

Tekstil Ürünlerindeki Hataların Transfer Öğrenmesi Tabanlı Yaklaşımlarla Tespiti

Kürşat Demir¹ ve Fatih Demir^{2*}

¹Mekatronik Mühendisliği / Fen Bilimleri Enstitüsü, Fırat Üniversitesi, Türkiye

²Elektronik ve Otomasyon Bölümü / Fen Bilimleri Enstitüsü, Fırat Üniversitesi, Türkiye

*fatihdemir@firat.edu.tr

Özet – Çoklu üretimin yapıldığı fabrikalarda üretim kalitesini artırmak birinci hedeftir. Kalite artırımını da hatasız ürün çıkarmakla mümkündür. Gün içerisinde birçok ürünün elde edildiği fabrikalarda hata tespiti yapmak için kuvvetli otomasyon sistemlerine ihtiyaç duyulmaktadır. Tekstil ürünleri de en çok hatanın yapıldığı ve bu hataların tespitinin bulunmasının zor olduğu bir alandır. Günümüzde yapay zekâ teknolojileri hata tespitleri üzerine başarılı sonuçlar vermektedir. Bu çalışmada farklı fabrikalardan alınan tekstil ürünlerindeki hatalar, görüntüler kullanılarak derin öğrenme tabanlı yaklaşımlarla otomatik olarak tespit edilmeye çalışılmıştır. Bu tespit için transfer öğrenmesi yaklaşımları kullanılmıştır. Transfer öğrenmesi yaklaşımı için 3 farklı (ResNet50, VGG16 ve MobileNetV2) ön-eğitilmiş popüler modellerden yararlanılmıştır. Bu modeller içerisinde en başarılı sonucu %93.19 ile ResNet50 modeli vermiştir.

Anahtar Kelimeler – Tekstil Ürünleri, Transfer Öğrenmesi, Hata Tespiti

I. GİRİŞ

İnsanların yaşam standartlarının iyileşmesiyle birlikte canlı ürünlerin kalite talepleri de artmaktadır. Ancak çatlak, leke gibi kusurlar, kişilerin ürünleri kullanma deneyimi üzerinde büyük bir olumsuz etkiye sahiptir. Bu nedenle tekstil sektörü, inşaat sektörü, elektronik üretim sektörü gibi sektörlerde kalite denetimi çok önemli bir görevdir. Ayrıca giyim, insanların katı bir talebidir, rolü sadece sıcak tutmak değil, aynı zamanda kişisel imajı tamamlamak ve rahat bir dokunsal ortam oluşturmaktır. Bu nedenle, tekstil endüstrisinde titiz kalite test prosedürleri esastır [1].

Kumaşın yüzey bozuklukları, kumaşın kalite sorunlarına neden olan ana faktördür. Bu nedenle kumaşların yüzey kusurlarının tespiti, kumaş kalite denetiminin kritik noktasıdır. Bir dereceye kadar, kumaş kusurlarının ölçüğü ipliğin ve tezgahın kalitesinden etkilenir [2]. Hata nedenlerinin çoğu, dokuma sırasında renk veya genişlikteki tutarsızlıklar, tüylülük, bambu düğümleri ve kırık uçlar gibi iplik sorunlarıdır. Ayrıca uygun olmayan makine parametreleri, makine hasarı, aşırı gerilme

ve diğer makine kusurlarından da kaynaklanabilir. Tekstil endüstrisi tarafından 70'den fazla kumaş hatası tanımlanmıştır [3]. Çoğu, dokuma sırasında kumaş hareketinin yönünde veya dikey yönünde ortaya çıkar. Kalite standartlarına göre kumaş yüzeyindeki kusurlar, yüzeyin düzgün olmayan rengi ve yerel doku düzensizlikleri olmak üzere iki kategoriye ayrılabilir [4]. Dokumadaki yaygın kumaş kusurları arasında dikişlerin ayrılması, çözgü kırılması, çözgü yapışması, hamur lekeleri, yüzen iplikler, kırık delikler, haddelenmiş atkı, lekeler vb. tezgahta hasar. İlgili bir araştırmaya göre, kumaş kusurları genel fiyatı %45-65 oranında düşürür. Bu ciddi kusurlar yalnızca gelir düşüşüne yol açmaz, aynı zamanda bazen kumaş satılamaz hale getirir. Ayrıca, ürünü satan tüccar üzerinde itibar etkisi ve gereksiz satış sonrası işlemler mümkündür. Bu sorunlara işaret eden, kumaş kusurlarının tespit etmeye yönelik otomatik sistem, ürün kalitesini artırabilir, dokuma maliyetinden tasarruf sağlayabilir ve kaynak israfını azaltabilir [5].


