Karadeniz Fen Bilimleri Dergisi
The Black Sea Journal of Sciences
DOI: 10.31466/kfbd.1727104
ISSN (Online): 2564-7377
https://dergipark.org.tr/tr/pub/kfbd
Araştırma Makalesi / Research Article

Hu Momentleri ve CNN Tabanlı Hibrit Model ile Hazır Giyim Kalıp Görsellerinde Kusur Sınıflandırması

Defect Classification in Garment Pattern Images Using a Hu Moment and CNN-Based Hybrid Model

Ethem Sefa KÜÇÜKYILMAZ[1]*, Erhan AKIN[2], Alper DİKTAŞ[3]

Öz

Bu çalışma, hazır giyim ve konfeksiyon alanında farklı beden gruplarına ait kalıp/giyim parçası görsellerindeki yapısal kusurların sınıflandırılması için Hu momentleri ile evrişimsel sinir ağı (CNN) mimarisini birleştiren hibrit bir model önermektedir. Small (S), Medium (M) ve Large (L) beden gruplarındaki clean ve defect sınıflarından oluşan veri kümesi, gerçek kumaş/kalıp görselleri temel alınarak hazırlanmış ve veri artırma yöntemleriyle dengelenmiştir. Modelde her görüntüden çıkarılan yedi boyutlu Hu moment vektörü, CNN tarafından öğrenilen görsel özniteliklerle erken füzyon yöntemiyle birleştirilmiştir. Böylece Hu momentlerinin dönüşüm-bağımsız geometrik temsil gücü ile CNN'in otomatik örüntü öğrenme kapasitesi birlikte kullanılmıştır. Çalışmanın özgün yönü, bu iki öznitelik türünün beden bazlı kalıp kusuru sınıflandırması için bütünleştirilmesidir. Aşırı öğrenmeyi azaltmak amacıyla erken durdurma ve öğrenme oranı azaltma stratejileri uygulanmıştır. Deneysel sonuçlarda model, tüm beden gruplarında yüksek başarı göstermiş; M beden grubunda doğruluk ve F1-score %99'a ulaşmıştır. Karışıklık matrisi ve ROC analizleri de clean ve defect sınıflarının başarılı biçimde ayrıldığını göstermiştir. Bulgular, önerilen hibrit yapının sınırlı veri koşullarındaki hazır giyim kalite kontrol uygulamaları için etkili ve uygulanabilir bir alternatif olduğunu göstermektedir.

Anahtar Kelimeler: Hu Momentleri, Evrişimsel Sinir Ağları, Hazır Giyim, Kalıp Kusuru Sınıflandırması, Hibrit Model.

Abstract

This study proposes a hybrid model combining Hu moment-based feature extraction with a convolutional neural network (CNN) for classifying structural defects in garment pattern images from different size groups. The dataset consists of clean and defect classes for Small (S), Medium (M), and Large (L) sizes, prepared from real garment/fabric pattern images and balanced through data augmentation. In the proposed model, a seven-dimensional Hu moment vector extracted from each image is combined with CNN-learned visual features using early fusion. This approach integrates the transformation-invariant geometric representation of Hu moments with the automatic pattern-learning capability of CNNs. The main contribution of the study is the integration of these feature types for size-based garment pattern defect classification. Early stopping and learning rate reduction were used to reduce overfitting. Experimental results showed high classification performance across all size groups, with accuracy and F1-score reaching 99% for the M size group. Confusion matrix and ROC analyses also confirmed effective discrimination between clean and defect classes. The findings suggest that the proposed hybrid model is an effective and applicable alternative for garment quality control under limited-data conditions.

Keywords: Hu Moments, Convolutional Neural Networks, Ready-to-Wear, Garment Pattern Defect Classification, Hybrid Model.

[1]Fırat Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Yönetim Bilişim Sistemleri Bölümü, Elazığ, Türkiye
[2]Fatih Sultan Mehmet Vakıf Üniversitesi, Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye
[3]Serkon Teknoloji, İstanbul, Türkiye

***Sorumlu Yazar/Corresponding Author:** eskucukyilmaz@firat.edu.tr

Geliş/Received: 07.07.2025 **Kabul/Accepted:** 05.08.2026 **Yayın/Published:** 18.08.2026

Küçükyılmaz, E.S., Akın, E., Diktaş, A. (2026). Hu Momentleri ve CNN Tabanlı Hibrit Model ile Hazır Giyim Kalıp Görsellerinde Kusur Sınıflandırması. *Karadeniz Fen Bilimleri Dergisi*, 16(3), 1080-1105. https://doi.org/10.31466/kfbd.1727104

1. Giriş

Hazır giyim ve konfeksiyon sektöründe ürün kalitesinin korunması, üretim sürecinde ortaya çıkabilecek kusurların erken aşamada belirlenmesi ve nihai ürünün ölçü-form uygunluğunun sağlanması, üretim verimliliği ve müşteri memnuniyeti açısından kritik öneme sahiptir. Özellikle farklı beden gruplarına ait kalıp/giyim parçası görsellerinde meydana gelen kenar-kontur düzensizlikleri, geometrik sapmalar, eksik bölge oluşumları veya biçimsel deformasyonlar, yalnızca görsel bir bozulma olarak değil, aynı zamanda ürünün ölçü uyumu, kalıp doğruluğu ve üretim kalitesi üzerinde doğrudan etkili olabilecek yapısal kusurlar olarak değerlendirilmektedir. Geleneksel kalite kontrol süreçlerinin büyük ölçüde manuel incelemeye dayanması; operatör yorgunluğu, dikkat dağınıklığı, deneyime bağlı yorum farklılıkları ve zaman kaybı gibi nedenlerle denetim sürecinde tutarsızlıklara yol açabilmektedir. Bu nedenle görüntü işleme ve derin öğrenme tabanlı otomatik denetim sistemleri, hazır giyim kalıp/giyim parçası görsellerindeki yapısal kusurların daha hızlı, nesnel ve tekrarlanabilir biçimde sınıflandırılması açısından önemli bir potansiyel sunmaktadır.

Literatürde tekstil ve hazır giyim kalite kontrolüne yönelik çok sayıda görüntü tabanlı çalışma bulunmakla birlikte, bu çalışmaların önemli bir kısmı kumaş yüzeyi, doku bozuklukları, iplik hataları, renk anomalileri, üretim dokusu veya genel endüstriyel yüzey kusurları üzerine yoğunlaşmaktadır. Örneğin yüksek çözünürlüklü optik görüntüler, mikroskobik görüntüler, termal veya hiperspektral görüntüleme yöntemleriyle küçük ölçekli yüzey kusurlarının tespit edilmesine yönelik çalışmalar model başarımını artırabilmektedir (Wei ve ark., 2022; Liu ve ark., 2023). Bunun yanında farklı görüntüleme kaynaklarının ve veri artırma stratejilerinin modelin genelleme kabiliyetini güçlendirdiği de belirtilmektedir (Chen ve ark., 2024). Ancak bu çalışmalar çoğunlukla kumaş yüzeyindeki doku veya malzeme tabanlı kusurları ele almakta; hazır giyim kalıp/giyim parçası görsellerinde beden gruplarına bağlı geometrik form değişimlerinin clean/defect sınıflandırması üzerindeki etkisini doğrudan incelememektedir. Bu yönüyle mevcut çalışma, genel bir şekil sınıflandırma probleminden ziyade, hazır giyim üretiminde kalıp/giyim parçası formuna bağlı yapısal kusurların otomatik sınıflandırılmasına odaklanmaktadır.

Hazır giyim kalıp/giyim parçası kusurları, klasik kumaş yüzeyi kusurlarından farklı bir problem yapısına sahiptir. Kumaş yüzeyi kusurlarında çoğunlukla renk, doku, iplik yoğunluğu veya yüzey anomalileri ön plana çıkarken; kalıp/giyim parçası görsellerinde temel belirleyici unsur parçanın genel geometrik formu, kenar sürekliliği, kontur düzeni ve beklenen beden formuna uygunluğudur. Bu nedenle bu problem, yalnızca piksel tabanlı görsel örüntülerin öğrenilmesini değil, aynı zamanda kalıp parçasının yapısal ve geometrik özelliklerinin de temsil edilmesini gerektirmektedir. Small (S), Medium (M) ve Large (L) beden gruplarında aynı kusur türü farklı ölçeklerde veya farklı görsel etkilerle ortaya çıkabildiğinden, model performansının beden bazlı olarak değerlendirilmesi de önem

kazanmaktadır. Bu bağlamda çalışmada, hazır giyim kalıp/giyim parçası görsellerinde clean ve defect sınıflarının S, M ve L beden grupları özelinde ayrı ayrı incelenmesi hedeflenmiştir.

Görüntü işleme alanında geometrik dönüşümlere karşı değişmez özellikler sunması nedeniyle Hu momentleri, şekil temelli öznitelik çıkarımı ve nesne tanıma görevlerinde uzun süredir kullanılan etkili yöntemlerden biridir. Hu momentleri; öteleme, döndürme ve ölçekleme gibi temel dönüşümlere karşı dayanıklı yapısal öznitelikler sağlayarak görüntülerin geometrik karakterini matematiksel olarak temsil eder. Bununla birlikte, dijital görüntülerdeki ayrık yapı bu değişmezliği belirli ölçüde sınırlayabilmekte ve yalnızca Hu momentlerine dayalı yaklaşımlar karmaşık görüntü sınıflandırma problemlerinde yeterli olmayabilmektedir (Agrawal ve ark., 2024). Bu nedenle son yıllarda Hu momentleri gibi geleneksel geometrik özniteliklerin, evrişimsel sinir ağları (CNN) gibi derin öğrenme mimarileriyle birlikte kullanıldığı hibrit yaklaşımlar önem kazanmıştır.

Hu momentleri ile CNN tabanlı modellerin birlikte kullanıldığı çalışmalarda, geleneksel geometrik özniteliklerin öğrenilmiş derin öznitelikleri tamamlayarak sınıflandırma doğruluğunu artırabildiği gösterilmiştir (Al-Zoubi ve ark., 2020). Özellikle düşük çözünürlüklü görüntüler, sınırlı veri kümeleri veya kontur/şekil ayrımının önemli olduğu görevlerde Hu momentlerinin ayırt edici katkı sağladığı belirtilmektedir (Zaeri, 2018; Li ve ark., 2020). Video gözetim sistemlerinde Hu momentleri ve CNN birleşimiyle gerçekleştirilen gemi tanıma çalışmalarında yüksek doğruluk değerlerine ulaşılması da bu tür hibrit yapıların farklı görüntü sınıflandırma problemlerindeki potansiyelini göstermektedir (Ren ve ark., 2020). Bununla birlikte, bu çalışmaların büyük bölümü yüz tanıma, gemi tanıma, düşük çözünürlüklü desen sınıflandırma veya genel nesne tanıma gibi hazır giyim alanı dışındaki problemlere odaklanmaktadır. Dolayısıyla Hu momentleri ile CNN tabanlı hibrit modellerin, hazır giyim kalıp/giyim parçası görsellerinde beden bazlı yapısal kusur sınıflandırması amacıyla kullanımı literatürde yeterince ele alınmamıştır.

