

Hayvan Derisinin Kusur Tespitinde Makine Öğrenmesi Tekniklerinin Kullanımı – Literatür Taraması

Hasan Onur ATAÇ^{1*}, Ahmet KAYABAŞI¹, Mehmet Fatih ASLAN¹

¹ Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Karaman, Türkiye

Alındı/Received: 20/05/2024; Kabul/Accepted: 25/06/2024; Yayın/Published: 11/12/2024

* Sorumlu yazar e-posta: hasanonuratac@gmail.com

Öz

Derinin insan hayatında ilk çağlardan beri var olduğu tahmin edilmektedir. Nitekim ilk başlarda sadece soğuktan ve rüzgârdan korunmak için kullanıldığı düşünülürken günümüzde deri, dayanıklılığı ve estetikliği sebebiyle moda, mobilya ve otomotiv gibi devasa sektörlerde çok geniş bir kullanım alanına sahiptir. Küresel deri pazarı her geçen yıl daha da büyümektedir. Bu durum deri üretiminde akıllı yaklaşımların önemini her geçen gün artırmaktadır. Tabakhanelerde deri ürünlerindeki yüzey kusurlarını tespit edebilmek için tecrübeli insan denetçilerin kullanılması uzun zamandır süregelen bir uygulamadır. Ancak bu yöntem, yorucu, zaman alıcı, hatalara açık ve kişinin tecrübesine göre değişkendir. Kaliteli deri ürünlerinde hata payının düşük olması ekonomik olarak ciddi öneme sahiptir. Sektördeki insan hatalarından kurtulmak ve verilen kararları nesnelleştirebilmek adına deri yüzeyindeki kusurların otomatik tespit edilebilmesi ihtiyacı ortaya çıkmıştır. Bu çalışmada hayvan derisinin kusurlarını tespit edebilmek amacı ile makine öğrenmesi tekniklerini kullanan çalışmalar hakkında literatür taraması yapılmıştır. Görüntü analizi ve makine öğrenmesi yöntemleri ile deri yüzeylerindeki kusurları tespit etme yöntemlerinin detaylı bir incelemesi yapılmıştır. Bu alanda gelecekte yapılacak çalışmalarını teşvik etmek amacı ile zorluklar ve gelişim evreleri sunulmuştur.

Anahtar Kelimeler: Hayvan derisi, yüzey kusur tespiti, bilgisayar görüşü, makine öğrenmesi

Use of Machine Learning Techniques in Defect Detection of Leather - Review

Abstract

It is estimated that leather has existed in human life since ancient times. As a matter of fact, while it was initially thought that it was used only to protect from cold and wind, today leather has a wide range of usage in huge sectors such as fashion, furniture, and automotive due to its durability and aesthetics. The global leather market is growing every year. This situation increases the importance of smart approaches in leather production day by day. It has been a long-standing practice for tanneries to use experienced human inspectors to detect surface defects in leather products. However, this method is tiring, time-consuming, prone to errors, and varies depending on the person's experience. A low margin of error in determining the quality of leather products is of serious economic importance. In order to get rid of human errors in the sector and to objectify the decisions made, the need to automatically detect flaws on the leather surface has emerged. In this study, a literature review was conducted on studies using machine learning techniques to detect defects in animal leather. A detailed review of methods for detecting defects on leather surfaces using image analysis and machine learning methods was conducted. Challenges and stages of development are presented with the aim of encouraging future work in this field.

Key Words: Leather, surface defect detection, computer vision, machine learning

Atıf / To cite: Ataç HO, Kayabaşı A, Aslan MF M (2024). Hayvan Derisinin Kusur Tespitinde Makine Öğrenmesi Tekniklerinin Kullanımı – Literatür Taraması. Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi, 6(2): 58-67.

1. GİRİŞ

Hayvan derisi, tarih boyunca insanların yaşamını kolaylaştıran çeşitli ürünlerin temel malzemesi olarak kullanılmıştır. İlk insanlar hayvan derisini giyim ve barınma ihtiyaçlarını karşılamak için kullanmaya başladılar (Liong ve ark. 2020). Bu dönemde deri, avcılar

doğal etkenlerden korunurken aynı zamanda sığınakların dayanıklılığını artırmak için kullanıldı. Daha sonralarda tarımın gelişmesiyle birlikte deri kullanımı daha da çeşitlendi ve artık çantalar, kovalar, su depoları,

ayakkabılar gibi günlük eşyaların yapımında yaygın olarak kullanılmaktadır (Smith ve ark. 2023).

2020'de, deri ve deri ürünlerinin yıllık ticaret hacmi 80 Milyar \$'ı geçerek dünya genelinde en fazla ticareti yapılan ürünlerden biri olarak kabul edilmiştir (Omoloso ve ark. 2021). Bu sayı 2003 yılında yaklaşık 40 Milyar \$ olarak hesaplanmıştır (Doble ve ark. 2007). Sadece 17 yılda 2 kat büyüme yaşanan deri ve deri ürünleri sektöründeki üretimin büyük kısmı Türkiye gibi gelişmekte olan ülkelerde yapılmaktadır (Branca ve ark. 1996). Ekonomik ve teknolojik ilerlemeler sayesinde Türkiye'de deri ve deri mamulleri üretimi ile ihracatı her geçen gün artmaktadır. Türkiye İstatistik Kurumu (TÜİK) verilerine göre, 2020'de en çok üretilen deri türü 4.358.732 adetle koyun derisi olmuştur. Onu, 3.228.632 adetle sığır derisi takip etmiştir (TÜİK 2020). Deri ve deri mamulleri sektörü ihracatı ise 2021'de %38,6 oranında artarak 1,9 milyar \$ seviyesine ulaşmıştır. Ayakkabılar, sektördeki en büyük ihraç kalemi olarak %56,9'luk bir paya sahiptir. Deri eşyalar, ham ve işlenmiş deri ürünleri ile postlar ve kürklerin ihracattaki payları ise sırasıyla %21,7, %13,3 ve %8'dir (Ticaret Bakanlığı 2022).

