

Atf İçin: Durgun, Y. ve Durgun, M. (2024). Kenar Hesaplama Tabanlı, Mikrodenetleyici Entegreli, Çok Amaçlı Ve Düşük Maliyetli Modül Geliştirilmesi: Bakteriye Koloni Sayımı Örneği. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(2), 531-543.

To Cite: Durgun, Y. & Durgun, M. (2024). Development of an Edge-Computing-Based, Microcontroller-Integrated, Multi-Purpose, and Low-Cost Module: A Bacterial Colony Counting Case Study. *Journal of the Institute of Science and Technology*, 14(2), 531-543.

Kenar Hesaplama Tabanlı, Mikrodenetleyici Entegreli, Çok Amaçlı ve Düşük Maliyetli Modül Geliştirilmesi: Bakteriye Koloni Sayımı Örneği

Yeliz DURGUN^{1*}, Mahmut DURGUN²

Öne Çıkanlar:

- Düşük maliyetli ve enerji tasarruflu bir kenar hesaplama tabanlı modül
- Mikrodenetleyici entegrasyonu sayesinde donanım ve yazılım maliyetlerini azaltırken kullanıcı dostu bir deneyim
- Bakteriye koloni sayımı örneği ile temel uygulama alanında başarılı sonuçlar elde eden modül

Anahtar Kelimeler:

- Arduino Nano 33 BLE
- Bakteriye koloni sayımı
- Görüntü işleme
- Mikrodenetleyici entegrasyonu

ÖZET:

Bu çalışma, bakteriye koloni sayımı ve sınıflandırması için edge-computing temelli, düşük maliyetli ve çok amaçlı bir modül geliştirmeyi amaçlamaktadır. Geleneksel koloni sayım yöntemleri zaman alıcı ve hata payı yüksek olduğundan, özellikle düşük yoğunluklu örneklerde doğruluk ve hassasiyet kaybına yol açar. Bu nedenle, mikrodenetleyici entegrasyonlu ve yapay zeka destekli bir sistem geliştirilmiştir. Çalışmada, Arduino Nano 33 BLE mikrodenetleyici ve 0.3MP OV7675 kamera modülü kullanılmıştır. Görüntü işleme süreçleri, bakteriye kolonilerin segmentasyonu ve morfolojik işlemlerle daha iyi tanımlanması için Gaussian Blur ile Adaptif eşikleme teknikleri kullanılarak gerçekleştirilmiştir. Kolonilerin etiketlenmesi ve özellik çıkarımı için, alan, çevre ve yoğunluk gibi özellikler analiz edilmiştir. Bakteriye koloni sayımı ve sınıflandırma işlemleri için Convolutional Neural Networks (CNN) ve Support Vector Machines (SVM) gibi iki farklı yapay zeka algoritması bir arada kullanılmıştır. CNN, görüntülerin doğrudan işlenmesi ve özellik çıkarımı için derin öğrenme tabanlı bir yöntemken, SVM çıkarılan özelliklere dayalı olarak sınıflandırma gerçekleştiren bir makine öğrenimi algoritmasıdır. Bu iki algoritmanın kombinasyonu, bakteriye koloni analizinde kolaylık sağlamıştır. Geliştirilen sistem, bakteri kolonisi sayılarını ve büyüme hızını zamanla izlemeye olanak tanımaktadır. Bu çalışmanın sonuçları, bakteriye koloni sayımı ve sınıflandırma süreçlerinde daha hızlı ve izlenebilir sonuçlar elde etmek için mikrodenetleyici entegrasyonlu ve yapay zeka destekli bir sistemin önemini vurgulamaktadır.

Development of an Edge-Computing-Based, Microcontroller-Integrated, Multi-Purpose, and Low-Cost Module: A Bacterial Colony Counting Case Study

Highlights:

- A low-cost and energy-efficient edge-computing-based module
- User-friendly experience while reducing hardware and software costs through microcontroller integration.
- Module achieving successful results in the primary application area of bacterial colony counting

Keywords:

- Arduino Nano 33 BLE
- Colony counting
- Image processing
- Bacterial Analysis

ABSTRACT:

This study aims to develop a low-cost, multi-purpose module based on edge computing for bacterial colony counting and classification. Due to the time-consuming and error-prone nature of traditional methods, this new system has been developed with microcontroller integration and artificial intelligence support. The system utilizes the Arduino Nano 33 BLE microcontroller and a 0.3MP OV7675 camera module, employing Gaussian Blur and Adaptive Thresholding techniques for image processing to better define bacterial colonies. The labeling and feature extraction of colonies involve analyzing characteristics such as area, perimeter, and density. Convolutional Neural Networks and Support Vector Machines have been used for bacterial colony counting and classification. The combination of these two algorithms has facilitated colony analysis. The developed system enables tracking of colony numbers and growth rates over time, emphasizing the importance of a microcontroller-integrated and AI-supported system in achieving fast and traceable results in bacterial colony counting and classification.

¹Yeliz DURGUN ([Orcid ID: 0000-0003-3834-5533](https://orcid.org/0000-0003-3834-5533)), Tokat Gaziosmanpaşa Üniversitesi, Turhal Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Tokat, Türkiye

²Mahmut DURGUN ([Orcid ID: 0000-0002-5010-687X](https://orcid.org/0000-0002-5010-687X)), Tokat Gaziosmanpaşa Üniversitesi, Turhal Uygulamalı Bilimler Fakültesi, Elektronik Ticaret ve Yönetim Bölümü, Tokat, Türkiye

*Sorumlu Yazar/Corresponding Author: Yeliz DURGUN, e-mail: yeliz.durgun@gop.edu.tr

GİRİŞ

Bakteriyel koloni sayımı ve sınıflandırması, mikrobiyoloji ve biyoteknoloji alanlarında önemli bir araştırma konusudur (Yoon ve ark., 2015; Aneja, 2007). Bu süreç, çevre analizi, sağlık kontrolü, endüstriyel üretim, gıda güvenliği ve klinik tanı gibi birçok uygulamada yer almaktadır (Ferrari ve ark., 2015; Pacal 2022). Koloni sayımı ve sınıflandırması, bakteriyel büyüme oranlarını ve etkilerini anlamak için kullanılmaktadır. Bu bilgiler, hastalıkların teşhisi ve tedavisi, hijyen kontrolü ve gıda güvenliği gibi alanlarda önemlidir (Yerlikaya ve ark., 2022). Dolayısıyla, hızlı ve doğru bakteriyel koloni sayımı ve sınıflandırma yöntemleri geliştirmek, bu alanlarda etkin kararlar alabilmek için kritik öneme sahiptir. Geleneksel koloni sayım yöntemleri, genellikle petri kutularında mikroorganizmaların yetişmesine, belirli bir sıcaklıkta belirli bir süre tutulması sonrasında ve ardından manuel olarak sayılmasına dayanmaktadır (Yerlikaya, 2022; Şen ve ark., 2021). Bu yöntemler, zaman alıcı ve hata payı yüksek olup, özellikle düşük yoğunluklu örneklerde doğruluk ve hassasiyet kaybına yol açmıştır. Bu nedenle, otomatik ve doğru koloni sayımı ve sınıflandırma yöntemleri geliştirmek büyük önem arz etmektedir.