Benzer biçimde, geleneksel öznitelik çıkarımı ile derin öğrenme mimarilerini birleştiren hibrit modellerin farklı alanlarda başarılı sonuçlar verdiği görülmektedir. Hu, Zernike, LBP ve HOG gibi geleneksel özniteliklerin derin öğrenme yapılarıyla birleştirilmesi; doğruluk, hesaplama verimliliği ve yorumlanabilirlik açısından çeşitli avantajlar sağlayabilmektedir (Yang ve ark., 2020). Ayrıca klasik ve öğrenilmiş özniteliklerin bir arada kullanıldığı sistemlerin farklı sınıflandırma görevlerinde performansı artırabildiği rapor edilmiştir (Ismail ve ark., 2023; Tan ve ark., 2023). CNN mimarilerinde klasik özniteliklerin hangi düzeyde entegre edildiği de model davranışını etkileyebilmekte; erken veya geç füzyon stratejileri mimarinin yapısına bağlı olarak farklı sonuçlar üretebilmektedir (Qureshi ve ark., 2019; Dhillon ve Verma, 2019; Mukherjee ve ark., 2019). Bununla birlikte söz konusu çalışmaların önemli bir bölümü medikal görüntü analizi, doğal görüntü sınıflandırması, duygu analizi, genel endüstriyel kusur tespiti veya farklı bilgisayarlı görü görevleri üzerinde yoğunlaşmaktadır. Bu durum, hibrit model yaklaşımının genel başarısını göstermesine

rağmen, hazır giyim kalıp/giyim parçası kusurlarına özgü literatür boşluğunu doğrudan kapatmamaktadır.

Tekstil kusur tespiti alanında sentetik veri üretimi ve veri artırma yaklaşımları da son yıllarda önemli bir araştırma konusu hâline gelmiştir. GAN ve cGAN gibi üretici modeller kullanılarak sınırlı etiketli veri kümelerinde kusur çeşitliliğinin artırılabildiği ve modelin daha geniş hata örüntülerine karşı dayanıklı hâle getirilebildiği belirtilmektedir (Clarke ve Mohammed, 2024; Chen ve ark., 2025). DD-Aug gibi yeni nesil veri üretim yaklaşımları da endüstriyel kusur tespitinde bilgiye dayalı sentetik örnekleme ile başarı artışı sağlayabilmektedir (Chen ve ark., 2025). Ancak bu çalışmalar da çoğunlukla kumaş yüzeyi, doku veya endüstriyel yüzey anomalilerine odaklanmakta; hazır giyim kalıp/giyim parçası formundaki kenar-kontur bozulmaları, eksik bölge oluşumları ve beden temelli geometrik sapmaların clean/defect düzeyinde sınıflandırılmasına doğrudan odaklanmamaktadır. Bu nedenle hazır giyim kalıp kusurlarında hem geometrik yapıyı temsil eden klasik özniteliklerin hem de CNN tabanlı öğrenilmiş görsel özniteliklerin birlikte ele alınması önemli bir araştırma gereksinimi olarak ortaya çıkmaktadır.

Bu literatür değerlendirmesi doğrultusunda mevcut çalışmalar üç ana grupta özetlenebilir. Birinci grup çalışmalar, Hu momentleri ve diğer klasik geometrik özniteliklerin genel görüntü tanıma problemlerindeki temsil gücünü ortaya koymaktadır. İkinci grup çalışmalar, CNN ve hibrit derin öğrenme mimarilerinin farklı görüntü sınıflandırma alanlarında yüksek başarı sağlayabildiğini göstermektedir. Üçüncü grup çalışmalar ise tekstil kalite kontrolünde yüzey, doku, iplik veya üretim anomalilerinin otomatik tespitine odaklanmaktadır. Ancak bu üç araştırma çizgisinin kesişiminde yer alan “hazır giyim kalıp/giyim parçası görsellerinde beden bazlı yapısal kusur sınıflandırması” problemi sınırlı düzeyde ele alınmıştır. Özellikle S, M ve L beden gruplarındaki form farklılıklarının clean/defect sınıflandırma performansı üzerindeki etkisini inceleyen ve Hu momentleri ile CNN tabanlı öğrenilmiş öznitelikleri erken füzyon yaklaşımıyla birleştiren çalışmaların eksikliği, bu çalışmanın temel literatür boşluğunu oluşturmaktadır.

Bu çalışmada, hazır giyim kalıp/giyim parçası görsellerinde yapısal kusurların sınıflandırılması amacıyla Hu momentleri ve CNN mimarisini birleştiren erken füzyon tabanlı hibrit bir model önerilmektedir. Önerilen yaklaşımda, CNN tarafından öğrenilen görsel öznitelikler ile Hu momentlerinden elde edilen yedi boyutlu geometrik öznitelik vektörü birlikte kullanılarak clean ve defect sınıflarının daha güçlü biçimde ayrıştırılması amaçlanmıştır. Çalışmanın odaklandığı kusur kavramı; kumaş yüzeyi kusurlarından ziyade, kalıp/giyim parçası formunu etkileyen kenar-kontur düzensizlikleri, geometrik deformasyonlar, eksik bölge oluşumları ve biçimsel sapmalar kapsamında değerlendirilmiştir. Bu yönüyle çalışma, hazır giyim ve konfeksiyon kalite kontrol süreçlerinde kalıp/giyim parçası görsellerine yönelik beden bazlı yapısal kusur sınıflandırması için uygulanabilir bir hibrit model önerisi sunmaktadır.

Bu çalışmanın başlıca katkıları şu şekilde özetlenebilir:

• Hazır giyim kalıp/giyim parçası görsellerinde clean ve defect sınıflarının yalnızca genel bir şekil sınıflandırma problemi olarak değil, beden gruplarına bağlı yapısal kusur sınıflandırması bağlamında ele alınması sağlanmıştır.

• Hu momentleri ile CNN tabanlı öğrenilmiş öznitelikler erken füzyon yaklaşımıyla birleştirilerek kalıp/giyim parçası formundaki kenar, kontur ve geometrik yapı farklılıklarının daha etkili temsil edilmesi amaçlanmıştır.

• Small (S), Medium (M) ve Large (L) beden grupları ayrı ayrı değerlendirilerek beden bazlı geometrik varyasyonların model performansı üzerindeki etkisi incelenmiştir.

• Önerilen Hu+CNN hibrit model, yalnızca CNN kullanan model ile karşılaştırılarak Hu momentlerinin sınıflandırma başarımına katkısı ablation analiziyle ortaya konmuştur.

• Model performansı doğruluk, precision, recall, F1-score, karışıklık matrisi, ROC AUC ve doğru/hatalı sınıflandırma örnekleri ile çok yönlü olarak değerlendirilmiştir.

Yukarıda özetlenen çalışmalar değerlendirildiğinde, mevcut literatürün üç ana araştırma ekseninde yoğunlaştığı görülmektedir. Birinci eksen, Hu momentleri ve benzeri geleneksel geometrik özniteliklerin genel şekil, nesne veya düşük çözünürlüklü görüntü sınıflandırma problemlerindeki temsil gücünü ortaya koymaktadır. İkinci eksen, klasik öznitelik çıkarım teknikleri ile CNN tabanlı derin öğrenme mimarilerinin farklı alanlardaki hibrit kullanımına odaklanmaktadır. Üçüncü eksen ise tekstil kalite kontrolünde kumaş yüzeyi, doku, iplik yapısı veya yüzey anomalilerinin otomatik tespitini ele almaktadır. Ancak bu çalışmaların önemli bir bölümü hazır giyim kalıp/giyim parçası görsellerinde ortaya çıkan kenar-kontur bozulmaları, eksik bölge oluşumları ve beden gruplarına bağlı geometrik form sapmalarını doğrudan incelememektedir. Bu nedenle literatürde, hazır giyim kalıp/giyim parçası görsellerinde clean/defect sınıflandırmasını beden bazlı olarak ele alan ve Hu momentleri ile CNN tabanlı öğrenilmiş öznitelikleri erken füzyon yaklaşımıyla birleştiren çalışmaların sınırlı olduğu görülmektedir. Bu araştırma boşluğu Tablo 1'de sistematik olarak özetlenmiştir.

Tablo 1. Mevcut literatürün çalışma odağı ve bu çalışmanın konumlandırılması

Literatür Grubu	Temsilî Çalışmalar	Temel Odak	Sınırlılık / Araştırma Boşluğu	Bu Çalışmanın Konumu
Hu momentleri ve geometrik öznitelik tabanlı çalışmalar	Agrawal ve ark. (2024), Al-Zoubi ve ark. (2020), Zaeri (2018), Li ve ark. (2020), Ren ve ark. (2020), Dhanya ve ark. (2024)	Şekil, kontur, düşük çözünürlüklü görüntü, yüz/gemi/desen tanıma gibi genel görüntü sınıflandırma problemleri	Hazır giyim kalıp/giyim parçası kusurları ve beden bazlı form sapmaları doğrudan ele alınmamaktadır	Hu momentleri, hazır giyim kalıp/giyim parçası görsellerindeki kenar-kontur ve geometrik kusurların temsilinde kullanılmıştır

Klasik öznitelik + derin öğrenme hibrit modelleri	Yang ve ark. (2020), Ismail ve ark. (2023), Qureshi ve ark. (2019), Dhillon ve Verma (2019), Mukherjee ve ark. (2019), Tan ve ark. (2023), Kalaivani ve ark. (2024), Chaffin ve ark. (2023)	Geleneksel özniteliklerin CNN veya farklı derin öğrenme mimarileriyle birleştirilmesi	Çalışmalar çoğunlukla medikal görüntü, doğal görüntü, duygu analizi veya genel bilgisayarlı görü problemlerine yöneliktir	Hu momentleri ile CNN öznitelikleri erken füzyon yöntemiyle birleştirilerek hazır giyim kalıp kusuru sınıflandırmasına uygulanmıştır
Tekstil ve konfeksiyon kalite kontrol çalışmaları	Wei ve ark. (2022), Liu ve ark. (2023), Chen ve ark. (2024), Montazeri ve ark. (2020)	Kumaş yüzeyi, doku, iplik organizasyonu, yüzey anomalileri ve görüntüleme türlerinin kusur tespitine etkisi	Odak çoğunlukla kumaş yüzeyi veya mikro-doku kusurlarıdır; kalıp/giyim parçası formundaki geometrik bozulmalar sınırlı ele alınmaktadır	Çalışma, kumaş yüzeyi yerine kalıp/giyim parçası formundaki yapısal kusurlara odaklanmaktadır
Veri artırma ve kusur çeşitliliğini artırmaya yönelik çalışmalar	Clarke ve Mohammed (2024), Chen ve ark. (2025), Obi (2023)	GAN, cGAN, veri artırma ve örnek çeşitlendirme ile sınırlı veri koşullarında model dayanıklılığının artırılması	Mevcut çalışmalar çoğunlukla kumaş yüzeyi, doku veya genel endüstriyel kusurlara odaklanmakta; hazır giyim kalıp/giyim parçası formundaki gerçek kusurların beden bazlı sınıflandırılması sınırlı ele alınmaktadır	Bu çalışmada gerçek kumaş/kalıp görselleri kullanılmış; buruşma, kumaş içi boşluk, kenar-kontur düzensizliği ve form bozulması içeren defect örnekleri veri artırma yöntemleriyle çoğaltılarak S, M ve L beden gruplarında değerlendirilmiştir
Hazır giyim kalıp/giyim parçası görsellerinde beden bazlı yapısal kusur sınıflandırması	Önerilen yöntem	Kalıp/giyim parçası görsellerinde kenar-kontur bozulması, geometrik deformasyon, eksik bölge ve biçimsel düzensizliklerin sınıflandırılması	Literatürde sınırlı çalışılmış bir alan	Hu+CNN erken füzyon tabanlı hibrit model ile S, M ve L beden gruplarında ayrı ayrı değerlendirme yapılmıştır

