

Araştırma Makalesi / Research Article

BİTKİSEL TABAKLANMIŞ KOYUN DERİLERİNDE TANEN FORMÜLASYONLARININ RGB YÜZEY GÖRÜNTÜLERİ VE DERİN ÖĞRENME İLE SINIFLANDIRILMASI

Şükrü ÖMÜR¹
Nilay ÖRK EFENDİOĞLU²
Mahmut SİNECEN^{3*}

¹Aydın Adnan Menderes Üniversitesi, Aydın Meslek Yüksekokulu, Tasarım Bölümü, Aydın, Türkiye

²Ege Üniversitesi, Mühendislik Fakültesi, Deri Mühendisliği Bölümü, İzmir, Türkiye

³Fırat Üniversitesi, Yapay Zeka ve Veri Mühendisliği Bölümü, Elazığ, Türkiye

Gönderilme Tarihi / Received: 28.06.2026

Kabul Tarihi / Accepted: 13.08.2026

ÖZ: Bu çalışma, bitkisel tabaklanmış koyun derilerinde tanen formülasyonlarının standartlaştırılmış RGB yüzey görüntüleri ve evrişimli sinir ağları kullanılarak ayırt edilme potansiyelini incelemektedir. Deneysel tasarımda iki tanen ailesinden toplam 26 formülasyon kullanılmıştır: mimoza, kebrako ve çam esaslı kondanse formülasyonlar ile valeks, kestane ve mazı esaslı hidrolize formülasyonlar. Canon EOS 760D ile alınan görüntüler ön plan ayırımı sonrasında 15.600 adet 200 × 200 px deri yüzey yamasına dönüştürülmüştür. ImageNet ağırlıklarıyla başlatılan ResNet-18 ve EfficientNet-B0 modelleri 26 sınıflı sınıflandırma için eğitilmiş; K numunesinden gelen yamalar model geliştirme, bağımsız T numunesinden gelen yamalar ise nihai test amacıyla kullanılmıştır. ResNet-18 K-doğrulama aşamasında 0,960 makro-F1 değerine, bağımsız T-test setinde ise %25,1 doğruluk ve 0,225 makro-F1 değerine ulaşmıştır. EfficientNet-B0 için bu değerler sırasıyla 0,927, %27,2 ve 0,240 olarak hesaplanmıştır. Performans değerleri 26 sınıflı rastgele tahmin düzeyinin üzerinde olmakla birlikte, K-doğrulama ve T-test sonuçları arasındaki belirgin fark bağımsız tekerrür kaynaklı alan değişimini ortaya koymaktadır. Sonuçlar, bitkisel tanen kimyasının deri yüzeyinde ölçülebilir görsel izler bırakabildiğini; ancak yalnız RGB yamalarıyla bağımsız numunelerde kesin 26 sınıflı formülasyon tanımanın sınırlı kaldığını göstermektedir.

Anahtar Kelimeler: Koyun derisi, Bitkisel tabaklama, Tanen formülasyonu, Evrişimli sinir ağı, Görüntü işleme, Veri sızıntısı

CLASSIFICATION OF TANNIN FORMULATIONS IN VEGETABLE-TANNED SHEEP LEATHER USING RGB SURFACE IMAGES AND DEEP LEARNING

ABSTRACT: This study investigates the potential of discriminating tannin formulations in vegetable-tanned sheep leather using standardized RGB surface images and convolutional neural networks. A total of 26 formulations from two tannin families were examined: condensed formulations based on mimosa, quebracho, and pine, and hydrolyzable formulations based on valonea, chestnut, and gallnut. Images acquired with a Canon EOS 760D were segmented to remove the background and converted into 15,600 leather surface patches of 200 × 200 px. ResNet-18 and EfficientNet-B0 models initialized with ImageNet weights were trained for 26-class classification. Patches from the K sample were used for model development, whereas patches from the independent T sample were reserved exclusively for final testing. ResNet-18 achieved a validation macro-F1 of 0.960 on K samples and 25.1% accuracy with a macro-F1 of 0.225 on the independent T-test set. EfficientNet-B0 achieved a validation macro-F1 of 0.927 and 27.2% accuracy, with a macro-F1 of 0.240 on the independent test set. Although both models performed above random expectation for a balanced 26-class task, the marked decrease from K-validation to T-test performance indicated a pronounced replicate-domain shift. The findings demonstrate that vegetable tannin chemistry can leave measurable visual traces on the leather surface; however, exact 26-class formulation recognition using only RGB patches remains limited under independent sample replication.

Keywords: Sheep leather, Vegetable tanning, Tannin formulation, Convolutional neural network, Image processing, Data leakage

***Sorumlu Yazarlar/Corresponding Authors:** mahmutsinecen@gmail.com

DOI: <https://doi.org/10.7216/tekstilmuh.1980874>

www.tekstilmuhendis.org.tr

1. GİRİŞ

Bitkisel tabaklama, hayvansal derideki kolajen matrisin bitkisel kökenli polifenollerle etkileştirilerek stabilize edilmesine dayanır. Kullanılan tabaklama maddesinin türü ve miktarı, nihai derinin yüzey rengini, tutumunu, sırça görünümünü ve bazı mekanik yanıtlarını etkiler. Bu nedenle bitkisel tanen kimyası, deri üretiminde yalnızca bir proses değişkeni değil, aynı zamanda malzeme tasarımıyla yönlendiren temel faktörlerden biridir [1-3].

