

Pestisit Tespiti için Sensör Optimizasyonlu Bir Elektronik Burun: Kirazlarda Diazinon'un YSA ve Genetik Algoritma Tabanlı Sınıflandırılması

Cemaleddin ŞİMŞEK^{1*}, Ahmet YILMAZ²

Öz

Tarım, insan yaşamını sürdürmek için vazgeçilmez olan besin kaynaklarını sağlamak açısından hayati öneme sahiptir. Artan nüfusun taleplerini karşılamak ve yüksek verimli tarım elde etmek amacıyla, zirai pestisit kullanımı yaygın bir uygulama haline gelmiştir. Çeşitli pestisitler tarımsal verimliliği artırabilse de, çalışmalar bunların insan sağlığı üzerinde çeşitli etkilere sahip olabileceğini göstermiştir. Bu nedenle, bu maddelerin tespiti ve insan sağlığı üzerindeki etkilerinin en aza indirilmesi kritik öneme sahiptir. Bu çalışma, kirazlardaki Diazinon pestisit kalıntılarını tespit etmek için bir elektronik burun, yapay sinir ağları (YSA) ve genetik algoritmalar (GA) kullanarak etkili bir sınıflandırma yöntemi sunmaktadır. Piyasada kolayca bulunabilen 11 gaz sensörü kullanılarak bir elektronik burun sistemi geliştirilmiştir. Farklı seviyelerde pestisit kontaminasyonu olan ve olmayan kiraz örneklerinden elde edilen veriler, bir YSA sınıflandırıcısı ile sensör tepkilerini analiz etmek için kullanılmıştır. Ardından, gereken sensör sayısını en aza indirmek için GA kullanılmıştır. Sonuçlar, yalnızca 3 sensör kullanılarak bile %100'e varan sınıflandırma doğruluğunun elde edilebileceğini göstermektedir. Bu çalışma, zirai pestisit kalıntılarının tespiti için maliyet etkin ve yüksek doğruluklu bir yöntem sunarak mevcut literatüre önemli bir katkı sağlamaktadır.

Anahtar Kelimeler: Elektronik burun, Pestisit tespiti, Yapay sinir ağı, Genetik algoritma, Sınıflandırma.

A Sensor-Optimized Electronic Nose for Pesticide Detection: ANN and Genetic Algorithm-Based Classification of Diazinon in Cherries

Abstract

Agriculture is vital for providing the indispensable food sources that sustain human life. To meet the demands of a growing population and achieve high-yield farming, the use of agricultural pesticides has become a widespread practice. While various pesticides can increase agricultural productivity, studies have shown they can also have diverse effects on human health. Therefore, the detection of these substances and the minimization of their impact on human health are crucial. This study introduces an effective classification method for detecting Diazinon pesticide residues in cherries using an electronic nose, artificial neural networks (ANN), and genetic algorithms (GA). An electronic nose system was developed using 11 commercially available gas sensors. Data obtained from cherry samples with varying levels of pesticide contamination, as well as pesticide-free samples, were used to analyze sensor responses with an ANN classifier. GA was then employed to minimize the number of sensors required. The results demonstrate that classification accuracy reaching 100% can be achieved using as few as 3 sensors. This study offers a cost-effective and highly accurate method for detecting agricultural pesticide residues, making a significant contribution to the existing literature.

Keywords: Electronic nose, Pesticide detection, Artificial neural network, Genetic algorithm, Classification.

¹Karamanoğlu Mehmetbey Üniversitesi, Elektrik-Elektronik Mühendisliği, Karaman, Türkiye, csimsek@kmu.edu.tr

²Karamanoğlu Mehmetbey Üniversitesi, Bilgisayar Mühendisliği, Karaman, Türkiye, yilmazahmet@kmu.edu.tr

*Sorumlu Yazar/Corresponding Author

1. Giriş

Tarım sektörü, dünya genelinde gıda üretiminin sürdürülebilirliğini sağlamak için kritik bir rol oynamaktadır (FAO, 2021; Godfray ve ark., 2010). Bu sektörün sürdürülebilirliğinde de bitki hastalıkları ve zararlılarla mücadele amacıyla uygulanan ilaçlamalar önemli bir rol oynamaktadır (Oerke, 2006; Popp ve ark., 2013). Ürün verimliliğini artırmak (Pretty ve ark., 2011; Zhang ve ark., 2018) ve gıda güvenliğini sağlamak (Carvalho, 2017; Damalas ve Eleftherohorinos, 2011) için kullanılan ilaçların asıl amaçlarının dışında çok önemli etkileri de bulunmaktadır. Kimyasal ilaçların aşırı kullanımı, çevre ve insan sağlığına oluşturduğu riskler ve tarımsal ürünlerde ve toprakta kimyasal kalıntıların (Nicolopoulou-Stamati ve ark., 2016; Sharma ve ark., 2019) gibi sorunların oluşması ilaçlamanın negatif yan etkileri arasındadır (Aktar ve ark., 2009; Mahmood ve ark., 2016). Bu nedenle, etkili ve sürdürülebilir ilaçlama yöntemlerinin geliştirilmesi ve ölçülebilir boyutlara taşınması büyük önem taşımaktadır.

