

paintistanbul TURKCOAT CONGRESS


Makine Öğrenmesinin Boya Endüstrisindeki Rolü ve Uygulama Alanları: Yüksek Doğruluk, Düşük Hata ve Sürdürülebilir Üretim İçin Yeni Yaklaşımlar

The Role and Application Areas of Machine Learning in the Paint Industry: New Approaches for High Accuracy, Low Error and Sustainable Production


Dr. Öğr. Üyesi Özgün YÜCEL
Gebze Teknik Üniversitesi
Kimya Mühendisliği Bölümü

Giriş

Makine öğrenmesi (ML) nedir?



Classification



Regression

Makine öğrenmesinin boya üretimindeki rolü ve önemi

Makine Öğrenimi, boya üretim süreçlerinde aşağıdaki avantajları sağlar:

1. Formülasyon Optimizasyonu:

- ML algoritmaları, çok sayıda hammadde kombinasyonunu analiz ederek, maliyet, kalite ve sürdürülebilirlik açısından optimum formüller geliştirir. Formülasyonların tutarlı ve standart hale getirilmesi sağlanır.

2. Kalite Kontrol ve Tahminleme:

- ML, kalite parametrelerini sürekli olarak izleyerek kalite sapmalarını önceden tahmin edebilir. Üretim süreçlerindeki anormallikler ve hatalar hızlıca belirlenebilir ve önleyici tedbirler alınabilir.

3. Üretim Süreçlerinde Verimlilik Artışı:

- Sensörler ve IoT cihazları ile birlikte çalışan ML sistemleri, enerji tüketimini azaltarak ve üretim sürelerini optimize ederek maliyetleri düşürür. Süreç parametrelerinin optimizasyonu (sıcaklık, karıştırma hızı vb.) daha hızlı ve hassas yapılabilir.

4. Çevresel Etkilerin Azaltılması:

- ML algoritmaları, üretimde minimum atık üretimi ve maksimum geri dönüşüm oranları sağlayacak süreçleri öngörür. Daha çevreci ve sürdürülebilir formüller oluşturularak çevreye duyarlı üretim yapılır.

5. Stok ve Talep Yönetimi:

- Tahmin algoritmaları ile pazar eğilimleri analiz edilerek daha doğru üretim ve stok planlaması yapılabilir. Üretim planları talebe daha hızlı uyum sağlar ve stok maliyetleri azalır.

Bilgisayarlı Görü ve Makine Öğreniminin Boya Endüstrisindeki Birlikte Kullanımı

1. Renk ve Kalite Kontrolünde Otomasyon

- İnsan gözüyle yapılan renk değerlendirmesi, tutarsızlık ve subjektiflik içerir.

2. Ürün Yüzeyi Kusur Tespiti

- Ürün yüzeyindeki çatlaklar, kabarcıklar ve homojen olmayan dağılımlar manuel kontrollerde kolayca gözden kaçabilir.

3. Formülasyon ve Renk Eşleştirmede Akıllı Tahminleme

- Yeni renklerin formülasyonu veya mevcut renklerin eşleştirilmesi zaman alıcı ve deneme-yanılmaya dayalıdır.

4. Proses İzleme ve Optimizasyonu

- Üretim süreçlerindeki parametrelerin (karıştırma, öğütme, sıcaklık vb.) manuel takibi, süreci yavaşlatır ve hatalara açık hale getirir.

5. Akıllı Stok ve Üretim Planlaması

- Üretim planlaması ve stok yönetimi, yanlış tahminler nedeniyle maliyet artışına neden olur.

Yapay Zeka ve Bilgisayarlı Görüye Dayalı Endüstriyel Boya Kusurları Denetimi ve Tespiti

- Yapay zeka öğrenme algoritması (SVM) ile eğitim süreci ve sınıflandırma modeli geliştirilmesi.

Airsang, M., & Kumar, N. G. N. (2017). Industrial paint defect inspection and detection based on artificial intelligence and computer vision. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 5(XI), 2583–2592.




Figure 1: Block diagram

Yapay Zeka ve Bilgisayarlı Görüye Dayalı Endüstriyel Boya Kusurları Denetimi ve Tespiti




Figure 2 : Paint drop



Figure 3 : Edge





Figure 4 : Scratch


- Figür 2: Boya Damlacığı (Paint Drop) Boyama işlemi sırasında boya tabakasının akması sonucu oluşan yüzey kusuru.
- Figür 3: Kenar Kusuru (Edge) Boya uygulaması sırasında yüzeyde oluşan, kabarcık veya hatalı kenar görünümündeki küçük deformasyon.
- Figür 4: Çizik (Scratch) Boyanmış yüzey üzerinde oluşan yüzey hasarı veya çizikler.

