Uluslararası İleri Doğa Bilimleri ve Mühendislik Araştırmaları Dergisi
Sayı 10, S. 33-38, 5, 2026
© Telif hakkı IJANSER'e aittir
Araştırma Makalesi

International Journal of Advanced Natural Sciences and Engineering Researches
Volume 10, pp. 33-38, 5, 2026
Copyright © 2026 IJANSER
ResearchArticle

https://as-proceeding.com/index.php/ijanser
ISSN: 2980-0811

Treyler Üretiminde "Sıfır Hata" Vizyonu: Derin Öğrenme Toplulukları ile Akıllı Ahşap Hammadde Denetimi

Ayten YILMAZ YALÇINER*, Hasan DURGUT [2] ve Murat ESER [3]

[1]*Endüstri Mühendisliği Bölümü / Sakarya Üniversitesi, Türkiye; (ORCID: https://orcid.org/0000-0002-2453-1645)*
[2] *Endüstri Mühendisliği Bölümü / Sakarya Üniversitesi, Türkiye (ORCID: https://orcid.org/0000-0002-2453-1645)*
[3] *Bilgi İşlem Daire Başkanlığı / Çanakkale Onsekiz Mart Üniversitesi, Türkiye Ülke (ORCID: https://orcid.org/0000-0002-2453-1645)*

(ayteny@sakarya.edu.tr,hasan.durgut1@ogr.sakarya.edu.tr, meser@comu.edu.tr)

(Received: 27 April 2026, Accepted: 04 May 2026)

(4th International Conference on Recent and Innovative Results in Engineering and Technology ICRIRET 2026, April 27-28, 2026)

ATIF/REFERENCE: Yalçıner, A. Y., Durgut, H. & Eser, M. (2026). Treyler Üretiminde "Sıfır Hata" Vizyonu: Derin Öğrenme Toplulukları ile Akıllı Ahşap Hammadde Denetimi, *International Journal of Advanced Natural Sciences and Engineering Researches*, 10(5), 33-38.

Özet **–** Günümüz otomotiv sektöründe araç taban döşemesi olarak kullanılan ahşap panellerin yapısal bütünlüğünün korunması ve kalite sınıflandırması, manuel denetim süreçlerinin subjektif doğası ve yüksek hata payı nedeniyle endüstriyel bir zorluk teşkil etmektedir. Bu araştırmanın temel amacı, derin evrişimli sinir ağları ve topluluk öğrenmesi tekniklerini sinerjik bir şekilde birleştirerek; ahşap yüzeyindeki budak, çatlak ve doku düzensizliklerini A Kalite, B Kalite, C Kalite ve Hurda olarak yüksek hassasiyetle kategorize eden otomatik bir dijital çerçeve geliştirmektir. Araştırma metodolojisi kapsamında, 1024x1024 çözünürlükte standardize edilmiş görsel veriler ve bunlarla eşleşen 40.000 sayısal ölçümü içeren özgün bir veri seti kullanılmıştır. Çalışmada; özel tasarlanmış bir CNN mimarisi, CNN+SVM hibrit yapısı ve transfer öğrenme tabanlı ResNet50 modelleri 5 ile 50 döngü arasında eğitilerek performansları 5-katlı çapraz doğrulama stratejisiyle analiz edilmiştir. Bireysel modellerin zayıf yönlerini telafi etmek amacıyla Sert ve Yumuşak Oylama gibi topluluk öğrenmesi stratejileri uygulanmıştır. Deneysel sonuçlar, ResNet50 mimarisinin %99,0 doğrulukla en sağlam tekil model olduğunu, ancak en yüksek başarının %99,38 doğruluk ve 0,9937 F1-skoru ile Ağırlıklı Yumuşak Oylama (Weighted Soft Voting) yöntemiyle elde edildiğini ortaya koymuştur. Elde edilen 0,998'lik ROC-AUC değeri, sistemin endüstriyel sınıflandırma eşiklerinden bağımsız olarak mükemmel bir ayırt edicilik sergilediğini kanıtlamaktadır. Sonuç olarak, önerilen bu model insan yorgunluğundan kaynaklanan hataları ortadan kaldırarak hammadde israfını azaltmakta ve otomotiv üretim hatlarında dijital dönüşüm için ölçeklenebilir, bilimsel olarak doğrulanmış bir çözüm sunmaktadır