Taze kesilmiş hayvanlardan soyulan deri genellikle kürk veya ham deri olarak bilinir. Yağdan arındırma, tüy giderme, kromlama gibi işlemlerden sonra mavi bir renk alır. Bu form genellikle ıslak mavi deri olarak adlandırılır. Deri işleme aşamalarının yarı mamulüdür (Chen ve ark. 2021). Deriden üretilen ürünler güçlü, pahalı ve dayanıklıdır dolayısıyla onlarca yıl kullanılabilir. Ayrıca lüks tüketimde de yaygın olarak kullanılmaktadır. Bu nedenle sektörün maksimum kar elde edebilmesi ve müşterilerden iyi geri bildirim alabilmesi için hatasız ürün üretmesi çok önemlidir (Ghimire ve ark. 2022). Dünya standartlarında, kaliteli ürünler üretebilmek için kullanılan derinin hatasız olduğundan emin olmak gerekir. Ancak çoğu deri parçaları, böcek ısırıkları, kesikler, lekeler ve kırışıklıklar gibi doğal kökenlerinin izlerini taşır (Liong ve ark. 2019). Deri yüzey kusurlarının geleneksel tespiti ve sınıflandırılması, insanların temelde tutarsız olması ve bu tür basit ve tekrarlanan görevler için uygun olmaması nedeniyle önemli sayıda kusuru gözden kaçırma eğiliminde olan insan denetçiler tarafından gerçekleştirilir. Sorunun zor doğasından dolayı, otomatik deri yüzey kusur muayenesi üzerine nispeten az sayıda çalışma yapılmıştır. Görünümleri ve boyutları büyük ölçüde farklılık gösterdiğinden kesin denetim modellerini oluşturmak çok zordur. Aynı kusur sınıfına ait olsalar bile aynı şekil ve büyüklükte iki kusur bulmak neredeyse imkansızdır (Kwak ve ark. 2001). Ayrıca, manuel denetimler yavaş ve emek yoğun işlerdir. Yorumu açıklığı nedeni ile farklı uzmanlar arasında görüş ayrılıkları meydana gelmektedir (Pereira ve ark.). Bu faktörler deri endüstrisini kısıtlayan darboğazlar haline gelmiştir (Kohli ve Garg 2013). Tüm bu nedenlerle, kusur inceleme prosedürüne yardımcı olmak için deri parçaları üzerinde dijital görüntü işleme gibi insandan bağımsız bir metot ile otomatik kalite denetimi yapılması önemlidir. Ancak literatürde konuyu araştıran nispeten az sayıda araştırmacı bulunmaktadır (Liong ve ark. 2019). Bu çalışmada otomatik deri kusur tespiti ile ilgili literatür çeşitli perspektiflerden incelenmiştir.

2. DERİ KALİTESİ VE KUSURLARI

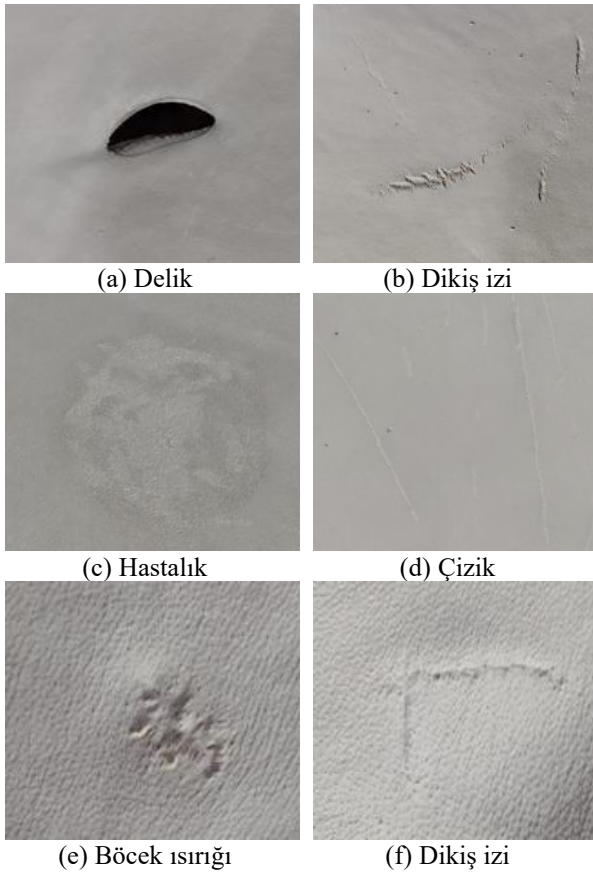
2.1. Deride kalite

Deri endüstrisi, et endüstrisinin yan ürünü olarak değerlendirilse de derinin kullanım alanının çok geniş olması, insan hayatına olan doğrudan ya da dolaylı etkilerinin çok olması gibi nedenlerden dolayı büyük öneme sahiptir. İnsanlık tarihi boyunca birçok farklı amaç için kullanılmıştır. Deri ilk çağlarda soğuktan ve çevresel faktörlerden korunmak amaçlı giyim ve barınak alanlarında kullanılmış olsa da (Liong ve ark. 2020) zaman içinde tarımın gelişmesi ile çanta, ayakkabı gibi gündelik ihtiyaç malzemelerinin yapımında kendisine yer bulmuştur. Günümüzde lüks tüketim sektöründe de çok büyük bir paya sahip olan deri, birçok alanda alternatifleri çıkmış olsa da insanlar tarafından rağbet görmeye devam etmektedir. Dünyadaki deri üretim miktarları incelendiğinde üretimdeki %60'lık büyük payın gelişmekte olan ülkeler tarafından karşılandığı ve bu payın gün geçtikçe arttığı görülmektedir (Branca ve ark. 1996). Endüstri devriminden beri toplu üretim söz konusu olduğunda imalat endüstrisi her zaman kaliteyi artırırken maliyetleri düşürmeyi hedeflemiştir. Yüzey kusurları derinin kalitesini belirlemede çok önemli bir etkiye sahiptir. Günümüzde deri üzerinde kusur tespiti hala insan denetçiler tarafından göz ile yapılmaktadır. Ancak bu yöntem zaman alıcı, yorucu, sıkıcı ve kişinin tecrübelerine göre değişkendir (Khanal ve ark. 2022). Bu nedenle deri yüzeyi kusur tespitini otomatik hale getirebilecek bir sistemin geliştirilmesine olan ihtiyaç önem arz etmektedir. Kontrol sistemleri birçok sektörde manuel insan operasyonlarının yerini alabilmiş olsa da deri yüzeyindeki kusur tespiti işinde hala dünya çapında standart olarak kullanılabilecek bir yaklaşım benimsenememiştir. Deride kalite üretim maliyetinin yaklaşık %50-70'ini oluşturduğu için en önemli unsurdur (Aslam ve ark. 2019).

2.2. Deri kusurları

Yaygın olarak, post ve derilerdeki kusurlar, antemortem (hayvanın ölümünden önce), postmortem (hayvanın ölümünden sonra) ve işleme kusurları olarak sınıflandırılır. Hayvanların yaşamları boyunca meydana gelebilecek olası kusurlar marka ve damgalama işaretleri, kene izleri, hastalık izleri, böcek ısırıkları, yaralar, çizikler, büyüme izleri vb.'dir. Ölüm sonrasında ise kesim kaynaklı hatalar (delikler, çizikler vb.), saklama koşulları yanlışsa meydana gelen hatalar (tuz lekeleri, çürümeler vb.) ve tabaklama hataları (et kesikleri, yarılma nedeniyle eşit olmayan kalınlıklar, kimyasal kaynaklı kusurlar, nem kaynaklı kusurlar vb.) olarak sınıflandırılabilir. Şekil 1'de ıslak mavi formdaki deri fotoğraflarında çeşitli kusurların örnekleri gösterilmiştir.

