

Madde Tanıma Sistemlerinde Makine Öğrenmesi Metotlarının Kullanımı

Utilization of Machine Learning Methods in Substance Recognition Systems

Ekrem Kürşad Dal^{*1} , Recai Kılıç² ¹Bilgisayar Programcılığı Bölümü, Kapadokya Üniversitesi, Nevşehir, Türkiye²Elektrik-Elektronik Mühendisliği Bölümü, Erciyes Üniversitesi, Kayseri, Türkiye

(ekrem.dal@kapadokya.edu.tr, kilic@erciyes.edu.tr)

Received: Aug. 21, 2023

Accepted: Aug. 26, 2023

Published: Oct. 18, 2023

Özetçe— Maddelerin cinsinin tayin edilmesi, mevcut maddeye karışan kimyasalların ve partiküllerin tespiti insan sağlığı açısından önemlidir. Tespitler hastalanan insanların şikâyeti sonrasında ya da periyodik aralıklarla yapılan denetimler ile anlaşılabilir. Bunun nedeni bu tür sistemlerin teknik kişilerce değerlendirilmesinin gerekmesinden ve günlük değerlendirilebilecek numunelerin kısıtlı sayıda olmasından kaynaklanmaktadır. Makine öğrenmesi ile eğitilmiş olan sistemler bu değerlendirmeleri gerçek zamanlı sistemlere yakın sürelerde, yüksek doğrulukla gerçekleştirebilmektedir. Makine öğrenmesi kullanan sistemlerde kabul edilebilir ve kabul edilemez olan numuneler ile ağ yapısı eğitilerek oluşabilecek numunedeki farklılıklar otonom olarak sınıflandırılarak değerlendirilebilmektedir. Böylece uzman kişilerin ufak değişimleri gözden kaçırma ihtimali azalırken, daha fazla sayıda numune değerlendirilebilmektedir. Optik sistemler ile yapılan tespitler hem partikül incelemesi açısından hem de çözülmüş madde açısından incelemeye olanak sağlamaktadır. Ayrıca tahribatsız inceleme yapısı ile şeffaf tüp, şeffaf boru, spektrofotometre küveti gibi alternatif ortamlarda ölçümler alınabilmekte, bu da esnek kullanım imkânı sunmaktadır. Yaptığımız çalışmalarda sütün kompleks yapısındaki farklılıklar ve su içerisindeki mikroplastiklerin optik sistemler kullanılarak sınıflandırılması yapılmıştır. Yapılan deneylerin sınıflandırılmasında yapay sinir ağlarından ve derin öğrenme algoritmalarından faydalanılmıştır. Bu algoritmaların madde tayini açısından yüksek doğruluk gösterdiği görülmüştür.

Anahtar Kelimeler : *Yapay Sinir Ağı, Derin Öğrenme, Makine Öğrenmesi, Optik Sensörler, YOLO*

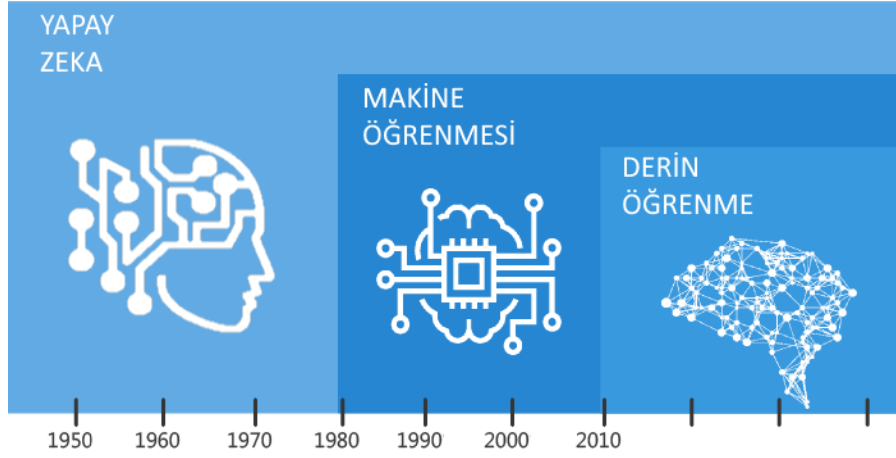
Abstract— Detection of the types of substances, chemicals, and particles present in a given substance is crucial for human health. The detections can only be made after the complaints of affected individuals or through periodic inspections. The reason for this is the need for evaluation by technical experts and the limited number of samples that can be assessed daily. Systems trained with machine learning can perform these evaluations with high accuracy and in near real-time, similar to real-time systems. By training the network with acceptable and unacceptable samples, machine learning-based systems can autonomously classify and evaluate differences in potential samples. As a result, the possibility of experts overlooking minor changes decreases, and a greater number of samples can be evaluated. Detection using optical systems allows examination of both particles and dissolved substances. Furthermore, its non-destructive nature enables measurements in alternative environments such as transparent tubes, transparent pipes, and spectrophotometer cuvettes, offering flexible usability options. In our research, we classified the differences in the complex structure of milk and microparticles in water using optical systems. Artificial neural networks and deep learning algorithms were utilized for the classification of these experiments. It was observed that these algorithms demonstrated high accuracy in substance recognition.