Anahtar Kelimeler – Derin Öğrenme, ResNet50, Topluluk Öğrenmesi (Ensemble Learning), Kalite Kontrol, Görüntü İşleme

I. GİRİŞ

Bu doküman Ahşap ve ahşap esaslı ürünler, yaklaşık 11.000 yıldır insan yaşamının hemen her alanında vazgeçilmez ve çok yönlü bir yenilenebilir malzeme olmuştur[1], [2]. Çevre dostu yapısı, karbon emisyonlarını azaltma yeteneği, işleme sırasındaki düşük enerji tüketimi ve biyolojik olarak parçalanabilirliği, ahşabı sürdürülebilir endüstriler için son derece değerli bir kaynak haline getirmektedir[1], [3], [4], [5]. Yüksek mukavemet-ağırlık oranı, estetik çekiciliği ve tasarım esnekliği

sayesinde ahşap; konut inşaatından mobilya üretimine, taşıma araçlarının imalatına kadar geniş bir yelpazede stratejik bir hammadde olarak hizmet vermektedir[3], [6], [7].

Otomotiv sektöründe ahşap, özellikle ticari araç gövde yapıları ve araç taban döşemeleri gibi yüksek dayanıklılık gerektiren alanlarda yapısal bir bileşen olarak tercih edilmektedir[5]. Örneğin, Betula (huş) gibi yüksek mekanik dayanıma ve elastikiyete sahip ahşap türleri, hafif konstrüksiyonu ve yük taşıma kapasitesini optimize ettikleri için bu alanda öne çıkmaktadır[5]. Araç taban ahşabının kalitesi; lif yönelimi, yoğunluk ve elastisite modülü (MOE) gibi doğrudan aracın genel operasyonel güvenliğini ve hizmet ömrünü belirleyen fiziksel özelliklere bağlıdır[5], [8], [9]. Bu nedenle, otomotiv standartlarına uygun üretim yapmak için malzemenin belirli kalite derecelerine göre hassas bir şekilde sınıflandırılması zorunludur.

Ancak ahşap, biyolojik bir malzeme olarak, doğal büyüme süreçleri ve çevresel faktörler nedeniyle anizotropik ve heterojen bir yapıya sahiptir[5], [8], [9]. Ahşap homojenliğini bozan temel kusurlar arasında budaklar (canlı, ölü veya çürük), yüzey çatlakları, reçine keseleri, öz kusurları ve çürümeler yer alır[7], [8], [10], [11]. Bu kusurlar, eğilme direnci (MOR) ve elastisite modülü (MOE) gibi kritik mühendislik özelliklerini %20 ile %50 oranında azaltarak yapısal bütünlüğü tehlikeye atabilir[8], [9]. Dinamik ve statik yüklerin bir arada bulunduğu araç tabanı gibi bir bileşende, gözden kaçan bir budak veya çatlak, kullanım sırasında ani kırılmalara ve hayati güvenlik risklerine yol açabilir[7], [8], [9].

Tarihsel olarak, bu sorunları önlemek için uygulanan en yaygın yöntem, eğitimli operatörler tarafından gerçekleştirilen manuel görsel inceleme olmuştur[4], [7], [8]. Ancak manuel muayene süreci; göz yorgunluğu, dikkat kaybı ve kişisel öznellik gibi biyolojik insan kısıtları nedeniyle sınırlı bir doğruluğa sahiptir[4], [7], [8]. Endüstri 4.0 paradigması çerçevesinde artan üretim hızları ve "Sıfır Hata İmalat" hedefleri, geleneksel yöntemlerin yetersizliğini ortaya koymuş; daha hızlı, objektif ve güvenilir otomatik denetim sistemlerini zorunlu kılmıştır[4], [11], [12].