Son yıllarda, görüntü işleme ve yapay zeka teknikleri, bakteriyel koloni sayımı ve sınıflandırma alanında önemli gelişmelere yol açmıştır. Özellikle, derin öğrenme ve makine öğrenimi algoritmaları, büyük miktarda verinin analiz edilerek koloni sayımı ve sınıflandırma süreçlerinin otomatikleştirilmesine olanak tanımıştır (Rani ve ark., 2022; Albaradei ve ark., 2020). Ayrıca, geliştirilen yöntemler, Petri kutusu görüntülerinin ön işleme ve segmentasyonu gibi adımları içeren geleneksel işlemleri otomatikleştirmeye yönelik olmuştur (Ferrari ve ark., 2017; Michal ve ark., 2022).

Önceki çalışmalarda, bakteriyel koloni sayımı ve sınıflandırma alanında derin öğrenme yöntemlerinin kullanılmasıyla önemli başarılar elde edildiği gösterilmiştir. Özellikle, Evrişimsel Sinir Ağları (CNN) ve Destek Vektör Makineleri (SVM) gibi sınıflandırma algoritmaları, bu tür problemler için iyi sonuçlar vermiştir (Petersson ve ark., 2016; Zhang ve ark., 2021; Pacal, 2023) Bu çalışmalar, görüntü işleme ve derin öğrenme tekniklerine dayalı yöntemlerin, manuel yöntemlerden daha hızlı ve doğru sonuçlar sağlayabileceğini göstermiştir (Jin ve ark., 2021; Choudhry, 2016).

Bu çalışma, önceki çalışmalarla bağlantı kurarak, bakteriyel koloni sayımı ve sınıflandırma süreçlerini geliştirmeyi hedeflemektedir. Çalışmanın temel amacı, CNN ve SVM gibi iki farklı yapay zeka algoritmasını kullanarak, bakteriyel koloni sayımı ve sınıflandırması için etkin ve uygun maliyetli bir çözüm sunmaktır. Bu iki algoritma, çıkarılan özelliklere göre kolonileri sınıflandırmak ve saymak amacıyla bir arada kullanılmıştır. CNN, görüntülerin doğrudan işlenmesi ve özellik çıkarımı için derin öğrenme tabanlı bir yöntemdir. SVM ise, çıkarılan özelliklere dayalı olarak sınıflandırma gerçekleştiren bir makine öğrenimi algoritmasıdır (Varshni ve ark., 2019).

Çalışmanın diğer çalışmalardan farkı, CNN ve SVM algoritmalarının kombinasyonunun, bakteriyel koloni sayımı ve sınıflandırma süreçlerinde daha güçlü ve hassas sonuçlar elde etmeyi sağlamasıdır. Özellikle, CNN'nin otomatik özellik çıkarımı yeteneği ve SVM'nin sınıflandırma performansı, birlikte çalıştığında, bakteriyel koloni analizinde kolaylık sağlamaktadır.


Bu çalışma, bakteriyel koloni sayımı ve sınıflandırma alanında teorik ve uygulamalı yansımaları ile önemli bir katkı sağlamaktadır. Teorik olarak, CNN ve SVM algoritmalarının kombinasyonunun etkinliğini inceleyerek, bu alandaki mevcut bilgi birikimine katkıda bulunmaktadır. Uygulamalı olarak, bu çalışma, mikrobiyoloji laboratuvarlarında kullanılabilecek hızlı, doğru ve uygun maliyetli bir bakteriyel koloni sayımı ve sınıflandırma yöntemi sunmaktadır. Derin öğrenme ve makine öğrenimi algoritmalarının bakteriyel koloni sayımı ve sınıflandırma problemlerine uygulanması, bu alandaki teknik gelişmelere katkı sağlamıştır (Qu ve ark., 2019; Signoroni ve ark., 2019). Görüntü işleme ve

segmentasyon yöntemlerinin geliştirilmesi, otomatik koloni sayımı ve sınıflandırma süreçlerinde önemli adımlar atmıştır (Chen ve Zhang, 2009; Zhang ve ark., 2022). Çeşitli sınıflandırma algoritmalarının (CNN, SVM vb.) bakteriyel koloni sayımı ve sınıflandırma problemlerine uygulanması, bu alanda farklı yöntemlerin avantajlarını ve dezavantajlarını anlamaya yardımcı olmuştur (Zhang ve ark., 2022; Mahmud ve ark., 2018). Derin öğrenme tabanlı yöntemlerin başarıları ve gelişmeleri, manuel yöntemlere kıyasla daha hızlı ve doğru sonuçlar elde etme potansiyelini göstermiştir (Zhang ve ark., 2021; Melanthota ve ark., 2022). Bu çalışma, önceki çalışmalardan elde edilen bilgi ve deneyimleri kullanarak, bakteriyel koloni sayımı ve sınıflandırma alanında daha iyi sonuçlar elde etmeyi amaçlamaktadır. Özellikle, CNN ve SVM algoritmalarının kombinasyonu sağlayarak, bu alanda önemli bir ilerleme kaydedebileceğini öngörmüştür.

Çalışma, bakteriyel koloni sayımı ve sınıflandırma alanında önemli bir araştırma konusunu ele alarak, bu alandaki bilgi birikimine ve uygulamalara katkı sağlaması hedeflenmektedir. Önceki çalışmaların önemli bulgularını ve deneyimlerini kullanarak, bu çalışma, daha hızlı, doğru ve uygun maliyetli bir bakteriyel koloni sayımı ve sınıflandırma yöntemini sunmaktadır. Bu yöntem, mikrobiyoloji laboratuvarları, endüstri ve sağlık sektöründe, daha etkin ve güvenilir sonuçlar elde etmeye yardımcı olacaktır.

MATERYAL VE METOT

Bu bölümde, çalışmada kullanılan temel materyaller ve metotlar ele alınmaktadır. Öncelikle, mikrodenetleyici olarak Arduino Nano 33 BLE kullanılmıştır. Bu mikrodenetleyici, kamera modülüne sahip olup, makine öğrenme algoritmalarını da entegre edebilme özelliği ile dikkat çekmektedir (Şekil 1). Şekil 1'de Arduino Nano 33 BLE ve kamera modülü görülmektedir.