Tablo 1'de görüldüğü üzere, mevcut çalışmalar Hu momentleri, hibrit modelleme, tekstil kusur tespiti ve veri artırma yaklaşımları açısından önemli katkılar sunsa da, bu yaklaşımların hazır giyim kalıp/giyim parçası görsellerinde beden bazlı yapısal kusur sınıflandırması bağlamında birlikte ele alındığı çalışmalar sınırlıdır.

2. Materyal ve Metot

Bu bölümde çalışmada kullanılan materyal ve metotlar detaylı ve açık bir şekilde anlatılmalıdır.

2.1. Alt Başlık

Bu çalışmada, hazır giyim ve konfeksiyon alanında kalıp/giyim parçası görsellerindeki yapısal kusurları sınıflandırmaya yönelik geliştirilen hibrit modelin eğitimi ve değerlendirilmesi amacıyla gerçek kumaş/kalıp görsellerinden oluşan bir görüntü veri kümesi kullanılmıştır. Veri kümesi, üç farklı beden grubunu temsil eden Small (S), Medium (M) ve Large (L) kalıp/giyim parçası görsellerinden oluşmaktadır. Görseller clean ve defect olmak üzere iki sınıfa ayrılmıştır. Clean sınıfı, belirgin bir yapısal bozulma içermeyen ve beklenen kalıp/giyim parçası formunu koruyan örneklerden; defect sınıfı ise kumaş yüzeyinde buruşma, kumaş içi boşluklar, kenar-kontur düzensizlikleri, bölgesel form bozulmaları ve yapısal sürekliliği etkileyen görsel kusurlar içeren örneklerden meydana gelmektedir. Model eğitiminin dengeli biçimde yürütülebilmesi amacıyla her beden grubu ve sınıf için örnek sayıları veri artırma yöntemleri kullanılarak eşitlenmiştir.

Gerçek üretim ve kumaş görüntülerinde kusurlu örneklerin her beden grubu için aynı sayıda ve aynı görüntüleme koşullarında elde edilmesi güç olabilmektedir. Bu durum, modelin bazı sınıf veya beden gruplarına karşı yanlı öğrenme yapmasına neden olabilir. Bu nedenle çalışmada, gerçek görüntüler temel alınmış; ancak sınıf dengesini sağlamak, modelin farklı konum ve ölçek değişimlerine karşı daha dayanıklı öğrenmesini desteklemek ve sınırlı veri koşullarında anlamlı bir eğitim süreci oluşturmak amacıyla veri artırma işlemleri uygulanmıştır. Veri artırma sürecinde yeni kusurlar yapay olarak üretilmemiş; mevcut gerçek clean ve defect görüntülerinin sınıf etiketleri korunarak geometrik ve görsel çeşitlilik artırılmıştır. Böylece modelin yalnızca belirli bir görüntü pozisyonunu veya sabit bir örüntüyü ezberlemesi yerine, gerçek kusur özelliklerini farklı dönüşümler altında öğrenmesi amaçlanmıştır.

Bu çalışmada “kusur” kavramı, klasik anlamda tüm tekstil yüzey hatalarını kapsayan geniş bir kusur sınıflandırması olarak değil; kalıp/giyim parçası görselinin beklenen temiz formundan veya yüzey bütünlüğünden sapması olarak değerlendirilmiştir. Bu kapsamda defect sınıfı; kumaş yüzeyinde buruşma, kumaş içi boşluklar, bölgesel eksilme izlenimi, kenar ve kontur düzensizlikleri, geometrik form bozulmaları ve kalıp/giyim parçası bütünlüğünü etkileyen görsel farklılıkları kapsamaktadır. Clean sınıfı ise belirgin buruşma, boşluk, kontur bozulması veya form sapması içermeyen ve beklenen kalıp/giyim parçası görünümünü koruyan örneklerden oluşmaktadır. Bu ayrım, gerçek görüntüler üzerinde uzman gözlemiyle clean/defect düzeyinde etiketleme yapılarak oluşturulmuştur.

Veri kümesindeki görüntüler, sınıflar (clean/defect) ve beden grupları (S/M/L) olmak üzere iki eksende organize edilmiştir. Veri artırma işlemleri sonrasında her bir beden-sınıf kombinasyonunda 1250 görüntü yer alacak şekilde dengeli bir yapı elde edilmiş ve toplamda 7500 görüntü kullanılmıştır. Görüntüler white_bg_fixed_ ön işleme işlemi uygulanarak arka plan etkisi azaltılmış biçimde hazırlanmış ve her bir örnek png formatında, 64×64 piksel çözünürlükte kaydedilmiştir. Bu yapı sayesinde modelin hem beden grupları arasındaki görsel farklılıkları hem de gerçek kusur örüntülerini ayırt edebilme kapasitesi kontrollü ve dengeli bir deneysel düzende değerlendirilmiştir. Tablo 2'de veri kümesinin detaylı örnek sayıları, Şekil 1'de ise veri setinden örnek görüntüler verilmiştir.

Tablo 2. Veri kümesindeki görüntü sayıları (clean/defect ayrımına göre)

Beden Boyutu	Clean Görüntü Sayısı	Defect Görüntü Sayısı	Toplam
Small (S)	1250	1250	2500
Medium (M)	1250	1250	2500
Large (L)	1250	1250	2500
Toplam	3750	3750	7500



Şekil 1. Veri setinden S, M ve L beden gruplarına ait örnek kalıp/giyim parçası görselleri

Bununla birlikte, veri kümesinin veri artırma yöntemleriyle çoğaltılmış olması çalışmanın değerlendirilmesinde dikkate alınması gereken bir noktadır. Veri artırma işlemleri modelin farklı geometrik ve görsel varyasyonlara karşı dayanıklılığını artırsa da, gerçek üretim ortamlarında karşılaşılabilecek tüm ışık, kamera açısı, kumaş tipi, deformasyon şiddeti ve kusur çeşitliliğini bütünüyle temsil etmeyebilir. Bu nedenle elde edilen bulgular, gerçek görüntülerden türetilmiş ve dengelenmiş bir deneysel veri kümesi üzerinde önerilen hibrit modelin performansını göstermekte; farklı üretim hatlarından ve daha geniş kumaş türlerinden elde edilecek bağımsız veri kümeleriyle yapılacak ek doğrulamalar ise gelecek çalışmalar kapsamında değerlendirilmektedir.

2.1.1. Veri Artırma Süreci

Çalışmada kullanılan görüntüler sentetik olarak üretilmemiş, gerçek kumaş/kalıp görselleri temel alınarak oluşturulmuştur. Ancak veri kümesinde her beden grubu ve sınıf için dengeli örnek sayısına ulaşmak ve modelin farklı görsel koşullara karşı genelleme yeteneğini artırmak amacıyla veri artırma işlemleri uygulanmıştır. Veri artırma süreci Python programlama dili kullanılarak OpenCV, NumPy ve TensorFlow/Keras tabanlı görüntü işleme araçlarıyla gerçekleştirilmiştir.

Veri artırma işlemleri sırasında clean ve defect sınıf etiketleri korunmuş; görüntülerin temel sınıf karakterini değiştirecek düzeyde yapay kusur ekleme veya sınıfı değiştirecek manipülasyonlar yapılmamıştır. Başka bir ifadeyle defect sınıfında yer alan buruşma, kumaş içi boşluk, kenar-kontur düzensizliği ve form bozulması gibi kusurlar gerçek görüntülerden gelmekte; veri artırma süreci bu gerçek kusurların farklı konum, ölçek ve açılarda modele sunulmasını sağlamaktadır.

Uygulanan veri artırma işlemleri, görüntünün sınıf bilgisini değiştirmeyecek sınırlı aralıklarda tutulmuştur. Bu kapsamda küçük açılı döndürme, yatay/dikey kaydırma, yakınlaştırma-uzaklaştırma, parlaklık değişimi ve gerekli durumlarda hafif kontrast düzenleme işlemleri uygulanmıştır. Bu dönüşümler rastgele seçilmiş ve her görüntüye aynı dönüşüm dizisi sabit biçimde uygulanmamıştır. Böylece eğitim veri kümesinde görsel çeşitlilik artırılmış, ancak gerçek kusur yapısı korunmuştur. Veri artırma işlemlerinde kullanılan temel dönüşümler Tablo 3'te özetlenmiştir.

Tablo 3. Veri artırma sürecinde kullanılan dönüşümler ve amaçları

İşlem	Uygulama Biçimi	Parametrik Dağılım / Aralık	Amaç
Döndürme	Görüntünün küçük açılarla döndürülmesi	Rastgele, sınırlı açı aralığı	Kalıp/giyim parçasının farklı kamera veya yerleşim açılarında temsil edilmesi
Yatay/dikey kaydırma	Görüntünün x ve y ekseninde sınırlı oranda ötelenmesi	Rastgele, görüntü boyutuna oranlı sınırlı aralık	Parçanın görüntü içindeki konum değişimlerine karşı dayanıklılık sağlanması
Yakınlaştırma/uzaklaştırma	Görüntünün sınırlı oranda ölçeklendirilmesi	Rastgele, sınıf yapısını bozmayacak dar aralık	Farklı ölçek ve beden görünümü varyasyonlarının temsil edilmesi
Parlaklık değişimi	Görüntü parlaklığının hafif artırılıp azaltılması	Rastgele, düşük şiddetli değişim	Işık koşullarındaki küçük farklılıklara karşı genelleme sağlanması
Kontrast düzenleme	Görüntüde sınırlı kontrast değişimi	Rastgele, düşük şiddetli değişim	Kumaş yüzeyi ve kusur görünürlüğündeki doğal değişimleri temsil etmek
Yeniden boyutlandırma	Tüm görüntülerin 64×64 piksele getirilmesi	Sabit	CNN mimarisi için standart giriş boyutu sağlamak

Bu çalışmada kusurlar parametrik olarak yapay biçimde oluşturulmamış; gerçek kumaş/kalıp görüntülerinde mevcut olan buruşma, boşluk görünümü, kenar-kontur düzensizliği ve form bozulması gibi görsel özellikler defect sınıfının temelini oluşturmuştur. Parametrik yapı, yalnızca veri artırma sürecinde kullanılan döndürme, kaydırma, ölçekleme, parlaklık ve kontrast değişimi gibi dönüşümlerin rastgele ve sınırlı aralıklarda uygulanmasıyla ilişkilidir. Bu nedenle veri kümesi, sentetik kusur üretimine dayalı bir yapıdan ziyade, gerçek kusur örneklerinin veri artırma yoluyla dengelenmiş ve çeşitlendirilmiş hâli olarak değerlendirilmiştir.