Bu çalışma, makine öğrenmesi ve Topluluk Öğrenmesi (Ensemble Learning) tekniklerini kullanarak araç taban ahşabı için gelişmiş bir kalite sınıflandırma modeli geliştirmeyi amaçlamaktadır[10], [13], [14]. Çalışma kapsamında, öğrenme dinamiklerini analiz etmek amacıyla CNN, ResNet50 ve hibrit CNN+SVM modellerinin performansları farklı eğitim aralıklarında test edilmiştir[6], [8], [9], [10]. Performans değerlendirmesi, Doğruluk (Accuracy) ve dengesiz veri setleri için daha güvenilir olan F1-makro skoruna dayanmaktadır. Bu araştırma, bir "Yumuşak Oylama" (Soft Voting) topluluk modeli uygulayarak, otomotiv standartlarını karşılayan, insan hatasını en aza indiren ve üretim verimliliğini artıran yüksek hassasiyetli bir otomatik kalite kontrol altyapısı sunmayı hedeflemektedir[7], [14].

MATERYAL VE YÖNTEM

Materyal ve Yöntemler bölümü; veri seti oluşturma, görüntü ön işleme, model mimarileri, eğitim süreçleri, topluluk yaklaşımı ve performans değerlendirme ölçütlerini, çalışmanın yeniden uygulanabilmesini (replikasyonunu) sağlayacak düzeyde detaylandırmaktadır.

A. Veri Seti

Bu çalışma için özel olarak geliştirilmiş yapay zeka tabanlı bir görüntü üreteci kullanılarak, 400 adet yüksek çözünürlüklü RGB görüntüden oluşan sentetik bir veri seti oluşturulmuştur. Veri seti; her bir sınıfa 100 görüntü atanacak şekilde A-kalite, B-kalite, C-kalite ve Hurda (D-kalite) olmak üzere dört dengeli sınıftan oluşmaktadır. Tüm görüntüler 1024 × 1024 piksel çözünürlükte, kenar boşluğu veya boş alan kalmayacak şekilde ahşap yüzeyi tamamen kaplayacak biçimde üretilmiştir. Üretim süreci; budaklar, çatlaklar, mantar lekeleri, doku düzensizlikleri ve renk varyasyonları dahil olmak üzere gerçekçi ahşap yüzey özelliklerini simüle etmek amacıyla, her sınıf için önceden tanımlanmış kalite kriterleri aralıklarıyla kontrol edilmiştir.

B. Evrişimli Sinir Ağları (CNN)

Konvansiyonel Sinir Ağları (CNN), biyolojik olarak memelilerin görsel korteks yapısından esinlenen ve özellikle görüntü tanıma, sınıflandırma ve nesne tespiti gibi bilgisayarlı görü görevlerinde kullanılan bir derin öğrenme mimarisidir[15], [16], [17]. Bu metodun en temel üstünlüğü, geleneksel yöntemlerin aksine özelliklerin manuel olarak tasarlanmasına ihtiyaç duymadan, veri içerisindeki hiyerarşik yapıları ve