Sanayii devrimi sonrasında, tarımda teknoloji kullanımının artmasıyla birlikte, bitki sağlığını izlemek ve ilaçlama etkinliğini değerlendirmek için yenilikçi yöntemler kullanılmaya başlanmıştır. Elektronik burun (e-burun) teknolojisi, bu alanda kullanılan teknolojik yenilikçi yöntemler arasında bulunmaktadır (Wilson ve Baietto, 2009; Loutfi ve ark., 2015). E-burun, uçucu kimyasal bileşenleri algılayabilen sensör gruplarından meydana getirilmiş bir elektronik sistemdir (Peris ve Escuder-Gilabert, 2009; Röck ve ark., 2008). Bahsi geçen sistemin hastalık tanımlamadan (Biondi ve ark., 2014; Sankaran ve ark., 2010), kalite denetimine (Ghasemi-Varnamkhasti ve ark., 2011) kadar çok geniş uygulama alanları bulunmaktadır. Tarım sektöründe de çeşitli kullanım alanları bulunmasının yanında (Baietto ve Wilson, 2015; Pathange ve ark., 2006), meyve ile sebzelerde bulunan kimyasal kalıntıları tespit etmek için de kullanılmaktadır (Concina ve ark., 2012; Li ve ark., 2019). Bununla birlikte, akademik çalışmalarda rastladığımız elektronik burun sistemlerinin maliyet ve işlem yükü bakımında son kullanıcıya hitap etme kabiliyetlerinin düşük olduğu gözlemlenmiştir (Wijaya ve ark., 2017; Haddi ve ark., 2014; Kiani ve ark., 2016). Bu çalışmada, literatürde bulunan (Tozlu, 2024) çalışmasındaki metaryel ve metot tekrarlanmak suretiyle, benzer sonuçların son kullanıcıya hitap edecek, düşük maliyetli bir yapıya büründürülmesi amacıyla sensör sayısının ve gerekli işlem yükünün azaltılması amaçlanmıştır.

Bu amaç doğrultusunda (Tozlu, 2024) çalışmasında ele alınan kiraz meyvesi ve kiraz için zirai pestisit Diazinon'un etkisi incelenerek deneyler tekrarlanmış ve geliştirilen e-burun üzerinde optimizasyona gidilmiştir. Bu optimizasyondaki asıl amaç, ev tipi bir cihaz olacak şekilde düşünülen elektronik burun sisteminin maliyet optimizasyonunu en etkin şekilde yapabilmektir. Zirai pestisit olan Diazinon'un 1/1000 oranında suyla karıştırılarak uygulandığı 10 adet kiraz ağacından, dört farklı olgunluk döneminde toplamda 50 kiraz numunesi toplanmıştır. Eşit miktarda kiraz numunesi, pestisit

uygulanmayan ağaçlardan da toplanarak numune toplama işlemi tamamlanarak 100 adet numune elde edilmiştir. Toplanan numuneler, 24 saatlik süreç içerisinde analiz için ısı yalıtımlı bir kutu içinde deney ortamına ulaştırılmıştır.

Deney ortamında (Tozlu, 2024) çalışmasında kullanılan sensörlerin aynılarının kullanıldığı bir e-burun sistemi bulunmaktadır (Gaz sensörleri MQ-2, MQ-3, MQ-4, MQ-5, MQ-6, MQ-7, MQ-8, MQ-9, MQ-131, MQ-135 ve MQ-137). Toplamda 100 numune e-burun sistemiyle her bir ölçüm çevrimi 60 saniye olacak şekilde ölçülmüştür.

Toplanan elektronik burun verileri daha sonra yapay sinir ağı (YSA) sınıflandırıcıyla sınıflandırılmış, sınıflandırma doğruluğu genetik algoritmaya (GA) girdi olarak verilerek en az sayıda sensör ile en yüksek sınıflandırma doğruluğu elde edilmeye çalışılmıştır. Buradaki amaç, maliyet ve işlem karmaşasını düşürerek, ev tipi bir pestisit tespit cihazının tasarımına bir adım daha yaklaştırmaktır.

Sonuçlar en fazla 3 sensör kullanmak suretiyle dahi (MQ5, MQ7 ve MQ137) %100 sınıflandırma başarımı elde etmenin mümkün olacağını göstermektedir. Bu sonuçlarla çalışmanın, literatürde bulunan diğer yöntemlere göre hem maliyet etkin hem de yüksek doğruluğu sahip olması açısından literatüre önemli bir katkı sağladığını söylemek mümkündür.

2. Materyal ve Metot

Materyal ve metot kısmında mümkün mertebede sıkı bir şekilde çalışma (Tozlu, 2024)'deki elektronik burun tasarımı, ürünlerin temini ve veri toplama yöntemlerine sadık kalınmıştır. Kirazların toplanması, elektronik burnun tasarımı ve ölçümlerin alınması noktasında deneyin tekrarlanabilmesi için gerekli titizlik gösterilmiştir. Bunun birkaç istisnasından birisi olarak, kirazların temin edildiği konum ve kiraz tipleri gösterilebilir. Buna ilaveten çevre bahçelerde ne tip ürünlerin olduğuna ve dolaylı olarak ne tip bitki ilaçlarının kullanıldığına dair bir bilginiz bulunmamaktadır.