2.2. Görüntü Ön İşleme ve Özellik Çıkarımı

Modelin doğru ve güvenilir bir şekilde eğitilebilmesi için, veri kümesindeki her bir görüntüye belirli bir ön işleme süreci uygulanmıştır. İlk olarak, tüm görüntüler RGB renk uzayında okunmuş ve 64×64 piksel boyutuna yeniden ölçeklendirilmiştir. Bu işlem, farklı boyutlardaki kumaş görüntülerinin ağ mimarisiyle uyumlu hâle getirilmesini sağlamıştır. Görüntü pikselleri daha sonra 0–1 aralığına normalize edilerek modele giriş olarak uygun biçime getirilmiştir. Özellik çıkarımı aşamasında, görüntülerin yalnızca görsel temsilleri değil, aynı zamanda şekil temelli öznitelikleri de dikkate alınmıştır. Bu kapsamda her bir görüntüden Hu momentleri hesaplanarak, yedi boyutlu bir öznitelik vektörü elde edilmiştir. Bu vektörler, görüntünün şekilsel yapısına ilişkin ölçümler içerdiği için özellikle kontur bozulmaları ve kusur kaynaklı yapısal değişimleri temsil etmede güçlü bir araç olarak kullanılmıştır. Veri artırma işlemleri tamamlandıktan sonra tüm görüntüler ortak bir ön işleme sürecinden geçirilmiştir.

Veri akışı özetle aşağıdaki gibi gerçekleştirilmiştir:

1. Gerçek clean ve defect görüntülerinin beden gruplarına göre düzenlenmesi
2. Sınıf dengesini sağlamak amacıyla veri artırma işlemlerinin uygulanması
3. Görüntü dosyalarının okunması ve 64×64 piksel boyutuna yeniden boyutlandırılması
4. Piksel düzeyinde normalizasyon yapılması (RGB değerleri / 255)
5. Gri ölçekli görüntüye dönüşüm ve Hu momentlerinin hesaplanması
6. Görüntü vektörlerinin ve Hu momentlerinin ayrı ayrı kayıt altına alınması
7. İlgili sınıf etiketi ile eşleştirilerek eğitim/test bölümlerine ayrılması

Bu işlem sayesinde her bir görüntü hem piksel bazlı temsil (CNN için giriş) hem de yapısal temsil (Hu momentleri ile) olarak modelde hibrit biçimde değerlendirilmiştir. Böylece, yalnızca dokusal ve renk bilgisine dayalı değil, aynı zamanda geometrik şekil farklılıklarını da yakalayabilen daha derin ve anlamlı bir temsil elde edilmiştir.

2.3. Görüntü Ön İşleme ve Özellik Çıkarımı

Görüntü işleme literatüründe sıkça kullanılan Hu momentleri, iki boyutlu bir şeklin geometrik özelliklerini, özellikle de şeklin dönme, ölçekleme ve öteleme gibi geometrik dönüşümler karşısında değişmeyen (invariant) özniteliklerle temsil etmeye olanak sağlar. Bu çalışmada, her bir gri ölçekli görüntü için yedi adet Hu momenti hesaplanmıştır. Bir görüntünün m_{pq} dereceli geometrik momenti, Denklem 1'de olduğu gibi tanımlanır:

$$\boldsymbol{m_{pq} = \sum_x \sum_y x^p y^q I(x,y)} \quad (1)$$

Burada:

- $I(x,y)$: (x,y) konumundaki pikselin yoğunluk değerini ifade eder.
- p ve q: moment derecelerini belirleyen sıfır veya pozitif tamsayılardır.

Görüntünün geometrik merkezi (ağırlık merkezi) kullanılarak merkezlenmiş momentler u_{pq} Denklem 2'deki gibi tanımlanır:

$$u_{pq} = \sum_x \sum_y (x - x')^P (y - y')^q \boldsymbol{I(x,y)} \quad (2)$$

Burada $x' = \frac{m_{10}}{m_{00}}$ ve $\mathrm{y}' = \frac{m_{01}}{m_{00}}$ görüntünün ağırlık merkezinin koordinatlarıdır. Dönüşümlere karşı değişmezlik sağlamak amacıyla, merkezlenmiş momentler Denklem 3'teki gibi normalize edilir:

$$n_{pq} = \frac{u_{pq}}{u_{00}^{(1+\left(p+\frac{q}{2}\right))}} \quad (3)$$

Son olarak, Hu tarafından türetilmiş yedi adet invariant moment (Hu momentleri) Denklem 4-10'da olduğu gibi ifade edilir. Bu momentler, normalize edilmiş momentlerin kombinasyonlarından elde edilir:

$$H_1 = n_{20} + n_{02} \quad (4)$$

$$H_2 = (n_{20} - n_{02})^2 + 4n_{11}^2 \quad (5)$$

$$H_3 = (n_{30} - 3n_{12})^2 + (3n_{21} - n_{03})^2 \quad (6)$$

$$H_4 = (n_{30} + n_{12})^2 + (n_{21} + n_{03})^2 \quad (7)$$

$$H_5 = (n_{30} - 3n_{12})(n_{30} + n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2] + (3n_{21} - n_{03})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] \quad (8)$$

$$H_6 = (n_{20} - n_{02})[(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] + 4n_{11}(n_{30} + n_{12})\,(n_{21} + n_{03}) \quad (9)$$

$$H_7 = (3n_{21} - n_{03})(n_{30} + n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2] - (n_{30} + 3n_{12})\,(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] \quad (10)$$

Çalışmada, her bir görüntü için bu yedi Hu momenti hesaplanmış ve negatif logaritmik dönüşüm uygulanarak model girişine uygun bir format elde edilmiştir. Bu işlem, değerlerin çok küçük olduğu durumlarda sayısal kararlılığı artırmak için gerçekleştirilmiştir.

2.3. Görüntü Ön İşleme ve Özellik Çıkarımı

Bu çalışmada, görüntü verisine dayalı sınıflandırma işlemi için Evrişimli Sinir Ağı (CNN) tabanlı bir derin öğrenme mimarisi geliştirilmiştir. Mimari, giriş katmanından başlayarak sırasıyla evrişim, aktivasyon, havuzlama ve yoğun bağlantılı (dense) katmanlardan oluşmaktadır. Yapı, hem düşük seviyeli hem de yüksek seviyeli özniteliklerin etkili şekilde çıkarılmasını sağlamayı amaçlamaktadır. Aşağıda kullanılan CNN mimarisine ilişkin katmanlar, filtre sayıları, kernel boyutları ve aktivasyon fonksiyonları Tablo 4'te verilmiştir.

Tablo 4. Önerilen CNN Tabanlı Derin Öğrenme Mimarisine Ait Katman Yapısı

Katman No	Katman Türü	Filtre/Ünite Sayısı	Kernel Boyutu	Aktivasyon Fonksiyonu
1	Input	-	(64, 64, 3)	-
2	Conv2D	32	(3x3)	ReLU
3	MaxPooling2D	-	(2x2)	-
4	Conv2D	64	(3x3)	ReLU
5	MaxPooling2D	-	(2x2)	-
6	Flatten	-	-	-
7	Dense	128	-	ReLU
8	Dropout	-	-	-
9	Dense (Output)	2	-	Softmax

Modelin genel yapısı, düşük seviyeli öznitelik çıkarımına odaklanan ilk evrişim katmanlarıyla başlamakta; ardından öznitelik haritalarının boyutları max-pooling ile azaltılmakta ve elde edilen özellikler tam bağlantılı katmanlarla sınıflandırma işlemine aktarılmaktadır. Model, eğitim verisinin sınırlı olduğu durumlarda bile yüksek doğrulukta sınıflandırma performansı göstermiştir.

2.5. Hibrit Modelin Yapılandırılması

Bu çalışmada, görüntülerden elde edilen Hu momentleri ile Evrişimli Sinir Ağı (CNN) tabanlı bir yapay sinir ağı birleştirilerek hibrit bir sınıflandırma modeli tasarlanmıştır. Amaç, geleneksel istatistiksel öznitelik çıkarımı ile derin öğrenmeye dayalı otomatik öznitelik öğrenimini bir arada kullanarak sınıflandırma başarımını artırmaktır. Model, iki ayrı girişten oluşmaktadır: birincisi 64x64 boyutundaki normalize edilmiş RGB görüntüler, ikincisi ise aynı görüntülerden çıkarılan ve logaritmik dönüşüm uygulanmış 7 boyutlu Hu moment vektörüdür. Görüntü girişine uygulanan CNN katmanları ile düşük ve orta düzey görsel öznitelikler öğrenilmiş, bu çıktılar düzleştirme (flatten) ve dropout işlemleri ile son katmanlara hazırlanmıştır. Diğer yandan, Hu momentlerine dayalı 7 boyutlu vektör basit bir tam bağlantılı (dense) katmandan geçirilerek öznitelik uzayı genişletilmiştir. İki öznitelik kümesi, erken füzyon (early fusion) yöntemiyle birleştirilmiş ve ardından tam bağlantılı iki katmandan oluşan sınıflandırıcıya gönderilmiştir. Sonuç katmanında softmax aktivasyonu ile clean ve defect sınıflarına ait olasılıklar elde edilmiştir. Bu yapılandırma sayesinde dönüşümsel değişmezliğe sahip Hu momentleri ile CNN'in örüntü tanıma kapasitesi birleştirilmiş, özellikle sınırlı veri koşullarında daha kararlı ve genellenebilir bir sınıflandırma başarımı sağlanmıştır.