Deri kalitesinin derecelendirilmesi için ülkeler farklı ilkeler benimsemiştir. Bazı ülkelerde 3'lü sınıflandırma kullanılırken bazılarında ise 4'lü sınıflandırma metodu uygulanmaktadır. Genel olarak ufak değişikliklere rağmen ülkeler benzer derecelendirme ilkeleri kullanırlar. Örnek bir standart sınıflandırma ilkesi Tablo 1'te verilmiştir.



Şekil 1. Kromlama aşamasında deri kusur örnekleri

Tablo 1. Deride kalite sınıfları

1.Sınıf	Düzenli ve iyi kürlenmiş, çürüme belirtisi olmayan, genel olarak kusursuz ya da çok az kusurlu (sadece birkaç çizik izi veya karın bölgesinde bir delik), marka izi yok, böcek ısırıkları yok ya da çok az (birkaç adet).
2.Sınıf	Düzenli ve iyi kürlenmiş, çürüme belirtisi olmayan, az kusurlu (alt kısımda birkaç küçük delik ve/veya çizik), dış kısma yakın münferit bölgelerde birkaç çeşit/adet kusur, 18cm'den küçük bir marka izi, 10 ile 20 adet arası böcek ısırığı.
3.Sınıf	Kötü desenli veya bozuk görünümlü, ufak çürüme belirtili, kusurlar deri yüzeyinin %30'una kadar yayılmış, marka izli ve genellikle 18 cm'den büyük, 10 ile 20 adet arası böcek ısırığı, leke ve idrar izleri bariz.
4.Sınıf	Çok kötü desenli veya bozuk görünümlü, çürüme belirtileri yoğun, kusurlar deri yüzeyinin %50'sine kadar yayılmış, böcek ısırıkları genellikle çok fazla.

Derecelendirme ilkeleri hem alıcılar hem satıcılar için afaki öneme sahiptir. Genel olarak ilkeler sektörde küresel çapta kabul edilmiş olsa da insan yorumuna dayandıkları için karışıklıklar sık sık meydana gelmektedir. İlkelerin uygulanabilmesi için makinelerin yorumlarına dayanan bir otomasyon ihtiyacı ortaya çıkmıştır.

2.3. Kusur Tanımlamaları

Belirli bir kusura odaklanan sınıflandırıcılar ile yapılan birçok çalışma literatürde mevcuttur. Geçmişten

günümüze bu yöntemler ile birçok farklı kusur tipine odaklanılarak yüksek başarı oranları elde edilmiş olsa da kusur çeşitleri çok fazla olduğu için tamamında yüksek başarı gösteren bir sınıflandırıcı henüz uygulanamamıştır. Bu metodlar genellikle öznelite çıkarma ve desen sınıflandırma olarak 2 ana başlıkta gerçekleşir.

2.3.1. Kusurlarda Öznelite Çıkarmı

Deri kusurlarının tespit edilebilmesi için kusurların özneliteklarının çıkartılması geniş kullanıma sahip bir yöntemdir (Ding ve ark. 2020). Bu sayede kusursuz alan/kusurlu alan ve kusur tipleri aralarındaki farkların matematiksel olarak ifade edilebilmesi sağlanır. Resmin özneliteklarını çıkarmak için renk özellikleri, desen özellikleri, şekil özellikleri, spektral özellikleri ve istatistiksel özellikleri tabanlı metodlar ön plana çıkmaktadır.

Tablo 2. Zaman içinde deri kusurlarında öznelite çıkarmı

Çalışma	Öznelite Çıkarmı Yolu
Wang ve ark. (1992)	Tahmini lokal yoğunluk, histogram güç spektrumu özellikleri
Tafari ve ark. (1996)	Deneme yanılma yoluyla yönlendirilmiş akış alanı modellemesi
Branca ve ark. (1996)	Desen yapısının değiştiği her bölgeye bir parametre vektörü atayıp, daha sonrasında bu vektörleri filtreleme yöntemi ile
Branca ve ark. (1997)	Çoklu çözünürlüklü analizle yönlendirilmiş akış alanı tahmini
Kwak ve ark. (2000)	Normalize edilen ölçülendirme ile geometrik ve istatistiksel özellikler
Georgieva ve ark. (2003)	χ^2 -kriteri ile desen üzerinde kalite tespiti
(Krastev ve ark. 2004; Krastev ve Georgieva 2005)	Histogram özellikleri
Sobral ve ark. (2005)	Optimize edilmiş filtrelerin her birini bir dalgalık alt bandına uygulayarak boyut ve şekil bilgilerine göre ayırma
Peters ve Koenig (2007)	1D&2D konvolüsyon çekirdekleri
Amorim ve ark. (2009)	HSB ve RGB uzaylarında öznelite çıkarmı, gabor filtresi
Jian ve ark. (2010)	Geometrik özelliklerine göre (uzunluk, genişlik, alan, çevre, doku, renk) öznelite çıkarmı
Kasi ve ark. (2014)	Otomatik uyarlamalı bir kenar algılama algoritması
Wu ve ark. (2016)	Bir görüntü özelliğini, iyileştirme olmadan alt görüntünün gri seviye farkı ile karşılaştırma (istatistiksel)
Liong ve ark. (2019)	Mask R-CNN (Mask Regional Convolutional Neural Network)

2.3.1.1. Kusur Öznelite Çıkarmında Renk Özellikleri

Renk özelliği, ölçek değiştirme, döndürme gibi değişkenlerden bağımsız olarak kullanılabilirdiği için birçok çalışmada kullanılmıştır. Bong ve ark. (2018), 6 adımlı bir muayene yöntemi ile deri kusur tespitinde SVM (Support Vector Machines) yaklaşımını kullanmıştır.

RGB (Red-Green-Blue) görüntülerin her bir renk kanalındaki ortalama, standart sapma, çarpıklık değerini hesaplamış daha sonra resmi griye çevirip her bir kanalda renk momenti ve gri momenti birleştirilerek görüntünün renk modelini oluşturmuştur. Bu bilgi kullanılarak SVM yardımı ile %98'den yüksek doğruluk oranına ulaşılmıştır.

Amorim ve ark. (2010), deri yüzey kusurlarını tespit edebilmek için HSB (Hue-Saturation-Blur) ve RGB'nin her bir renk bileşenin ortalama değerini alıp histogram değerini çıkardılar. Bu verileri C4.5, kNN (k-Nearest Neighbor), Naive Bayes ve SVM olmak üzere 4 farklı sınıflandırıcı ile değerlendirdiler. Islak mavi deri ve ham deri örnekleri üzerinde yaptıkları kusur sınıflandırma işlemlerinde en yüksek %95,9 doğruluk oranına kNN ile ulaşmışlardır.

2.3.1.2. Kusur Öznitelik Çıkarımında Doku ve Geometri Özellikleri

Cisimlerin doku özellikleri 3 ayrı kategoride incelenmektedir. Bunlar güçlü sıralı doku, zayıf sıralı doku ve sırasız doku olarak isimlendirilir (Rao 2012). Güçlü sıralı dokular tekrarlayan desenler içerirlerken zayıf sıralı dokular, dokunun çeşitli noktalarında farklı desenler içerebilir. Bunların aksine sırasız dokular ise tekrarlama yönelimi göstermez ancak pürüzlülüklerine göre tanımlanabilir. Deri, yapısı itibari ile sırasız doku kategorisine girer. Geometrik olarak deri kusurları 3 türde incelenebilir. Bunlar noktasal, çizgisel ve yüzeyel kusurlardır.