mekânsal bilgileri otomatik olarak öğrenebilmesidir[17]. Tipik bir CNN mimarisi; konvolüsyonel (evrişim) katmanlar, aktivasyon fonksiyonları, havuzlama (pooling) katmanları ve tam bağlantılı (fully connected) katmanlar olmak üzere dört ana bileşenden oluşur[16], [17]. Konvolüsyonel katman, ağın temel hesaplama birimidir ve giriş verisi üzerinde kaydırılan öğrenilebilir filtreler (kernel) aracılığıyla kenarlar, köşeler ve dokular gibi yerel özellikleri çıkarır[16], [17]. Bu süreçte "ağırlık paylaşımı" (weight sharing) tekniği kullanılarak parametre sayısı önemli ölçüde azaltılır ve hesaplama verimliliği artırılır [15], [16], [17]. Elde edilen özellik haritaları, modele doğrusal olmayan özellikler kazandırmak için genellikle ReLU gibi aktivasyon fonksiyonlarından geçirilir [15], [16], [17]. Ardından gelen havuzlama katmanı, özellik haritalarının boyutunu küçülterek (down-sampling) hesaplama karmaşıklığını azaltır, en önemli bilgileri korur ve modelin aşırı öğrenmeye (overfitting) karşı direncini artırır [15], [16], [17]. Son aşamada ise, önceki katmanlardan gelen yüksek seviyeli özellikler düzleştirilerek tam bağlantılı katmanlara aktarılır ve burada nihai sınıflandırma işlemi gerçekleştirilir[16], [17]. Bu hiyerarşik yapı, ağın derinleştikçe daha karmaşık ve soyut özellikleri öğrenmesine olanak tanıyarak yüksek doğruluk oranlarına ulaşmasını sağlar[17].

C. CNN+SVM hibrit yaklaşımı

Derin öğrenme mimarilerinin otomatik özellik çıkarımı yetenekleri ile geleneksel makine öğrenmesi sınıflandırıcılarından biri olan Destek Vektör Makineleri'nin (SVM) güçlü sınıflandırma performansını birleştiren bütünsel bir metodolojidir[18]. Bu metodolojik yapıda, evrişimli sinir ağı (CNN), girdi verilerindeki (örneğin görüntüler) hiyerarşik yapıları ve karmaşık desenleri öğrenmek üzere bir özellik çıkarıcı (feature extractor) olarak konumlandırılır[18], [19]. Ham veriler, CNN'in evrişim ve havuzlama katmanlarından geçirilerek kenarlar, dokular ve nesne parçaları gibi ayırt edici temsilciler olan "derin özelliklere" dönüştürülür[19]. Bu süreç, el yapımı özellik tasarımına ihtiyaç duymadan verinin anlamlı öznitelik vektörlerine indirgenmesini sağlar[18], [20].

Genel yapısı itibarıyla bu hibrit yaklaşım, CNN'in görsel veriyi temsil etme gücü ile SVM'nin yapısal risk minimizasyonu ve güçlü genelleme kapasitesini bir araya getirir[18], [19], [20]. SVM aşamasında kullanılan Lineer, Kübik, Quadratik veya Gaussian (RBF) gibi farklı çekirdek (kernel) fonksiyonları, CNN'den gelen özelliklerin yüksek boyutlu uzaylarda daha hassas bir şekilde ayrıştırılmasına olanak tanır [18], [19], [20]. Böylece metot, karmaşık veri setlerinde hem otomatik özellik öğrenimini sağlar hem de matematiksel olarak optimize edilmiş bir sınıflandırma düzlemi üzerinden operasyonel verimliliği artırır[18], [19].

D. ResNet50

Derin sinir ağlarında katman sayısı arttıkça ortaya çıkan performans bozulması ve "kaybolan gradyan" (vanishing gradient) sorunlarını çözmek amacıyla geliştirilmiş 50 katmanlı ileri bir evrişimli sinir ağı (CNN) mimarisidir[21], [22]. Geleneksel derin ağların aksine, bu metodun temel yeniliği verinin bir veya daha fazla katmanı atlayarak doğrudan sonraki aşamalara iletilmesini sağlayan "atlamalı bağlantılar" (skip connections) veya kısayol mekanizmasıdır[21], [23]. Bu yapı sayesinde ağ, doğrudan bir hedef haritalamayı öğrenmek yerine girdi ile çıktı arasındaki farkı, yani "artığı" (residual learning) öğrenmeye zorlanır; bu da gradyanların derin katmanlar boyunca daha kolay akmasına ve çok daha derin mimarilerin eğitim kaybı yaşamadan eğitilmesine olanak tanır[21], [22], [23].