Şekil 1. Deney düzeneği

Mikrodenetleyici: Arduino Nano 33 BLE

Çalışmada kullanılan mikrodenetleyici olarak Arduino Nano 33 BLE tercih edilmiştir. Bu mikrodenetleyici, düşük enerji tüketimi, yüksek işlem gücü ve genişletilebilirlik özellikleri ile ön plana çıkmaktadır. Ayrıca, Arduino Nano 33 BLE, TensorFlow Lite Micro desteği ile makine öğrenme algoritmalarını entegre etme imkanı sunmaktadır (Durgun, 2024). Bu özellikler, bakteriyel koloni sayımı ve endüstriyel ürün sayma gibi uygulamalar için etkin ve maliyet-etkin çözümler geliştirilmesini sağlamaktadır.

Kamera modülü

Bu çalışmada kullanılan kamera modülü, OV7675 çipi ile donatılmış 0.3MP bir kameradır ve istikrarlı çalışma performansı ile net görüntüleme sağlamaktadır. Kamera modülü, 50 derecelik bozulma olmaksızın geniş bir görüş alanı sunarak kullanıcıya geniş görsel aralık ve görüntüleme imkanı sağlamaktadır. Bu kamera modülü, esas olarak modifikasyon için kullanılırken, reklam

makinesi, yüz tanıma, drone fotoğrafçılığı gibi alanlarda da kullanılabilir. Özellikle tasarımı, 30FPS hızı, 640 x 480 maksimum çözünürlük ve YUV formatına uygun olacak şekilde optimize edilmiştir. Arduino Nano 33 BLE ile entegre edilen bu kamera modülü, projemiz için başarılı bir şekilde bakteriyel koloni sayımı gerçekleştirmeye olanak tanımaktadır. Kamera ile elde edilen veriler, makine öğrenme algoritmalarının eğitimi ve testi için kullanılmıştır.

Değişkenler

Çalışmada kullanılan değişkenler şunlardır:

- Bakteriyel koloni sayısı
- Zaman
- Kamera modülünün çözünürlüğü
- Makine öğrenme algoritmasının performansı

Bu değişkenler, çalışmanın sonuçlarının değerlendirilmesinde ve modülün optimizasyonunda önemli rol oynamaktadır.

Manipülasyon ve gözlem süreçleri

Bakteriyel koloni sayımı

Bakteriyel koloni sayımı sürecinde, kamera modülü kullanılarak bakteriyel kolonilerin görüntüleri alınmıştır. Bu görüntüler, makine öğrenme algoritmasının eğitimi ve testi için kullanılmıştır. Ayrıca, zaman değişkeni dikkate alınarak, bakteriyel kolonilerin zamana bağlı değişimlerinin analizi gerçekleştirilmiştir.

Veri analizi

Çalışmamızda kullanılan veri seti, toplamda 112 adet görüntüden oluşmaktadır. Bu görüntülerin her biri 320x240 piksel boyutlarındadır ve çeşitli bakteriyel koloni türlerini ve yoğunluklarını içermektedir. Veri setinin 88'i eğitim seti için, geriye kalan 24'ü ise test seti olarak ayrılmıştır. Bu ayırım, modelin genelleştirme kabiliyetini değerlendirmek ve gerçek dünya koşullarında nasıl performans göstereceğini test etmek için önemlidir.

Eğitim seti, modelin öğrenme sürecinde kullanılmış ve bakteriyel kolonilerin çeşitli özelliklerini tanıması için gereken bilgileri sağlamıştır. Test seti ise, eğitim sürecinden bağımsız olarak modelin doğruluğunu ve güvenilirliğini değerlendirmek için kullanılmıştır.

Ön işleme

Gürültüyü azaltmak ve görüntü kontrastını iyileştirmek için filtreleme teknikleri uygulanabilmektedir. Düzleştirme filtresi görüntü ön işlemede kullanılan yaygın filtreleme tekniğidir. Bu tekniğin bakteriyel koloni sayımı için ön işleme aşamasında kullanılması, görüntüdeki gürültüyü azaltırken detayları korumaya yardımcı olmuştur. Düzleştirme filtresi: Görüntü üzerindeki gürültüyü azaltmak için kullanılan bir düşük geçiren filtredir. Bu yöntem, görüntüdeki her pikselin değerini, çevresindeki piksellerin değerleriyle ağırlıklı bir ortalamaya göre düzenlenmektedir. Düzleştirme filtresi, bakteriyel koloni sayımı için ön işleme aşamasında kullanılmıştır. Gürültüyü azaltarak kolonilerin daha iyi tanımlanmasına ve segmentasyonun daha doğru gerçekleştirilmesine yardımcı olmuştur. Bu filtreleme tekniğini kullanarak, bakteriyel koloni sayımı ve değişiminin izlenmesi için gerekli görüntü ön işlemini gerçekleştirilmiştir. Bu sayede, kolonilerin daha iyi tanımlanması ve segmentasyonun daha doğru gerçekleştirilmesi sağlanmıştır, böylece koloni sayımı ve değişiminin izlenmesi daha hızlı ve güvenilir sonuçlar sunmuştur.

Görüntü ayrıştırma: bakteriyel kolonilerin arka plandan ayrılması

Bakteriyel koloni sayımında, kolonilerin arka plandan doğru bir şekilde ayırt edilmesi önemli bir adımdır. Bu çalışmada, arka planın ve bakteriyel kolonilerin etkili bir şekilde ayrılması için adaptif eşikleme yöntemi kullanılmıştır (Yoon ve ark., 2015; Zhang ve ark.2021). Adaptif eşikleme: Bu yöntem, görüntüdeki her piksel için özelleştirilmiş bir eşik değeri belirler ve bu değere göre piksellerin beyaz veya siyah olarak sınıflandırılmasını sağlar. Global eşikleme yöntemlerinden farklı olarak, adaptif eşikleme, yerel görüntü özelliklerini dikkate alarak daha iyi sonuçlar sunmaktadır. Bu sayede, aydınlık ve koyu bölgelerdeki farklı özelliklerin dikkate alınması ile daha doğru ve etkili bir segmentasyon elde edilmektedir (Zhang ve ark.2022). Bu çalışmada, adaptif eşikleme yöntemi ile bakteriyel kolonilerin arka plandan ayrılması sağlanmıştır. Öncelikle, görüntüdeki gürültüyü azaltmak için Gaussian Bulanıklığı tekniği kullanılarak görüntü ön işleme gerçekleştirilmiştir. Ardından, adaptif eşikleme yöntemi uygulanarak kolonilerin arka plandan ayrılması sağlanmıştır. Bu işlem sonucunda, bakteriyel koloniler net ve düzgün bir şekilde belirlenmiş ve sayım için hazır hale getirilmiştir.