Giyim endüstrisi çok büyük bir üretim hacmine sahiptir, bu nedenle tekstil üretimi için kumaş

kusur tespit sistemlerine olan ihtiyaç da aynı derecede yüksektir. Özellikle yüksek kaliteli kumaşlar, yüksek kaliteli hammaddeler kullanılarak dokunduğunda, kumaş kusur tespit sistemleri için gereksinimler daha katı olacaktır. Tekstil dokuma testi genellikle iki aşamaya ayrılır. İlk aşama, dokuma işlemi sırasında işlem parametrelerinin incelenmesidir. Önleyici bir denetim olarak, bu tür bir denetim, dokuma sürecini ve parametreleri hatalar ve değişiklikler için sürekli izleyen bir izleme davranışıdır. Bununla birlikte, dokuma işleminde çok fazla etkileyen faktör ve değişken olduğundan ve küçük değişiklikler farklı kumaş kusur kategorilerine yol açabileceğinden, dokuma işlemi genellikle sadece parametre incelemesidir, ancak kusur olup olmadığını tespit etmez. İkinci aşama ürün denetimidir. Dokuma sonrası kumaşta kusur olup olmadığını tespit eder. Mevcut araştırma, esas olarak ürün inceleme aşamasına odaklanmıştır [6]. Bugüne kadar, manuel görsel inceleme, tekstil endüstrisinde kumaş kusuru tespitinin ana yöntemi ve kumaş kalite kontrolünde büyük rol oynuyor. Bununla birlikte, yöntem, işçilerin yüksek emek yoğunluğundan, dokuma tezgahının yakınındaki zorlu çalışma ortamından, düşük algılama verimliliğinden ve yüksek yanlış algılama oranından mustarıdır [7]. Bu nedenle, manuel gözle muayene yöntemlerinin yüksek maliyeti ve düşük etkinliği insanları her zaman rahatsız etmektedir [8].

Bilgisayarla görme, sorunları çözmek amacıyla görüntüleri işlemek için bilgisayarları kullanan bir teknolojidir. Son yıllarda bilgisayarlı görü alanında araştırmaların artması ve teknolojinin hızla gelişmesi nedeniyle bilgisayarlı görü teknolojisini kullanarak araştırma yapmak için birçok yenilikçi konu ortaya çıkmıştır [9]. Bu nedenle, bilgisayarlı görü teknolojisine dayalı otomatik kumaş hatası tespit yöntemleri oldukça ilgi çekmiştir.

II. MATERYAL VE YÖNTEM

Çalışmamız için AITEX kumaş kusuru veri seti kullanıldı. Bu veri seti, 4096×256 çözünürlüğe sahip 106 hatalı ve 141 hatasız kumaş görüntüsü içermektedir. AITEX veri setine [10] internet üzerinden erişilebilir (www.aitex.es/afid). Veri setindeki her iki sınıf için örnek gösterimler Şekil 1'de verilmiştir.




Şekil 1. Veri setindeki kumaş görüntüleri için örnek gösterimler

Bu veriler üzerinde otomatik sınıflandırma yapmak için transfer öğrenmesi yaklaşımı benimsenmiştir. Transfer öğrenmesi yaklaşımında popüler üç adet ön-egitimli evrimsel sinir ağları (ESA) modeli kullanılmıştır. Bu modeller VGG16, MobileNetV2 ve ResNet50 modellerinden oluşmaktadır.


III. BULGULAR

Bu çalışmada kullanılan tüm kodlamalar i9 12. nesil işlemcili, 64 GB DDR5 bellekli ve 12 GB ekran kartına sahip bir dizüstüne bilgisayara kurulu MATLAB programı ile gerçekleştirilmiştir. Veri seti eğitim-test işlemi için rastgele sırasıyla %70-30 oranında bölünmüştür. Eğitim seçeneklerinde başlangıç öğrenme oranı 0.001, mini-toptan öğrenme boyutu 32 olarak ayarlanmıştır. Diğer tüm parametreler varsayılan seçenekte bırakılmıştır. Performans değerlendirme kriteri olarak doğruluk kullanılmıştır. Kayıp fonksiyonu olarak cross entropi baz alınmıştır. Ayrıca sınıflar içindeki doğru tahmin oranları hakkında bilgi sahibi olunması için karmaşıklık matrisleri de verilmiştir.

İlk olarak MobileNetV2 modeli ile transfer öğrenmesi yaklaşımı stratejisi veri seti üzerine uygulanmıştır. Bu yaklaşım ile elde edilen eğitim-test doğruluk ve kayıp değerleri sırasıyla Şekil 2 ve 3'te verilmiştir. 150 yineleme sonunda %83.78 test doğruluk ve 0.59 test kayıp değerleri elde edilmiştir.