Keywords : *Artificial Neural Network, Deep Learning, Machine Learning, Optical Sensors, YOLO.*

1. Giriş

Makine öğrenmesi, bir cihazın eğitildiği verilere göre öğrenen, öğrendiği verilere göre çıktı verileri üretip sınıflandırmalar yapabilen yapay zekanın alt kollarından birisidir. Eğitilen ağ sayesinde belli işlevsellik içerisinde insan değerlendirmelerini taklit edebilmektedir. Verilerdeki ufak değişimleri sezme yeteneği, teknik bir uzmanın değerlendirmesinde gözden kaçabilecek değişimleri algılamasına olanak sağlamaktadır. Bunun yanı sıra bu değerlendirmeleri yorulmadan sürekli olarak gerçekleştirebilmektedir. Günümüzde makine öğrenmesi temelli sistemler yüz tanıma sistemlerinde, hastalık ön tanısı konulan yerlerde, madde algılama sistemlerinde, fotoğraf

ortamı algılama gibi farklı alanlarda kullanılmaktadır. Otonom olarak sistemler eğitim verilerini güncelleyerek, verdiği sonuçlarda iyileştirmeler yapabildiği gibi, sürekli olarak çalıştırılabilmektedir. Makine öğrenmesi metotları kullanılmadan önce, bütün değerlendirmelerin teknik kişiler tarafından yapılması gerekmektedir. Mikroskop, spektrofotometre, spektroskop, pH metre, boyar kimyasallar gibi metotlar kullanılmaktaydı. Günümüzde halen bu cihazlar kullanılmakta olup, değerlendirme yapacak uzman ekiplerin ve ortamların oluşturulması gerekmektedir. Bu cihazlar sonrasında taşınabilir yapılara dönüştürülmüştür. Ölçüm cihazlarının taşınabilir olması ile problem kaynağının olduğu yerde ölçümler alınabilmektedir. Bu durum numunenin taşınması sırasında bozulması, dökülmesi veya karıştırılması durumlarını en aza indirir de uzman kişilerce değerlendirilmesinin gerekmesi bu cihazlarda da devam etmiştir. Sonrasında çıkan bazı cihazlarda görüntü işleme ile ön değerlendirme yapabilen ve veri tabanı üzerinden sonuç karşılaştırması yapabilen cihazlar çıkmıştır. Bu cihazlar uzman kişilerin işlerini kolaylaştırmakta ve gözden kaçabilecek küçük değişimlerin gözden kaçması durumları çözülsün de görüntü işlemede bulunan şekil, desen kısıtlamaları sebebiyle gözden kaçmalar mevcuttur. Bu sebeple sonuçların doğruluğunun güvenilirliği ise düşüktü. Yapay sinir ağları ve sonrasında geliştirilen derin öğrenme algoritmaları sayesinde güvenilirlik problemleri büyük ölçüde ortadan kalkmıştır. Çünkü büyük veri (big data) ile eğitime tabi tutulan veriler sayesinde farklı şekiller, desenler, renkler ve ışık yoğunluğu gibi öncesinde sonuçlar üzerinde olumsuz etkisi olan parametreler önemsiz hale gelmiştir. Şekil 1’de yapay zekâ kavramının ortaya çıkışı ve yapay zeka kavramının alt kolları olan makine öğrenmesi ve derin öğrenme kavramlarının ortaya çıkışı görülmektedir. Zaman zaman bu kavramlar birbirlerinin yerine kullanılsa da aslında farklı kavramlar olup amaçları insan karar mekanizmasını taklit edebilen sistemler ortaya konulmasıdır.