2.6. Eğitim Parametreleri ve Deneysel Ayarlar

Model eğitimi sürecinde her bir beden (Small, Medium, Large) için ayrı ayrı veri ayrımı ve model eğitimi gerçekleştirilmiştir. Eğitim-veri oranı %80, test-veri oranı ise %20 olarak belirlenmiştir. Giriş görüntüleri 64×64 piksel boyutuna yeniden boyutlandırılmış ve 0–1 aralığında normalize edilmiştir. Hu momentleri ise her görüntü için gri tonlamalı hâle getirilmiş sürümden hesaplanmıştır. Sınıflar dengeli olacak şekilde (clean: 1250, defect: 1250) oluşturulmuştur. Tablo 5'te modelin eğitim sürecinde kullanılan temel hiperparametreler ve deneysel ayarlar özetlenmiştir.

Tablo 5. Model Eğitimi İçin Kullanılan Hiperparametreler ve Deneysel Ayarlar

Parametre	Değer / Açıklama
Optimizer	Adam
Öğrenme Oranı	Varsayılan (0.001); ReduceLROnPlateau ile adaptif güncelleme uygulanmıştır
Kayıp Fonksiyonu	Categorical Crossentropy
Aktivasyon Fonksiyonları	ReLU (ara katmanlar), Softmax (çıktı katmanı)
Epoch Sayısı	35 (EarlyStopping ile erken durdurma uygulanmıştır)
Batch Boyutu	32
Dropout Oranları	0.4 (CNN çıkışı), 0.3 (birleşik katman sonrası)
Callback 1	EarlyStopping (patience = 8, val_loss takibi, en iyi ağırlıkların yüklenmesi)
Callback 2	ReduceLROnPlateau (val_loss takibi, patience = 4, factor = 0.5)

Bu parametreler kullanılarak gerçekleştirilen model eğitimi, doğruluk, kayıp, karışıklık matrisi, sınıflandırma raporu ve ROC eğrileri gibi performans göstergeleri ile değerlendirilmiştir. Eğitim sırasında sabit bir random_state değeri ile çalışılmış ve modelin genellenebilirliği korunmuştur.

2.7. Performans Metrikleri

Sınıflandırma modellerinin başarımını değerlendirmek için çeşitli istatistiksel metrikler kullanılmıştır. Bu metriklerin temelini oluşturan kavramlar aşağıda tanımlanmıştır:

- TP (True Positive – Doğru Pozitif): Pozitif sınıfa ait olan ve model tarafından doğru şekilde pozitif olarak tahmin edilen örnek sayısıdır.
- TN (True Negative – Doğru Negatif): Negatif sınıfa ait olan ve model tarafından doğru şekilde negatif olarak tahmin edilen örnek sayısıdır.
- FP (False Positive – Yanlış Pozitif): Negatif sınıfa ait olmasına rağmen model tarafından hatalı şekilde pozitif olarak tahmin edilen örnek sayısıdır.
- FN (False Negative – Yanlış Negatif): Pozitif sınıfa ait olmasına rağmen model tarafından hatalı şekilde negatif olarak tahmin edilen örnek sayısıdır.

Bu temel kavramlara dayalı olarak kullanılan metriklerin matematiksel tanımları aşağıda verilmiştir:

Doğruluk (Accuracy): Modelin doğru tahmin ettiği (hem pozitif hem negatif) örneklerin, toplam örnek sayısına oranıdır ve Denklem 11'deki gibi hesaplanır.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{11}$$

Hassasiyet (Precision): Pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Yanlış pozitifleri azaltma performansını ifade eder ve Denklem 12'deki gibi hesaplanır.

$$Precision = \frac{TP}{TP+FP} \tag{12}$$

Duyarlılık / Gerçek Pozitif Oranı (Recall / Sensitivity): Gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir. Yanlış negatifleri azaltma başarımını ölçer ve Denklem 13'teki gibi hesaplanır.

$$Recall = \frac{TP}{TP+FN} \tag{13}$$

F1 Skoru (F1-Score): Precision ve Recall metriklerinin harmonik ortalamasıdır. Sınıf dengesizliklerinin bulunduğu durumlarda daha adil bir başarı ölçütü sunar ve Denklem 14'teki gibi hesaplanır.

$$F1\ Score = 2\ x\ \frac{Precision\ x\ Recall}{Precision+Recall} \quad (14)$$

3. Bulgular ve Tartışma

3.1. Sınıflandırma Performansı ve Ablation Analizi

Geliştirilen hibrit model, her bir beden kategorisi (S, M, L) için ayrı ayrı eğitilerek test edilmiş ve sınıflandırma performans metrikleri doğrultusunda değerlendirilmiştir. Modelin performansı doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru gibi yaygın ölçütlerle analiz edilmiştir. Her bir sınıf için "Clean" (kusursuz) ve "Defect" (kusurlu) olmak üzere iki kategori altında değerlendirme yapılmıştır. Ayrıca önerilen Hu momentleri ile desteklenen CNN tabanlı hibrit yapının katkısını daha açık gösterebilmek amacıyla ablation analizi gerçekleştirilmiştir. Bu kapsamda yalnızca görüntü girdisini kullanan yalın CNN modeli ile Hu momentleri ve CNN özniteliklerini erken füzyon yaklaşımıyla birleştiren hibrit model karşılaştırılmıştır.

Yalın CNN modelinde yalnızca 64×64 piksel boyutundaki RGB görüntüler kullanılmış; Hu momentlerine dayalı ek yapısal öznitelikler modele dahil edilmemiştir. Buna karşılık önerilen hibrit modelde, CNN tarafından öğrenilen görsel öznitelikler ile her görüntüden çıkarılan yedi boyutlu Hu moment vektörü birleştirilmiştir. Böylece Hu momentlerinin sınıflandırma performansına katkısı doğrudan test edilmiştir.

S (Small) beden görüntüleri için yalın CNN modeli %88.33 doğruluk elde ederken, önerilen hibrit modelin doğruluğu %95'e yükselmiştir. CNN-only modelinde Clean sınıfı için precision 0.8108, recall 1.0000 ve F1-score 0.8955 olarak elde edilmiştir. Defect sınıfında ise precision 1.0000, recall 0.7667 ve F1-score 0.8679 olarak hesaplanmıştır. Bu sonuç, yalın CNN modelinin özellikle kusurlu örneklerin bir kısmını clean sınıfı olarak tahmin etme eğiliminde olduğunu göstermektedir. Hibrit modelde ise S beden grubunda Clean sınıfı için 0.92 precision, 0.98 recall ve 0.95 F1-score; Defect sınıfı için ise 0.98 precision, 0.93 recall ve 0.95 F1-score elde edilmiştir. Bu bulgu, Hu momentlerinin özellikle küçük beden grubunda kusur kaynaklı geometrik farklılıkların daha iyi temsil edilmesine katkı sağladığını göstermektedir.

M (Medium) beden grubunda yalın CNN modeli %94.44 doğruluk değerine ulaşmıştır. Bu modelde Clean sınıfı için precision 0.9762, recall 0.9111 ve F1-score 0.9425; Defect sınıfı için precision 0.9167, recall 0.9778 ve F1-score 0.9462 olarak hesaplanmıştır. Önerilen hibrit model ise M beden grubunda %99 doğruluk elde ederek en yüksek sınıflandırma başarısını göstermiştir. Hibrit modelde Clean sınıfı için precision 0.99, recall 1.00 ve F1-score 0.99; Defect sınıfı için precision 1.00, recall 0.99 ve F1-score 0.99 olarak bulunmuştur. Bu sonuçlar, hibrit modelin M beden grubunda hem clean hem de defect sınıfları için oldukça dengeli ve güçlü bir ayrım performansı sunduğunu ortaya koymaktadır.

L (Large) beden grubunda yalın CNN modeli %93.33 doğruluk elde etmiştir. CNN-only modelinde Clean sınıfı için precision 0.9062, recall 0.9667 ve F1-score 0.9355; Defect sınıfı için precision 0.9643, recall 0.9000 ve F1-score 0.9310 olarak hesaplanmıştır. Önerilen hibrit modelde ise doğruluk %96'ya yükselmiştir. Hibrit modelde Clean sınıfında precision 0.99, recall 0.93 ve F1-score 0.96; Defect sınıfında ise precision 0.94, recall 0.99 ve F1-score 0.96 olarak elde edilmiştir. Bu sonuç, büyük beden grubunda da Hu momentleri ile desteklenen yapının genel sınıflandırma performansını artırdığını göstermektedir.

Tablo 6'da yalın CNN modeli ile önerilen Hu momentleri + CNN tabanlı hibrit modelin her beden grubu için karşılaştırmalı sınıflandırma performansları verilmiştir.

Tablo 6. CNN-only ve Hu+CNN hibrit modellerinin beden bazlı sınıflandırma performansları

Beden	Model	Sınıf	Precision	Recall	F1-Score	Accuracy
S	CNN-only	Clean	0.81	1.0	0.89	0.88
S	CNN-only	Defect	1.0	0.76	0.86	0.88
M	CNN-only	Clean	0.97	0.91	0.94	0.94
M	CNN-only	Defect	0.91	0.97	0.94	0.94
L	CNN-only	Clean	0.90	0.96	0.93	0.93
L	CNN-only	Defect	0.96	0.90	0.93	0.93
S	Hu+CNN Hibrit	Clean	0.92	0.98	0.95	0.95
S	Hu+CNN Hibrit	Defect	0.98	0.93	0.95	0.95
M	Hu+CNN Hibrit	Clean	0.99	1.00	0.99	0.99
M	Hu+CNN Hibrit	Defect	1.00	0.99	0.99	0.99
L	Hu+CNN Hibrit	Clean	0.99	0.93	0.96	0.96
L	Hu+CNN Hibrit	Defect	0.94	0.99	0.96	0.96

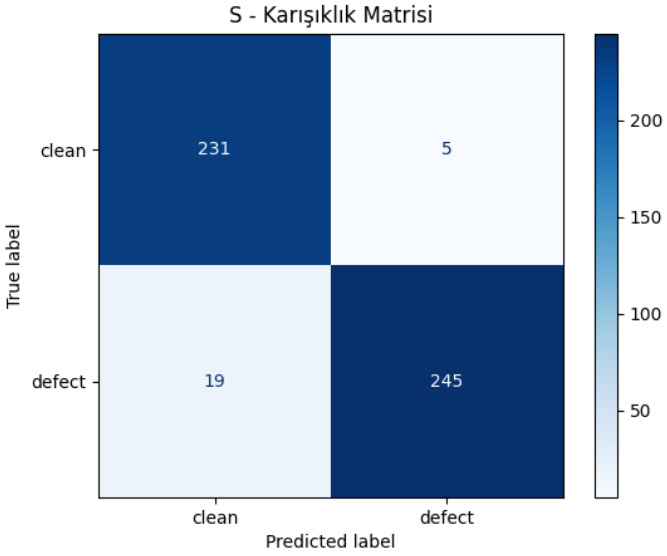
Ablation analizi sonuçları, Hu momentleri ile desteklenen hibrit modelin tüm beden gruplarında yalın CNN modeline kıyasla daha yüksek doğruluk ve F1-score değerleri sunduğunu göstermektedir. Doğruluk açısından değerlendirildiğinde, hibrit model CNN-only modele göre S beden grubunda yaklaşık 6.67 yüzde puan, M beden grubunda 4.56 yüzde puan ve L beden grubunda 2.67 yüzde puan iyileşme sağlamıştır. En belirgin artış S beden grubunda gözlemlenmiştir. Bu durum, küçük ölçekli kalıp/giyim parçası görsellerinde yalnızca CNN tarafından öğrenilen piksel tabanlı özniteliklerin bazı kusurları ayırt etmede yetersiz kalabildiğini; Hu momentleriyle sağlanan geometrik ve yapısal özniteliklerin ise bu ayrımı güçlendirdiğini göstermektedir.