2.1. Örnek Hazırlama

Böcek ilacı püskürtülmüş kirazlar ve böcek ilacı püskürtülmemiş kirazlar, konum olarak Karaman/Merkez ilçesinde bulunan şahsi bir meyve bahçesinden toplanmıştır. Meyve toplama aşaması gerçek dünyadaki etkinin aynı ile elde edilmesi adına meyvelere zarar vermeden el ile gerçekleştirilmiştir. İlaçsız olacak kontrol grubundaki kirazlar, ilaçlama işlemi yapılmadan önce toplanırken, ikinci grup kirazlar kurtçukların yumurta bırakmasına neden olan kiraz sineğinden korumaya yarayan Korban 25W adlı böcek ilacı 20gr/10lt derişimde olacak şekilde hazırlanarak püskürtüldükten sonra toplanmıştır. İkinci grup kirazların toplanma işlemi, ilaçlama işleminden 24

saat sonra gerçekleştirilmiştir.

2.2. Elektronik Burun Sistemi

Çalışmada, (Tozlu, 2024)'deki çalışmada üretilen verilerin tekrarlanabilmesi adına aynı donanımsal yapı üzerinden deneyler yapılmıştır. Elektronik burun kurulumu için, piyasada kolayca ve yaygın olarak bulunabilen 11 farklı gaz sensörü bir araya getirilmiştir (MQ-2, MQ-3, MQ-4, MQ-5, MQ-6, MQ-7, MQ-8, MQ-9, MQ-131, MQ-135, MQ-137). Sistem kokusuz kilitli bir plastik kabın içine yerleştirilerek ölçüme hazır hale getirilmiştir. Kap içindeki donanımın dış dünya ile bağlantısını kablosuz haberleşme özelliği olan ve T3 Vakfı tarafından geliştirilen Deneyap Kart kullanılarak sağlanmıştır. Gaz sensörlerinin çok enerji tüketmesinden dolayı 2S LiON 18650 paket piller sisteme gerilim sağlarken, sensör gerilimleri kalibrasyon kaymasını minimize etmek adına daima takipte tutulmuştur. Tüm veriler 2 adet Deneyap Kart bünyesinde bulunan Wifi modülü sayesinde PC'ye aktararak, ölçüm esnasında dış ortam uçucu kimyasallarından daha ziyade korunması mümkün olmuştur.

2.3. Veri Toplama

Sınıflandırılacak iki farklı gruptan, tekrarlanmaya çalışılan çalışmada (Tozlu, 2024)'te kullanılan metoda sadık kalabilmek adına, yeterli miktarda kiraz temin edilerek farklı gramajlarda toplama işleminden sonraki 3-8. saatler arasında ölçüm işlemine geçilmiştir. Ölçüm için daha sonraki çalışmalarda da değerlendirilmek üzere, elektronik burun kapalı kutusundaki uçucu organik bileşenlerin konsantrasyonuna etkisini de incelenebilmesi adına 100gr, 200gr, 300gr, 400gr ve 500gr'lık kiraz numunelerinden 10'ar adet olacak şekilde ölçümler alınmıştır. Toplam 100 adet koku kaydı, 50'si ilaç püskürtülmüş kirazlar ve geri kalan 50'si ilaçlanmamış kirazlardan alınmış sayısal veriler kaydedilmiştir. Veri kaydı esnasında ortam sıcaklığı 2 °C sapma ile 25 °C 'lik sıcaklık ve %10 sapma ile %50 nem miktarı korunması adına iklimlendirme sisteminden faydalanılmıştır. Ölçümler arasında, elektronik burun kutusunun ağzı açılarak ortam havası ile sensör havalandırma işlemleri yapılmıştır.

2.4. Sınıflandırma Yapay Sinir Ağları

Bu çalışmada önerilen algoritmanın akış şeması Şekil 1'de verilmiştir. Şekil 1'den de görüldüğü üzere, bu çalışmada sınıflandırma noktasında sadece Yapay sinir ağları (YSA) (Hassoun, 1995; Yegnanarayana, 2009) kullanılmıştır. YSA makine öğrenmesinin bir türü olan özel bir tekniği

kullanan bir grup yöntemin genel adıdır. Karmaşık veri ilişkilerini öğrenme kabiliyetleri nedeniyle genellikle tahmin ve sınıflandırma gibi görevlerde tercih edilirler. Genel olarak giriş katmanı, ara katman(lar) ve çıkış katmanı olmak üzere üç katman grubundan oluşan YSA'lar, girdi katmanındaki verileri katmanlardaki nöronlar ve bu nöronları birbirine bağlayan bağlantı ağırlıkları aracılığıyla çıktı katmanına ileterek işler. Ağın nihai hedefi, giriş katmanında gösterilen verilerin özelliklerine göre o verinin istenen çıktısını çıkış katmanında doğru tahmin etmektir. Bunun için eğitim ya da öğrenme adı verilen bir süreç ile ağıdaki bağlantı ağırlıkları optimize edilir. Ağın öğrenme süreci genellikle hata geri yayılım algoritması ile gerçekleştirilir; bu algoritma tahmin edilen çıktı ile gerçek çıktı arasındaki farkı hesaplayarak ağırlıkları günceller ve hata oranını en aza indirmeye çalışır. Ağın performansı ağ topolojisi, kullanılan aktivasyon fonksiyonu, öğrenme hızı, öğrenme algoritması gibi birçok parametreye bağlıdır.