Şekil 1. Yapay zekâ gelişim süreci

Sağlık alanında diyabet hastalığı gibi kritik öneme sahip durumlarda makine öğrenmesinin kullanıldığı çalışmalar mevcuttur (Kavakiotis et al., 2017; Mhaskar et al., 2017; Potansiyeli Görmek - Google, n.d.). Bu noktada makine öğrenmesi metotlarının popüler konulardan olduğu, medikal alanı gibi kritik görevlerde dahi kullanılabildiğini kanıtlamıştır. Gıda endüstrisinde, tüketim maddelerinde makine öğrenmesi metotları kullanılarak yapılan tespitler ile insan sağlığını koruması da bu sebeple mümkündür. Suların içerisinde ağır metaller, toksik kimyasallar, çeşitli boyutta ve türde partiküller, mikroorganizmalar bulunabilmektedir (Zulkifli et al., 2018). Bu zararlı kimyasalların kaynakları da sorunun ortadan kaldırılması açısından önemlidir. Geliştirilen optik cihazlar ve makine öğrenmesi sayesinde suyun kalitesinde oluşabilecek değişimler hızlı şekilde tespit edilebilir ve sorun kaynağından, tüketicilere ulaşmadan çözülebilir (Asheri Arnon et al., 2019). Yapılan bazı çalışmalarda kanalizasyon suyunun karışması, su depolarındaki kirlilikler, boru hatlarında meydana gelen açıklıklar ve sızıntılar, fabrika atıkları, sel, deprem ve heyelan gibi farklı faktörler sebebiyle suyun kirlenebildiği görülmüştür (Asheri Arnon et al., 2019; Bridgeman et al., 2015; Sayato, 1989; Skadsen et al., 2008; Zulkifli et al., 2018).

Probleme yönelik olarak geliştirilen sistemlerde daha az parametreyi incelemek yeterli olabilmektedir. Genel ölçüm sistemlerinin aksine bu tip sistemlerde sonucu değerlendirmek daha kolay olurken, problemi daha doğru tespit edebilmek mümkündür. Kullanılmayan sensör parametreleri bozucu etkilere sahip olmaktadır. Kullanılacak önemli parametrelerin tespitinde özellik çıkarımı (feature extraction) algoritmaları kullanılabilmektedir (Lyu et al., 2019). Bu algoritmalar sınıflandırmada önemli olan özellikleri puanlayarak ağırlıklandırma sıralaması yapmaktadır (Bajaj et al., 2023). Makine öğrenmesi algoritmalarında daha az giriş oluşturarak ağ yapısında bir anlamda sadeleştirme gerçekleştirilebilmektedir. Probleme yönelik olarak algılama sisteminin geliştirilmesi ile daha düşük maliyet, örnekleme hızının artırılması ve gerçek zamanlı sistem geliştirilebilmesi avantajlarına da sahiptir. Örneğin spektrofotometre ile ölçülen bir numunede özellik çıkarımı sonucunda 550-600nm bölgesinde absorban yoğunluğu olduğu görülsün. Diğer bölgeleri incelemek sistemdeki gürültü yoğunluğunu artıracaktır. Üstelik bu

bölgede çalışan ışık kaynağı olarak LED ya da LED'ler seçilerek ölçüm sistemi LED ve fotosensör basitliğine indirilebilmektedir.

Mikroplastikler günümüzde tespiti zor maddelerden olup çevre sorunlarından birisi haline gelmiştir. Sindirilemeyen bu partiküller doğada parçalanarak birkaç milimetre boyutlardan başlayıp nanometre boyutlarına kadar ulaşabilmektedir. Hayvan doku içlerinde dahi bu partiküllerin olduğunu gösteren çalışmalar bulunmaktadır. Bu partiküller doğada parçalanmayan plastiklerden kendiliğinden oluştuğu gibi kozmetik ve temizlik endüstrisinde etkiyi artırmak adına bilinçli olarak da üretilmektedir. Aşınan araç lastikleri, tekstil ürünlerinin doğal yıpranması ve doğada geri dönüştürülmemiş plastikler bazı aşınma kaynaklı mikroplastik kaynaklarıdır. Bu mikroplastiklerin bir kısmı sadece plastikten değil, kirleticilerden de oluşmaktadır. Boyar maddeler, ağır metaller, mikrobiyolojik canlılar, toksinler mikroplastikler ile taşınabilmektedir.