Genel olarak elde edilen bulgular, önerilen Hu+CNN hibrit modelin yalnızca görüntü tabanlı CNN yaklaşımına göre daha dengeli ve daha güçlü bir sınıflandırma performansı sunduğunu ortaya koymaktadır. Bu sonuçlar, Hu momentlerinin dönüşüm-bağımsız geometrik temsil gücünün CNN mimarisiyle birleştirildiğinde clean ve defect sınıflarının ayrımını güçlendirdiğini ve önerilen hibrit yapının hazır giyim kalıp/giyim parçası görsellerinde kusur sınıflandırması için etkili bir yaklaşım olduğunu desteklemektedir.

3.2. Önerilen Hibrit Modelin Karışıklık Matrisi ve ROC Eğrisi Analizi

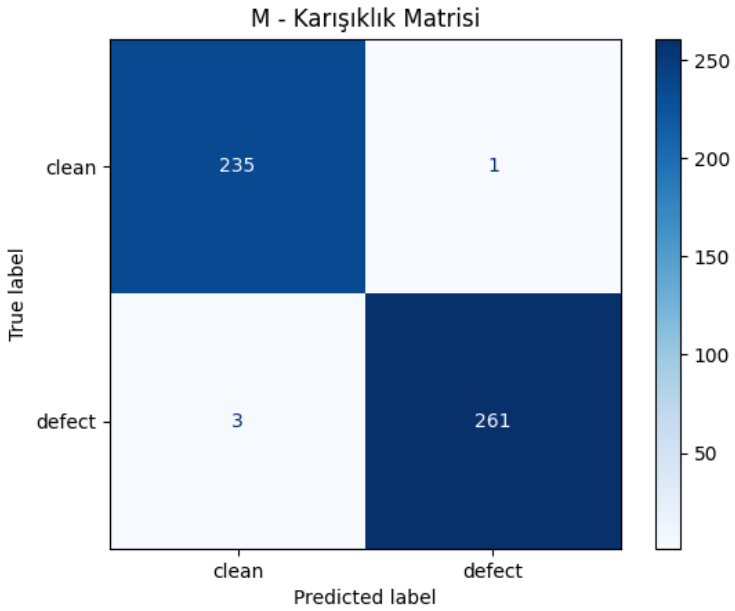
Ablation analizi kapsamında CNN-only model ile önerilen Hu+CNN hibrit model karşılaştırıldıktan sonra, bu bölümde yalnızca çalışmanın temel önerisi olan Hu momentleri ile desteklenen CNN tabanlı hibrit modelin hata dağılımı ve sınıf ayırt etme başarımı ayrıntılı olarak değerlendirilmiştir. Bu amaçla her beden grubu için karışıklık matrisi ve ROC eğrileri incelenmiştir. Karışıklık matrisleri, clean ve defect sınıflarındaki doğru ve hatalı sınıflandırma örüntülerini göstermesi açısından; ROC eğrileri ise modelin sınıflar arasındaki genel ayırt edicilik gücünü değerlendirmek açısından kullanılmıştır.

Sınıflandırma başarısının daha derinlemesine değerlendirilmesi amacıyla karışıklık matrisleri ve ROC (Receiver Operating Characteristic) eğrileri incelenmiştir. Şekil 2'de sunulan S boyutu karışıklık matrisi incelendiğinde, modelin 231 temiz örneği doğru şekilde sınıflandırdığı, buna karşılık 5 temiz örneği hatalı biçimde "defect" olarak tahmin ettiği görülmektedir. Aynı şekilde, 264 kusurlu örnekten 245'i doğru tahmin edilirken, 19 örnekte hatalı negatif sınıflandırma gerçekleşmiştir. Bu durum, modelin özellikle S boyutunda hatalı negatif oranının göreli olarak yüksek olduğunu ortaya koymaktadır.



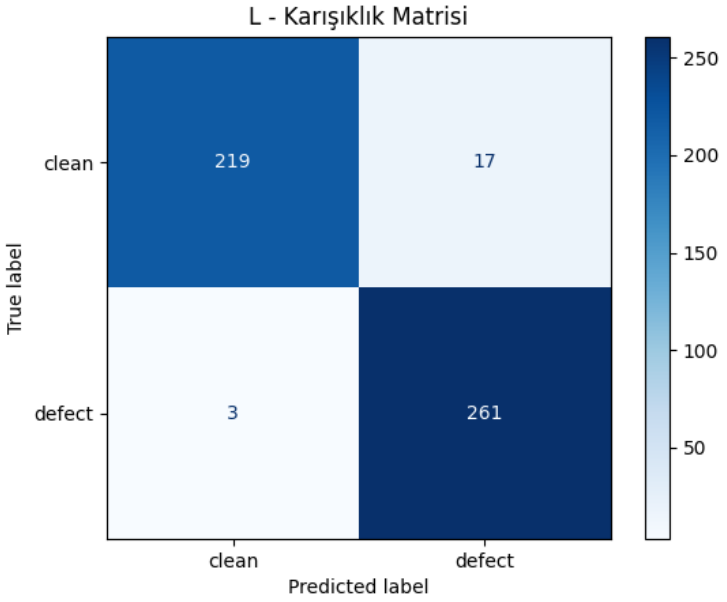
Şekil 1. S Boyutuna Ait Karışıklık Matrisi

Şekil 3'te yer alan M boyutu karışıklık matrisinde ise modelin yalnızca 4 örnekte hata yaptığı, 235 temiz örnekten 234'ünü ve 264 kusurlu örnekten 261'ini doğru sınıflandırdığı gözlemlenmiştir. Bu sonuç, modelin bu boyutta oldukça yüksek tutarlılığa ulaştığını göstermektedir.



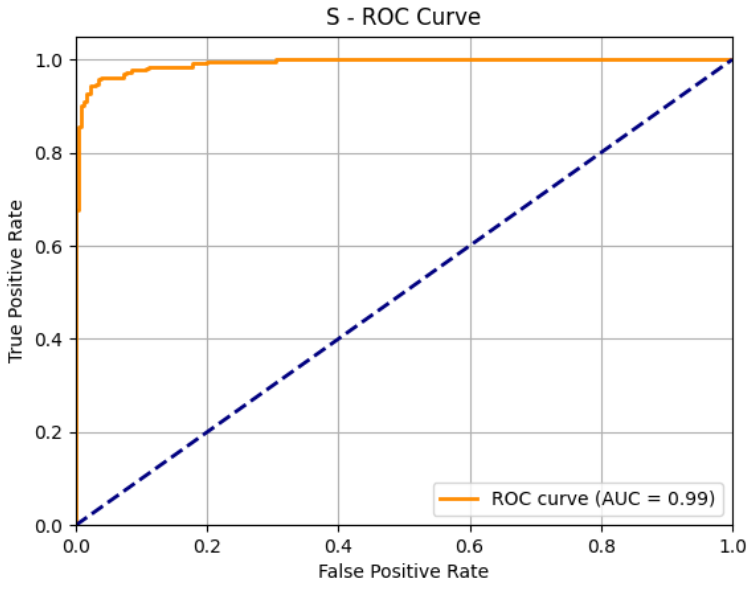
Şekil 2. M Boyutuna Ait Karışıklık Matrisi

L boyutu için Şekil 4'te yer alan matris incelendiğinde, 219 temiz örneğin doğru, 17 tanesinin ise hatalı biçimde kusurlu olarak sınıflandırıldığı; öte yandan 264 kusurlu örnekten 261'inin doğru tahmin edildiği anlaşılmaktadır. Bu da modelin L boyutunda özellikle temiz sınıf üzerindeki yanlış pozitif oranının arttığını ancak genel dengenin korunduğunu göstermektedir.



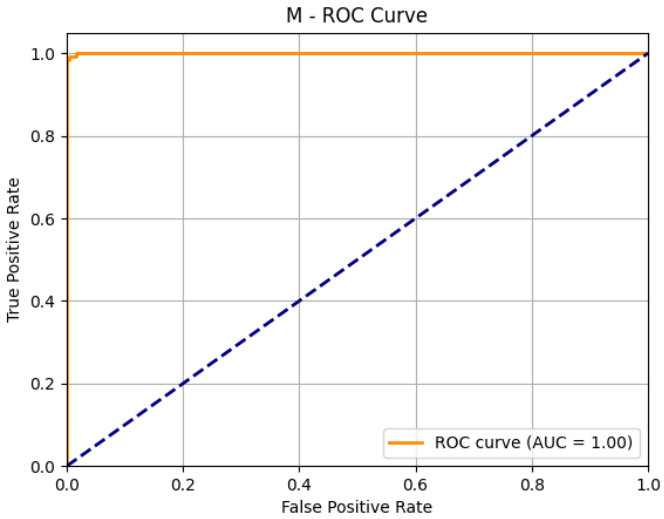
Şekil 3. L Boyutuna Ait Karışıklık Matrisi

ROC eğrileri üzerinden yapılan analizler ise modelin genel ayırt edici gücünü yansıtmaktadır. Şekil 5'te görülen S boyutuna ait ROC eğrisinde AUC (Area Under Curve) değeri 0.99 olarak hesaplanmış ve bu yüksek değer, modelin sınıf ayrım kapasitesinin oldukça güçlü olduğunu ortaya koymuştur.



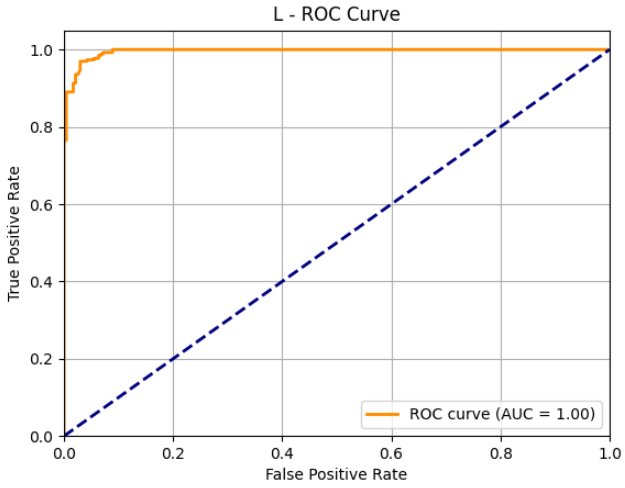
Şekil 4. S Boyutuna Ait ROC Eğrisi

M boyutuna ait ROC eğrisi Şekil 6'da sunulmakta olup, AUC değeri 1.00 olarak hesaplanmıştır. Eğrinin ideal sınıra yakın seyretmesi, modelin M boyutunda neredeyse mükemmel bir ayrım gerçekleştirdiğine işaret etmektedir.