Airsang, M., & Kumar, N. G. N. (2017). Industrial paint defect inspection and detection based on artificial intelligence and computer vision. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 5(XI), 2583–2592.

Yapay Zeka ve Bilgisayarlı Görüye Dayalı Endüstriyel Boya Kusurları Denetimi ve Tespiti



- Erken aşamalarda hata tespiti maliyetleri düşürmesi ve müşteri memnuniyetini artırması. Manuel kalite kontrol süreçlerine göre daha hızlı ve etkili sonuçlar alınabilmesi. Otomasyon sayesinde ürün kalitesinin sürekli ve stabil olarak sağlanması



Airsang, M., & Kumar, N. G. N. (2017). Industrial paint defect inspection and detection based on artificial intelligence and computer vision. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 5(XI), 2583–2592.


Kusur tespiti için öngörülmesi için makine öğrenimi tabanlı karar verme yaklaşımı: bir vaka çalışması

Makine öğrenmesi (ML) algoritmalarını kullanarak, üretim süreçlerinde kalite kontrolü amacıyla ürünlerdeki kusurları tahmin eden bir karar destek sistemi geliştirmek ve değerlendirmektir.


Barzizza, E., Biasetton, N., Ceccato, R., & Molena, A. (2024). Machine learning-based decision-making approach for predicting defects detection: A case study. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(3), 3052–3060.

Kusur tespiti için makine öğrenimi tabanlı karar verme yaklaşımı: bir vaka çalışması

Synthetic Minority Over-sampling Technique (SMOTE)



Random Undersampling



Barzizza, E., Biasetton, N., Ceccato, R., & Molena, A. (2024). Machine learning-based decision-making approach for predicting defects detection: A case study. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(3), 3052–3060.

Kusur tespiti için öngörülmesi için makine öğrenimi tabanlı karar verme yaklaşımı: bir vaka çalışması


Özellikle hata içeren ürünlerin kusursuz olarak sınıflandırılması durumu (yanlış negatif) kritik olarak ele alınmıştır. Veri setleri iki farklı şekilde kullanılmıştır: Orijinal dengesiz veri seti. Rastgele alt örnekleme yöntemiyle dengelenmiş veri seti.

Table 2. Performance of RF, LightGBM and C5.0, threshold equal to 0.2, unbalanced and balanced data

ML algorithm	Unbalanced data			Balanced data		
	RF	LightGBM	C5.0	RF	LightGBM	C5.0
AUC	0.7447	0.7209	0.7110	0.7294	0.6979	0.6875
Accuracy	0.6659	0.6662	0.6807	0.5377	0.5733	0.5584
Recall	0.7076	0.6490	0.6029	0.9929	0.9572	0.9608
Precision	0.3552	0.3465	0.3520	0.5288	0.5508	0.5420
Sensitivity	0.7076	0.6490	0.6029	0.9929	0.9572	0.9608
Specificity	0.6547	0.6709	0.7014	0.0480	0.1602	0.1259
FNR	0.2924	0.3510	0.3971	0.0071	0.0428	0.0392
FPR	0.3453	0.3291	0.2986	0.9520	0.8398	0.8741

Barzizza, E., Biasetton, N., Ceccato, R., & Molena, A. (2024). Machine learning-based decision-making approach for predicting defects detection: A case study. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(3), 3052–3060.

OTOMOTİV ENDÜSTRİSİ İÇİN BAZKAT BOYADA KALİTE ÖZELLİKLERİNE YÖNELİK MAKİNE ÖĞRENİMİ




OTOMOTİV ENDÜSTRİSİ İÇİN BAZKAT BOYADA KALİTE ÖZELLİKLERİNE YÖNELİK MAKİNE ÖĞRENİMİ

Tablo 3.1: Bazkat uygulama parametreleri.

Panel No	Akış Hızı	RPM	Set Sıcaklık	Viskozite	Set Nem Değeri	1. Tur		2. Tur	
						Okunan Sıcaklık 1	Okunan Nem 1	Okunan Sıcaklık 2	Okunan Nem 2
1	120	50	24	63	62-65	22,9	64	22,8	62,9
2	120	50	24	65	62-65	23	60,5	22,7	58,9
3	120	50	26	63	62-65	20,7	75,7	20,8	77,6



İnce Film Kalınlığı	9-13µm	1.
İdeal Film Kalınlığı	14-17µm	2.
Kalın Film Tabakası	18-25µm	3.
Çok Kalın Film Tabakası	26-40µm	4.