Mimari açıdan ResNet50, hesaplama verimliliğini artırmak için 1×1, 3×3 ve tekrar 1×1 evrişim katmanlarından oluşan "darboğaz" (bottleneck) birimlerini kullanarak parametre sayısını optimize eder [21], [22], [23]. Uygulama aşamasında genellikle, ImageNet gibi milyonlarca görüntü içeren devasa veri setlerinde önceden eğitilmiş ağırlıkların kullanıldığı "transfer öğrenme" yaklaşımıyla yapılandırılır[21], [22]. Bu süreçte, ağın son katmanlarının hedeflenen sınıflara göre yeniden düzenlendiği "ağ cerrahisi" (network surgery) uygulanarak, model tıbbi görüntü analizinden uydu görüntüsü sınıflandırmasına kadar geniş bir yelpazede yüksek doğruluk oranlarıyla optimize edilebilir[21], [22]. Sonuç olarak ResNet50 metodu, derinlikten kaynaklanan karmaşıklığı atlamalı bağlantılarla yöneterek kararlı ve ölçeklenebilir bir öğrenme performansı sunar [21], [22], [23].

D. Topluluk Öğrenmesi (Ensemble Learning)

Karmaşık sorunların çözümünde tek bir modelin sınırlarını aşmak için birden fazla öğrenme algoritmasının güçlü yönlerini birleştiren kritik bir stratejidir[24]. Bu metodun temel amacı, veriden tek bir hipotez öğrenmek yerine birden fazla hipotez oluşturup bunları harmanlayarak tahmin doğruluğunu, modelin sağlamlığını (robustness) ve genellenebilirliğini artırmaktır[24], [25]. Topluluk yöntemleri, farklı modellerin yaptığı hataların birbirini dengelemesi prensibine dayanır; bu sayede bireysel modellerin zayıflıkları hafifletilirken, çeşitlilikten yararlanılarak daha güvenilir sonuçlar elde edilir[24], [25].

Topluluk modellerinde nihai çıktıyı belirlemek için sıklıkla oylama (voting) mekanizmalarına başvurulur[26], [27]. Bu mekanizmalar, modellerin net etiket tahminlerini temel alan "sert oylama" (hard voting) veya modellerin sınıf olasılıklarını dikkate alan "yumuşak oylama" (soft voting) şeklinde ikiye ayrılır [28], [29]. Yumuşak oylama; olasılıkların ortalaması, çarpımı, maksimumu veya minimumu gibi farklı varyasyonlarla uygulanarak karar sürecine daha fazla bilgi katılmasına olanak tanır[27]. Topluluk öğrenmesi, sağladığı yüksek performansa rağmen, birden fazla modelin eğitilmesi ve saklanması nedeniyle yüksek hesaplama maliyeti, modellerin karmaşıklığından dolayı yorumlanabilirlik zorlukları ve dikkatli yapılandırılmadığında veri kirliliğine karşı hassasiyet gibi zorlukları da beraberinde getirir[24].

II. BULGULAR

Araştırma kapsamında geliştirilen modellerin sınıflandırma performansları; doğruluk, F1-makro skoru, kesinlik ve duyarlılık metrikleri üzerinden 5-katlı çapraz doğrulama yöntemiyle detaylıca analiz edilmiştir. Deneysel bulgular, transfer öğrenme tabanlı ResNet50 mimarisinin tüm tekil modeller arasında en sağlam performansı sergileyerek 40 döngü (epoch) sonunda %99,0 doğruluk ve 0,990 F1-skoru ile en yüksek başarıya ulaştığını göstermektedir. Buna karşılık, sıfırdan eğitilen CNN modelinin sınırlı veri rejiminde %74,5 ile %96,5 arasında dalgalı bir öğrenme eğrisi izlediği, hibrit CNN-SVM modelinin ise özellikle kısa eğitim sürelerinde (%89,5) hızlı bir yakınsama göstermesine rağmen uzun vadeli eğitim rejimlerinde saf derin öğrenme modellerinin gerisinde kalarak plato yaptığı saptanmıştır. Çalışmanın mutlak zirve noktası, farklı modellerin sunduğu olasılık kestirimlerini sentezleyen Ağırlıklı Yumuşak Oylama (Weighted Soft Voting) yöntemiyle 40 epoch sonunda elde edilen %99,38 doğruluk ve %99,37 F1-makro skorudur. Sınıf bazlı analizlerde, tüm modellerin "A Kalite" ahşap numunelerini %100 başarıyla ayırt edebildiği, ancak morfolojik benzerlikler ve doku geçişkenlikleri nedeniyle en zorlayıcı kategorinin "C Kalite" olduğu belirlenmiştir. Son olarak, sistemin istatistiksel ayırt ediciliğini kanıtlayan ROC-AUC analizinde 0,998'lik bir makro ortalama değerine ulaşılarak, geliştirilen dijital çerçevenin endüstriyel kalite standartlarında kusursuz bir sınıflandırma kapasitesine sahip olduğu doğrulanmıştır.