2. Meteryaller ve Ölçüm Sistemleri

Gerçekleştirilen çalışmalarda sütün markasına göre ayırımında yapay sinir ağı kullanılarak yüksek doğrulukta sınıflandırma başarıları elde edilmiştir. Süt kompleks yapıda bir madde olup yapılan bazı çalışmalarda deniz suyunun simüle edilmesinde kullanılmaktadır (Dubreuil et al., 2013; Piederrière et al., 2005; Wang et al., 2021). Ayrıca sütün bu kompleks yapısı aynı hayvandan alınan aynı miktardaki sütlerin içerisindeki bileşimin farklı olabilmesi, sütün sınıflandırmasında zorluk oluşturabilmektedir.

Bir diğer çalışmada ise mikroplastiklerin su içerisindeki tespiti gerçekleştirilmiştir. Mikroplastiklerin su içerisinde Mie saçılımına bağlı dar açıda oluşturmuş olduğu girişim desenleri üzerinden derin öğrenme algoritması olan YOLO v4 ile partikül boyutu ve partikül cinsi sınıflandırması yapılmıştır. Mikroplastikler üzerindeki çalışmalar halen sürdürülmektedir.

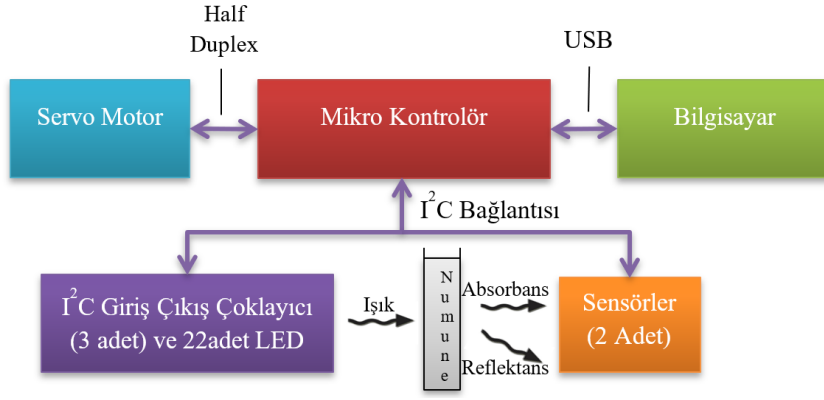
2.1. Markasına göre süt üzerine deneyler

Yapılan çalışmalarda çok LED'li sensör sistemi gerçekleştirilmiş olup sistemde 19 adet dar bantlı, 3 adet ise geniş bantlı LED kullanılmıştır. Böylece 365-950nm arasında çoklu ışık kaynağı elde edilmiştir. Işık kaynağı disk'in arkasında bulunan servo motor vasıtasıyla konumlandırılarak ilgili LED'in açılması ile gerçekleştirilmektedir. Geniş bantlı LED'ler kullanılarak ışık spektrumunda boşluk oluşması engellenmiştir. Şekil 2'de tasarlanan sistem görülmektedir. Sistemin bağlantıları ve çalışma prensibi Şekil 3'teki diyagramda verilmiştir. Elde edilen bu ışık kaynağı ile beraber bir adet dar bantlı bir adet geniş bantlı fotodiyot barındıran 16-bit analog dijital dönüştürücüsüne sahip ışık dijital dönüştürücüsü (TSL2561) ışık dijital dönüştürücüsü kullanılmıştır. Şekil 4'de kullanılan ışık dijital dönüştürücüsünün dalgaboyuna bağlı duyarlılık grafiği verilmiştir. Kullanılan ışık kaynakları sensörün cevap aralığı içerisinde bulunmaktadır.