Bitkisel tanenler genel olarak kondanse ve hidrolize tanenler olmak üzere iki ana kimyasal ailede değerlendirilir. Mimoza, kebrako ve çam kabuğu ekstraktları gibi kondanse tanenler çoğunlukla proantosiyanidin bakımından zengin flavonoid yapılarla ilişkilidir. Valeks, kestane ve mazı gibi hidrolize tanenler ise galloyl ve ellagyl birimleri ile karakterize edilir. Bu kimyasal ailelerin kromofor yapıları, moleküler büyüklükleri ve kolajenle bağlanma davranışları farklı olduğundan, etkileri derinin optik ve fiziksel özelliklerine yansiyabilir [4-6]. Tekstil ve Mühendis dergisinde yayımlanan bitkisel tabaklanmış saraciyelik deri çalışmaları da proses kimyasındaki değişimlerin renk, mekanik özellikler ve morfolojik davranış üzerinde ölçülebilir etkiler oluşturabildiğini göstermektedir [7].

Bilgisayarlı görü, deri ve tekstil yüzeylerindeki renk, doku ve mikroyapı farklılıklarının tahribatsız olarak incelenmesi için tamamlayıcı bir yöntem sunmaktadır. Tekstil ve Mühendis literatüründe görüntü işleme; kumaş sıklığının otomatik belirlenmesi [8], örme kumaşlarda boncuklanmanın objektif ölçümü [9], iplik ve kumaş hatalarının makine görüşü ile denetlenmesi [10], dokusuz yüzey morfolojisinden yapay sinir ağı ile performans tahmini [11] ve denim kumaşlarda yıkama sonrası çekmenin bilgisayarlı görü ile ölçülmesi [12] gibi problemlerde kullanılmıştır. Bu çalışmalar, kontrollü yüzey görüntülerinin tekstil malzemelerinde nicel kalite göstergelerine dönüştürülebileceğini göstermektedir. Derin evrişimli sinir ağları ise düşük düzeyli renk ve kenar örüntülerinden daha üst düzey doku ve mekânsal yapılar kadar hiyerarşik görsel temsiller öğrenebilir [13]. ResNet-18, artık bağlantılar yoluyla derin ağların eğitimini kararlı hâle getirdiği için [14]; EfficientNet-B0 ise ağ derinliği, genişliği ve giriş çözünürlüğünü dengeli biçimde ölçeklediği için [15] bu çalışmada değerlendirmeye alınmıştır. Alan özgü deri görüntülerinin sayısı genel görüntü veri kümelerine göre sınırlı olduğundan, ImageNet üzerinde önceden eğitilmiş ağırlıklarla aktarım öğrenmesi kullanılmıştır [16].

Yama tabanlı malzeme görüntülemeye temel metodolojik sorunlardan biri, görsel olarak ilişkili örneklerden kaynaklanan veri sızıntısıdır. Aynı fiziksel deri yüzeyinden çıkarılan yamalar rastgele biçimde model geliştirme ve test kümelerine dağıtılsa model, formülasyona ait genellenebilir bilgiden çok numuneye özgü yüzey örüntülerini, aydınlatma farklarını veya kenar artefaktlarını öğrenebilir. Görüntü tabanlı sınıflandırma çalışmalarında benzer sızıntı etkileri gösterilmiş ve gerçekçi genelleme için örnek/kişi düzeyinde ayırımın gerekli olduğu belirtilmiştir [17]. Derinin yüzey boyunca yapısal olarak heterojen

olması ve numune alma bölgesinin fiziksel özellikleri etkileyebilmesi de bu yaklaşımı deri çalışmaları açısından önemli kılmaktadır [18].

Bu çalışmanın amacı, sıkı bir bağımsız tekrerrür değerlendirmesi altında 26 bitkisel tanen formülasyonunun yalnızca RGB yüzey yamalarıyla ne ölçüde ayırt edilebildiğini belirlemektir. Çalışmanın özgün katkısı, bitkisel tabaklanmış koyun derilerinde formülasyon etkisini veri sızıntısına duyarlı K/T numune ayırımıyla değerlendirmesi ve RGB görüntü tabanlı derin öğrenme için tekstil ve deri mühendisliği alanına uygulanabilir bir başlangıç protokolü sunmasıdır.