Morfolojik işlemler: kolonilerin iyileştirilmesi ve yanlış pozitiflerin azaltılması

Morfolojik işlemler, görüntü işleme alanında kullanılan temel işlemlerden biridir ve yapısal özelliklerin iyileştirilmesi veya dikkate değer özelliklerin vurgulanması için kullanılmaktadır. Bu çalışmada, segmentasyon işlemi sonrasında bakteriyel kolonilerin daha iyi tanımlanması ve yanlış pozitiflerin azaltılması amacıyla erozyon morfolojik işlemi kullanılmıştır. Erozyon işlemi, görüntüdeki nesnelerin sınırlarını incelterek arka plana daha yakın hale getirir ve küçük nesnelere ortadan kaldırır. Bu sayede, arka plan ve koloni arasındaki sınırlar daha net hale gelir ve yanlış pozitiflerin etkisi azaltılır. Bu çalışmada, morfolojik işlemler ile bakteriyel kolonilerin sınırları daha iyi tanımlanmış ve yanlış pozitiflerin etkisi azaltılmıştır. Bu süreç, koloni sayımının doğruluğunu artırmakta ve sonuçların güvenilirliğini sağlamaktadır.

Etiketleme ve özellik çıkarımı: kolonilerin karakteristiklerinin belirlenmesi

Bu projede, bakteriyel kolonilerin özelliklerini belirlemek ve analiz etmek için etiketleme ve özellik çıkarımı işlemleri kullanılmıştır. Öncelikle, morfolojik işlemlerle iyileştirilmiş görüntülerdeki tüm koloniler etiketlenmiştir. Bu işlem, bağlı bileşenlerin analizi (Connected Component Analysis-CCA) kullanılarak gerçekleştirilmiştir. CCA, görüntüdeki bağlı piksel gruplarını tanımlayarak nesnelere etiketlemeye ve ayırmaya olanak tanır. Etiketleme işlemi tamamlandıktan sonra, her bir koloni için çeşitli özellikler çıkarılmıştır. Bu özellikler arasında koloni alanı, çevre ve yoğunluk gibi temel özellikler yer almaktadır. Ayrıca, şekil faktörleri gibi daha karmaşık özellikler de hesaplanarak kolonilerin morfolojik farklılıklarının belirlenmesi amaçlanmıştır. Özellik çıkarımı, her bir koloni hakkında detaylı bilgi sağlayarak, daha kesin ve doğru koloni sayımı ve sınıflandırması yapılmasına olanak tanır. Bu sayede, bakteriyel koloni sayımı ve değişiminin izlenmesi süreci daha güvenilir ve başarılı bir şekilde gerçekleştirilmiştir.

CNN mimarisi:

Bu çalışmada, bakteriyel koloni sayımı ve sınıflandırması için kullanılan CNN mimarisi, özelleştirilmiş bir Evrişimsel Sinir Ağları yapılandırmasıdır. Seçilen CNN mimarisi, özellikle mikroskopik görüntülerin karmaşıklığını ve çeşitliliğini işleyebilecek biçimde tasarlanmıştır. Mimarimiz, birden fazla evrişim katmanı, aktivasyon fonksiyonları, havuzlama katmanları ve tam bağlı katmanlardan oluşur. Her evrişim katmanı, görüntünün farklı özelliklerini (örneğin, kenarlar, doku, şekiller) algılamak üzere tasarlanmıştır. Aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) kullanılmıştır, bu da modelin doğrusal olmayan problemleri daha iyi çözmesini sağlamaktadır.

Bu çalışmada, özelleştirilmiş bir Konvolüsyonel Sinir Ağı (CNN) mimarisi kullanılmıştır. Mimari, dört ana konvolüsyonel katmandan oluşur. Bu katmanların her biri, farklı düzeylerde özellik çıkarımı için tasarlanmıştır.

1. Katman: İlk katman, 16 filtre içerir. Bu katman, giriş görüntülerinden temel özellikleri (kenarlar, köşeler vb.) çıkarmak için kullanılır. Bu temel özellikler, sonraki katmanlarda daha karmaşık özelliklere dönüştürülür.

2. Katman: İkinci katman, 32 filtre içerir. Bu katman, birinci katmandan elde edilen temel özellikler üzerine kurulur ve daha karmaşık özelliklerin (doku, şekiller vb.) çıkarımını gerçekleştirir.

3. Katman: Üçüncü katman yine 16 filtreye sahiptir. Bu aşama, özelliklerin daha da rafine edilmesini sağlar, böylece modelin bakteriyel kolonileri daha iyi tanımasına olanak tanır.

4. Katman: Son katman 8 filtreye sahiptir ve bu, özellik çıkarımının son aşamasıdır. Bu katmanda, önceki katmanlardan gelen özellikler, sınıflandırma için gerekli olan son özellik setine dönüştürülür.

Bu özelleştirilmiş CNN mimarisi, görüntülerden önemli özellikleri çıkarmak ve bu özellikleri SVM algoritmasına beslemek için tasarlanmıştır. Geliştirilen bu mimari, bakteriyel koloni sayımı ve sınıflandırma gibi spesifik görevler için optimize edilmiştir.

Yapay zeka algoritması: bakteriyel koloni sayımı ve sınıflandırma için algoritma kombinasyonları

Bu çalışmada, bakteriyel koloni sayımı ve sınıflandırma işlemleri için CNN ve SVM gibi iki farklı yapay zeka algoritması kullanılmıştır. CNN, görüntülerin doğrudan işlenmesi ve özellik çıkarımı için derin öğrenme tabanlı bir yöntemdir ve bu çalışmada, bakteriyel kolonilerin görüntülerinden özellikler öğrenmek ve kolonilerin farklı sınıflarını ayırt etmek için kullanılmıştır. Öğrenilen bu özellikler daha sonra SVM algoritmasına beslenmiştir. SVM, çıkarılan özelliklere dayalı olarak sınıflandırma gerçekleştiren bir makine öğrenimi algoritmasıdır ve bu çalışmada, CNN tarafından öğrenilen özellikler kullanılarak bakteriyel kolonileri doğru bir şekilde sınıflandırmak ve saymak için eğitilmiştir.