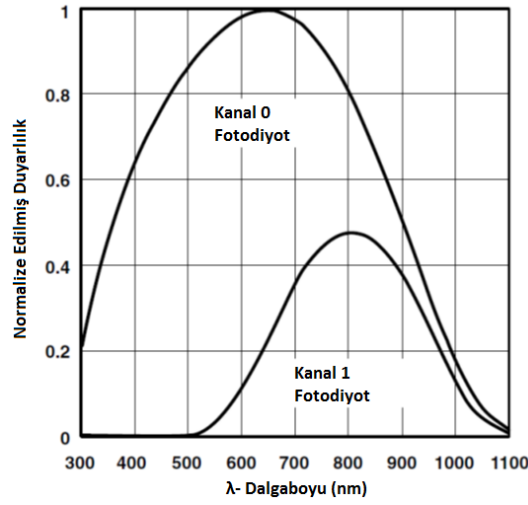
Sistemde bir adet absorban ölçümü için, bir adet de reflektans ölçümü için olmak üzere 2 adet ışık dijital dönüştürücüsü kullanılmıştır. Ölçülecek numunelerdeki fosforesans ve lüminesans içerikli maddelerin oluşturduğu emitans ise kullanılan iki sensördeki toplamda 4 fotodiyot tarafından algılanmaktadır. Ancak buradaki ölçüm parametrik olduğu için ayrı bir emitans verisi oluşturulmamaktadır. Burada birinci ve ikinci kanaldaki fotodiyotlardan alınan veriler 4 veriye ayrılmıştır. Bunlar birinci fotodiyot sayısı değeri, ikinci fotodiyot sayısı değeri, toplam ışık değeri (birinci ve ikinci fotodiyot sayısı değerleri toplamı) ve lux biriminde ışık değerleridir. Sayı değeri olarak ifade edilen birim, analog dijital dönüştürücüsünün kaydedicisinden alınan tam sayı değerleridir. Toplamda iki farklı sensörden bir numune için 176 özellik elde edilmiştir.



Şekil 2. Süt deneylerinde kullanılan yapay sinir ağı destekli ölçüm sistemi




Şekil 3. Süt deneylerinde kullanılan sistemin blok diyagramı



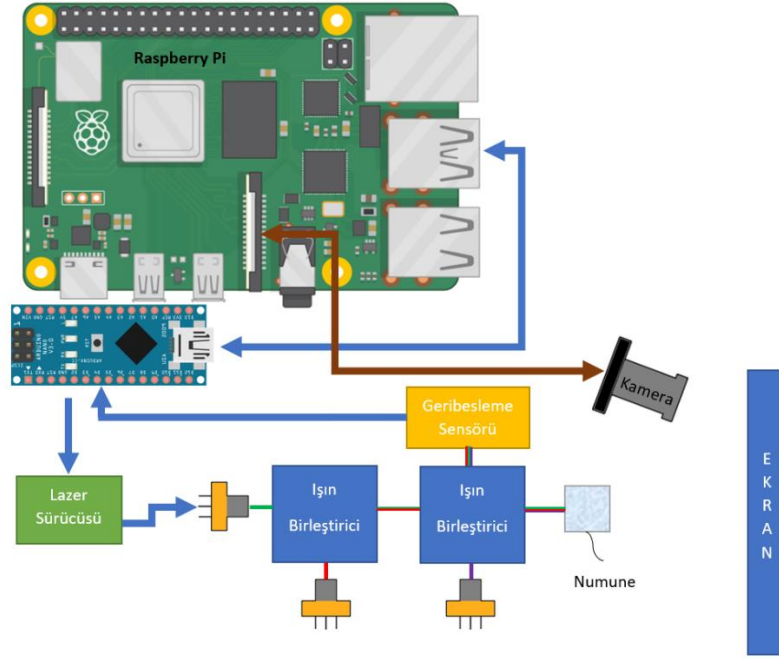
Şekil 4. Işık dijital dönüştürücüsünün (TSL2561) dalgaboyuna bağlı duyarlılık grafiği

2.2. Mikroplastik tespiti üzerine deneyler

Mikroplastik tespit sistemi 3 farklı lazer modülü ışık kaynağı olarak kullanmakta olup, ışın ayırıcıların ışınları birleştirme amacıyla kullanılması ile elde edilmiştir. Lazer modülleri, sunumlarda kullanılan lazer işaretçilerden elde edilmiştir. Sistemde değiştirilebilir odağa sahip kamera ve ön işlemleri yürütmek üzere Raspberry Pi kullanılmıştır. Lazerlerin kontrolü ve geri besleme sensöründen verileri almak için Arduino Nano kullanılmıştır. Gerçekleştirilen sensör sistemi Şekil 5'te verilmiştir. Sistemin bağlantıları ve çalışma prensibi Şekil 6'da verilmiştir.