Bowman ve ark. (1996), zor tanımlanan kusurları tespit edebilmek için lazer kaynaklı floresan görüntüler için otomatik bir kusur tespit yöntemi geliştirmişlerdir. Çok boyutlu özellikler kullanılarak (renk, doku, kenar, yoğunluk) koyun derisi üzerindeki kusurlar tespit edilmiştir. Pistori ve arkadaşları (Amorim ve ark. 2010; Viana ve ark. 2007; Pistori ve ark. 2018), deri kusur tespitinde doku analizi ve makine öğrenimi yöntemlerini denemişlerdir. Doku özelliklerini çıkarmak için entropi, ters fark momenti, farklılık, kolerasyon, kontrast, açısız ikinci moment gibi yöntemlerden faydalanmışlardır. Renk özelliklerine göre de HSB uzayında histogramları incelenmiş olup SVM, MLP gibi algoritmalar ile makine öğrenmesi yöntemleri uygulanmıştır. Amorim ve ark. (2010), 12'si HSB ve RGB uzayı, 7'si etkileşim haritaları, 12'si birlikte oluşum matrisi ve 17'si gabor filtresi olmak üzere toplamda 160 renk-doku özniteliği çıkarılmıştır. Bu öznitelikler, C4.5, KNN, Naive Bayes ve Destek Vektör Makineleri (SVM) isminde dört farklı sınıflandırıcı kullanılarak deri kusur sınıflandırma problemine uygulanmıştır. FisherFace, CLDA, DLDA ve YLDA olmak üzere dört doğrusal diskriminant analiz tekniği ile bir nitelik azaltma karşılaştırmalı çalışması sunulmuştur.

Jian ve ark. (2010), derinin geometrik özelliklerine göre kusur özelliklerini araştırmışlardır. Deri örneklerinin dış dikdörtgeninin uzunluğuna, genişliğine, alanına, çevresine, dokusuna ve rengine göre özniteliklerini çıkararak sinir ağları ve karar ağaçları yardımı ile sınıflandırma yapmışlardır.

2.3.1.3. Kusur Öznitelik Çıkarımında Cisimlerin Spektral Özellikleri

Kenar tespiti gibi pek çok yaygın düşük seviyeli istatistiksel yaklaşım, yoğunluktaki ince geçişler nedeniyle çeşitli deri kusurlarını ortadan kaldırır. Bu nedenle deri kusurlarını tespit etmek için diğer sağlam ve etkili bilgisayarlı görme yaklaşımlarını keşfetmek çok önemlidir. Filtre dönüşümü, görüntüyü uzamsal alandan frekans alanına veya zaman-frekans alanına dönüştürür. Örnek olarak Fourier dönüşümü, dalgacık dönüşümü ve Gabor dönüşümü yaygın olarak kullanılır. Fourier dönüşümü görüntüyü bir frekans alanına dönüştürür ve dokuyu ifade etmek için spektral enerjiyi veya spektral entropiyi kullanır. Periyodiklik, yönlülük ve rastgelelik dokuyu karakterize eden üç önemli faktördür (Rao ve Lohse 1993). Deri gibi düzenli ve periyodik bir yapı, spektral özelliklerin kusurları tespit etmek için kullanılmasını kolaylaştırır. Ancak rastgele dokulu görüntülerde, gri tonlarının dağılımı genellikle daha rastgele olduğundan, bu tür dokuların spektral analizleri kusurlarını tespit etmek için uygun değildir. Yani, rastgele dokulu malzemelerde, periyodik bir desen olmadığı için spektral yaklaşımlar etkili değildir. Öte yandan dalgacık dönüşümü, bir görüntünün frekans bileşenlerini analiz etme yeteneğinden dolayı, özellikle deri kusurlarının tanınması gibi görevlerde, görüntü işlemede kullanılan güçlü bir tekniktir.

Düşük ve yüksek frekanslı ayrıntılar arasında ayırım yaparak görüntüyü çeşitli ölçeklere böler. Yüksek frekanslı alt bant görüntüleri, görüntünün dokusundaki ince desenleri ortaya çıkardığından, bu çoklu çözünürlüklü yaklaşım özellikle doku ayrıntılarının yakalanması açısından değerlidir. Piramit dalgacık dönüşümü gibi geleneksel yöntemler öncelikle düşük frekanslı bileşenlere odaklanır ve çoğu zaman yüksek frekanslı alanlarda bulunan temel özellikleri gözden kaçırmaz. Bununla birlikte, dalgacık paket ayrıştırması ve ağaç yapısı dalgacık ayrıştırması hem düşük hem de yüksek frekanslı alt bantları kapsamlı bir şekilde inceleyerek bu sınırlamayı giderir ve hiçbir kritik bilginin kaçırılmamasını sağlar. Bu gelişmiş teknikler, görüntüde mevcut olan doku özelliklerinin tüm spektrumunu analiz ederek deri üzerindeki kusurların tanınmasında etkilidir.

Fuqiang ve ark. (2006), ortalama, standart sapma, entropi, basıklık ve enerji özellikleri gibi spektral özellikleri kullanmışlardır. Aynı şekilde Jawahar ve ark. (2014), deri görüntülerinden entropi, enerji, kontrast, korelasyon, kümelenme önemi, standart sapma, ortalama değer gibi dalgacık istatistiksel özelliklerini ve dalgacık birlikte oluşum matrisi özelliklerini çıkarmak için dalgacık dönüşümünü kullanmıştır. Sobral (2005), hal dalgacık dönüşümü ve sekiz optimize edilmiş filtre kullanarak doku özelliklerini çıkardı. Branca ve ark. (1997), vektör bilgi anormalliklerini baz olarak çeşitli doku bölgelerini filtreledi. Küçük kusurların gözden kaçmasını engellemek için filtre boyutları ayarlandı. Villar ve ark. (2011), Fourier dönüşümü, kosinüs dönüşümü, gabor özellikleri, hu momentleri vb. kullanarak 2002 öznitelik çıkardı.

2.3.1.4. Kusur Öznitelik Çıkarımında Cisimlerin İstatistiksel Özellikleri

Deri görüntülerinin doku özelliği çıkarımında, yaygın olarak kullanılan istatistiksel özellikler arasında histogram özelliği ve gri düzey birlikte oluşum matrisi (GLCM) özelliği yer almaktadır. GLCM görüntü uzayında belirli bir mesafeyle ayrılmış iki piksel arasında belli bir gri ilişki olduğunu kabul eder. Yaygın olarak kullanılan özellik miktarları kontrast, korelasyon, enerji, entropi ve otokorelasyondur (Chen ve ark. 2022). Sousa ve ark. (2021), ıslak mavi formdaki keçi derilerinde yaptıkları çalışmalarında kusur tespiti ve kategorileme işlemi yapmışlardır. Öznitelik çıkarımı için Yerel İkili Model (LBP) ve GLCM yöntemlerini kullanmışlardır. Moganam ve Seelan (2020) tarafından toplam 2000 kusurlu ve kusursuz fotoğraftan oluşan veri kümesini kullanarak kusurluları 0 kusursuzları 1 olarak etiketleme yapılmıştır. Kusurlu ve kusursuz derinin ayrımı için GLCM kullanılmıştır.