Bu iki algoritmanın kombinasyonu, bakteriyel koloni sayımı ve sınıflandırma süreçlerinde daha güçlü ve hassas sonuçlar elde etmeyi sağlamıştır. Özellikle, CNN'nin otomatik özellik çıkarımı yeteneği ve SVM'nin sınıflandırma performansı birleştirildiğinde, bakteriyel koloni analizinde hem hız hem de izlenebilirlik artmaktadır. Ayrıca, bu hibrid modelin performansı, yalnızca CNN veya yalnızca SVM kullanılarak elde edilen sonuçlarla kıyaslandığında, CNN'nin derin öğrenme tabanlı özellik çıkarımı ve SVM'nin etkili sınıflandırma kabiliyetinin birleşimi, daha doğru sonuçlar ve daha az yanlış pozitif oranı sunmaktadır. Bu modelin avantajları, derin öğrenmenin gücünü ve makine öğreniminin hassasiyetini birleştirmesidir, ancak dezavantaj olarak daha karmaşık bir yapı ve potansiyel olarak daha uzun eğitim süreleri gösterilebilir.

CNN (Evrışimsel Sinir Ağları) ve SVM (Destek Vektör Makineleri), yapay zeka ve makine öğrenimi alanında sıkça kullanılan iki farklı modeldir ve her biri belirli avantajlara sahiptir. Bunların kombinasyonu olan hibrid model, her iki yöntemin avantajlarını birleştirerek daha güçlü ve etkili bir çözüm sunar.

CNN, görüntü işleme ve analizi konusunda özellikle etkilidir. Evrışimsel katmanlar sayesinde, görüntülerden yüksek düzeyde özellikler çıkarabilir. Bu özellikler, görüntünün temel bileşenlerini (kenarlar, doku, şekiller vb.) temsil eder ve karmaşık görsel verilerin anlaşılmasını sağlar. CNN'ler, özellikle görüntü tanıma, sınıflandırma ve segmentasyon gibi görevlerde başarılıdır. Ancak, CNN

tabanlı sistemler bazen sınıflandırma aşamasında yetersiz kalabilir veya overfitting (aşırı uyum) gibi sorunlarla karşılaşabilir.

Diğer yandan, SVM, özellikle sınıflandırma görevlerinde güçlüdür. Verilen özellik setini kullanarak, farklı sınıflar arasında en iyi ayrımı yapacak hiperdüzlemi bulmaya çalışır. SVM, özellikle yüksek boyutlu verilerde ve veri noktaları arasındaki sınırların belirsiz olduğu durumlarda etkilidir. Ancak SVM, doğrudan görüntü işleme veya özellik çıkarımında kullanılmaz; bunun yerine, önceden tanımlanmış özellik setlerine dayanarak çalışmaktadır.



Şekil 2. Yapay zeka algoritmaları kombinasyonu şeması


Şekil 2, çalışmamızda kullanılan yapay zeka algoritmaları CNN (Convolutional Neural Network) ve SVM (Support Vector Machine)'nin entegre edilmesini göstermektedir. Bu diyagram, CNN'nin görüntü işleme ve öznitelik çıkarımı sürecinde nasıl kullanıldığını ve çıkarılan bu özniteliklerin SVM tarafından nasıl sınıflandırıldığını açıkça göstermektedir. Bu entegrasyon, bakteriyel koloni sayımı ve sınıflandırmasında daha etkili ve hızlı sonuçlar elde etmemizi sağlamaktadır. Şekilde, her bir adımın akışı ve algoritmaların birbiriyle nasıl etkileşime girdiği detaylı bir şekilde gösterilmiştir.

Hibrid modelde, CNN'nin güçlü özellik çıkarım kabiliyeti ve SVM'nin etkili sınıflandırma performansı birleştirilir. Bu yaklaşımda, CNN öncelikle görüntülerden özellikleri çıkarır ve bu özellikler daha sonra SVM tarafından sınıflandırılır. Bu kombinasyon, CNN'nin bazen karşılaştığı sınıflandırma zorluklarını aşmada ve SVM'nin özellik çıkarımındaki eksikliklerini gidermede etkili olmaktadır. Sonuç olarak, hibrid model, her iki tekniğin tek başına kullanılmasına göre daha hassas ve güvenilir sonuçlar sunar ve karmaşık sınıflandırma görevlerinde daha iyi performans gösterir. Bu yaklaşım, özellikle bakteriyel koloni sayımı gibi karmaşık ve hassas görevler için idealdir, çünkü hem yüksek seviyede özellik çıkarımı hem de etkili sınıflandırma sağlamaktadır.

BULGULAR VE TARTIŞMA


Bu çalışma, kenar hesaplama tabanlı, mikrodnetleyici entegreli, çok amaçlı ve düşük maliyetli bir modülün geliştirilmesini amaçlamaktadır. Bakteriyel koloni sayımı, bu modülün temel uygulama alanı olarak örnek teşkil etmektedir. Çalışmada hem geleneksel yöntemlerin zorluklarını gidermek hem de daha doğru ve hızlı sonuçlar elde etmek adına, görüntü işleme ve yapay zeka algoritmaları kullanılarak bakteriyel koloni sayımı gerçekleştirilmiştir. Geliştirilen modül, özellikle biyoteknoloji, gıda güvenliği, tıbbi teşhis ve çevre analizi gibi alanlarda büyük öneme sahiptir. Endüstriyel ürün sayma gibi alternatif uygulama alanlarında da kullanılması mümkün olacaktır. Kenar hesaplama prensipleri kullanılarak gerçek zamanlı analiz ve sayım imkanı sunulmuştur. Mikrodnetleyici

entegrasyonu ile donanım ve yazılım maliyetlerinin düşürülmesi sağlanırken, kullanıcı dostu bir deneyim sunulmaktadır. Çalışma sonuçlarında, Gaussian Bulanıklığı filtre uygulanarak görüntü gürültüsünün azaltılması, ardından Adaptif eşikleme yöntemi ile görüntü ayrıştırmanın başarılı bir şekilde gerçekleştirildiği görülmüştür. Morfolojik işlemler ile kolonilerin daha iyi tanımlanması ve yanlış pozitiflerin azaltılması sağlanmıştır. Etiketleme ve özellik çıkarımı ile kolonilerin karakteristiklerini belirlemeye yönelik önemli bilgiler elde edilmiştir. Bu veriler üzerinden CNN ve SVM algoritmalarının kombinasyonu kullanılarak yüksek doğruluk ve güvenilirlik sağlanmıştır. Bulgular, geliştirilen modülün başarılı bir şekilde bakteriyel koloni sayımı yapabildiğini ve düşük maliyetli, enerji tasarruflu ve kullanıcı dostu bir çözüm sunabileceğini göstermektedir. Bu nedenle, bu modülün geniş çapta uygulanmasının, ilgili alanlarda önemli bir katkı sağlayabileceği düşünülmektedir.




Şekil 3. Görüntü İşleme Adımlarını Gösteren Bir Akış Şeması

Şekil 3'de, Gaussian Bulanıklığı filtre uygulaması, adaptif eşikleme ile segmentasyon, morfolojik işlemler ve etiketleme ve özellik çıkarımı süreçlerini görsel olarak temsil etmektedir.