Şekil 5. Mikroplastik tespit sistemi



Şekil 6. Mikroplastik tespit sistemi blok diyagramı

3. Deneysel Sonuçları

Yapılan ilk çalışmada sütün markasına göre sınıflandırılması deneyi gerçekleştirilmiştir. Süt kompleks yapıda bir madde olup, bağışıklık hücreleri, enzimler, mineraller gibi yeni doğmuş canlının en çok ihtiyaç duyacağı maddeleri içermektedir. Bu maddelerin miktarı sütün veren canlının beslenmesi, stres durumları, hastalığı, mevsimler gibi parametrelere bağlıdır. Marketlerde satılan sütler ise birçok hayvandan toplanmış olan bir karışımın belirli teknikler ile sterilizasyonu sonucunda paketlenmesi ile meydana gelmektedir. Bu nedenle kompleks bir maddenin ayrımı açısından sütün iyi bir örnek olduğu görülmektedir. Sütün markasına ve tipine göre sınıflandırılmasında yapay sinir ağları kullanılmıştır. Yapay sinir ağının eğitimi ve test edilmesi Weka programı üzerinde gerçekleştirilmiştir.

Yapılan ikinci çalışmada ise 8µm melamin, 8µm polistren ve 10µm polistren mikroplastik numunelerinin tespiti gerçekleştirilmiştir. Burada hem aynı boyutta farklı malzemeden numuneler, hem de aynı malzemeden farklı numunelerin incelenmesi gerçekleştirilmiştir. Her birinden 1µl aralıklarla 1-10µl arasında mikroplastik alınarak toplam hacmi 2.5ml olan, üçer kez tekrarlı 90 ölçüm numunesi elde edilmiştir. Deneylerde hatayı minimize etmek için üç kez tekrar edilmiş, her bir numuneden her bir lazer kaynağı için 20 görüntü alınmıştır. Sınıflandırma işleminde YOLO v4 algoritması kullanılmıştır.

3.1. Markasına göre sütün deneysel sonuçları

Markasına göre sütün deneylerinde 16 farklı marka ve tipte ait farklı tipteki sütler sistem tarafından ölçülmüştür. Ölçümlerde tam yağlı sütün, yarım yağlı sütün, organik sütün, günlük sütün ve laktozsuz sütün numuneleri kullanılmıştır. Sınıflandırma sonrasında oluşturulan karışıklık matrisi Şekil 7'de verilmiştir.

	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	
a	23	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	a
b	1	23	0	0	0	0	0	0	0	0	0	1	0	0	0	0	b
c	0	0	25	0	0	0	0	0	0	0	0	0	0	0	0	0	c
d	0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	0	d
e	0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	e
f	0	0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	f
g	0	0	0	0	0	0	25	0	0	0	0	0	0	0	0	0	g
h	1	0	0	0	1	0	0	23	0	0	0	0	0	0	0	0	h
i	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	0	i
j	0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	j
k	0	0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	k
l	2	2	0	0	0	0	0	0	0	0	0	21	0	0	0	0	l
m	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	m
n	0	0	0	0	0	0	0	0	0	0	0	1	0	24	0	0	n
o	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	o
p	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	p

Şekil 7. Markasına göre sütün karışıklık matrisi (confusion matrix)

Bu örnekler arasından (f) organik süt; (g), (i) ve (m) yarım yağlı süt; (n) günlük süt, (o) laktozsuz süt, diğer sütler ise yağlı inek sütüdür.


Özellik seçilimi uygulandığında sistem başarısının daha az parametre için yeterli olduğu görülmüştür. Tablo 1’de info gain (bilgi kazancı) algoritmasının ranker (puanlayıcı) metodu ile puanlanmış özellikler seçilerek sistemin eğitimleri kısıtlı parametrelerin eğitimi ile elde edilen sınıflandırma sonuçları görülmektedir.

Tablo 1. Özellik seçilimine göre sistemin başarısı

Kullanılan Özellik Sayısı	Çapraz Doğrulama (Cross Validation) Başarısı
En iyi 1 parametre	287 doğru sınıflandırma %71,25 başarı
En iyi 2 parametre	288 doğru sınıflandırma %72 başarı
En iyi 3 parametre	289 doğru sınıflandırma %72.25 başarı
En iyi 4 parametre	283 doğru sınıflandırma %70.75 başarı
En iyi 5 parametre	290 doğru sınıflandırma %72.5 başarı
En iyi 6 parametre	306 doğru sınıflandırma %76.5 başarı
En iyi 7 parametre	311 doğru sınıflandırma %77.75 başarı
En iyi 8 parametre	385 doğru sınıflandırma %96.25 başarı
En iyi 9 parametre	392 doğru sınıflandırma %98 başarı
En iyi 10 parametre	392 doğru sınıflandırma %98 başarı
En iyi 11 parametre	393 doğru sınıflandırma %98.25 başarı
En iyi 12 parametre	396 doğru sınıflandırma %99 başarı
En iyi 13 parametre	395 doğru sınıflandırma %98.75 başarı
En iyi 14 parametre	393 doğru sınıflandırma %98.25 başarı
En iyi 15 parametre	395 doğru sınıflandırma %98.75 başarı
En iyi 16 parametre	396 doğru sınıflandırma %99 başarı
En iyi 17 parametre	396 doğru sınıflandırma %99 başarı
En iyi 18 parametre	395 doğru sınıflandırma %98.75 başarı