TARTIŞMA

Bu çalışmada elde edilen sonuçlar, derin öğrenme ve topluluk öğrenmesi yaklaşımlarının ahşap kalite sınıflandırmasında manuel yöntemlerin %70-80 bandındaki kısıtlı doğruluğunu aşarak "sıfır hata" vizyonuna hizmet ettiğini kanıtlamaktadır. Araştırmanın en temel bulgusu, transfer öğrenme avantajına sahip **ResNet50** mimarisinin "atlama bağlantıları" (skip connections) sayesinde öznitelikleri daha etkin öğrenerek %99,0 doğruluğa ulaşması, ancak en yüksek başarının modellerin olasılık kestirimlerini sentezleyen **Yumuşak Oylama (Soft Voting)** yöntemiyle %99,38 seviyesine taşınmasıdır. Özellikle modellerin morfolojik benzerlikler ve doku geçişkenlikleri nedeniyle en çok zorlandığı "C Kalite" sınıfında, topluluk öğrenmesi yöntemi F1-skorunu 0,982 seviyesine yükselterek tekil modellerin zayıflıklarını başarıyla telafi etmiştir. **CNN+SVM** hibrit modelinin kısa sürede doygunluğa ulaşarak uzun vadeli eğitimlerde saf derin öğrenme modellerinin gerisinde kalması, organik ahşap dokularının karmaşıklığını modellemede uçtan uca derin ağların ve kolektif karar mekanizmalarının üstünlüğünü doğrulamaktadır. Sonuç olarak önerilen bu dijital çerçeve, treyler üretim hatlarında operatör yorgunluğundan kaynaklanan hataları minimize ederek hammadde israfını azaltan ve **Endüstri 4.0** standartlarında ölçeklenebilir bir kalite kontrol çözümü sunmaktadır.

III. SONUÇLAR

Bu çalışma, treyler üretiminde kritik öneme sahip araç taban ahşaplarının kalite sınıflandırma süreçlerini otomatize etmek amacıyla derin öğrenme ve topluluk öğrenmesi yaklaşımlarını birleştiren yüksek performanslı bir dijital çerçeve geliştirmiştir. Araştırma sonuçları, geleneksel manuel denetim yöntemlerindeki %70-80 bandında kalan subjektif başarı oranlarının, önerilen hibrit mimarilerle "sıfır hata" vizyonuna uygun şekilde %99'un üzerine çıkarılabileceğini kanıtlamıştır. Deneysel analizler sonucunda, **ResNet50** mimarisinin %99,0 doğrulukla en güçlü tekil model olduğu; ancak modellerin olasılık kestirimlerini sentezleyen **Ağırlıklı Yumuşak Oylama (Weighted Soft Voting)** yönteminin **%99,38 doğruluk** ve **0,9937 F1-skoru** ile çalışmanın mutlak performans zirvesini oluşturduğu saptanmıştır. Geliştirilen bu sistem, özellikle "A Kalite" ürünlerde kusursuz bir ayırt edicilik sergileyerek ve "C Kalite" gibi zorlayıcı sınıflarda dahi yüksek hassasiyet sağlayarak hammadde fire oranlarını minimize etme ve üretim hattında 7/24 nesnel denetim sağlama potansiyeline sahiptir. Sonuç olarak, önerilen metodoloji otomotiv yan sanayinde dijital dönüşüm için ölçeklenebilir bir temel sunarken; gelecek çalışmalarda **Vision Transformer** gibi yeni nesil mimarilerin kullanımı ve IoT tabanlı sensör entegrasyonu ile sistemin operasyonel dayanıklılığının daha da artırılması hedeflenmektedir