2. MATERYAL VE YÖNTEM

2.1. Tanen Formülasyon Tasarımı

Deneyisel formülasyon matrisi Tablo 1'de verilmiştir. Tablo, hesaplamalı iş akışından önce sunulmuştur; çünkü evrişimli sinir ağlarında kullanılan sınıf etiketleri rastgele görsel kategoriler değil, tanımlı kimyasal reçetelerdir. 1-13 sınıfları kondanse mimoza-quebracho-çam formülasyonlarını; 14-26 sınıfları ise hidrolize valeks-kestane-mazı formülasyonlarını temsil etmektedir. Aynı sınıf yapısı görüntü etiketleme, yama çıkarımı ve model değerlendirme adımlarında korunmuştur.

2.2. Görüntü Alma ve Yama Çıkarımı

Temsili deri yüzeyleri Şekil 1'de gösterilmiştir. Numune sınırlarının düzensiz olması ve yüzey içinde mikrodoku değişimlerinin bulunması, yama tabanlı bir analiz stratejisini gerekli kılmıştır. Temsili görüntü dosyalarının EXIF üst verilerine göre çekimler, EF-S 18-135 mm f/3.5-5.6 IS lens takılı Canon EOS 760D DSLR fotoğraf makinesi ile gerçekleştirilmiştir. Görüntüler 6000 × 4000 piksel çözünürlükte, sRGB renk uzayında 24-bit derinlikte kaydedilmiştir. Temsili çekim ayarları f/29 diyafram, 1/30 s pozlama süresi, ISO 800, 52 mm odak uzaklığı, manuel pozlama modu, pattern ölçüm, otomatik beyaz dengesi ve flaşsız çekimdir. Görüntüleme protokolünün yeniden üretilebilirliğini artırmak amacıyla bu bilgiler raporlanmıştır.

Yama çıkarımından önce arka plan bölgelerinin modele dâhil olmasını önlemek için ön plan ayırımı uygulanmıştır. Bu aşamada kullanılan ön plan maskesi, her pikselin deri yüzeyine ait olup olmadığını ikili olarak tanımlayan bir bölütleme haritasıdır. Açık renkli derilerde arka plan ile deri arasındaki ayırımı desteklemek amacıyla LAB renk bileşenleri üzerinden renk uzaklığı bilgisi kullanılmıştır; böylece yalnız parlaklık farkına bağlı bir eşikleme yerine renk bileşenlerindeki farklılıklar da maske kararına dâhil edilmiştir. Yama çıkarım iş akışında yama boyutu 200 × 200 px olarak belirlenmiş ve bir yamanın kabul edilmesi için piksellerinin en az %90'ının ön plan maskesi içinde kalması şartı uygulanmıştır. Maske sınırına 5 px erozyon uygulanması, deri-arka plan sınırındaki karışık piksellerin ve kenar artefaktlarının yama içine taşınma olasılığını azaltmak amacıyla maskeyi içe doğru daraltmaktadır. Her görüntüden en fazla 300 yama kabul edilmesi ise tek bir görüntünün veri kümesine orantısız katkıda bulunmasını sınırlandırmak için kullanılmıştır. Kabul edilen

yamalar {class_id}_{K|T}_{####}.jpg biçiminde kaydedilmiştir. Şekil 1, yüzey görüntülerini ve yama penceresi kavramını


göstermektedir; tüm kabul edilen yamalar segmentasyon maskesine göre otomatik olarak üretilmiştir.

Tablo 1. Kondanse ve hidrolize tanen grupları için deneysel formülasyon matrisi

Sınıf	M	Q	P	Sınıf	V	C	G
1	36	0	0	14	36	0	0
2	0	36	0	15	0	36	0
3	0	0	36	16	0	0	36
4	12	12	12	17	12	12	12
5	24	12	0	18	24	12	0
6	24	0	12	19	24	0	12
7	0	24	12	20	0	24	12
8	12	24	0	21	12	24	0
9	12	0	24	22	12	0	24
10	0	12	24	23	0	12	24
11	24	6	6	24	24	6	6
12	6	24	6	25	6	24	6
13	6	6	24	26	6	6	24


M: mimoza; Q: quebracho; P: çam; V: valeks; C: kestane; G: mazi. Değerler deneysel formülasyon tasarımında kullanılan yüzde/banyo oranı seviyelerini ifade eder.

Condensed sample: 6M-6Q-24P



Illustrative 200 x 200 px patch windows (not all accepted patches shown).

Hydrolyzable sample: 6V-6C-24G



Illustrative 200 x 200 px patch windows (not all accepted patches shown).

Şekil 1. Temsili kondanse ve hidrolize deri yüzeyleri üzerinde 200 × 200 px yama penceresi kavramı. Gösterilen pencereler yama çıkarım fikrini örneklemektedir; kabul edilen yamalar ön plan maskesi ve kapsama ölçütlerine göre otomatik seçilmiştir.


2.3. Veri Ayrımı ve Sızıntı Kontrollü Değerlendirme

Veri ayrımı Tablo 2’de özetlenmiş ve Şekil 2’de görselleştirilmiştir. Orijinal K numuneleri model geliştirme için, bağımsız T numuneleri ise nihai test için kullanılmıştır. Bu ayırım, numune düzeyindeki sızıntıyı azaltması ve sınıflandırıcıları aynı fiziksel yüzeyden türetilmiş yamaları ezberlemek yerine görülmemiş bir tekrerrü alanına genelleme yapmaya zorlaması bakımından çalışmanın temel yöntemsel tercihidir.

