6114). PMLR.
- [6] Mai, U. T. (2016). *Photo quality assessment: Predicting crowd opinions* [University Honors Thesis]. Portland State University. <https://doi.org/10.15760/honors.283>
- [7] Çakir, S., & Sofu, B. (2021). *An application of deep features on image quality assessment. Proceedings of SPIE*, 12547, 125470S. <https://doi.org/10.1117/12.2663463>
- [8] Lin, Z., Jin, H., & Yang, J. (2016). *Image assessment using deep convolutional neural networks* (U.S. Patent No. US 2016/0035078 A1). United States Patent and Trademark Office.
- [9] Daryanavard Chouchenani, M., Shahbahrami, A., Hassanpour, R., & Gaydadjiev, G. (2025). Deep learning based image aesthetic quality assessment- A review. *ACM Computing Surveys*, 57(7), Article 183. <https://doi.org/10.1145/3716820>
- [10] Liang, L., & Xue, C. (2020). A shallow and deep feature fusion model for image quality assessment. *Springer*, 165–179.
- [11] Bouzerdoun, A., Havstad, A., & Beghdadi, A. (2004). Image quality assessment using a neural network approach. *Proceedings of the Fourth IEEE International Symposium on Signal Processing and Information Technology*, 330–333. <https://ro.uow.edu.au/infopapers/43>

- [12] Bianco, S., Celona, L., Napoletano, P., & Schettini, R. (2016). On the use of deep learning for blind image quality assessment. *Signal, Image and Video Processing*, 10(1), 1–12.
- [13] Feng, Z., Zhang, K., Jia, S., Chen, B., & Wang, S. (2023). *Learning from mixed datasets: A monotonic image quality assessment model*. *Electronics Letters*, 59(3), 1–4. <https://doi.org/10.1049/ell2.12698>
- [14] Li, Y., Ye, X., & Li, Y. (2017). *Image quality assessment using deep convolutional networks*. *AIP Advances*, 7(12), 125324.
- [15] Kang, L., Lu, X., Li, Y., & Wang, J. (2021). A deep learning approach to real estate image quality assessment. *IEEE Transactions on Image Processing*, 30, 2003–2015.
- [16] Kumari, A., Maan, V., & Dhiraj. (2020). A deep learning-based segregation of housing image data for real estate application. *Springer, Singapore*, 165–179.
- [17] Kiyota, Y. (2021). *Frontiers of computer vision technologies on real estate property photographs and floorplans*. In Y. Asami, et al. (Eds.), *Frontiers of real estate science in Japan* (pp. 325–337). Springer, Singapore. https://doi.org/10.1007/978-981-15-8848-8_23
- [18] Florea, C., Racovițeanu, A., Florea, L., & Florea, B. (2022). *Automatic real-estate image analysis for retrieval and classification*. *Bul. Inst. Polit. Iași*, 68(2), 36–45. <https://doi.org/10.2478/bipie-2022-0009>
- [19] Zhu, X., & Milanfar, P. (2013). Automatic image quality assessment using a deep CNN. *IEEE Transactions on Image Processing*, 22(12), 4728–4741. <https://doi.org/10.1109/TIP.2013.2277814>

ÖZGEÇMİŞ

Ad-Soyad : Akın YAŞAR

ÖĞRENİM DURUMU:

- Lisans** : 2022, Sakarya Üniversitesi, Bilgisayar ve Bilişim Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü

MESLEKİ DENEYİM:

- 2022-2023 yılları arasında Sakarya Üniversitesi Teknokent bünyesindeki Alfatek Yazılım A.Ş.'de Frontend Developer olarak görev yaptı.
- 2023 yılından itibaren Hepsiemlak firmasında Software Developer olarak çalışmaktadır.

TEZDEN TÜRETİLEN ESERLER:

- Yaşar, A., & Yurtay, Y. (2025, Nisan). *Emlak fotoğraflarının kalite değerlendirilmesi: Derin öğrenme tabanlı bir yaklaşım*. 10. Uluslararası Bilimsel Araştırmalar ve İnovasyon Kongresi Bildiri Kitabı (ss. 584–596). Dubai, Birleşik Arap Emirlikleri. (Yayınlandı). Erişim:

DİĞER ESERLER:

- Güney, E., Yaşar, A., Ağırtaş, G. ve Bayılmış, C. (2022). Mobil platformda IoT temelli ve soket programlamaya dayalı termal sensör uygulaması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(3), 1582-1596. <https://doi.org/10.29130/dubited.1064120>