Şekil 4. Yapay zeka algoritmalarının (CNN ve SVM) kombinasyonunun şeması

Şekil 4'de, algoritma kombinasyonlarının koloni sayımı ve sınıflandırmada birlikte kullanım şekli gösterilmektedir



Şekil 5. Geliştirilen modülün başarılı koloni sayımı sonuçlarını gösteren örnek bir görüntü

Şekil 5’de görüntü, önceden belirlenmiş özelliklere göre kolonilerin sınıflandırılmasını ve sayılmasını görsel olarak temsil etmektedir. Sonuç olarak, geliştirilen kenar hesaplama tabanlı modül, bakteriyel koloni sayımı ve diğer benzer uygulamalar için etkili ve düşük maliyetli bir çözüm sunmaktadır. Çalışmamızda geliştirilen kenar hesaplama tabanlı modül, bakteriyel koloni sayımı ve benzer uygulamalar için etkili ve düşük maliyetli bir çözüm sunmaktadır. Maliyet analizine göre, modülümüzde kullanılan Arduino Nano 33 BLE mikrodenetleyicinin maliyeti yaklaşık €22,80, OV7675 kamera modülünün maliyeti €20 ve ek plastik aparatların maliyeti ise €10 olarak hesaplanmıştır. Bu toplam maliyet, ülkemizde yaygın olarak kullanılan ve fiyatı yaklaşık €250 olan düşük fiyatlı koloni sayımı için kullanılan ışık ünitelerine kıyasla oldukça ekonomiktir. Bu maliyet farkı, geliştirdiğimiz sistemin, bakteriyel koloni sayımı alanında hem maliyet-etkin hem de yüksek performanslı bir alternatif sunduğunu göstermektedir. Dolayısıyla, görüntü işleme ve yapay zeka algoritmalarının entegrasyonu, daha doğru ve hızlı sonuçlar elde etmeyi mümkün kılmaktadır (Veziroglu ve ark., 2023). Bu çalışmanın bulguları, ilgili alanlarda önemli bir katkı sağlayabilecek potansiyele işaret etmektedir. Geliştirilen modülün daha fazla uygulama alanında test edilmesi ve optimize edilmesi önemlidir. Ayrıca, daha karmaşık ve geniş veri kümesi üzerinde algoritmaların performansını değerlendirmek ve modülü daha geniş bir kullanıcı kitlesi için erişilebilir kılmak için çalışmalar yapılmalıdır. Bu tür çalışmalar, modülün kullanım alanlarını genişleterek daha fazla sektörde ve uygulamada değer oluşturmaktadır (Pacal ve Alaftekin 2023).

Tablo 1. Kenar hesaplama tabanlı bakteriyel koloni sayım yöntemleri üzerine yapılmış çalışmalar

Yazar(lar)	Yayın Yılı	Yöntem	Sonuçlar ve Önemli Noktalar
Zhang ve ark., 2022	2022	YOLOv3 tabanlı az sayıda öğrenme Mikroakışkan cihazlar ve akıllı telefonlar	Kenar cihazlarda yüksek doğrulukla bakteriyel koloni tespiti
Needs ve ark., 2021	2021	Görüntü analizi yazılımı	Basit ve etkili bakteriyel hücre sayımı
Raju ve ark., 2020	2020	MATLAB tabanlı görüntü işleme	Otomatik ve hızlı koloni sayımı
Kis ve ark., 2019	2019	Hiperspektral özellikler	Etkili ve kullanıcı dostu koloni sayımı
Shi ve ark., 2019	2019	VCC yöntemi	Gıda kalitesi değerlendirmesi için gürültüsüz sayım
Hoffmann ve ark., 2018	2018	Gelişmiş CNN algılama metodu	Yüksek hacimli antibakteriyel etki değerlendirmesi
Shousheng ve ark., 2021	2021	Biyoluminesans etiketleme	Düşük hata oranıyla hassas koloni sayımı
Matsumoto ve ark., 2021	2021	Akış sitometrisi	Bitki-bakteri etkileşimlerinde kullanım Hücrelerin antibakteriyel etkisinin hızlı değerlendirilmesi
Lórinéz ve ark., 2018	2018	Kaskad ağ tabanlı algılama	Su içinde bakteri tespiti için küçük hedef algılama
Liu ve ark., 2021	2021	Mikroakışkan dip-stick şeritler	Hızlı ve basit CFU ml-1 ölçümü
Dönmez ve ark., 2022	2022	Görüntü tabanlı sayım	Escherichia coli için görüntü tabanlı sayım
Karatepe ve ark., 2022	2022	Mask R-CNN modeli	Yüksek doğrulukta otomatik koloni sayımı
Naets ve ark., 2021	2021	Mikroskopik tarama	Hızlı ve doğru mikro-koloni sayımı
Song ve ark., 2018	2018		

Tablo 1’de, çalışmamızla ilgili olarak literatürde yer alan ve kenar hesaplama tabanlı bakteriyel koloni sayım yöntemleri üzerine yapılmış 15 farklı çalışmayı kıyaslayarak sunulmaktadır. Her bir çalışma, uygulanan yöntemler ve elde edilen sonuçlar açısından özetlenmiştir.

Çalışmada kullanılan veri seti, toplamda 112 adet görüntü içermektedir. Bu görüntülerin 88’i eğitim seti için, 24’ü ise test seti için ayrılmıştır ve her iki set de çeşitli bakteriyel koloni türlerini ve

yoğunluklarını kapsamaktadır. Her bir görüntü için bakteriyel koloniler manuel olarak sayılmış ve bu sayım sonuçları kaydedilmiştir. Aynı görüntüler, geliştirilen mikrodenetleyici tabanlı sistem kullanılarak sayılmış ve bu sayım sonuçları manuel sayım sonuçları ile karşılaştırılmıştır. Bu karşılaştırmada, ortalama hata oranı %4 olarak bulunmuştur. Bu sonuçlar, önerilen hibrid modelin (CNN+SVM) manuel sayım sonuçlarına oldukça yakın performans gösterdiğini ve yüksek doğrulukta bakteriyel koloni sayımını sağladığını göstermektedir.

Tablo 2: Manuel sayım ve mikrodenetleyici ile sayım karşılaştırması örneği

Görüntü ID	Manuel Sayım	Mikrodenetleyici ile Sayım	Ortalama Hata (%)
1	100	98	2.0
2	105	107	1.9
3	110	109	0.9
4	115	117	1.7
5	120	119	0.8
6	125	126	0.8
7	130	132	1.5
8	135	133	1.5
9	140	141	0.7
10	145	146	0.7

Bu değerlendirmeleri görsel olarak sunmak için bir tablo hazırlanmıştır. Tablo 2’de, manuel sayım ve mikrodenetleyici tabanlı sayım sonuçları karşılaştırılmış ve her bir görüntü için hata oranları belirtilmiştir. Bu tablo, sistemin her bir görüntü üzerindeki performansını ve manuel sayım ile olan karşılaştırmasını göstermektedir. Her bir görüntü için hata oranı, sistemin tutarlılığını ve güvenilirliğini değerlendirmek için önemli bir göstergedir.