TEŞEKKÜR

Bu çalışmanın planlanması, yürütülmesi ve analiz süreçlerinde değerli bilgi birikimi, akademik yönlendirmeleri ve sürekli desteği ile bana rehberlik eden kıymetli hocam Doç. Dr. Ayten YILMAZ YALÇINER'e en içten teşekkürlerimi sunarım. Ayrıca, araştırmanın gerçekleştirilmesi için gerekli olan teknik altyapı ve imkanları sağlayan Sakarya Üniversitesi'ne ve veri toplama sürecindeki katkılarından dolayı ilgili tüm birimlere şükranlarımı sunarım.

KAYNAKLAR

[1] Ş. Turan Avcı and S. Karaman Öztaş, "Ahşap Teknolojilerinin Süreç ve Performans Kriterleri Bağlamında Değerlendirilmesi: Sürdürülebilir Tasarım ve Üretim Yaklaşımları," *Kent Akademisi*, vol. 18, no. 5, pp. 2813–2830, 2025, doi: 10.35674/kent.1615320.

[2] R. Barış and N. V. Gür, "Ahşap Yapı Üretiminde Cephe Kuruluşunun Değerlendirilmesi," *Artium*, vol. 9, no. 2, pp. 47–67, 2021, doi: 10.51664/artium.802513.

[3] E. Çavdar, B. Yıldız, and S. Kaya, "Ahşap Ürünleri İmalatı Sektöründe Teknolojik Hazırlık Düzeyinin Tespiti; Sorunlar ve Çözüm Önerileri," *Econder Uluslararası Akademik Dergi*, vol. 9, no. 1, pp. 116–154, 2025, doi: 10.35342/econder.1704561.

[4] M. Ericsson, D. Johansson, and D. Stjern, "AI-based quality control of wood surfaces with autonomous material handling," *Applied Sciences*, vol. 11, no. 21, p. 9965, 2021.

[5] M. Ji, W. Zhang, X. Diao, G. Wang, and H. Miao, "Intelligent Automation Manufacturing for Betula Solid Timber Based on Machine Vision Detection and Optimization Grading System Applied to Building Materials," *Forests*, vol. 14, no. 7, Jul. 2023, doi: 10.3390/f14071510.

[6] C. Fan, Z. Zhuang, Y. Liu, Y. Yang, H. Zhou, and X. Wang, "Bilateral Defect Cutting Strategy for Sawn Timber Based on Artificial Intelligence Defect Detection Model," *Sensors*, vol. 24, no. 20, Oct. 2024, doi: 10.3390/s24206697.

[7] M. Kryl, L. Danys, R. Jaros, R. Martinek, P. Kodytek, and P. Bilik, "Wood Recognition and Quality Imaging Inspection Systems," 2020, *Hindawi Limited*. doi: 10.1155/2020/3217126.

[8] U. Şevik, "Kereste Kalite Kontrolünde Derin Öğrenme: YOLOv8 Mimarisi ile Gerçek Zamanlı Çok Sınıflı Yüzey Kusur Tespiti," *Düzce Üniversitesi Orman Fakültesi Ormancılık Dergisi*, vol. 21, no. 2, pp. 352–378, 2025, doi: 10.58816/duzceod.1814094.

[9] O. Burström, S. Zou, M. Fredriksson, and J. A. J. Huber, "Machine learning for non-destructive evaluation of wood," *Wood Mater. Sci. Eng.*, 2026, doi: 10.1080/17480272.2026.2621200.