Ağın giriş katmanına öznitelik olarak sensörlerden alınan her bir ölçümün ortalama değeri girdi olarak verilmiştir. Buradaki mantık, önceki çalışmalarda hususen tekrar edilmek istenen elektronik burun sisteminde (Tozlu, 2024) kullanılan farklı özniteliklerin tamamının sensör ortalama değeri ile ilintili olması ve gaz sensörlerinin saniyeler mertebesindeki tepki süreleri göz önüne alınarak sadeleştirme maksadı gözetilmesidir. (Tozlu, 2024) çalışmasında ortalama değer, toplam, median ve standart sapma olmak üzere 4 farklı öznitelik kullanılmıştır ki, burada toplam ve median değerleri ortalama değer ile doğrudan ilintilidir. İlâveten öznitelik etkisi olarak da standart sapma değeri en düşük etkiye sahip olduğu da belirtilmiştir. Ortalama değer denklem 1 'deki gibi hesaplanmıştır. Denklem 1'deki x 'ler tek bir sensör için 60 saniyelik ölçümü içeren zaman serisini temsil ederken, s değişkeni sensörden bir ölçümde (60sn) alınan örnek sayısını temsil etmektedir.

$$x_{ortalama} = \frac{1}{s} \sum_{t=1}^s x(t) \quad (1)$$

Sensörlerden örnekleme yapılırken, 60 saniye boyunca her saniyede 10 örnek alındığı için toplam 600 örnek bir numuneden alınmıştır. Bu durumda denklem 1'de $s=600$ 'e denk düştüğünden, örneklenen tüm değerlerin toplanarak 600'e bölünmesi ile ortalama değer elde edilmiştir. Öznitelik olarak sadece ortalama değer kullanılmasıyla, yöntem olarak da sadeleştirmeye gidilmiştir ki bu kararın etkisi sonuç bölümünde daha detaylı incelenecektir.

2.5. Genetik Algoritmalar

Bu çalışmada amaç, daha önce çalışılan bir sistemin başarımını tekrarladıktan sonra optimize etmek olduğu için, sensör sayısının azaltılması adına genetik algoritma (GA) kullanılmıştır. GA (Holland, 1992; Katoch ve ark., 2021), doğal seçim ve genetik fikirlerinden türetilen bir


optimizasyon ve arama algoritmasıdır. Biyolojik evrimi taklit eden ve döngüsel bir süreçle işleyen, seçim, çaprazlama ve mutasyon gibi genetik operatörleri kapsayan evrimsel algoritmaların bir alt kümesidir. Standart bir GA'da, kromozom adı verilen çözüm adaylarından oluşan bir popülasyon vardır. Popülasyondaki bu kromozomlar belirtilen bir uygunluk fonksiyonuna göre değerlendirilir. Uygunluğu yüksek olan kromozomun düşük olana göre seçilme şansı daha yüksek olacak şekilde çalışan bir seçim operatörüyle popülasyondaki kromozomlar üremek için seçilir ve ebeveyn olarak isimlendirilirler. Çaprazlama operatörü ebeveyn kromozomlardan gelen özellikleri birleştirir ve mutasyon operatörü de popülasyondaki çeşitliliği sağlamak için ebeveyn ya da çocuk kromozomlarda küçük rastgele değişiklikler yaparak popülasyonun çeşitliliğini arttırmayı amaçlar. Algoritma, birkaç nesil boyunca çözümleri iyileştirerek ideal veya neredeyse en iyi bir sonuca yaklaşır. Genetik algoritmalar, mühendislik tasarımı, planlama ve kombinasyonel optimizasyon gibi karmaşık problem çözme alanlarında yaygın olarak kullanılır.

2.6. Sensor Seçim Algoritması ve Parametreleri

Bölüm 2.2'de bahsedildiği gibi bu çalışmada kullanılan elektronik burun sisteminde 11 tane genel amaçlı sensör vardır. Makine öğrenmesi algoritmalarının sınıflandırma başarısı için bu sensörlerden hangilerinin sınıflandırma başarısına etkisinin düşük olduğu ya da hangilerinin en yüksek etkiye sahip olduğu bilinmemektedir. Bu noktadaki optimizasyon çalışması, sınıflandırma başarısına en yüksek katkıyı sağlayan sensör veya sensör kombinasyonlarını tespit ederek sensör sayısını optimize etmeyi hedeflemektedir. Özet olarak elektronik burun sistemindeki sensör sayısını, dolayısıyla maliyeti minimize etmeyi ve kullanım kolaylığını arttırmayı amaçlamaktadır. Önerilen model bunu yaparken doğru tahmin başarısını da yüksek tutmayı hedeflemektedir.