Öte yandan histogram, bir görüntüdeki farklı piksel değerlerinin sıklığını gösteren grafiksel bir gösterimdir. En yüksek ve en düşük yoğunluklar, ortalama değerler ve piksel değerlerinin yayılması gibi bilgileri sunarak bir görüntünün görsel özelliklerini analiz etmek için güçlü bir araç görevi görür. Histogramlardan elde edilen ortalama, medyan ve aralık gibi temel özellikler görüntünün kontrast ve parlaklık düzeylerine ilişkin bilgiler sunar. Ek olarak entropi ve varyans gibi ölçümler bize görüntünün dokusu ve karmaşıklığı hakkında bilgi verir. Daha da önemlisi, histogram özellikleri piksellerin uzamsal düzenlenmesinden etkilenmez, bu da onları öteleme ve döndürme gibi görüntü dönüşümlerine karşı dayanıklı kılar. Gan ve ark. (2021), 2 veri kümesi üzerinde çalışıp birincisinde çıplak gözle daha rahat fark edildikleri için koyu çizgi kusurlarına odaklanmışlardır. İkincisinde ise böcek ısırtığı kusur tipine odaklanmışlardır. Histogramın incelenmesi için Kolmogorov-Smirnov testi (Conover 1965) uygulanmıştır. Öznitelik sayısını azaltmak için eşikleme yapılmıştır. Pistori ve arkadaşları (Amorim ve ark. 2010; Viana ve ark. 2007; Pistori ve ark. 2018), GLCM ve histogram özelliklerini kullanarak toplamda 63 birlikte oluşum ve 3 renk özelliği çıkarmışlardır. Histogram özelliklerini çıkarırken HSB renk uzayının her kanalı ayrı kullanılmıştır. Ding ve ark. (2020), etkileşim haritaları, birlikte oluşum ve renk özelliklerini kullanarak resimlerin özniteliklerini çıkarmıştır. Kwon ve ark. (2004), ortalama, varyans, standart sapma, düz alanın uç noktası, genişlik, düz alan sayısı ve kutupların konumunu içeren histogramı kullanarak kusurları analiz etti. Bu histogram özelliklerini kullanarak iğne deliği, çizik, kırışıklık hataları gibi kusurlar başarıyla tespit edilirken diğer birkaç kusur gözden kaçırıldı. Krastev ve ark. (Georgieva ve ark. 2003; Krastev ve diğerleri 2004; Krastev ve Georgieva 2005) deri kusurlarının tanımlanmasında histogram uç seviyeleri, medyan, ortalama, varyans ve doku özellikleri gibi önerilen özellikler kullanılmıştır.

2.3.2. Desen Sınıflandırma

Desen sınıflandırma deri kusur tespiti çalışmalarında çok önemli bir yere sahiptir. Araştırmacılar, çeşitli kusur

desenlerini/modellerini analiz ederek düzensizlikleri yüksek doğrulukla kategorize etmeyi amaçlayan karmaşık sınıflandırıcılar geliştirmektedir. Bu sınıflandırıcılar, karmaşık kusur modellerinin sınıflandırma algoritmaları tarafından etkili bir şekilde kullanılabilir yapıya dönüştürülmesine olanak tanıyan çeşitli öznitelik çıkarma teknikleri kullanılarak eğitilir. Uygulanan teknikler arasında 2.3.1 başlığı altında belirtilen renk, doku, geometrik, istatistiksel gibi özellikler kullanılmaktadır. Eğitim sırasında kusur modellerinden kapsamlı bir öznitelik vektörü üretilir ve sonraki sınıflandırma sürecinin temelini oluşturur.

Kusur desenleri öznitelik vektörlerine dönüştürüldükten sonraki adım, herhangi bir örtüşmeyi belirlemek için bilinen kusur desenleri ile titiz bir karşılaştırma yapmaktır. Bu, çıkarılan özelliklerin benzerliğini inceleyen desen sınıflandırma algoritmalarının uygulanmasıyla elde edilir. Benzerlik derecesi, cildin belirli bir bölgesindeki kusurların varlığının bir göstergesi olarak kabul edilir. Araştırmacılar, desen sınıflandırma yöntemlerinden yararlanarak çeşitli kusur türlerinin tespit doğruluğunu önemli ölçüde artırabilir. Bu sistematik yaklaşım, yalnızca hayvan derisindeki kusur analizinin ilerlemesine katkıda bulunmakla kalmaz, aynı zamanda geniş bir kusur dizisine uyum sağlayabilen daha genelleştirilmiş sınıflandırıcıların geliştirilmesinin yolunu da açar.



Şekil 2. Deri kusur tespitinde öznitelik çıkarımı ve desen sınıflandırma adımları

3. MAKİNE ÖĞRENMESİ TABANLI KUSUR TANIMLAMALARI

Geleneksel deri yüzey kusuru tanımlama yaklaşımı, farklı türdeki kusurları ayırt etmek için çeşitli görüntü özelliklerinin çıkarılmasını içeren desen tanıma algoritmalarının kullanımına dayanır. Bu özellikler genel olarak dört gruba ayrılabilir: birinci dereceden istatistiksel ölçümler, ikinci dereceden istatistiksel ölçümler, spektral ölçümler ve görüntü seviyesi tanımlayıcılar. Birinci

dereceden istatistiksel ölçümler, görüntünün yoğunluk dağılımına ilişkin genel bir anlayış sağlayan ortalama, varyans ve çarpıklık gibi temel görüntü özelliklerini kapsar. İkinci dereceden istatistiksel ölçümler ise komşu pikseller arasındaki mekânsal ilişkilerin karakterize edilmesinde önemli olan kontrast, korelasyon ve homojenlik dahil olmak üzere doku özelliklerinin analizini içerir. Frekans alanının analizini içeren spektral ölçümler, periyodik modeller sergileyen kusurların belirlenmesinde faydalıdır.