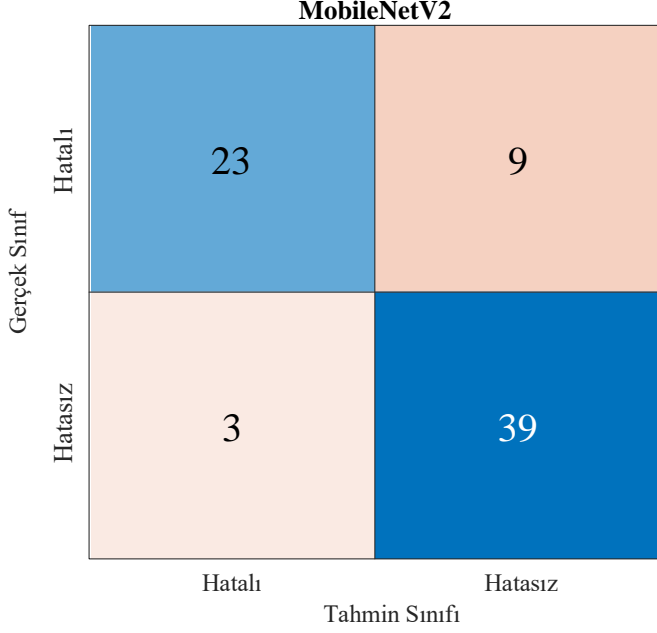


Şekil 2. MobileNetV2 modeli için doğruluk değişim grafiği




Şekil 3. MobileNetV2 modeli için kayıp değişim grafiği

Şekil 4'te MobileNetV2 modelinde elde edilen test tahminlerine göre karmaşıklık matrisi oluşturulmuştur. Karmaşıklık matrisinden de görüldüğü gibi hatalı sınıftan 9, hatasız sınıftan 3 örnek veri yanlış tahmin edilmiştir.




Şekil 4. MobileNetV2 modeli için karmaşıklık matrisi sonuçları

İkinci olarak VGG16 modeli ile transfer öğrenmesi yaklaşımı stratejisi veri seti üzerine uygulanmıştır. Bu yaklaşım ile elde edilen eğitim-test doğruluk ve kayıp değerleri sırasıyla Şekil 5 ve 6'da verilmiştir. 450 yineleme sonunda %85.13 test doğruluk ve 1.04 test kayıp değerleri elde edilmiştir.



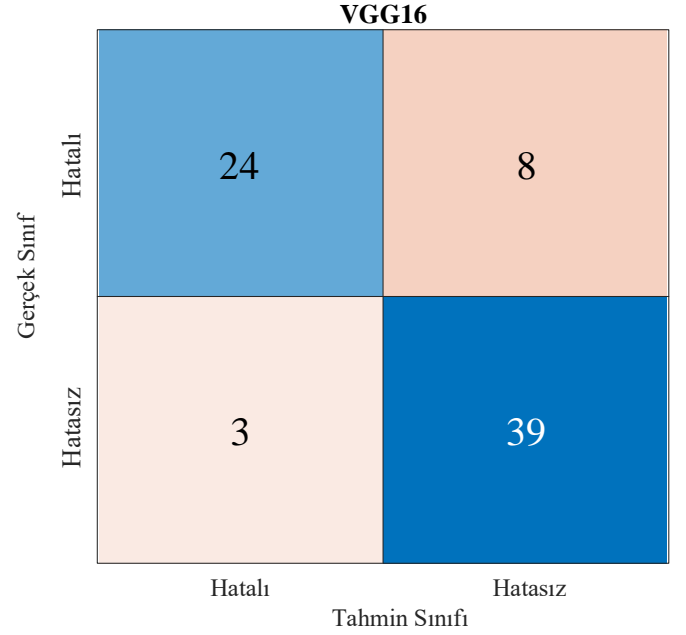
Şekil 5. VGG16 modeli için doğruluk değişim grafiği



Şekil 6. VGG16 modeli için kayıp değişim grafiği


Şekil 7'de VGG16 modelinde elde edilen test tahminlerine göre karmaşıklık matrisi oluşturulmuştur. Karmaşıklık matrisinden de görüldüğü gibi hatalı sınıftan 5, hatasız sınıftan 0 örnek veri yanlış tahmin edilmiştir.

görüldüğü gibi hatalı sınıftan 8, hatasız sınıftan 3 örnek veri yanlış tahmin edilmiştir.