Çalışmada tasarlanan karar mekanizması kombinasyonel bir GA'yı, YSA'nın girdi parametrelerine uygulamaktan ibarettir. YSA'nın girdi katmanındaki nöron sayısı kullanılan sensör sayısına eşittir, dolayısıyla YSA'nın girdi katmanında da 11 adet nöron olduğu için, GA'nın kromozomları 11 bit uzunluğundaki bit dizesinden oluşturulmuştur. Bit dizesindeki değerlerin indis numaraları sensörlerin indis numaralarıyla eşleşmektedir. Bu kromozomlarda (dizelerde) "0" olan bitlere karşılık gelen sensörlerin kullanılmadığı ve "1" olan bitlere karşılık gelen sensörlerin kullanıldığı anlamına gelmektedir. GA başlangıç popülasyonu 30 kromozomdan oluşmaktadır. Kromozomların uygunluk değerleri YSA eğitimi sonunda elde edilen doğruluk değerleriyle doğru orantılı ve kromozom tarafından seçilen sensör sayısı ile ters orantılı olacak şekilde belirlenmiştir. Bu sayede en yüksek doğruluğu verebilen en az sayıda sensöre sahip kromozomun en iyi uygunluk değerine sahip olması sağlanmıştır ki asıl amaç da budur. Seçim operatörü olarak ikili turnuva

yöntemi kullanan GA sistemi, %90 çaprazlama oranı ve %10 mutasyon oranıyla çalışmaktadır. GA sistemi 20 nesil boyunca çalıştırılmıştır.



Şekil 1. Önerilen algoritmanın akış şeması

2.7. Uygunluk Değerlendirmesi

Uygunluk popülasyon içindeki kromozomların çözüme yakınlık seviyelerini gösteren bir değerdir ve bir fonksiyon tarafından ölçülür. Bu sistemde uygunluk fonksiyonu eğitilen YSA'nın doğrulama verisindeki doğruluk oranı ve kullanılan sensör sayısının birleşiminden oluşmaktadır. YSA eğitimi için veriler %70'e %30 oranında eğitim ve doğrulama verisi olarak rastgele bölünür. YSA'nın başarımı bazen başlangıçta atanan rastgele ağırlıklara da bağlı olabilir. Bu şans faktörünün etkisini azaltmak için YSA her kromozom için 3 defa çalıştırılarak ortalama sonuçlar kullanılmaktadır. Kullanılan uygunluk fonksiyonu denklem 2'de verilmektedir.

$$Uygunluk = \frac{1}{n} \sum_{i=1}^n a_i + \frac{\alpha}{\sum_{j=1}^t c_j} \quad (2)$$

Burada n YSA'nın her bir kromozom için çalışma sayısını göstermektedir ve 3'e eşittir, a eğitim sonundaki doğrulama verisinin doğruluk oranıdır, α kullanılan sensör sayısının ölçekleme katsayısıdır ve 0.5'e eşittir, t kromozom uzunluğudur ve 11'e eşittir ve son olarak c ölçüm yapılan kromozomun bit dizesidir.

YSA birçok parametre içerir ve başarımı bu parametre ayarından etkilenir. Bu parametreler genellikle kullanıcı deneyimine dayanarak ya da deneme yanılma yöntemine dayanarak yapılır. Bu çalışmada kullanılan YSA parametreleri deneme yanılma yöntemiyle belirlenmiştir. Bu süreçte tüm

sensörlerden gelen sinyaller kullanılarak ağın kararlılıkla en yüksek performansı sergilemesi göz önünde bulundurulmuştur. Sonuç olarak, 10 nörona sahip 1 gizli katmanlı bir ağ kullanılmıştır. Girdi katmanı ve çıktı katmanındaki nöron sayıları doğal olarak sırasıyla 11 (sensör sayısı) ve 1'e eşittir. Fakat popülasyondaki kromozomlar sensör vektörü ile çarpıldığında "0" değerlerine karşılık gelen indislerdeki sensör değerleri 0 değerini alır. Bu işlem sonucunda kromozomdaki 0 değerine sahip indislere karşılık gelen öznelikler ağ için etkisiz eleman olur dolayısıyla bu ağdaki girdi sayısı kromozomdan kromozoma değişkenlik gösterir hale gelir. Ağın gizli katmanındaki ve çıktı katmanındaki nöronlar sigmoid aktivasyonunu kullanmaktadır. Ağlar 1000 epoch boyunca Adam optimize edici (Kingma ve Ba, 2014) ve ortalama karesel hata kullanılarak eğitilir. Batch boyutu 1'e eşitlendiği için her epochta eğitim verisindeki örnek sayısı kadar ağırlık güncellenmesi gerçekleşmektedir.