Yerel ikili desenler ve Gabor özellikleri gibi görüntü düzeyinde tanımlayıcılar, yerel doku desenlerini ve kenarlarını yakalayarak görüntünün daha ayrıntılı bir temsilini sağlar. Çıkarılan bu özellikleri farklı kusur kategorilerine sınıflandırmak için çeşitli makine öğrenme algoritmaları kullanılır. Deri yüzeyindeki kusurların tanımlanmasında en yaygın kullanılan algoritmalarından bazıları arasında k-En Yakın Komşu (kNN), Sinir Ağı (NN), Destek Vektör Makinesi (SVM), Bayesian Ağı (Bayes) ve Karar Ağacı (DT) yer alır. Örneğin kNN algoritması, belirli bir özellik kümesine en yakın eşleşmeleri bularak kusurları tanımlarken, NN algoritması, özellikler arasındaki kalıpları ve ilişkileri öğrenmek için birbirine bağlı düğümlerden oluşan karmaşık bir ağ kullanır. Gürültüye ve yüksek boyutlu verilere karşı dayanıklılığıyla bilinen SVM algoritması, sınıflar arasındaki marjı maksimuma çıkaran optimal hiperdüzlemi bularak kusurları farklı sınıflara ayırır. Olasılık teorisine dayanan Bayes algoritması, kusurların tanımlanması için olasılıksal bir çerçeve sağlarken, DT algoritması, kusurları bir dizi kural ve koşula göre sınıflandırmak için ağaç benzeri bir model kullanır. Bu algoritmaları çıkarılan görüntü özellikleriyle birleştirerek deri yüzey kusurlarını tespit etmek için doğru ve güvenilir bir sistem geliştirilmeye çalışılmıştır.

Literatürde makine öğrenmesi yöntemlerini kullanarak yapılan birçok çalışmada %90 üzerinde başarıya ulaşılmıştır. Örneğin (Gan ve ark. 2021; Gan ve ark. 2022) SVM, DT, kNN, NN, Bayes sınıflandırıcılarını kullanarak %99 ve %94, Jawahar ve ark. (2014), SVM kullanarak %98.8, Moganam ve Seelan (2020), NN sınıflandırıcı ile %94.2, Santos ve ark. (2020) Naive Bayes ve SVM kullanarak 93.2, hatta Pistori ve diğerleri (2018) kNN, SVM, NN kullanıp kNN ile %100 doğruluk oranına ulaşmışlardır. Ancak bu oranlar bu yöntemlerin küçük veri kümeleri üzerinde değerlendirilmesinden kaynaklıdır (Aslam ve ark. 2019). Ayrıca endüstriyel uygulamalardaki deri yüzey kusurlarından çok farklıdır (Chen ve ark. 2022). Pratikte deri yüzey kusur şekilleri rasgele ve değişkendir. Bir görüntüde ondan fazla kusur bulunabilir.

4. DERİN ÖĞRENME TABANLI KUSUR TANIMLAMALARI

Derin öğrenme (DL) sayesinde bir makine, her ağ katmanındaki parametre ayarlarını geri yayılım algoritmaları ile tekrar tekrar düzenlemektedir. Bu sayede derin öğrenme, büyük veri kümeleri gibi karmaşık

yapılarda başarısını ciddi miktarda artırmaktadır. Derin öğrenme konuşma tanıma, nesne algılama, nesne tanıma gibi alanlarda kullanılıp etkisini kanıtlamıştır (LeCun ve ark. 2015).

Deri yüzey kusurlarının lokasyon tespiti ve tanımlanması gibi konularda kullanımı gün geçtikçe artmaktadır. Hayvan derilerinde kusur tespitinde derin öğrenmenin kullanılmasının deri endüstrisi için birçok potansiyel faydası vardır. Birincisi, manuel denetim ihtiyacını azaltmaya yardımcı olarak personelin daha yüksek değerli görevlere odaklanmasına olanak tanır. Ek olarak, derin öğrenme algoritmaları otomatik sistemlere entegre edilebilir ve böylece gerçek zamanlı kusur tespiti ve derilerin sınıflandırılması mümkün olur. Bu, üretim sürecinin verimliliğini ve doğruluğunu artırmaya yardımcı olurken aynı zamanda israfı azaltıp nihai ürünün genel kalitesini de artırabilir. Ayrıca, derin öğrenme algoritmaları, yeni veriler elde edildikçe sürekli olarak güncellenebilir ve iyileştirilebilir; bu da onların, deri kalitesindeki değişen kalıplara ve trendlere uyum sağlamasına olanak tanır. Tablo 3'te derin öğrenme metodları ile kusur tespiti ve tanımlanması yapılan çalışmalar gösterilmiştir.

4. SONUÇ VE ÖNERİLER

Deri yüzey kusurlarının deri kalitesine doğrudan etkisi olmasından dolayı, bu kusurların tespit hassasiyeti dericilik sektörü için muazzam öneme sahiptir. Bu sebepten deri görüntülerindeki kusurların tespiti için yıllar boyunca birçok yöntem önerilmiştir. Her ne kadar bazı araştırmacıların çalışmalarında çok yüksek tespit oranı yakalanmış olsa da bu değerler hala sektördeki gerçek çalışma koşullarına aktarılamamıştır. Bu çalışmada, deri kusurlarının tespiti konusunda literatür taranmış olup, mevcut çalışmaların öznetelik çıkarma yöntemleri ve daha sonrasında yapılan tespit işlemi için makine öğrenmesi yöntemlerinin alt branşları sırasıyla sunulmuştur. Bu yöntemlerin analizleri, sonuçları, performansları değerlendirilmiştir. Tartışılan yöntem ve sistemler 1992'den itibaren yayınlanmış dikkate değer çalışmalardır.

Literatürdeki çalışmalar incelendiğinde ekseriyetinin küçük boyutlu fotoğraflardan oluşan veri kümeleri üzerinde çalıştığı görülmüş olup gerçek tabakhane üretimlerinde deri boyutlarının ortalama 2m x 3m olmasından dolayı çalışmalarda yüksek başarı oranları tabakhanelere aktarılamamaktadır. Gelecekteki çalışmacıların daha yüksek çözünürlüklü fotoğraflar üzerinden çalışmasının, gerçek tabakhane koşullarına daha uygun olacağı kanaatindeyiz. Ayrıca özellikle derin öğrenme metodlarının doğruluk oranlarını artırma konusunda veri çok önemli olduğu için, veri çoğaltma (data augmentation) metodları kullanılmasını öneririz.

ÇIKAR ÇATIŞMASI

Yazarlar arasında bir çıkar çatışması olmadığını beyan ederler.

Tablo 3. Deri kusur tespiti ve tanımlanmasında derin öğrenme kullanılan çalışmalar