Bobin boyama prosesinin verimliliği ve nihai renk kalitesi; boya masuralarının geometrik ve yüzey karakteristikleri, sargı matrisinin homojenliği, ipliğin yapısal özellikleri ve boyarmaddenin kimyasal kalitesinin yanı sıra; flotte sirkülasyon hızı, yönü, pompalama basıncı ve boyama makinesinin teknik konfigürasyonları gibi proses parametreleri tarafından belirlenmektedir [12].

Tablo 2. Veri seti yapısı ve numune ayrık veri bölünmesi

Alt küme	Numune kaynağı	Yama sayısı	Sınıf sayısı	Rol
Eğitim	K	6.630	26	Parametre öğrenimi
Doğrulama	K	1.170	26	Model seçimi
Bağımsız test	T	7.800	26	Genelleme değerlendirme



Şekil 2. Tanen formülasyon tasarımından bağımsız T-numunesi ESA değerlendirmesine kadar görüntü sınıflandırma iş akışı *K/T ayrımı yama çıkarımı sonrasında korunarak yüzey düzeyli veri sızıntısı azaltılmıştır.

2.4. ESA Eğitim Yapılandırması

Model eğitiminde kullanılan hesaplamalı yapılandırma Tablo 3’te verilmiştir. RGB yamalar 224×224 px boyutuna yeniden ölçeklenmiş ve ImageNet üzerinde ön eğitim sırasında kullanılan kanal ortalama ve standart sapma değerleriyle normalize edilmiştir. Buradaki normalizasyon, her RGB kanalının ilgili ortalama ve standart sapmaya göre ölçeklenmesiyle ön eğitimdeki giriş dağılımıyla uyumu artırmayı amaçlamaktadır. Veri artırma yalnız eğitim alt kümesine uygulanmış; yatay/dikey çevirme ve $\pm 10^\circ$ döndürme geometrik çeşitlilik, parlaklık/kontrast, doygunluk ve hue değişimleri ise sınıf etiketini değiştirmeden sınırlı fotometrik çeşitlilik üretmek için kullanılmıştır [19]. Doğrulama ve bağımsız test görüntülerine

rastgele veri artırma uygulanmamıştır. Her iki mimaride AdamW optimizasyonu kullanılmıştır; AdamW, ağırlık azaltmayı kayıp gradyanından ayırıştırarak düzenleme terimini doğrudan parametre güncellemesine uygular [20]. Öğrenme oranı 15 epok boyunca kosinüs biçiminde azaltılmıştır; bu yaklaşım eğitim ilerledikçe öğrenme oranının yumuşak biçimde küçülmesini sağlar [21]. Batch size = 64, tek bir parametre güncellemesinde işlenen yama sayısını; worker = 2, veri yüklemede kullanılan paralel işçi sayısını; seed = 42 ise veri bölme ve stokastik işlemlerin tekrarlanabilirliğini ifade etmektedir. ResNet-18 ve EfficientNet-B0 için eğitim geçmişleri dışa aktarılmış ve her modelin en iyi doğrulama epoku bu kayıtlar üzerinden belirlenmiştir.

Tablo 3. Görüntü ön işleme ve ESA eğitim yapılandırması

Bileşen	Değer
Girdi boyutu	224×224 RGB
Yama kaynağı	200×200 px kabul edilmiş deri yüzey yamaları
Normalizasyon	ImageNet ortalaması = (0,485, 0,456, 0,406); standart sapma = (0,229, 0,224, 0,225)
Veri artırma	Yalnız eğitim kümesi: yatay çevirme $p=0,50$; dikey çevirme $p=0,20$; $\pm 10^\circ$ döndürme; parlaklık/kontrast 0,10; doygunluk 0,05; hue 0,02
Modeller	ResNet-18; EfficientNet-B0
Başlatma	ImageNet üzerinde önceden eğitilmiş ağırlıklar
Kayıp fonksiyonu	Çapraz entropi
Optimizasyon	AdamW; öğrenme oranı = 1×10^{-4} ; weight decay = 1×10^{-4}
Zamanlayıcı	15 epok boyunca kosinüs azalım
Batch size / worker / seed	64 / 2 / 42

2.5. Matematiksel Formülasyon ve Değerlendirme Metrikleri

x_i , i’inci görüntü yamasını; $y_i \in \{1, \dots, 26\}$ ise ilgili formülasyon sınıfını gösterir. Evrişimli sinir ağı f_θ , x_i girdisini $C = 26$ sınıfa ait olasılık vektörü p_i ’ye dönüştürür. Eğitimde kullanılan çapraz entropi kaybı Denklem (1)’de verilmiştir.

$$\mathcal{L}(\theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C \mathbf{1}(y_i = c) \log(p_{ic}), C = 26 \quad (1)$$