Özetle, bu çalışmada geliştirilen hibrid model, bakteriyel koloni sayımı için etkili bir yöntem sunmakta ve manuel sayım ile kıyaslandığında yüksek doğruluk oranıyla dikkat çekmektedir. Bu modelin başarısı hem alan uzmanlarına hem de otomatik sistemlerin geliştirilmesinde çalışan araştırmacılara önemli katkılar sağlayacaktır.

SONUÇ

Bu çalışma, kenar hesaplama tabanlı, mikrodenetleyici entegreli, çok amaçlı ve düşük maliyetli bir modülün geliştirilmesini amaçlamıştır. Özellikle bakteriyel koloni sayımı için kullanılan görüntü işleme ve yapay zeka algoritmaları, bu modülün temel uygulama alanı olarak örnek teşkil etmektedir. Geliştirilen modül sayesinde, bakteriyel koloni sayımı süreçleri hızlı, enerji tasarruflu ve kullanıcı dostu bir şekilde gerçekleştirilebilmiştir.

Çalışma sonucunda, kullanılan Gaussian Bulanıklığı ve Medyan Filtre ile görüntü gürültüsü azaltılmış ve Adaptif eşikleme yöntemi ile başarılı bir görüntü ayrıştırma sağlanmıştır. Morfolojik işlemler ve etiketleme yöntemleri ile bakteriyel koloniler daha iyi tanımlanmış ve özellikleri çıkarılarak karakteristik bilgiler elde edilmiştir. CNN ve SVM gibi yapay zeka algoritmalarının kombinasyonu, kolonilerin doğru bir şekilde sınıflandırılması ve sayılması için kullanılmıştır.

Bu çalışmanın sonuçları, geliştirilen modülün bakteriyel koloni sayımında başarılı bir şekilde kullanılabilirliğini göstermiştir. Bu sayede, biyoteknoloji, gıda güvenliği, tıbbi teşhis ve çevre analizi gibi alanlarda daha hızlı ve doğru analizlerin yapılması mümkün olacaktır. Ayrıca, modülün esnek yapısı sayesinde, endüstriyel ürün sayma gibi alternatif uygulama alanlarında da kullanılabilirliği arttırılacaktır.

Sonuç olarak, bu çalışma ile geliştirilen kenar hesaplama tabanlı, mikrodenetleyici entegreli, çok amaçlı ve düşük maliyetli modül, bakteriyel koloni sayımı ve diğer uygulama alanlarında önemli bir katkı sağlayarak, mevcut süreçlerin daha verimli ve doğru şekilde gerçekleştirilmesine yardımcı olacağı düşünülmektedir. Gelecekte bu modülün yaygınlaştırılması ile ilgili alanlarda önemli bir farkındalığın oluşması beklenebilir.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder

KAYNAKLAR

- Albaradei, S. A., Napolitano, F., Uludag, M., Thafar, M., Napolitano, S., Essack, M., Bajic, V. B., & Gao, X. (2020). Automated counting of colony forming units using deep transfer learning from a model for congested scenes analysis. *IEEE Access*, 8, 164340–164346.
- Andreini, P., Bonechi, S., Bianchini, M., Mecocci, A., & Scarselli, F. (2018). A deep learning approach to bacterial colony segmentation. *Artificial Neural Networks and Machine Learning–ICANN 2018: 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4–7, 2018, Proceedings, Part III 27*, 522–533.
- Aneja, K. R. (2007). *Experiments in microbiology, plant pathology and biotechnology*. New Age International.
- Bär, J., Boumasmoud, M., Kouyos, R. D., Zinkernagel, A. S., & Vulin, C. (2020). Efficient microbial colony growth dynamics quantification with ColTapp, an automated image analysis application. *Scientific reports*, 10(1), 16084.
- Chen, W.-B., & Zhang, C. (2009). An automated bacterial colony counting and classification system. *Information Systems Frontiers*, 11, 349–368.
- Choudhry, P. (2016). High-throughput method for automated colony and cell counting by digital image analysis based on edge detection. *PloS one*, 11(2), e0148469.
- Dönmez, S. İ., Needs, S. H., Osborn, H. M., Reis, N. M., & Edwards, A. D. (2022). Label-free 1D microfluidic dipstick counting of microbial colonies and bacteriophage plaques. *Lab on a Chip*, 22(15), 2820-2831.
- Durgun, Y. (2024). Classification of Starch Adulteration in Milk Using Spectroscopic Data and Machine Learning. *International Journal of Engineering Research and Development*, 16(1), 221-226. <https://doi.org/10.29137/umagd.1379171>
- Ferrari, A., Lombardi, S., & Signoroni, A. (2015). Bacterial colony counting by convolutional neural networks. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 7458–7461.
- Ferrari, A., Lombardi, S., & Signoroni, A. (2017). Bacterial colony counting with convolutional neural networks in digital microbiology imaging. *Pattern Recognition*, 61, 629–640.
- Hoffmann, S., Walter, S., Blume, A., Fuchs, S., Schmidt, C., Scholz, A., & Gerlach, R. (2018). High-Throughput Quantification of Bacterial-Cell Interactions Using Virtual Colony Counts. *Frontiers in Cellular and Infection Microbiology*, 8.
- Jin, S., Zeng, X., Xia, F., Huang, W., & Liu, X. (2021). Application of deep learning methods in biological networks. *Briefings in bioinformatics*, 22(2), 1902–1917.