Şekil 5. M Boyutuna Ait ROC Eğrisi

L boyutuna ait ROC eğrisi ise Şekil 7'de verilmiş ve yine 1.00 AUC değeriyle modelin yüksek ayırt ediciliğini koruduğu görülmüştür. Ancak özellikle L boyutunda gözlemlenen temiz sınıfa ait yanlış pozitifler, ROC eğrisine doğrudan yansımamıştır. Bu bulgu, ROC eğrisinin yalnızca genel ayrım performansını sunduğunu, hatalı sınıflandırma türleri (false positive ve false negative) hakkında sınırlı bilgi verdiğini ve bu nedenle karışıklık matrisleriyle birlikte değerlendirilmesinin gerekliliğini göstermektedir.

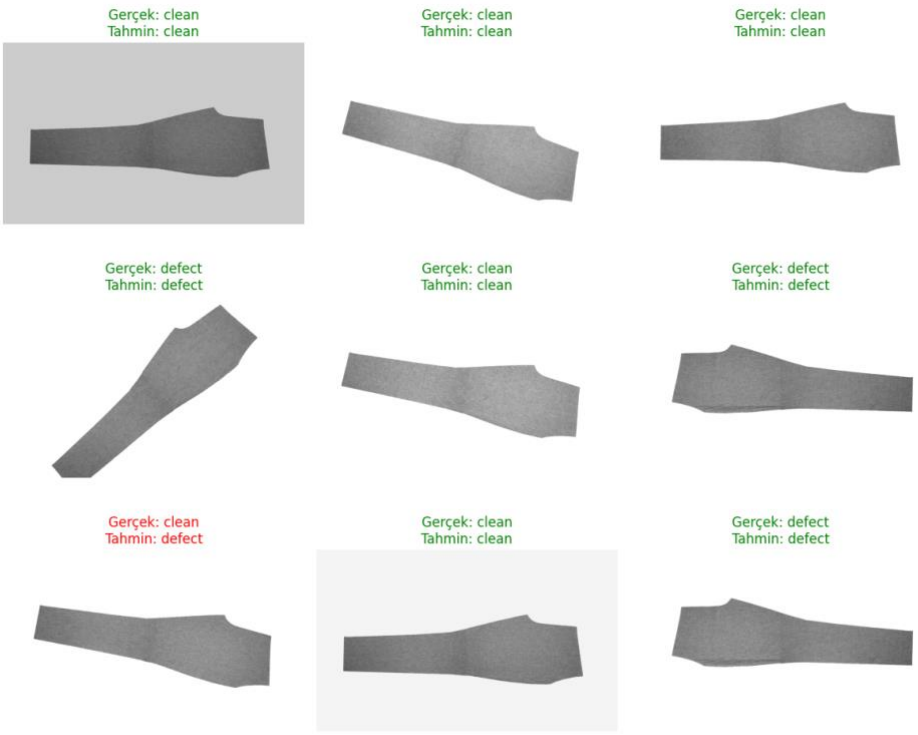


Şekil 6. L Boyutuna Ait ROC Eğrisi

Sonuç olarak, şekillerde sunulan görseller yardımıyla modelin sınıflandırma tutarlılığı, duyarlılığı ve genel başarımı çok boyutlu olarak değerlendirilmiştir.

3.3. Önerilen Hibrit Modelin Doğru ve Hatalı Sınıflandırma Örnekleri

Önerilen Hu+CNN hibrit modelin sınıflandırma performansını yalnızca sayısal metriklerle değil, görsel tahmin örnekleri üzerinden de değerlendirmek amacıyla test veri setinden seçilen bazı örnekler incelenmiştir. Şekil 8'de S, M ve L beden gruplarına ait clean ve defect sınıflarından seçilen örnek görüntüler ile bu görüntülere ilişkin gerçek sınıf ve model tahminleri sunulmuştur. Görselde üst satır S beden grubuna, orta satır M beden grubuna ve alt satır L beden grubuna ait örnekleri göstermektedir. Yeşil renkle belirtilen başlıklar modelin doğru sınıflandırma yaptığı örnekleri, kırmızı renkle belirtilen başlık ise hatalı sınıflandırılan örneği temsil etmektedir.



Şekil 8. S, M ve L beden gruplarına ait clean/defect örneklerinde doğru ve hatalı sınıflandırma sonuçları

Şekil 8 incelendiğinde, önerilen hibrit modelin farklı beden gruplarında hem clean hem de defect sınıflarına ait örnekleri genel olarak doğru biçimde sınıflandırabildiği görülmektedir. Özellikle clean örneklerin clean, defect örneklerin ise defect olarak tahmin edildiği örneklerde modelin kalıp/giyim parçası görsellerindeki temel geometrik formu ve kusur kaynaklı yapısal farklılıkları başarılı biçimde ayırt ettiği anlaşılmaktadır. Bununla birlikte, L beden grubuna ait bir clean örneğin defect olarak tahmin edildiği hatalı sınıflandırma örneği, bazı kalıp/giyim parçası görsellerinde bulunan kenar, kontur veya biçimsel benzerliklerin model tarafından kusur olarak algılanabildiğini

göstermektedir. Bu durum, karışıklık matrisi analizinde özellikle L beden grubunda gözlemlenen yanlış pozitif sınıflandırmalarla uyumludur.

Genel olarak görsel doğrulama örnekleri, önerilen Hu+CNN hibrit modelin clean ve defect sınıflarını farklı beden gruplarında büyük ölçüde başarılı biçimde ayırt edebildiğini göstermektedir. Bunun yanında, sınırlı sayıdaki hatalı tahmin örnekleri modelin özellikle birbirine yakın geometrik özellikler taşıyan clean ve defect görsellerinde daha hassas karar mekanizmalarına ihtiyaç duyabileceğini ortaya koymaktadır. Bu nedenle ilerleyen çalışmalarda daha çeşitli gerçek üretim hattı verileri, farklı kusur türleri ve ek öznitelik çıkarım yöntemleriyle modelin sınıflandırma kararlılığının artırılması hedeflenebilir.

3.4. Tartışma

Gerçekleştirilen deneysel çalışma sonucunda, geliştirilen Hu moment tabanlı hibrit CNN modeli; S, M ve L beden gruplarına ait kalıp/giyim parçası görsellerinde yüksek sınıflandırma doğruluğu elde etmiştir. Özellikle M beden grubu için ulaşılan %99 doğruluk oranı, önerilen modelin clean ve defect sınıflarını ayırt etmede oldukça tutarlı bir performans sergilediğini göstermektedir. Bununla birlikte, S beden grubunda hatalı negatif oranının görece yüksek olması, küçük ölçekli kalıp/giyim parçası görsellerinde kusur kaynaklı geometrik farklılıkların daha hassas biçimde ayırt edilmesi gerektiğine işaret etmektedir. L beden grubunda ise hatalı pozitif sınıflandırmaların artması, modelin bazı yapısal benzerlikleri kusur olarak algılayabildiğini ortaya koymuştur. Bu bulgular, beden grupları arasında ortaya çıkan geometrik varyasyonların sınıflandırma performansı üzerinde etkili olabileceğini göstermektedir.

ROC eğrisi analizleri, her üç beden grubunda da AUC değerlerinin 0.99 ve 1.00 gibi oldukça yüksek seviyelerde olduğunu ortaya koyarak önerilen hibrit modelin sınıf ayırt etme gücünün başarılı olduğunu doğrulamıştır. Bu bağlamda modelin özellikle defect sınıfını tanımadaki başarısı dikkat çekicidir. Çalışmanın en güçlü yönlerinden biri, klasik görüntü işleme tabanlı geometrik öznitelikler ile derin öğrenme tabanlı görsel öznitelikleri birlikte değerlendirmesidir. Hu momentlerinin dönüşüm-bağımsız yapısal temsil gücü, CNN mimarisinin otomatik örüntü öğrenme kapasitesiyle birleştirilerek daha dengeli ve güçlü bir sınıflandırma yapısı elde edilmiştir. Ayrıca ablation analizi sonuçları, önerilen Hu+CNN hibrit modelin yalın CNN modeline kıyasla tüm beden gruplarında daha yüksek doğruluk ve F1-score değerleri sunduğunu göstermiştir. Bu durum, Hu momentlerinin kalıp/giyim parçası görsellerindeki kenar, kontur ve geometrik form farklılıklarını temsil etmede modele ek katkı sağladığını desteklemektedir.

Bununla birlikte, çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle veri kümesi gerçek kumaş/kalıp görsellerine dayanmakla birlikte, dengeli bir eğitim yapısı oluşturmak amacıyla veri

artırma yöntemleriyle çoğaltılmıştır. Bu durum modelin farklı konum, ölçek ve ışık değişimlerine karşı daha dayanıklı öğrenmesini desteklese de, veri artırma işlemleri gerçek üretim ortamlarında karşılaşılabilecek tüm kumaş türlerini, kamera açılarını, ışık koşullarını, deformasyon şiddetlerini ve kusur çeşitliliğini tamamen temsil etmeyebilir. Ayrıca çalışmada kusurlar buruşma, kumaş içi boşluk, kenar-kontur düzensizliği ve form bozulması gibi gerçek kusur özelliklerini içermekle birlikte, modelleme sürecinde bu kusurlar ayrı alt sınıflar hâlinde değil, genel clean/defect ayrımı çerçevesinde değerlendirilmiştir. Bu nedenle model, farklı kusur türlerini ayrı ayrı tanıyabilen çok sınıflı bir yapı olarak değil, gerçek kusurlu ve kusursuz örnekleri ayırmaya yönelik ikili sınıflandırma modeli olarak ele alınmıştır.

4. Sonuçlar ve Öneriler

Bu çalışmada, klasik görüntü işleme yöntemlerinden biri olan Hu momentleri ile evrişimli sinir ağı (CNN) mimarisini birleştiren hibrit bir model önerilmiş ve bu model hazır giyim ve konfeksiyon alanında kalıp/giyim parçası görsellerindeki yapısal kusurların sınıflandırılması amacıyla uygulanmıştır. Small (S), Medium (M) ve Large (L) beden gruplarına ait clean ve defect sınıflarından oluşan görüntüler üzerinde gerçekleştirilen deneyler, önerilen hibrit modelin tüm beden gruplarında yüksek sınıflandırma başarımı elde ettiğini göstermiştir. Özellikle M beden grubunda ulaşılan %99 doğruluk oranı, modelin kalıp/giyim parçası görsellerindeki clean ve defect ayrımını oldukça tutarlı biçimde gerçekleştirebildiğini ortaya koymuştur.