3.2. Mikroplastik sınıflandırma ve tespit sonuçları

Mikroplastik sınıflandırma deneylerinde sistemden alınan görüntüler YOLO v4 algoritması kullanılarak sınıflandırılmıştır. Elde edilen görüntüler Şekil 8’de verilmiştir.



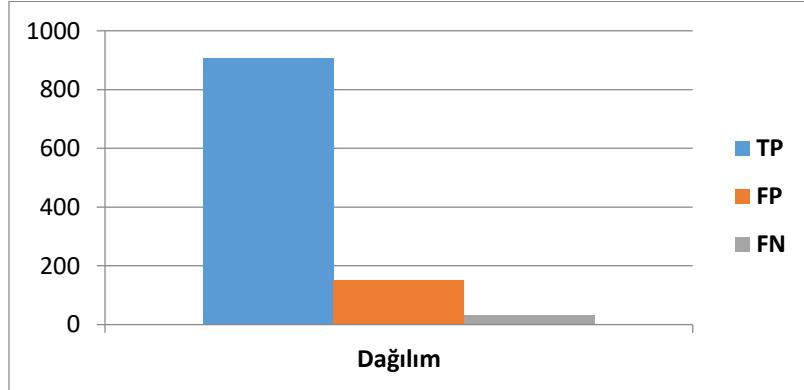
Şekil 8. 2,5ml distile su içerisinde 5µl partiküle sahip 10µm boyutlu polistren’in saçılım girişimi desenleri

Yolo V4’e ait eğitim grafiği Şekil 9’da verilmiştir.



Şekil 9. Sistemin eğitim grafiği

Sistemin testi için 1092 test görüntüsü ayrılmıştır. Bu görüntülere göre elde edilen doğru pozitif (True Positive – TP), yanlış pozitif (False Positive – FP) ve yanlış negatif (False Negative – FN) değerleri Şekil 10’da verilmiştir.



Şekil 10. TP, FP, FN dağılım grafiği

Sınıflandırma sonucunda elde edilen sınıflandırma başarısı Tablo 2’de verilmiştir. Doğruluk (Accuracy), doğru pozitif (TP) ve doğru negatiflerin (TN) toplamının matristeki nesnelere toplamına oranıdır. Hassasiyet (Precision), doğru pozitiflerin (TP), doğru pozitif (TP) ve yanlış pozitif (FP) toplamına oranıdır. Geri çekme (Recall), doğru pozitiflerin (TP), doğru pozitif (TP) ve yanlış negatif (FN) toplamına oranıdır. F1 skoru sistem başarısını daha iyi göstermektedir (Yacouby & Axman, 2020). F1 skoru hassasiyet ile geri çekme çarpımının, hassasiyet ile geri çekme toplamına olan oranının 2 katıdır.

Tablo 2. Yolo V4 algoritmasının mikroplastik numunelerini sınıflandırma başarısı

Doğruluk (Accuracy)	Hassasiyet (Precision)	Geri Çekme (Recall)	F1 Skoru
83	86	97	91

4. Sonuç

Gerçekleştirilen iki deneyde de yapay sinir ağının ve derin öğrenme algoritmalarının %90’ın üzerinde başarı gösterebildiği görülmektedir. Mevcut çalışmalar ekonomik, taşınabilir yapıda olup yerinde analiz yapılabilmesi için uygundur. Makine öğrenmesi metotları günümüzde çok daha karmaşık problemlerin çözümünde katkı

sağladığı görülmektedir. Her iki sistemde de oluşturulan ağlar FPGA veya belirli firmalarca geliştirilmiş yapay zekâ entegreleri üzerine yüklenerek kullanılabilmesi mümkündür. Optik algılama düzenekleri gelecekte küçültülerek cepte taşınabilecek ya da mobil telefonlara entegre edilebilecek yapılar haline getirilebilecektir. Özellik seçilimi ile çok daha az sayıda ışık kaynağı ile probleme yönelik özelleştirilmiş cihazlar geliştirilebilecektir. Yapılan bu çalışmalar farklı problemlerin tespitinde kullanılacak ışık kaynaklarının seçilebildiği çalışmalardır. Probleme yönelik olarak ışık kaynakları azaltıldığında daha az parametreye sahip cihazlar gerçekleştirilebilecektir.