OTOMOTİV ENDÜSTRİSİ İÇİN BAZKAT BOYADA KALİTE ÖZELLİKLERİNE YÖNELİK MAKİNE ÖĞRENİMİ

Tablo 3.1: Bazkat uygulama parametreleri.


Panel No	Akış Hızı	RPM	Set Sıcaklık	Viskozite	Set Nem Değeri	1. Tur		2. Tur	
						Okunan Sıcaklık 1	Okunan Nem 1	Okunan Sıcaklık 2	Okunan Nem 2
1	120	50	24	63	62-65	22,9	64	22,8	62,9
2	120	50	24	65	62-65	23	60,5	22,7	58,9
3	120	50	26	63	62-65	20,7	75,7	20,8	77,6



Tablo 4.4: Ölçülen L değerleri.

Panel No	L değeri 1			L değeri 2			L değeri 3			Ortalama
	25	45	75	25	45	75	25	45	75	
1	22,72	12,4	8,61	22,86	12,45	8,5	23,04	12,5	8,52	23,0
2	22,46	12,16	8,65	22,92	12,5	8,92	23,01	12,55	8,91	22,8
3	21,85	12,40	8,46	22,00	12,40	8,54	21,01	12,52	8,54	22,0


L* DEĞERLERİNİN TAHMİNİ



OTOMOTİV ENDÜSTRİSİ İÇİN BAZKAT BOYADA KALİTE ÖZELLİKLERİNE YÖNELİK MAKİNE ÖĞRENİMİ

CLASSIFICATION OF ADHESION TEST RESULTS		
CLASSIFICATION	PERCENT AREA REMOVED	SURFACE OF CROSS-CUT AREA FROM WHICH FLAKING HAS OCCURRED FOR SIX PARALLEL CUTS AND ADHESION RANGE BY PERCENT
5B	0% None	
4B	Less than 5%	
3B	5 - 15%	
2B	15 - 35%	
1B	35 - 65%	
0B	Greater than 65%	


- Yapışma testi uygulaması kuru film kalınlığı 50 mikron üzerinde olan kaplamalar için kesici alet ile 1'er mm aralıklarla 11 adet düz kesikler atılır. Panel yüzeyine atılan kesikler 11 dikey 11 yatay ve birbiri ile kesişecek şekilde uygulanır. Eş kareler elde edilir. Elde edilen eş kareler üzerine basınca duyarlı özel bir bant ile yüzeydeki kaplamanın yapışma kuvveti tayin edilir.



OTOMOTİV ENDÜSTRİSİ İÇİN BAZKAT BOYADA KALİTE ÖZELLİKLERİNE YÖNELİK MAKİNE ÖĞRENİMİ


Tablo 3.1: Bazkat uygulama parametreleri.

Panel No	Akış Hızı	RPM	Set Sıcaklık	Viskozite	Set Nem Değeri	1. Tur		2. Tur	
						Okunan Sıcaklık 1	Okunan Nem 1	Okunan Sıcaklık 2	Okunan Nem 2
1	120	50	24	63	62-65	22,9	64	22,8	62,9
2	120	50	24	65	62-65	23	60,5	22,7	58,9
3	120	50	26	63	62-65	20,7	75,7	20,8	77,6



Paneller yüzeydeki kaplamanın gevrekliğinden kaynaklı hatalı sonuç vermemesi adına 1 saat soğuması için bekletilmiştir. Panellere sırası ile sol ve sağ taraflarına ASTM D3359-09 test metodu kullanılarak yapışma testi uygulanmıştır.



YAPIŞMA TESTİ TAHMİNİ



Şekil 4.4: Yapışma testi sınıflandırma matrisi.

OTOMOTİV ENDÜSTRİSİ İÇİN BAZKAT BOYADA KALİTE ÖZELLİKLERİNE YÖNELİK MAKİNE ÖĞRENİMİ

YAPIŞMA TESTİ SONUÇLARININ BİLGİSAYARLI GÖRÜYE DAYALI DEĞERLENDİRİLMESİ



Doğru Sınıf	0B	1B	2B	3B	4B	5B
0B	20		1			
1B		8		1	1	
2B			6		1	
3B		2		7	2	
4B				1	7	1
5B		1			3	10
Tahmin Sınıfı	0B	1B	2B	3B	4B	5B