Karışıklık matrisi ve ROC eğrisi analizleri, önerilen hibrit modelin sınıf ayrım gücünün yüksek olduğunu ve doğru sınıflandırma performansı açısından başarılı sonuçlar sunduğunu göstermiştir. Ayrıca ablation analizi kapsamında, yalnızca görüntü girdisini kullanan yalın CNN modeli ile önerilen Hu+CNN hibrit model karşılaştırılmıştır. Elde edilen bulgular, Hu momentleriyle desteklenen hibrit yapının tüm beden gruplarında CNN-only modele kıyasla daha yüksek doğruluk ve F1-score değerleri sağladığını göstermiştir. Bu sonuç, Hu momentlerinin kenar, kontur ve geometrik form farklılıklarını temsil etmedeki katkısının CNN mimarisinin görsel örüntü öğrenme kapasitesini desteklediğini ortaya koymaktadır.

Hu momentlerinin düşük hesaplama maliyeti ve geometrik dönüşümlere karşı dayanıklı yapısı, CNN'in öğrenme kapasitesi ile birleştirildiğinde hem doğruluk hem de uygulanabilirlik açısından dengeli bir sınıflandırma yapısı elde edilmiştir. Özellikle öznitelik seviyesinde gerçekleştirilen erken füzyon stratejisi, geleneksel geometrik öznitelikler ile derin öğrenme tabanlı görsel özniteliklerin birlikte değerlendirilmesine imkân sağlamış ve model başarısına olumlu katkıda bulunmuştur. Bu yönüyle önerilen yaklaşım, sınırlı veri koşullarında çalışan ve hızlı karar verme gereksinimi bulunan hazır giyim kalite kontrol uygulamaları için etkili bir alternatif sunmaktadır.

Gelecek çalışmalarda, önerilen hibrit modelin gerçek üretim hattından elde edilecek kalıp/giyim parçası görselleri üzerinde test edilmesi, modelin saha koşullarındaki genelleme kabiliyetinin değerlendirilmesi açısından önemli olacaktır. Ayrıca yalnızca clean/defect ayrımı yerine, kenar bozulması, kontur deformasyonu, eksik bölge, biçimsel düzensizlik ve benzeri farklı yapısal kusur türlerini ayırt edebilen çok sınıflı modeller geliştirilebilir. Bunun yanında, Zernike momentleri, HOG ve LBP gibi farklı klasik öznitelik çıkarım yöntemlerinin hibrit yapıya entegre edilerek Hu momentleriyle karşılaştırmalı biçimde analiz edilmesi, modelin öznitelik çeşitliliği açısından daha kapsamlı değerlendirilmesini sağlayacaktır. Modelin termal, mikroskobik veya farklı ışık spektrumlarına sahip görüntüler üzerinde test edilmesi de dayanıklılığını ve genelleme yeteneğini ortaya koymak açısından değerlidir. Son olarak, gerçek zamanlı kalite kontrol sistemlerine entegrasyon, transfer öğrenme ve meta-öğrenme gibi stratejilerle modelin farklı veri koşullarına uyarlanabilirliği artırılabilir. Tüm bu yönelimler göz önüne alındığında, geliştirilen Hu+CNN hibrit modelin hazır giyim ve konfeksiyon kalite kontrol süreçlerinde hızlı, etkili ve yüksek doğrulukta karar verebilen sistemler için güçlü bir temel oluşturduğu söylenebilir.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

AbuRass, S., Huneiti, A., Al-Zoubi, M. B. (2020). Enhancing convolutional neural network using Hu's moments. International Journal of Advanced Computer Science and Applications, 11(12), 130-137. doi:10.14569/IJACSA.2020.0111216.

Ahanin, Z., Ismail, M. A., Singh, N. S. S., Al-Ashmori, A. (2023). Hybrid feature extraction for multi-label emotion classification in English text messages. Sustainability, 15(16), 12539. doi:10.3390/su151612539.

Basha, S. H. S., Dubey, S. R., Pulabaigari, V., Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. Neurocomputing, 378, 112-119. doi:10.1016/j.neucom.2019.10.008.

Bohrer, J. da S., Dorn, M. (2024). Enhancing classification with hybrid feature selection: A multi-objective genetic algorithm for high-dimensional data. Expert Systems with Applications, 255, 124518. doi:10.1016/j.eswa.2024.124518.

Dhanya, P., Praseeda, M., Choudhari, M. R., Kshema, B. S. (2024, August). Design and implementation of 2D object similarity detection using Hu's moments. 2024 4th Asian Conference on Innovation in Technology (ASIANCON) (pp. 1-5). Pune, India: IEEE.

Dhillon, A., Verma, G. K. (2020). Convolutional neural network: A review of models, methodologies and applications to object detection. Progress in Artificial Intelligence, 9, 85-112. doi:10.1007/s13748-019-00203-0.

Haruna, Y., Qin, S., Chukkol, A. H. A., Yusuf, A. A., Bello, I., Lawan, A. (2025). Exploring the synergies of hybrid convolutional neural network and Vision Transformer architectures for computer vision: A survey. Engineering Applications of Artificial Intelligence, 144, 110057. doi:10.1016/j.engappai.2025.110057.

Kalaivani, A., Jayapriya, P., Devi, S. (2024, December). Innovative approaches in deep neural networks: Enhancing performance through transfer learning techniques. 2024 3rd International Conference on Automation, Computing and Renewable Systems (ICACRS) (pp. 857-864). Pudukkottai, India: IEEE. doi:10.1109/ICACRS62842.2024.10841600.

Khan, A., Sohail, A., Zahoora, U., Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. Artificial Intelligence Review, 53(8), 5455-5516. doi:10.1007/s10462-020-09825-6.

Li, G., Li, B., Tan, S., Qiu, G. (2023). Learning deep co-occurrence features. IEEE Transactions on Circuits and Systems for Video Technology, 33(4), 1610-1623.

Li, L., Li, Q., Liu, Z., Xue, L. (2023). Effective fabric defect detection model for high-resolution images. Applied Sciences, 13(18), 10500. doi:10.3390/app131810500.

Li, M., Wang, H., Yang, L., Liang, Y., Shang, Z., Wan, H. (2020). Fast hybrid dimensionality reduction method for classification based on feature selection and grouped feature extraction. Expert Systems with Applications, 150, 113277. doi:10.1016/j.eswa.2020.113277.

Liu, H., Kyosev, Y., Jiang, G., Dong, Z. (2023). Realistic fabric rendering with yarn models. Textile Research Journal, 93(15-16), 3552-3563. doi:10.1177/00405175231154534.

Mohammed, S. S., Gökalp Clarke, H. (2024). Conditional image-to-image translation generative adversarial network (cGAN) for fabric defect data augmentation. Neural Computing and Applications, 36(32), 20231-20244. doi:10.1007/s00521-024-10179-1.

Montazeri, Z., Gammelmark, S. B., Zhao, S., Jensen, H. W. (2020). A practical ply-based appearance model of woven fabrics. ACM Transactions on Graphics, 39(6), 251:1-251:13. doi:10.1145/3414685.3417777.

Moosavi, S. K. R., Saadat, A., Abaid, Z., Ni, W., Li, K., Guizani, M. (2024). Feature selection based on dataset variance optimization using hybrid sine cosine-firehawk algorithm (HSCFHA). Future Generation Computer Systems, 155, 272-286. doi:10.1016/j.future.2024.02.017.

Obi, J. C. (2023). A comparative study of several classification metrics and their performances on data. World Journal of Advanced Engineering Technology and Sciences, 8(1), 308-314. doi:10.30574/wjaets.2023.8.1.0054.

Quinton, F., Presles, B., Leclerc, S., Nodari, G., Lopez, O., Chevallier, O., Pellegrinelli, J., Vrigneaud, J.-M., Popoff, R., Meriaudeau, F., Alberini, J.-L. (2024). Navigating the nuances: Comparative analysis and hyperparameter optimisation of neural architectures on contrast-enhanced MRI for liver and liver tumour segmentation. Scientific Reports, 14, 3522. doi:10.1038/s41598-024-53528-9.

Ren, W., Song, K., Chen, C.-Y., Chen, Y., Hong, J., Fan, M., Ouyang, X., Zhu, Y., Xiao, J. (2025). DD-Aug: A knowledge-to-image synthetic data augmentation pipeline for industrial defect detection. IEEE Transactions on Industrial Informatics, 21(3), 2284-2293. doi:10.1109/TII.2024.3495786.

Ren, Y., Yang, J., Zhang, Q., Guo, Z. (2021). Ship recognition based on Hu invariant moments and convolutional neural network for video surveillance. Multimedia Tools and Applications, 80, 1343-1373. doi:10.1007/s11042-020-09574-2.

Schneider, L., Krasowski, A., Pitchika, V., Bombeck, L., Schwendicke, F., Büttner, M. (2025). Assessment of CNNs, Transformers, and hybrid architectures in dental image segmentation. Journal of Dentistry, 156, 105668. doi:10.1016/j.jdent.2025.105668.

Singh, B. K., Rai, A., Kundu, K., Kalita, K., Agrawal, R. (2024, March). An empirical analysis of invariance Hu's moment feature over a digital image. 2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO) (pp. 1-5). Noida, India: IEEE. doi:10.1109/ICRITO61523.2024.10522255.

Theodoris, C. V., Xiao, L., Chopra, A., Chaffin, M. D., Al Sayed, Z. R., Hill, M. C., Mantineo, H., Brydon, E. M., Zeng, Z., Liu, X. S., Ellinor, P. T. (2023). Transfer learning enables predictions in network biology. Nature, 618(7965), 616-624. doi:10.1038/s41586-023-06139-9.

Wei, B., Xu, B., Hao, K., Gao, L. (2022). Textile defect detection using multilevel and attentional deep learning network (MLMA-Net). Textile Research Journal, 92(19-20), 3462-3477. doi:10.1177/00405175211073773.

Xu, Y., Zhi, C., Wang, S., Chen, J., Sun, R., Dong, Z., Yu, L. (2024). FabricGAN: An enhanced generative adversarial network for data augmentation and improved fabric defect detection. Textile Research Journal, 94(15-16), 1771-1785. doi:10.1177/00405175241237479.

Zaeri, N. (2018, March). Hu Li moments for low-resolution thermal face recognition. 2018 UKSim-AMSS 20th International Conference on Computer Modelling and Simulation (UKSim) (pp. 79-83). Cambridge, United Kingdom: IEEE. doi:10.1109/UKSim.2018.00026.

Zhang, T., Li, Z., Jing, X., Hu, B., Zhu, Y. (2020). Research on low-resolution pattern coding recognition method based on Hu-DBN. Journal of Northwestern Polytechnical University, 38(6), 1218-1224. doi:10.1051/jnwpu/20203861218.