Teşekkür

Çalışmalarımıza sağladığı fon desteği için Erciyes Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne teşekkür ederiz (Proje No: FDK-2020-9708).

Kaynaklar

- Asheri Arnon, T., Ezra, S., & Fishbain, B. (2019). Water characterization and early contamination detection in highly varying stochastic background water, based on Machine Learning methodology for processing real-time UV-Spectrophotometry. *Water Research*, 155, 333–342. <https://doi.org/10.1016/j.watres.2019.02.027>
- Bajaj, N. S., Patange, A. D., Jegadeeshwaran, R., Pardeshi, S. S., Kulkarni, K. A., & Ghatpande, R. S. (2023). Application of metaheuristic optimization based support vector machine for milling cutter health monitoring. *Intelligent Systems with Applications*, 18(February), 200196. <https://doi.org/10.1016/j.iswa.2023.200196>
- Bridgeman, J., Baker, A., Brown, D., & Boxall, J. B. (2015). Portable LED fluorescence instrumentation for the rapid assessment of potable water quality. *Science of the Total Environment*. <https://doi.org/10.1016/j.scitotenv.2015.04.050>
- Dubreuil, M., Delrot, P., Leonard, I., Alfalou, A., Brosseau, C., & Dogariu, A. (2013). Exploring underwater target detection by imaging polarimetry and correlation techniques. *Applied Optics*. <https://doi.org/10.1364/AO.52.000997>
- Kavakiotis, I., Tsave, O., Salifoglou, A., Maglaveras, N., Vlahavas, I., & Chouvarda, I. (2017). Machine Learning and Data Mining Methods in Diabetes Research. *Computational and Structural Biotechnology Journal*, 15, 104–116. <https://doi.org/10.1016/j.csbj.2016.12.005>
- Lyu, Y., Chen, J., & Song, Z. (2019). Image-based process monitoring using deep learning framework. In *Chemometrics and Intelligent Laboratory Systems* (Vol. 189). Elsevier B.V. <https://doi.org/10.1016/j.chemolab.2019.03.008>
- Mhaskar, H. N., Pereverzyev, S. V., & van der Walt, M. D. (2017). A Deep Learning Approach to Diabetic Blood Glucose Prediction. *Frontiers in Applied Mathematics and Statistics*, 3(July), 1–11. <https://doi.org/10.3389/fams.2017.00014>
- Piederrière, Y., Boulvert, F., Cariou, J., Le Jeune, B., Guern, Y., & Le Brun, G. (2005). Backscattered speckle size as a function of polarization: influence of particle-size and- concentration. *Optics Express*, 13(13), 5030. <https://doi.org/10.1364/opex.13.005030>
- Potansiyeli Görmek - Google*. (n.d.). Retrieved July 24, 2023, from https://about.google/intl/tr_zz/stories/seeingpotential/
- Sayato, Y. (1989). WHO Guidelines for Drinking-Water Quality. *Eisei Kagaku*, 35(5), 307–312. <https://doi.org/10.1248/jhs1956.35.307>
- Skadsen, J., Janke, R., Grayman, W., Samuels, W., Tenbroek, M., Steglitz, B., & Bahl, S. (2008). Distribution system on-line monitoring for detecting contamination and water quality changes. *Journal / American Water Works Association*, 100(7), 81–94. <https://doi.org/10.1002/j.1551-8833.2008.tb09678.x>
- Wang, H., Hu, H., Jiang, J., Li, J., Li, X., Zhang, W., Cheng, Z., & Liu, T. (2021). Polarization differential imaging in turbid water via Mueller matrix and illumination modulation. *Optics Communications*, 499(June), 127274. <https://doi.org/10.1016/j.optcom.2021.127274>
- Yacouby, R., & Axman, D. (2020). *Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models*. <https://doi.org/10.18653/v1/2020.eval4nlp-1.9>
- Zulkifli, S. N., Rahim, H. A., & Lau, W. J. (2018). Detection of contaminants in water supply: A review on state-of-the-art monitoring technologies and their applications. *Sensors and Actuators, B: Chemical*, 255, 2657–2689. <https://doi.org/10.1016/j.snb.2017.09.078>