Tüm sınıflar bilimsel olarak anlamlı formülasyon etiketleri olduğundan, doğruluk ile birlikte makro-F1 de raporlanmıştır. Precision, bir sınıf için pozitif tahminlerin ne kadarının doğru olduğunu; recall, o sınıfa ait gerçek örneklerin ne kadarının yakalandığını; F1 ise precision ve recall değerlerinin harmonik ortalamasını ifade eder. Makro-F1, her sınıfın F1 değerini eşit ağırlıkla ortaladığı için çok sınıflı değerlendirmede sınıf bazlı başarının tek bir baskın sınıf tarafından maskelenmesini azaltır

[22]. Precision, recall, F1 ve makro-F1 hesaplamaları Denklem (2)’de verilmiştir. Numune ayrık veri bölünmesi Denklem (3) ile ifade edilmiştir. K kaynaklı yamalar yalnızca model geliştirme, T kaynaklı yamalar ise yalnızca nihai test için kullanılmıştır. Karmaşıklık matrisleri Denklem (4) ile yorumlanmıştır. Burada Mab, gerçek sınıfı a olan kaç yamanın b sınıfı olarak tahmin edildiğini ifade eder.

$$\begin{aligned} \text{Precision}_c &= \frac{TP_c}{TP_c + FP_c}, \\ \text{Recall}_c &= \frac{TP_c}{TP_c + FN_c}, \\ F1_c &= \frac{2 \text{Precision}_c \text{Recall}_c}{\text{Precision}_c + \text{Recall}_c}, \\ \text{MacroF1} &= \frac{1}{C} \sum_{c=1}^C F1_c \end{aligned} \quad (2)$$

$$\mathcal{D}_K \cap \mathcal{D}_T = \emptyset, \mathcal{D}_{train} \cup \mathcal{D}_{val} \subset \mathcal{D}_K, \quad \mathcal{D}_{test} \subset \mathcal{D}_T \quad (3)$$

$$M_{ab} = |\{i: y_i = a \wedge \hat{y}_i = b\}|, \quad a, b \in \{1, \dots, C\} \quad (4)$$

3. BULGULAR VE TARTIŞMA

Bağımsız T-numunesi test sonuçları, model geliştirme sırasında elde edilen en iyi K-doğrulama makro-F1 değerleriyle birlikte Tablo 4'te sunulmuştur. ResNet-18 en yüksek K-doğrulama makro-F1 değerine 13. epokta ulaşmıştır (0,960); buna karşılık EfficientNet-B0 bağımsız T-testinde daha yüksek genelleme performansı göstermiştir (%27,2 doğruluk ve 0,240 makro-F1). Bu karşılaştırma, her iki modelin de rastgele olmayan formülasyon ilişkili yüzey sinyalleri öğrendiğini; ancak K-doğrulama ve T-test skorları arasındaki belirgin fark nedeniyle bağımsız deneysel tekrerrürlerden gelen test yüzeylerinde 26 sınıflı kesin formülasyon tanımanın hâlen güç olduğunu göstermektedir.

Tablo 5'te her iki model için bağımsız T-testindeki en iyi ve en zayıf beş sınıf birlikte özetlenmiştir. Her iki modelde de 16

numaralı sınıf F1 = 1,000 ile en tutarlı biçimde tanınmıştır. ResNet-18 için bunu 22 (0,845), 14 (0,594), 21 (0,544) ve 17 (0,532) numaralı sınıflar izlerken; EfficientNet-B0 için 22 (0,857), 14 (0,667), 17 (0,541) ve 21 (0,537) numaralı sınıflar öne çıkmıştır. ResNet-18'de 1, 5, 6 ve 7 numaralı sınıfların F1 değeri 0,000 olup beşinci en düşük değer sınıf 2'de 0,005'tir. EfficientNet-B0'da ise 1, 5, 6, 7 ve 25 numaralı sınıfların F1 değeri 0,000'dır. Bu örüntü, bazı hidrolize formülasyonların her iki mimaride de belirgin yüzey imzaları oluşturduğunu; buna karşılık bazı kondanse veya görsel olarak benzer formülasyonların mevcut RGB yama ölçeğinde belirsiz kaldığını göstermektedir.

Şekil 3'te verilen karmaşıklık matrisleri, kimyasal olarak yakın bazı formülasyonlarda sınıflandırma görevinin zorlaştığını göstermektedir. Şekil 4 ise sınıf düzeyindeki F1 skorlarını karşılaştırmaktadır. EfficientNet-B0 bağımsız T-testinde ResNet-18'e göre sınırlı bir üstünlük göstermiş olsa da, iki modelin sınıf bağımlı hata yapısı benzerdir: hidrolize sınıflar genel olarak daha yüksek F1 skorları üretmiş, bazı sınıflar ise yüksek K-doğrulama başarısına rağmen sifıra yakın kalmıştır.