Çalışma Sahibi	DL Methodu	Doğruluk Oranı	Kusur Tipi
Winiarti ve ark. (2018)	AlexNet + SVM	%99.97	Kusursuz, kertenkele, timsah, koyun, keçi, inek
Liong ve ark. (2019)	Mask R-CNN	%70.35	Kene ısırığı
Deng ve ark. (2020)	ResNet50	%94.6	Kusursuz, çizik, delik, böcek ısırığı
Liong ve ark. (2020)	AlexNet	%94.67	Kusursuz, çizik, kırışıklık
Ding ve ark. (2020)	CNN	%90	Siyah nokta, çürük, çizik, kan tendonu, boyun çizgileri, delik, mühür, yara izi, kesik
Gan ve ark. (2021)	AlexNet + SVM	%100	Kusursuz, Kesik
Chen ve ark. (2021)	1D-CNN, 2DUnet, 3D-Unet	%96	Mühür, çürük, yırtık, böcek ısırığı, çizik
Gan ve ark. (2022)	Alexnet + GAN*	%100	Kusursuz, siyah çizgi, kırışıklık
Chen ve ark. (2023)	26 Adet DL modeli (en iyi sonuç DenseNet169)	%72,5	Oyuk, iğne deliği, çizik, çürük, büyüme çizgisi, yara, kırışıklık, bakteri yarası
Yuan ve ark. (2023)	LWAFC** + Yolov5s	%89	Çizik, leke
Gan ve ark. (2023)	AlexNet + SVM + Yolov2 + Faster R-CNN	%73.47	-
Iqbal ve ark. (2023)	MLR-Net***	%85.9	-
Prananda ve Frannita (2023)	Nasnet	%86.03	Kusursuz, katlanma izleri, büyüme izleri, hafif ezilmeler, iğne deliği
Abdullah ve ark. (2024)	Inception V3-CNN + Mask R-CNN	%99	Kusursuz, kusurlu
Chen ve ark. (2024)	Yolov1'den Yolov8'e kadar (v8 dahil) tüm modeller	%52.3 (birden fazla kusur tipi) %85.1 (tek kusur tipi)	Oyuk, iğne deliği, çizik, çürük, büyüme çizgisi, yara, kırışıklık, bakteri yarası

*GAN: Generative adversarial network (Üretken rekabet ağı)

**LWAFC: Large window attention-based full connection (Geniş Pencere Dikkat Temelli Tam Bağlantı)

***MLR-Net: Multi-layer residual convolutional neural network (Çok katmanlı artık evrişimli sinir ağı)

KAYNAKLAR

- Abdullah AB, Jawahar M, Manogaran N, Subbiah G, Seeranagan K, Balusamy B, Saravanan AC (2024). Leather Image Quality Classification and Defect Detection System using Mask Region-based Convolution Neural Network Model. *International Journal of Advanced Computer Science & Applications*, 15(4).
- Amorim WP, Pistori H, Jacinto MAC, Sudeste EP (2009). A comparative analysis of attribute reduction algorithms applied to wet-blue leather defects classification. *Brazilian Symposium on Computer Graphics and Image Processing*, 2009(1):1-2.
- Amorim WP, Pistori H, Pereira MC, Jacinto MAC (2010). Attributes reduction applied to leather defects classification. *Patterns and Images*, 2010(1): 353-359.
- Aslam M, Khan TM, Naqvi SS, Holmes G, Naffa R (2019). On the application of automated machine vision for leather defect inspection and grading: a survey. *IEEE Access*, 7: 176065-176086.
- Bong HQ, Truong QB, Nguyen HC, Nguyen MT (2018). Vision-based inspection system for leather surface defect detection and classification. 5th NAFOSTED conference on information and computer science (NICS). Ho Chi Minh City, Vietnam.
- Bowman CC, Hilton PJ, Power PW, Hayes MP, Gabric RP (1996). Sheep-pelt grading using laser scanning and pattern recognition. *Machine vision applications, architectures, and systems integration*, SPIE, 1996(2908): 33-42.
- Branca A, Abbate MG, Lovergine FP, Attolico G, Distante A (1997). Leather inspection through singularities detection using wavelet transforms. *Image Analysis and Processing: 9th International Conference, ICIAP'97*. Florence, Italy.

- Branca A, Lovergine FP, Attolico G, Distante A (1997). Defect detection on leather by oriented singularities. *Computer Analysis of Images and Patterns*. 7th International Conference, CAIP'97. Kiel, Germany.
- Branca A, Tafuri M, Attolico G, Distante A (1996). Automated system for detection and classification of leather defects. *Optical Engineering*, 35(12): 3485-3494.
- Chen SY, Cheng YC, Yang WL, Wang MY (2021). Surface defect detection of wet-blue leather using hyperspectral imaging. *IEEE Access*, 2021(9): 127685-127702.
- Chen Z, Deng J, Zhu Q, Wang H, Chen Y (2022). A systematic review of machine-vision-based leather surface defect inspection. *Electronics*, 11(15): 2383.
- Chen Z, Xu D, Deng J, Chen Y, Li C (2023). Comparative study on deep-learning-based leather surface defect identification. *Measurement Science and Technology*, 35(1): 015402.
- Chen Z, Zhu Q, Zhou X, Deng J, Song W (2024). Experimental Study on YOLO-based Leather Surface Defect Detection. *IEEE Access*, 2024(12): 32830-32848.
- Conover W (1965). Several k-sample Kolmogorov-Smirnov tests. *The Annals of Mathematical Statistics*, 36(3): 1019-1026.
- Deng J, Liu J, Wu C, Zhong T, Gu G, Ling BWK (2020). A novel framework for classifying leather surface defects based on a parameter optimized residual network. *IEEE Access*, 8: 192109-192118.
- Ding C, Huang H, Ming P (2020). Inspection method of leather defect based on convolutional neural network and salient feature. *Donghua University Natural Sciences*, 2020(46): 408-413.
- Fuqiang H, Wen W, Zichen C (2006). Automatic defects detection based on adaptive wavelet packets for leather manufacture, In *Technology and Innovation Conference (ITIC)*. Hangzhou, China.
- Gan YS, Chee SS, Huang YC, Liong ST, Yau WC (2021). Automated leather defect inspection using statistical approach on image intensity. *Journal of Ambient Intelligence and Humanized Computing*, 12: 9269-9285.
- Gan YS, Liong ST, Zheng D, Xia Y, Wu S, Lin M, Huang YC (2023). Detection and localization of defects on natural leather surfaces. *Journal of Ambient Intelligence and Humanized Computing*, 2023(1): 1-15.
- Gan YS, Liong ST, Zheng D, Xia Y, Wu S, Lin M, Huang YC (2021). Detection and localization of defects on natural leather surfaces. *Journal of Ambient Intelligence and Humanized Computing*, 2021(1): 1-15.
- Gan YS, Yau WC, Liong ST, Chen CC (2022). Automated classification system for tick-bite defect on leather. *Mathematical Problems in Engineering*, 2022(1): 1-12.
- Georgieva L, Krastev K, Angelov N (2003). Identification of surface leather defects. *Proceedings of the 4th international conference on Computer systems and technologies, CompSysTech*. New York, United States.
- Ghimire A, Mahaseth A, Thapa R, Magar SA, Singh SK, Khanal SR (2022). Leather Defect Segmentation Using Semantic Segmentation Algorithms. *Journal of Artificial Intelligence and Capsule Networks*, 2022(2): 131-138.
- Iqbal S, Khan TM, Naqvi SS, Holmes G (2023). MLR-Net: A multi-layer residual convolutional neural network for leather defect segmentation. *Engineering Applications of Artificial Intelligence*, 126: 107007.
- Jawahar M, Babu NKC, Vani K (2014). Leather texture classification using wavelet feature extraction technique. *2014 IEEE International Conference on Computational Intelligence and Computing Research*. TamilNadu, India.
- Jian L, Wei H, Bin H (2010). Research on inspection and classification of leather surface defects based on neural network and decision tree. *International conference on computer design and applications*. Qinhuangdao, China.
- Kasi MK, Rao JB, Sahu VK (2014). Identification of leather defects using an autoadaptive edge detection image processing algorithm. *International conference on high performance computing and applications (ICHPCA)*. Bhubaneswar, India.
- Khanal SR, Silva J, Magalhães L, Soares J, Gonzalez DG, Castilla YC, Ferreira MJ (2022). Leather Defect Detection Using Semantic Segmentation: A Hardware platform and software prototype. *Procedia Computer Science*, 2022(204): 573-580.
- Kohli P, Garg S (2013). Leather quality estimation using an automated machine vision system. *IOSR Journal of Electronics and Communication Engineering*, 2013(6): 44-47.
- Krastev K, Georgieva L (2005). Identification of leather surface defects using fuzzy logic. *Proceedings of the International Conference on Computer Systems and Technologies*. Washington, United States.
- Krastev K, Georgieva L, Angelov N (2004). Leather features selection for defects recognition using fuzzy logic. *Energy*, 2004(3): 1-6.