3. Bulgular ve Tartışma

Bu çalışmada zirai pestisit Diazinon'un ile ilaçlanmış ve ilaçlanmamış kiraz meyvelerindeki ilaç kalıntıları elektronik burun, YSA ve GA yöntemleri kullanılarak verimli bir şekilde sınıflandırılmıştır. Piyasadan rahatlıkla temin edilebilecek ve nispeten laboratuvar seviyesi sensörlere göre uygun fiyatlı 11 farklı gaz sensörü içeren bir elektronik burun sistemi tasarlanmıştır. Bu donanıyla farklı miktarlarda (100gr, 200gr, 300gr, 400gr ve 500gr) ilaçlı ve ilaçsız numunelerden koku örnekleri alınarak veri toplama işlemi, her numuneden 60'şar saniye ve saniyede 10 örnek alınmak suretiyle toplam 100 örnekleme işlemi yapılmıştır. Başlık 2.4'te bahsedilen ilave özneliklerin de kullanımının sonuçları daha iyi bir noktaya taşımadığı tespit edilmiş olup, sonuçlar zaten en üst seviyede sınıflandırma sonucuna sahip olduğundan, önerilen sistemde tek bir öznelik olmasının daha mantıklı bir tercih olacağı da aşikârdır.

Önerilen algoritma, 2. bölümde belirtilen hiper parametrelerle tekrar tekrar çalıştırılmıştır. Model, farklı sayılarda sensör kombinasyonları önermiştir. Önerilen sonuçlar arasında sınıflandırma başarımı en yüksek olan sonuçlara Tablo 1'de yer verilmiştir. Tablo 1'de bulunan son 3 satırda verilen (9, 10 ve 11 sensörlü kombinasyonlar) veriler kıyaslama açısından algoritma dışında test edilmiştir. Örnekleme sonucundan elde edilen kayıtlardan ortalama değer özneliği çıkartılmış ve bu öznelik YSA sınıflandırıcıya girdi olarak verilmiştir. Sensörlerin etkilerini incelemek amacıyla YSA sınıflandırıcısının çıktısı GA'ya girdi olarak verilmiştir. Bu çalışma sayesinde, 11 sensör arasından seçilen kombinasyonlarla %100'e varan sınıflandırma başarısı sağlanmıştır. En dikkat çeken ise, bu başarının yalnızca üç sensörle bile elde edilebilmesidir. Şekil 1'de tüm ve 3 sensörlü durum için eğitim ve test verilerinin öğrenme eğrileri görülmektedir. GA ile sensör etkilerini ve başarımlarının


farklı kombinasyonlarla elde edildiği çıktıların bir kısmına Tablo 1’de en etkili sonuçları gösterecek şekilde yer verilmiştir.

Tablo 1. YSA – GA sensör seçimi sonuçlarına göre sensör indisi ve sayısına göre sınıflandırma başarımı.

Sensör Adı → Seçilen Toplam Sensor Sayısı ↓	MQ-2	MQ-3	MQ-4	MQ-5	MQ-6	MQ-7	MQ-8	MQ-9	MQ-131	MQ-135	MQ-137	Eğitim Kaybı (Train Loss)	Eğitim Doğruluğu (Train Accuracy)	Test Doğruluğu (Test Accuracy)
3	0	0	0	1	0	1	0	0	0	0	1	0,028296	%100	%100
4	0	0	0	1	0	1	0	0	0	1	1	0,010688	%100	%100
5	0	0	1	1	0	1	0	0	0	1	1	0,00832	%100	%100
6	0	0	0	1	0	1	0	1	1	1	1	0,008708	%100	%100
7	0	0	0	1	0	1	1	1	1	1	1	0,007778	%100	%100
8	0	1	1	1	0	1	1	0	1	1	1	0,004703	%100	%100
9	0	1	1	1	0	1	1	1	1	1	1	0,004593	%100	%99
10	1	1	1	1	0	1	1	1	1	1	1	0,003749	%100	%98
11	1	1	1	1	1	1	1	1	1	1	1	0,003162	%100	%96
Sensor Kullanım Sıklığı →	2	4	5	9	1	9	5	5	6	8	9			

Tablo 1’deki sonuçlardan da görüldüğü gibi 8 sensörlü kombinasyonlardan tam doğrulukta sınıflandırma başarımı elde etmenin mümkün olduğu anlaşılabilmektedir. Diğer kombinasyonlarda da literatürdeki diğer çalışmalara oranla daha yüksek sınıflandırma başarımı elde edilmiş ve bunu sağlarken tek öznetelik ve daha az sayıda sensor kullanılmıştır. İlaveten en etkili sensörlerin, Tablo 1’deki tüm sonuçlarda bulunan MQ5, MQ7 ve MQ137 olduğunu söylemek de mümkündür. Zira hem sadece bu 3 sensörle, hem de bu sensörün olduğu kombinasyonlarla tam doğrulukta sınıflandırma başarımı elde edilebilmiştir. Yine, Tablo 1’de gösterilen, 9, 10 ve 11 sensörlü sonuçlara bakıldığında, MQ2 ve MQ6 sensörlerinin sınıflandırma başarımına bir miktar negatif etkisi olduğunu söylemek de mümkün olacaktır.