[10] L. C. Chen *et al.*, "Edge-glued wooden panel defect detection using deep learning," *Wood Sci. Technol.*, vol. 56, no. 2, pp. 477–507, Mar. 2022, doi: 10.1007/s00226-021-01316-3.

[11] M. Cinal, A. Sioma, and B. Lenty, "The quality control system of planks using machine vision," *Applied Sciences*, vol. 13, no. 16, p. 9187, 2023.

[12] O. Morales Matamoros, J. G. Takeo Nava, J. J. Moreno Escobar, and B. A. Ceballos Chávez, "Artificial intelligence for quality defects in the automotive industry: A systemic review," *Sensors*, vol. 25, no. 5, p. 1288, 2025.

[13] Y. Çelik, B. Dengiz, and S. Güney, "Ahşap ham maddelerde yüzey hatasını belirlemek için görüntü işleme tabanlı kalite kontrol sistemi," *Mühendislik Bilimleri ve Tasarım Dergisi*, vol. 11, no. 4, pp. 1365–1382, 2023, doi: 10.21923/jesd.1248010.

[14] Y. Yang, X. Zhou, Y. Liu, Z. Hu, and F. Ding, "Wood defect detection based on depth extreme learning machine," *Applied Sciences (Switzerland)*, vol. 10, no. 21, pp. 1–14, Nov. 2020, doi: 10.3390/app10217488.

[15] S. Albelwi and A. Mahmood, "A framework for designing the architectures of deep convolutional neural networks," *Entropy*, vol. 19, no. 6, p. 242, 2017.

[16] S. Sakib, N. Ahmed, A. J. Kabir, and H. Ahmed, "An overview of convolutional neural network: Its architecture and applications," 2019.

[17] M. M. Taye, "Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions," *Computation*, vol. 11, no. 3, p. 52, 2023.

[18] M. E. Sonmez, K. Sabanci, and N. Aydin, "Convolutional neural network-support vector machine-based approach for identification of wheat hybrids," *European Food Research and Technology*, vol. 250, no. 5, pp. 1353–1362, 2024.

[19] Y. E. Almalki *et al.*, "Isolated convolutional-neural-network-based deep-feature extraction for brain tumor classification using shallow classifier," *Diagnostics*, vol. 12, no. 8, p. 1793, 2022.

[20] H. Hasan, H. Z. M. Shafri, and M. Habshi, "A comparison between support vector machine (SVM) and convolutional neural network (CNN) models for hyperspectral image classification," in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, 2019, p. 012035.

[21] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, "Deep learning in image classification using residual network (ResNet) variants for detection of colorectal cancer," *Procedia Comput. Sci.*, vol. 179, pp. 423–431, 2021.

[22] A. Shabbir *et al.*, "Satellite and scene image classification based on transfer learning and fine tuning of ResNet50," *Math. Probl. Eng.*, vol. 2021, no. 1, p. 5843816, 2021.

[23] M. Shafiq and Z. Gu, "Deep residual learning for image recognition: A survey," *Applied sciences*, vol. 12, no. 18, p. 8972, 2022.

[24] N. Rane, S. P. Choudhary, and J. Rane, "Ensemble deep learning and machine learning: applications, opportunities, challenges, and future directions," *Studies in Medical and Health Sciences*, vol. 1, no. 2, pp. 18–41, Jul. 2024, doi: 10.48185/smhs.v1i2.1225.

[25] Y. Zhang, J. Liu, and W. Shen, "A Review of Ensemble Learning Algorithms Used in Remote Sensing Applications," Sep. 01, 2022, *MDPI*. doi: 10.3390/app12178654.

[26] "ensemble".

[27] A. S. Assiri, S. Nazir, and S. A. Velastin, "Breast Tumor Classification Using an Ensemble Machine Learning Method," *J. Imaging*, vol. 6, no. 6, May 2020, doi: 10.3390/JIMAGING6060039.