- Kwak C, Ventura JA, Tofang-Sazi K (2000). A neural network approach for defect identification and classification on leather fabric. *Journal of Intelligent Manufacturing*, 2000(11): 485-499.
- Kwak C, Ventura JA, Tofang-Sazi K (2001). Automated defect inspection and classification of leather fabric. *Intelligent Data Analysis*, 2001(4): 355-370.
- Kwon JW, Choo YY, Choi HH, Cho JM, KiI GS (2004). Development of leather quality discrimination system by texture analysis. *Region 10 Conference TENCON*. Chiang Mai, Thailand.
- LeCun Y, Bengio Y, Hinton G (2015). Deep learning. *Nature*, 2015(1): 436-444.
- Liong ST, Gan YS, Huang YC, Yuan CA, Chang HC (2019). Automatic defect segmentation on leather with deep learning. *arXiv preprint arXiv: 1903.12139*.
- Liong ST, Gan YS, Liu KH, Binh TQ, Le CT, Wu CA, Yang CY, Huang YC (2019). Efficient neural network approaches for leather defect classification. *arXiv preprint arXiv: 1906.06446*.
- Liong ST, Zheng D, Huang YC, Gan YS (2020). Leather defect classification and segmentation using deep learning architecture. *International Journal of Computer Integrated Manufacturing*, 2020(33): 10-11.
- Moganam PK, Seelan DAS (2020). Perceptron Neural Network Based Machine Learning Approaches for Leather Defect Detection and Classification. *Instrumentation, Measures, Métrologies*, 2020(6): 421-429.
- Doble M, Rollins K, Kumar A (2007). *Industrial examples in Green Chemistry and Engineering*. Academic Press.
- Omoloso O, Mortimer K, Wise WR, Jraisat L (2021). Sustainability research in the leather industry: A critical review of progress and opportunities for future research. *Journal of Cleaner Production*, 2021(285): 421-429.
- Pereira RF, Dias MLD, de Sá Medeiros CM, Rebouças Filho PP (2018). Classification of Failures in Goat Leather Samples Using Computer Vision and Machine Learning. *SIBGRAPI 2018*. Foz do Iguaçu, Brazil.
- Peters S, Koenig A (2007). A hybrid texture analysis system based on non-linear & oriented kernels, particle swarm optimization, and kNN vs. support vector machines. *7th international conference on hybrid intelligent systems (HIS 2007)*. Kaiserslautern, Germany.
- Pistori H, Paraguassu WA, Martins PS, Conti MP, Pereira MA, Jacinto MA (2018). Defect detection in raw hide and wet blue leather. *Computational Modelling of Objects Represented in Images. Fundamentals, Methods and Applications*. Cracow, Poland.
- Prananda AR, Frannita EL (2023). Toward Adaptive Manufacturing Development: Implementation of Artificial Intelligence for Identifying Leather Defects. *Jurnal Ecotipe (Electronic, Control, Telecommunication, Information, and Power Engineering)*, 2023(2): 200-207.
- Rao AR (2012). *A taxonomy for texture description and identification*. Springer Science & Business Media.
- Rao AR, Lohse GL (1993). Identifying high level features of texture perception. *CVGIP: Graphical Models and Image Processing*, 1993(3): 218-233.
- Santos Filho EQ, de Sousa PHF, Rebouças Filho PP, Barreto GA, de Albuquerque VHC (2020). Evaluation of goat leather quality based on computational vision techniques. *Circuits, Systems, and Signal Processing*, 2020(2): 651-673.
- Smith AD, Du S, Kurien A (2023). Vision transformers for anomaly detection and localisation in leather surface defect classification based on low-resolution images and a small dataset. *Applied Sciences*, 13(15): 8716.
- Sobral JL (2005). Leather inspection based on wavelets. *Iberian conference on pattern recognition and image analysis*, Springer, 2005(1): 682-688.
- Sousa CEB, Medeiros CMS, Pereira RF, Neto AA, Neto MAV (2021). A decision support system for fault detection and definition of the quality of wet blue goat skins. *Heliyon*, 7(9).
- Tafari M, Branca A, Attolico G, Distante A, Delaney W (1996). Automatic leather inspection of defective patterns. *Machine vision applications in industrial inspection IV*, SPIE, 1996(2665): 108-119.
- Ticaret Bakanlığı (2022). Deri ve Deri Mamulleri Sektör Raporu. https://ticaret.gov.tr/data/5b87000813b8761450e18d7b/Deri_ve_Deri_Mamulleri_Sekt%C3%B6r%C3%BC.pdf.
- TÜİK (2020, Aralık). Deri Üretimi Miktarları. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Bulten/DownloadIstatistikselTablo?p=akVjpnzD2nodln2y9MutlfambT1xV5PmEU6zK9rXpGm5Ek0kCvdtPrMKm86QlLt>.
- Viana R, Rodrigues RB, Alvarez MA, Pistori H (2007). SVM with stochastic parameter selection for bovine leather defect classification. *Advances in Image and Video Technology: Second Pacific Rim Symposium, PSIVT 2007*. Santiago, Chile.

Villar P, Mora M, Gonzalez P (2011). A new approach for wet blue leather defect segmentation. Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 16th Iberoamerican Congress, CIARP 2011. Pucón, Chile.

Wang Q, Liu H, Liu J, Wu T (1992). A new method for leather texture image classification. IEEE International Symposium on Industrial Electronics. Xi'an, China.

Winiarti S, Prahara A, Murinto DPI, Ismi P (2018). Pretrained convolutional neural network for classification of tanning leather image. Network (CNN), 9(1): 9.

Wu X, Xiong H, Wen P (2016). A defect detection method based on sub-image statistical feature for texture surface. Eighth International Conference on Digital Image Processing (ICDIP 2016). Chengu, China.

Yuan S, Li L, Chen H, Li X (2023). Surface Defect Detection of Highly Reflective Leather Based on Dual-Mask Guided Deep Learning Model. IEEE Transactions on Instrumentation and Measurement, 2023(72): 1-13.