Şekil 2’de, önerilen modelin ürettiği 3 sensörlü sonuçlar ve sistemde bulunan bütün sensörler kullanılarak elde edilen öğrenme grafikleri verilmiştir. 3 sensor ve tüm sensörlerle denenen grafik sonuçları 50’şer kere farklı eğitim-test kümeleri seçilerek çalıştırılıp, median sonuçlarını kullanmak suretiyle grafik çizdirilmiştir. Şekil 2’deki grafiklerden de anlaşılabileceği gibi, 3 sensörlü 2 farklı kombinasyon sonuçları %100 eğitim ve test doğruluğuna ulaşırken, tüm sensörleri kullanan sonuçlar aşırı öğrenme eğilimindedir. Tablo 1’deki sonuçlar da bahsi geçen aşırı öğrenme eğilimini destekler niteliktedir.



Şekil 2. Tüm ve 3 sensörlü durum için eğitim ve test verilerinin öğrenme eğrileri

Yapılan analizler, gaz sensörleri tek bir moleküle spesifik tepki veremese bile, organik uçucu maddelere farklı tepkiler verebilen sensör kombinasyonlarıyla etkili sonuçlar alınabildiğini göstermektedir. Bu durum, ev tipi, uygun maliyetli ve düşük işlem gücü gerektiren bir zirai pestisit tespit cihazı geliştirilebileceğini ortaya koymaktadır. Bu çalışma sonucunda, zirai pestisit tespitinde ev tipi daha ekonomik ve daha yüksek başarımlı bir cihaz tasarlanması mümkün olduğu çıktısının elde edilebileceği kanıtlanmıştır. Başka bir çıktı olarak, 11, 10 ve 9 sensör sayılı sonuçlar kıyaslandığında, fazla sensör kullanılmasının sınıflandırma başarımını olumsuz etkilediği sonucuna da varmak mümkündür. Sonuçlar referans alınan (Tozlu, 2024) sonuçları ile kıyaslandığında başarımlı %94.30'dan %100'e taşımış ve bu başarımlı artışını 11 sensör yerine, sadece 3 sensör ve tek öznetelik kullanarak başarmıştır. Önerilen yöntem (Tozlu, 2024)'e kıyasla hem işlem yükünde ciddi bir avantaj sağlamış, hem de sensör sayısının azalması ile maliyeti yaklaşık 1/3'üne düşürmüştür.

4. Sonuçlar ve Öneriler

Ç Bu çalışmada, mevcut bir elektronik burun sistemini (Tozlu, 2024) tekrarlamak ve sensör optimizasyonu uygulamak suretiyle zirai pestisit tespiti için, düşük maliyetli alternatif bir metot önerilmiştir. Kıyaslanan sistemin daha yüksek maliyet ve işlem yükü sorunlarını aşmak amacıyla, kirazlardaki diazinon pestisit kalıntılarının tespitinde YSA ve GA kullanılmıştır.

Çalışmanın en dikkat çekici bulgusu, başlangıçta kullanılan **11 adet sensör yerine, yalnızca 3 sensör (MQ5, MQ7 ve MQ137)** kullanarak %100'e varan sınıflandırma başarımlı elde edilebilmesidir. Bu sonuç, referans alınan çalışmadaki %94,30'luk başarı oranını önemli ölçüde aşarak, sistemin hem doğruluk hem de verimlilik açısından ne kadar geliştirildiğini açıkça göstermektedir. Ayrıca, sensör sayısının 11'den 3'e düşürülmesi, işlem yükünde ciddi bir azalma sağlarken, sensör maliyetini de yaklaşık olarak üçte bir oranında düşürmüştür.

Sonuçlar, fazla sensör kullanımının her zaman sınıflandırma performansını artırmadığını, aksine bazı durumlarda negatif etki yaratabileceğini de ortaya koymuştur. Özellikle 9, 10 ve 11 sensörlü kombinasyonlarda, sistemin aşırı öğrenme eğilimi gösterdiği ve test doğruluğunun düştüğü gözlemlenmiştir. Bu bulgu, sensör optimizasyonunun, sadece maliyet ve işlem yükü değil, aynı zamanda modelin genelleme başarısı için de kritik olduğunu kanıtlamaktadır.

Özetle, bu çalışma, zirai pestisit kalıntılarının tespiti için maliyet etkin, düşük işlem yüküne sahip ve yüksek doğruluklu bir "ev tipi" cihaz prototipi geliştirilebileceğini kanıtlamıştır. Gelecek çalışmalarda, bu modelin farklı pestisit türleri ve çeşitli gıdalar üzerindeki performansının test edilmesi, elde edilen verinin genellenebilirliğini artırarak nihai bir ürün geliştirme sürecine katkı sağlayacaktır.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Aktar, W., et al. (2009). Impact of pesticides use in agriculture: Their benefits and hazards. *Interdisciplinary Toxicology*, 2(1), 1-12.
- Baietto, M., & Wilson, A. D. (2015). Electronic-nose applications for fruit identification, ripeness and quality grading. *Sensors*, 15(1), 899-931. <http://dx.doi.org/10.3390/s150100899>
- Biondi, E., et al. (2014). Electronic nose and electronic tongue for the detection of plant diseases: Review. *Plant Disease*, 98(9), 1044-1053. <https://doi.org/10.1094/PDIS-01-14-0033-FE>
- Carvalho, F. P. (2017). Pesticides, environment, and food safety. *Food and Energy Security*, 6(2), 48-60. <https://doi.org/10.1002/fes3.109>
- Concina, I., et al. (2012). Early detection of microbial contamination in processed tomatoes by electronic nose. *Food Control*, 23(2), 406-413. <https://doi.org/10.1016/j.foodcont.2011.07.032>
- Damalas, C. A., & Eleftherohorinos, I. G. (2011). Pesticide exposure, safety issues, and risk assessment indicators. *International Journal of Environmental Research and Public Health*, 8(5), 1402-1419. <https://doi.org/10.3390/ijerph8051402>
- FAO. (2021). The State of Food and Agriculture 2021. Food and Agriculture Organization of the United Nations.