Tablo 4. Bağımsız T-numunesi test setinde model performansı

Model	K-doğrulama makro-F1	Test kaybı	T-test doğruluk	T-test makro-F1	Kondanse ort. F1	Hidrolize ort. F1
ResNet-18	0,960	4,035	0,251	0,225	0,086	0,363
EfficientNet-B0	0,927	4,146	0,272	0,240	0,091	0,389


Tablo 5. Bağımsız T-numunesi testinde ResNet-18 ve EfficientNet-B0 için en iyi ve en zayıf sınıflar

Model	En iyi beş sınıf (F1)	En zayıf beş sınıf (F1)
ResNet-18	16 (1,000); 22 (0,845); 14 (0,594); 21 (0,544); 17 (0,532)	1 (0,000); 5 (0,000); 6 (0,000); 7 (0,000); 2 (0,005)
EfficientNet-B0	16 (1,000); 22 (0,857); 14 (0,667); 17 (0,541); 21 (0,537)	1 (0,000); 5 (0,000); 6 (0,000); 7 (0,000); 25 (0,000)


(a) ResNet-18



(b) EfficientNet-B0



Şekil 3. ResNet-18 ve EfficientNet-B0 modellerinin bağımsız T-numunesi test setindeki karmaşıklık matrisleri
 *Matrisler, kimyasal olarak yakın bazı formülasyonlarda görevin hâlen zor olduğunu göstermektedir.



Şekil 4. Bağımsız T-numunesi testinde ResNet-18 ve EfficientNet-B0 için sınıf düzeyinde F1 karşılaştırması
*Kesikli çizgi kondanse sınıflar (1-13) ile hidrolize sınıfları (14-26) ayırmaktadır


Şekil 5, her iki ESA omurgası için geliştirme kümesi eğitim geçmişlerini göstermektedir. Her iki model de en iyi doğrulama makro-F1 değerine 13. epokta ulaşmıştır. ResNet-18 için en iyi doğrulama makro-F1 0,960, EfficientNet-B0 için ise 0,927 olarak gerçekleşmiştir. Doğrulama kaybındaki düzenli azalma, K-geliştirme bölümünde optimizasyonun kararlı olduğunu göstermektedir; ancak Tablo 4, bu doğrulama başarısının bağımsız T-numunesi test setine tam olarak aktarılmadığını ortaya koymaktadır.

Bulgular, bitkisel tabaklanmış koyun derisinin RGB yüzey görüntülerinde tanen formülasyonu ile ilişkili bilgi bulunduğunu; ancak bu bilginin bağımsız deneysel tekrerrür altında 26 formülasyonun tamamını güvenilir biçimde tanımak için yeterli olmadığını göstermektedir. ResNet-18 için yaklaşık %25,1 ve EfficientNet-B0 için yaklaşık %27,2 düzeyindeki bağımsız test doğrulukları, dengeli 26 sınıflı bir görevde beklenen %3,85 rastgele tahmin düzeyinin belirgin biçimde üzerindedir. Bu sonuç,


tanen kimyasının deri yüzeyinde görünür özellikleri etkileyebildiğini desteklemektedir. Bununla birlikte, K-doğrulama makro-F1 değerlerinin 0,960 ve 0,927'den T-test makro-F1 değerlerinin 0,225 ve 0,240 düzeyine düşmesi, formülasyona özgü görsel imzaların tekrerrüre özgü yüzey değişimiyle kısmen karıştığını göstermektedir.

Bu sonuç yöntemsel açıdan önemlidir. Yama tabanlı çalışmalarda aynı fiziksel numuneden gelen yamaların rastgele biçimde eğitim ve test kümelerine dağılması, modelin formülasyon bilgisinden çok yerel yüzey kimliğini tanımasına neden olabilir. Bu çalışmada kullanılan K/T protokolü daha sıkı ve gerçekçi bir değerlendirme sunmaktadır; çünkü eğitilmiş bir sistemin yeni bir deri yüzeyine veya aynı nominal formülasyonun bağımsız tekrarına uygulanması beklenir. Bu nedenle elde edilen sınırlı fakat rastgele seviyenin üzerindeki başarı, RGB doku bilgisinin potansiyelini ve sınırlarını birlikte göstermektedir.

(a) ResNet-18



(b) EfficientNet-B0



Şekil 5. ResNet-18 ve EfficientNet-B0 için geliştirme kümesi optimizasyon dinamikleri

*Eğriler 15 epok boyunca eğitim kaybını, doğrulama kaybını ve doğrulama makro-F1 değerini göstermektedir; her iki model en iyi doğrulama makro-F1 değerine 13. epokta ulaşmıştır.

Tekstil ve Mühendis’de yayımlanan önceki görüntü işleme çalışmalarında kumaş sıklığı, boncuklanma, iplik/kumaş hataları, dokusuz yüzey performansı ve denim çekmesi gibi özellikler kontrollü görüntülerden başarıyla ölçülmüş veya tahmin edilmiştir [8-12]. Bu çalışmanın söz konusu literatürden temel farkı, aynı görüntüleme koşullarındaki bir yüzey özelliğini tahmin etmekten ziyade, aynı nominal formülasyonun bağımsız K/T tekerrürleri arasında 26 sınıflı genellemeyi sınamasıdır. Bu nedenle bağımsız T-testindeki daha düşük başarı, yalnız model mimarisinin bir yetersizliği olarak değil, örnek düzeyinde alan değişimini görünür kılan daha sıkı değerlendirme tasarımıyla birlikte yorumlanmalıdır.