- Karatepe, F., Taş, B., Coskun, O., & Kahriman, M. (2022). Detection of Escherichia Coli Bacteria by Using Image Processing Techniques. *International Journal of Biology and Biomedical Engineering*.
- Kis, B., Unay, M., Ekimci, G., Ercan, U., & Akan, A. (2019). Counting Bacteria Colonies Based on Image Processing Methods. *2019 Medical Technologies Congress (TIPTEKNO)*, 1-4.
- Liu, S., Gai, Z., Zhang, M., Guo, F., Chai, X., Wang, Y., Hu, D., Wang, S., Zhang, L., Zhang, X., Chen, Z., Sun, X., & Jiang, X. (2021). Small target detection method with high accuracy for visible colony RGB image formed by bacteria in water. , 11767, 117671D - 117671D-4.
- Lőrincz, Á. M., Szeifert, V., Bartos, B., & Ligeti, E. (2018). New flow cytometry-based method for the assessment of the antibacterial effect of immune cells and subcellular particles. *Journal of Leukocyte Biology*, 103(5), 955-963.
- Mahmud, M., Kaiser, M. S., Hussain, A., & Vassanelli, S. (2018). Applications of deep learning and reinforcement learning to biological data. *IEEE transactions on neural networks and learning systems*, 29(6), 2063–2079.
- Matsumoto, A., Schlüter, T., Melkonian, K., Takeda, A., Nakagami, H., & Mine, A. (2021). A versatile Tn7 transposon-based bioluminescence tagging tool for quantitative and spatial detection of bacteria in plants. *Plant Communications*, 3.
- Marotz, J., Lübbert, C., & Eisenbeiss, W. (2001). Effective object recognition for automated counting of colonies in Petri dishes (automated colony counting). *Computer methods and programs in biomedicine*, 66(2–3), 183–198.
- Melanthota, S. K., Gopal, D., Chakrabarti, S., Kashyap, A. A., Radhakrishnan, R., & Mazumder, N. (2022). Deep learning-based image processing in optical microscopy. *Biophysical Reviews*, 14(2), 463–481.
- Michal, Č., Radim, B., & Jan, K. (2022). Machine-learning Approach to Microbial Colony Localisation. *2022 45th International Conference on Telecommunications and Signal Processing (TSP)*, 206–211.
- Naets, T., Huijsmans, M., Smyth, P., Sorber, L., & Lannoy, G. (2021). A Mask R-CNN approach to counting bacterial colony forming units in pharmaceutical development.
- Needs, S., Osborn, H., & Edwards, A. (2021). Counting bacteria in microfluidic devices: Smartphone compatible 'dip-and-test' viable cell quantitation using resazurin amplified detection in microliter capillary arrays.. *Journal of microbiological methods*, 106199 .
- Pacal, I. (2022). Deep Learning Approaches for Classification of Breast Cancer in Ultrasound (US) Images. *Journal of the Institute of Science and Technology*, 12(4), 1917-1927.
- Pacal, I. (2023). Göğüs Röntgeni Görüntülerinden Otomatik COVID-19 Teşhisi için Görü Transformatörüne Dayalı Bir Yaklaşım. *Journal of the Institute of Science and Technology*, 13(2), 778-791.
- Pacal, I., & Alaftekin, M. (2023). Türk İşaret Dilinin Sınıflandırılması için Derin Öğrenme Yaklaşımları. *Journal of the Institute of Science and Technology*, 13(2), 760-777.
- Petersson, H., Gustafsson, D., & Bergstrom, D. (2016). Hyperspectral image analysis using deep learning—A review. *2016 sixth international conference on image processing theory, tools and applications (IPTA)*, 1–6.
- Qu, K., Guo, F., Liu, X., Lin, Y., & Zou, Q. (2019). Application of machine learning in microbiology. *Frontiers in microbiology*, 10, 827.

- Raju, S., Aparna, H., Krishnan, A., Naryanan, D., Gangadhran, V., & Paul, S. (2020). Automated counting of bacterial colonies by image analysis. *Journal of multidisciplinary dental research*.
- Rani, P., Kotwal, S., Manhas, J., Sharma, V., & Sharma, S. (2022). Machine learning and deep learning based computational approaches in automatic microorganisms image recognition: methodologies, challenges, and developments. *Archives of Computational Methods in Engineering*, 29(3), 1801–1837.
- Shi, J., Zhang, F., Wu, S., Guo, Z., Huang, X., Hu, X., Holmes, M., & Zou, X. (2019). Noise-free microbial colony counting method based on hyperspectral features of agar plates. *Food chemistry*, 274, 925-932 .
- Shousheng, L., Gai, Z., Xu, C., Fengxiang, G., Mei, Z., Xu, S., Yibao, W., Ding, H., Shaoyan, W., Zhang, L., Zhang, X., Chen, Z., Xiaoling, S., & Jiang, X. (2021). Bacterial colonies detecting and counting based on enhanced CNN detection method. *E3S Web of Conferences*.
- Signoroni, A., Savardi, M., Baronio, A., & Benini, S. (2019). Deep learning meets hyperspectral image analysis: A multidisciplinary review. *Journal of Imaging*, 5(5), 52.
- Song, D., Liu, H., Dong, Q., Bian, Z., Wu, H., & Lei, Y. (2018). Digital, Rapid, Accurate, and Label-Free Enumeration of Viable Microorganisms Enabled by Custom-Built On-Glass-Slide Culturing Device and Microscopic Scanning. *Sensors (Basel, Switzerland)*, 18.
- Şen Arslan, H., Cabi, A., Yerlikaya, S., & Sariçoban, C. (2021). Antibacterial and antioxidant activity of peach leaf extract prepared by air and microwave drying. *Journal of Food Processing and Preservation*, 45(10), e15847.
- Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R., & Mittal, A. (2019). Pneumonia detection using CNN based feature extraction. *2019 IEEE international conference on electrical, computer and communication technologies (ICECCT)*, 1–7.
- Veziroglu, E., Pacal, I., & Coşkunçay, A. (2023). Derin Evrişimli Sinir Ağları Kullanılarak Pirinç Hastalıklarının Sınıflandırılması. *Journal of the Institute of Science and Technology*, 13(2), 792-
- Yoon, S.-C., Lawrence, K. C., & Park, B. (2015). Automatic counting and classification of bacterial colonies using hyperspectral imaging. *Food and bioprocess technology*, 8, 2047–2065.
- Yerlikaya, S. (2021). Staphylococcus aureus ATCC 25923 inhibition with propolis in pasteurized and UHT milks. *Journal of Agroalimentary Processes & Technologies*, 27(3).
- Yerlikaya, S., Çiftçi, M., İşler, A., & Arslan, H. Ş. (2022). Determining antibacterial effect of yellow onion (allium cepa) peel extract on some pathogen inoculated in raw, uht and pasteurized milks. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(3), 707-716.
- Zhang, B., Zhou, Z., Cao, W., Qi, X., Xu, C., & Wen, W. (2022). A New Few-Shot Learning Method of Bacterial Colony Counting Based on the Edge Computing Device. *Biology*, 11.
- Zhang, J., Li, C., Rahaman, M. M., Yao, Y., Ma, P., Zhang, J., Zhao, X., Jiang, T., & Grzegorzec, M. (2022). A comprehensive review of image analysis methods for microorganism counting: from classical image processing to deep learning approaches. *Artificial Intelligence Review*, 1–70.
- Zhang, Y., Jiang, H., Ye, T., & Juhas, M. (2021). Deep learning for imaging and detection of microorganisms. *Trends in Microbiology*, 29(7), 569–572.