- Ghasemi-Varnamkhasti, M., et al. (2011). Electronic nose as a non-destructive tool to characterize peach cultivars and to monitor their ripening stage during shelf-life. *Postharvest Biology and Technology*, 59(3), 245-251. <https://doi.org/10.1016/j.postharvbio.2010.10.014>
- Godfray, H. C. J., et al. (2010). Food security: The challenge of feeding 9 billion people. *Science*, 327(5967), 812-818. <https://doi.org/10.1126/science.1185383>
- Haddi, Z., et al. (2014). A portable electronic nose system for the identification of cannabis-based drugs. *Sensors and Actuators B: Chemical*, 190, 280-291. <https://doi.org/10.1016/j.snb.2013.09.084>
- Hassoun, M. H. (1995). *Fundamentals of artificial neural networks*. MIT press.
- Holland, J. H. (1992). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press.
- Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*, 80, 8091-8126. <https://doi.org/10.1007/s11042-020-10139-y>
- Kiani, S., et al. (2016). A portable electronic nose as an expert system for aroma-based classification of saffron. *Chemometrics and Intelligent Laboratory Systems*, 156, 148-156. <https://doi.org/10.1016/j.chemolab.2016.06.009>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Li, C., et al. (2019). Detection of pesticide residues on fruit surfaces using an electronic nose system with chemometric methods. *Food Control*, 96, 16-24. <https://doi.org/10.1016/j.foodcont.2018.09.018>
- Loutfi, A., et al. (2015). Electronic noses for food quality: A review. *Journal of Food Engineering*, 144, 103-111. <https://doi.org/10.1016/j.jfoodeng.2014.08.024>
- Mahmood, I., et al. (2016). Effects of pesticides on environment. *Plant, Soil and Microbes*, 1, 253-269.
- Nicolopoulou-Stamati, P., et al. (2016). Chemical pesticides and human health: The urgent need for a new concept in agriculture. *Frontiers in Public Health*, 4, 148. <https://doi.org/10.3389/fpubh.2016.00148>
- Oerke, E. C. (2006). Crop losses to pests. *Journal of Agricultural Science*, 144(1), 31-43. <https://doi.org/10.1017/S002185960500571X>
- Pathange, L. P., et al. (2006). Non-destructive evaluation of apple maturity using an electronic nose system. *Journal of Food Engineering*, 77(4), 1018-1023. <https://doi.org/10.1016/j.jfoodeng.2005.08.026>
- Peris, M., & Escuder-Gilabert, L. (2009). A 21st century technique for food control: Electronic noses. *Analytica Chimica Acta*, 638(1), 1-15. <https://doi.org/10.1016/j.aca.2009.02.018>
- Popp, J., et al. (2013). Pesticide productivity and food security. *Agronomy for Sustainable Development*, 33(1), 243-255. <https://doi.org/10.1007/s13593-012-0092-x>
- Pretty, J., et al. (2011). Sustainable intensification in African agriculture. *International Journal of Agricultural Sustainability*, 9(1), 5-24. <https://doi.org/10.3763/ijas.2010.0515>
- Röck, F., et al. (2008). Electronic nose: Current status and future trends. *Chemical Reviews*, 108(2), 705-725. <https://doi.org/10.1021/cr068117q>
- Sankaran, S., et al. (2010). A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, 72(1), 1-13. <https://doi.org/10.1016/j.compag.2010.02.003>
- Sharma, A., et al. (2019). Worldwide pesticide usage and its impacts on ecosystem. *SN Applied Sciences*, 1(11), 1446. <https://doi.org/10.1007/s42452-019-1485-1>
- TOZLU, B. H. (2024). Electronic Detection of Pesticide Residue on Cherry Fruits. *International Journal of Computational and Experimental Science and Engineering*, 10(3). <https://doi.org/10.22399/ijcesen.401>
- Wijaya, D. R., et al. (2017). Low-cost electronic nose for classification of beef and pork using Naïve Bayes method. *Modern Applied Science*, 11(8), 35-46. <https://doi.org/10.5539/mas.v11n8p35>
- Wilson, A. D., & Baietto, M. (2009). Applications and advances in electronic-nose technologies. *Sensors*, 9(7), 5099-5148. <http://dx.doi.org/10.3390/s90705099>
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd.
- Zhang, W., et al. (2018). Global pesticide use: Profile, trend, cost/benefit and more. *Science of the Total Environment*, 616-617, 1056-1065. <https://doi.org/10.1016/j.scitotenv.2017.10.193>