Hidrolize formülasyonlarda ortalama F1 değerinin daha yüksek olması, valeks, kestane ve mazı kombinasyonlarının mevcut görüntüleme protokolünde mimoza, kebrako ve çam esaslı kondanse kombinasyonlara göre daha ayırt edilebilir görsel sinyaller ürettiğini düşündürmektedir. EfficientNet-B0 bağımsız testte en yüksek makro-F1 değerini sağlamış olsa da, ResNet-18’e göre artış sınırlıdır. Bu durum, tek başına mimari değişikliğin alan değişimi sorununu çözmek için yeterli olmayabileceğini; daha zengin görüntüleme, ek bağımsız deriler, renk kalibrasyonu veya tamamlayıcı modalitelere ihtiyaç olduğunu göstermektedir.

Çalışmanın temel sınırlılıkları, her formülasyon için bağımsız fiziksel deri sayısının sınırlı olması, kararların yama düzeyinde raporlanması ve mevcut görüntüleme hattında açık bir renk kalibrasyon hedefinin bulunmamasıdır. Gelecekte her formülasyon için daha fazla bağımsız deriyle çalışma tekrarlanmalı, renk kalibrasyonlu görüntüleme uygulanmalı, çok ölçekli yama temsilleri denenmeli ve yama düzeyindeki sonuçlar numune düzeyinde çoğunluk oylamasıyla desteklenmelidir. Ayrıca Grad-CAM veya Integrated Gradients gibi açıklanabilirlik yöntemleriyle modelin kenar artefaktları veya aydınlatma gradyanları yerine sırça dokusu ve gözenek yapısına odaklanıp odaklanmadığı incelenmelidir.

4. SONUÇ

Bu çalışmada, bitkisel tabaklanmış koyun derilerinde tanen formülasyonlarının sınıflandırılması için kontrollü görüntü tabanlı bir derin öğrenme çerçevesi geliştirilmiştir. ResNet-18 ve EfficientNet-B0, bağımsız T-numunesi yamalarında rastgele tahmin düzeyinin üzerinde performans göstermiş ve tanen formülasyonunun deri yüzeyinde ölçülebilir görsel izler bırakabildiğini göstermiştir. EfficientNet-B0 en yüksek bağımsız test skorunu, ResNet-18 ise daha yüksek K-doğrulama skorunu üretmiştir. Numune ayırık değerlendirme, yalnız RGB yamalarından 26 sınıflı kesin formülasyon tanımanın sınırlı kaldığını ortaya koymuştur. Bu nedenle çalışmanın temel katkısı, sonraki çok modlu ve kemometrik modelleme çalışmaları için veri sızıntısına duyarlı bir görsel başlangıç karşılaştırması ve numune ayırık değerlendirme protokolü sunmasıdır.

5. BEYANLAR

Etik kurul izni: Çalışma insan katılımcı, kişisel veri veya canlı hayvan deneyi içermediğinden etik kurul izni gerektirmemektedir.

Çıkar çatışması: Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Finansman: Bu çalışma için finansman desteği beyan edilmemiştir.

Veri erişilebilirliği: Bu çalışmada kullanılan görüntü yamaları ve deney kayıtları, makul talep üzerine sorumlu yazardan temin edilebilir.

Üretken yapay zekâ kullanımı: Makalenin dergi formatına uyarlanması, dil ve biçim düzenlemesi aşamasında üretken yapay zekâ destekli araçlardan yararlanılmıştır. Veri üretimi, analiz sonuçları ve bilimsel yorumlardan yazarlar sorumludur.

Yazar katkıları: Ş.Ö., N.Ö.E. ve M.S. çalışmanın kavramsallaştırılması, yöntemsel tasarımı, veri analizi ve makalenin yazım/gözden geçirilmesi süreçlerine katkı sağlamış; tüm yazarlar son metni okuyup onaylamıştır.