Şekil 7. VGG16 modeli için karmaşıklık matrisi sonuçları

Üçüncü olarak ResNet50 modeli ile transfer öğrenmesi yaklaşımı stratejisi veri seti üzerine uygulanmıştır. Bu yaklaşım ile elde edilen eğitim-test doğruluk ve kayıp değerleri sırasıyla Şekil 8 ve 9'da verilmiştir. 450 yineleme sonunda %93.24 test doğruluk ve 0.32 test kayıp değerleri elde edilmiştir.



Şekil 8. ResNet50 modeli için doğruluk değişim grafiği



Şekil 9. ResNet50 modeli için kayıp değişim grafiği

Şekil 10'da ResNet50 modelinde elde edilen test tahminlerine göre karmaşıklık matrisi oluşturulmuştur. Karmaşıklık matrisinden de görüldüğü gibi hatalı sınıftan 5, hatasız sınıftan 0 örnek veri yanlış tahmin edilmiştir.

		ResNet50	
		Hatalı	Hatasız
Gerçek Sınıf	Hatalı	27	5
	Hatasız	0	42
		Hatalı	Hatasız
		Tahmin Sınıfı	

Şekil 10. VGG16 modeli için karmaşıklık matrisi sonuçları

IV. SONUÇLAR

Bu çalışmada tekstil ürünlerindeki hataların görüntüler vasıtasıyla transfer öğrenme yaklaşımı kullanılarak otomatik olarak saptanması hedeflenmiştir. MobileNetV2, VGG16 ve ResNet50 ön-egitimli modelleri kullanılarak deneysel bulgular elde edilmiştir. Sırasıyla bu modeller için %83.78, %85.13 ve %93.24 test doğruluğu elde edilmiştir. ResNet50 modeli elde edilen bu performans yeterli olarak gözüktüğü de veri setindeki verilerin azlığı nedeni ile bu sonuçlar model güvenilirliği açısından sorgulanmayı gerektirmektedir. Bu nedenle ileriki dönem çalışmalarda daha büyük veri seti ile performans değerlendirmelerinin daha da farklı derin öğrenme modelleri ile tekrarlanması düşünülmektedir.

KAYNAKLAR

- [1] D. Wang and H. Liu, "Edge detection of cord fabric defects image based on an improved morphological erosion detection methods," in *Proceedings - 2010 6th International Conference on Natural Computation, ICNC 2010*, IEEE, 2010, pp. 3943–3947. doi: 10.1109/ICNC.2010.5584778.
- [2] P. M. Mahajan, S. R. Kolhe, and P. M. Patil, "A review of automatic fabric defect detection techniques 1," *Adv. Comput. Res.*, vol. 1, no. 2, pp. 18–29, 2009.
- [3] T. K. Y. Tang, "Hong Kong productivity council - The I-hub of productivity in Hong Kong," *J. Mater. Process. Technol.*, vol. 139, no. 1-3 SPEC, pp. 596–603, 2003, doi: 10.1016/S0924-0136(03)00517-X.
- [4] M. Emadi, P. Payvandy, M. A. Tavanaie, and M. M. Jalili, "Study on linear density effect on the vibration

- behavior of textile strings using video processing," *J. Text. Polym.*, vol. 8, no. 2, pp. 41–51, 2020.
- [5] J. G. Campbell and F. D. Murtagh, "Automatic visual inspection of woven textiles using a two-stage defect detector," *Opt. Eng.*, vol. 37, no. 9, pp. 2536–2542, 1998.
- [6] J. Huart and J.-G. Postaire, "Integration of computer vision onto weavers for quality control in the textile industry," in *Machine Vision Applications in Industrial Inspection II*, SPIE, 1994, pp. 155–163.
- [7] L. Bissi, G. Baruffa, P. Placidi, E. Ricci, A. Scorzoni, and P. Valigi, "Automated defect detection in uniform and structured fabrics using Gabor filters and PCA," *J. Vis. Commun. Image Represent.*, vol. 24, no. 7, pp. 838–845, 2013.
- [8] A. Kumar, "Neural network based detection of local textile defects," *Pattern Recognit.*, vol. 36, no. 7, pp. 1645–1659, 2003.
- [9] M. Shaha and M. Pawar, "Transfer Learning for Image Classification," in *Proceedings of the 2nd International Conference on Electronics, Communication and Aerospace Technology, ICECA 2018*, IEEE, 2018, pp. 656–660. doi: 10.1109/ICECA.2018.8474802.
- [10] J. Silvestre-Blanes, T. Albero-Albero, I. Miralles, R. Pérez-Llorens, and J. Moreno, "A Public Fabric Database for Defect Detection Methods and Results," *Autex Res. J.*, vol. 19, no. 4, pp. 363–374, 2019, doi: 10.2478/aut-2019-0035.