KAYNAKLAR

1. Bienkiewicz, K., (1983), Physical Chemistry of Leather Making, Krieger Publishing Company, Malabar, Florida, USA. <http://ci.nii.ac.jp/ncid/BA7835197X>
2. Covington, A.D., (1997), Modern tanning chemistry, Chemical Society Reviews, 26(2), 111-126. doi:10.1039/CS9972600111.
3. Covington, A.D., (2009), Tanning Chemistry: The Science of Leather, Royal Society of Chemistry, Cambridge, UK. <https://doi.org/10.1039/9781839168826>
4. Falcão, L., Araújo, M.E.M., (2018), Vegetable tannins used in the manufacture of historic leathers, Molecules, 23(5), 1081. doi:10.3390/molecules23051081.
5. Kanth, S.V., Venba, R., Madhan, B., Chandrababu, N.K., Sadulla, S., (2009), Cleaner tanning practices for tannery pollution abatement: Role of enzymes in eco-friendly vegetable tanning, Journal of Cleaner Production, 17(5), 507-515. doi:10.1016/j.jclepro.2008.05.004.
6. Pizzi, A., (2008), Tannins: Major sources, properties and applications, In: Belgacem, M.N., Gandini, A. (Eds.), Monomers, Polymers and Composites from Renewable Resources, Elsevier, Amsterdam, 179-199. <https://doi.org/10.1016/b978-0-08-045316-3.00008-9>
7. Zengin, G., Tekin, Y., Adıgüzel Zengin, A., (2016), Saraciyelik derilerde yağlayıcı akrilik polimerin yaşlanma üzerine etkisi, Tekstil ve Mühendis, 23(101), 33-43. <http://dx.doi.org/10.7216/1300759920162310104>
8. Aldemir, E., Özdemir, H., Kılınç, S., (2016), Kumaş sıklıklarının görüntü işleme teknikleri ile otomatik olarak belirlenmesi, Tekstil ve Mühendis, 23(104), 247-262. doi:10.7216/1300759920162310402.

9. Telli, A., & Özkan, İ. (2018). Görüntü İşleme Teknikleri ile Örme Kumaşlardaki Boncuklanma Direncinin Objektif Ölçümü. *Tekstil Ve Mühendis*, 25(112), 313-318. <https://izlik.org/JA72LM52DR>
10. Gültekin, E., Çelik, H. İ., Dülger, L. C., Sünbül, H. İ., & Kani, H. (2019). Image Processing Applications on Yarn Characteristics and Fault Inspection. *Tekstil Ve Mühendis*, 26(116), 340-345. <https://izlik.org/JA92SX42BD>
11. Gültekin, E., Çelik, H. İ., Civan, H. N., & Satıl, E. A. (2020). Spunlace (Su Jeti ile Bağlama) Teknolojisi ile Üretilen Dokusuz Yüzeylerin Morfolojik Özelliklerinden Bazı Performans Özelliklerinin Yapay Zeka ile Tahminlenmesi. *Tekstil ve Mühendis*, 27(119), 130-143. <https://izlik.org/JA25XS37NG>
12. Talu, M. F. (2021). Automatic measurement of shrinkage rate in denim fabrics after washing. *Tekstil Ve Mühendis*, 28(123), 191-198. <https://izlik.org/JA72GF59AG>
13. LeCun, Y., Bengio, Y., Hinton, G., (2015), Deep learning, *Nature*, 521(7553), 436-444. doi:10.1038/nature14539. <https://doi.org/10.1038/nature14539>
14. He, K., Zhang, X., Ren, S., Sun, J., (2016), Deep residual learning for image recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778, 27-30 June 2016, Las Vegas, NV, USA. doi:10.1109/CVPR.2016.90.
15. Tan, M., Le, Q.V., (2019), EfficientNet: Rethinking model scaling for convolutional neural networks, Proceedings of the 36th International Conference on Machine Learning, Proceedings of Machine Learning Research, 97, 6105-6114, 9-15 June 2019, Long Beach, CA, USA. <https://doi.org/10.48550/arxiv.1905.11946>
16. Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L., (2009), ImageNet: A large-scale hierarchical image database, 2009 IEEE Conference on Computer Vision and Pattern Recognition, 248-255, 20-25 June 2009, Miami, FL, USA. doi:10.1109/CVPR.2009.5206848.
17. Yagis, E., Atnafu, S.W., García Seco de Herrera, A., Marzi, C., Scheda, R., Giannelli, M., Tessa, C., Citi, L., Diciotti, S., (2021), Effect of data leakage in brain MRI classification using 2D convolutional neural networks, *Scientific Reports*, 11, 22544. doi:10.1038/s41598-021-01681-w.
18. Ork Efendioglu, N., Temel, E., (2023), Practically comparison of some mechanical standard test methods for leather and textile, *Journal of Engineering Sciences and Design*, 11(4), 1568-1579. doi:10.21923/jesd.1196657.
19. Shorten, C., Khoshgoftaar, T.M., (2019), A survey on Image Data Augmentation for Deep Learning, *Journal of Big Data*, 6, 60. doi:10.1186/s40537-019-0197-0.
20. Loshchilov, I., Hutter, F., (2019), Decoupled Weight Decay Regularization, 7th International Conference on Learning Representations (ICLR 2019), 6-9 May 2019, New Orleans, LA, USA. <https://doi.org/10.48550/arxiv.1711.05101>
21. Loshchilov, I., Hutter, F., (2017), SGDR: Stochastic Gradient Descent with Warm Restarts, International Conference on Learning Representations (ICLR 2017), 24-26 April 2017, Toulon, France. <https://doi.org/10.48550/arxiv.1608.03983>
22. Sokolova, M., Lapalme, G., (2009), A systematic analysis of performance measures for classification tasks, *Information Processing & Management*, 45(4), 427-437. doi:10.1016/j.ipm.2009.03.002.