

Makine Öğrenmesi ve Gömülü Sistem Yapısı ile Akıllı Tuzak Tasarımı

Smart Trap Design with Machine Learning and Embedded System Structure

Eren Atmaca, Berkan Höke, Cem Ünsalan
Marmara Üniversitesi

Mühendislik Fakültesi, Elektrik ve Elektronik Müh. Bölümü
e-posta: cem.unsalan@marmara.edu.tr

Özetçe—Ülkemizde meyve bahçelerinde Akdeniz meyve sineği zararlısı ile mücadele çok önemlidir. Bu mücadelenin verilmemesi durumunda ciddi ekonomik kayıplar oluşmaktadır. Şu anda zararlının tespit edilebilmesi için meyve ağaçlarının üzerine tuzaklar kurulmaktadır. Bu tuzakların düzenli aralıklarla çiftçiler tarafından kontrol edilmesi, meyvelerin ilaçlanma uygulamaları açısından önem arz etmektedir. Bu işlem çiftçilerin iş yükünü arttırmaktadır. Bu çalışmada, Akdeniz meyve sineği zararlısı sayısını otomatik olarak tespit eden bir akıllı tuzak tasarımı önerilmiştir. Akıllı tuzak, Arm Cortex M7 işlemcisi barındıran STM 32F746GDISCOVERY geliştirme kartı kullanılarak gömülü sistem olarak gerçekleştirilmiştir. Önerilen sistem sayesinde belirlenen bölgede Akdeniz meyve sineği zararlısının popülasyonu hakkında nicel veriler elde edilebilmektedir. Önerilen gömülü sistem üzerinde makine öğrenmesi yapılmaktadır. Bunun için gömülü sistem üzerinde çalışabilecek derin öğrenme temelli bir yapı kurgulanmıştır. Elde edilen ön sonuçlar önerilen sistemin Akdeniz meyve sineği tespiti ve belirli bir alandaki sayısının otomatik olarak bulunması için kullanılabilirliğini göstermektedir.

Anahtar Kelimeler—Akıllı tuzak, Akdeniz meyve sineği, gömülü sistem, derin öğrenme.

Abstract—It is very important to fight the Mediterranean fruit fly pest in orchards in our country. If this fight is not given, serious economic losses occur. Traps are currently being set up on trees to detect pests. It is important that these traps are checked by farmers at regular intervals in terms of pesticide applications of fruits. This process increases the workload of farmers. Therefore, a smart trap design that automatically detects the number of Mediterranean fruit flies is proposed in this study. The smart trap is implemented as an embedded system using the STM 32F746GDISCOVERY development board with an Arm Cortex M7 processor on it. Via the proposed system, quantitative data can be obtained about the population of Mediterranean fruit flies in the determined region. Machine learning is performed on the proposed embedded system. Therefore, a deep learning-based structure that can work on the embedded system has been designed. Obtained preliminary results indicate that the proposed system can be used for Mediterranean fruit fly detection and automatic determination of its number in a given region.

Keywords—Smart trap, Mediterranean fruit fly, embedded system, deep learning.

I. GİRİŞ

TÜİK verilerine göre 2019 yılında ülkemizde meyve üretim miktarı 20.578.453 tondur. Bu üretim içerisinde turuncgiller, kayısı, şeftali, nektarin, yenidünya, ayva, armut, elma, incir, Trabzon hurması ve nar gibi ürünler için en ciddi tehdit Akdeniz meyve sineğidir (*Ceratitis capitata Weid.*). Bu zararlı meyve kalitesini etkileyerek, %80'e kadar ulaşan ekonomik zarara neden olabilmektedir. Bu nedenle, çiftçiler bu zararlı ile mümkün olduğunca dikkatli bir şekilde pestisit kullanarak mücadele etmektedirler. Yapılan mücadelenin ana bileşenlerinden birisi, içerisinde Akdeniz meyve sineğini çeken cezbedici (feromon) bulunduran tuzak kullanılmaktadır. Burada önemli olan nokta sinekleri yakalamaktan çok, tuzak içerisindeki sinek sayısının bulunmasıdır. Çiftçiden beklenen ise bu tuzağı sık aralıklarla kontrol ederek Akdeniz meyve sineğinin bölgesel popülasyonu hakkında bilgi edinmektir. Buradan elde edilen veriler ışığında pestisit kullanımına başlanması, devam edilmesi gibi meyve kalitesini önemli derecede etkileyecek unsurlar hakkında karar verilir. Sonuç olarak ürün kalitesi hakkında ciddi bir soru cevaplanabilir.

Tuzak yardımı ile belirli bir bölgedeki Akdeniz meyve sineğinin sayısını bulmadaki en büyük problem, kullanılan tuzakların düzenli aralıklarla insanlar tarafından kontrol edilmesi gerekliliğidir. Tarım arazilerinin alan olarak büyük olması, mevsim koşullarına göre yağmurlu havalarda veya yağmur sonrası araziye girilememesi, tuzak kontrolü için ciddi kısıtlar getirmektedir. Bu nedenle, güncel çalışmalarda akıllı tuzaklar geliştirilmeye başlanmıştır. Burada örnek yapılardan biri Segalla vd. [1] tarafından geliştirilmiştir. Çalışmada Raspberry Pi kartı üzerinde LeNet ve VGG16 sinir ağı yapıları gerçekleştirilmiş ve bunların sonuçları incenmiştir. Benzer bir şekilde, Martins vd. [2] Raspberry Pi kartı üzerinde meyve sineklerini yüksek hassasiyetle tanıyan bir sistem önermiştir. Shaked vd. [3] meyve sineklerinin bulunması için akıllı tuzak tasarımı önermiştir. Zhong vd. [4] Raspberry Pi kartı üzerinde YOLO ile zararlı bulma yoluna gitmiştir. Akıllı tuzaklar ve tarımsal alanlarda kameralar ile zararlı tespiti üzerine birçok özet makalesi bulunmaktadır [5]–[7]. Bu makalelerden görülebileceği gibi, makine öğrenmesi uça (edge) yapıldığında ağırlıklı olarak Raspberry Pi kartından yararlanılmaktadır. Ancak bu kartın enjeksiyonu kendi başına bir alanda çalışamayacak kadar yüksek olabilmektedir. Diğer çalışmalarda farklı bir

yol izlenmiştir. Tirelli vd. [8] Texas Instruments MSP430 mikrodenetleyicisi ve Zigbee bağlantısı ile yalnızca görüntü iletimi yaparak zararlı kontrolüne çalışmıştır. López vd. [9] benzer bir şekilde tuzak içindeki zararlı görüntüsünü uzak sunucuya göndermeye odaklanmıştır. Bu iki çalışmada da uça görüntü kıymetlendirmesi yapılmamıştır.

Önerdiğimiz sistemin literatürdeki benzerlerinden en büyük farkı düşük güç tüketimli Arm Cortex M7 işlemcisi içeren STM 32F746GDISCOVERY geliştirme kartı kullanılmasıdır. Bu sayede, sistemin pil veya enerji hasadı modülü yardımı ile kendi başına daha uzun süre çalışabilmesi hedeflenmiştir. Önerilen sistemdeki en büyük zorluk, derin öğrenme temelli Akdeniz meyve sineği bulma makine öğrenme yönteminin düşük hafızaya sahip Arm Cortex M7 işlemcisi üzerinde gerçekleşmesidir. Bunun için çok fazla hafıza kullanımına ihtiyaç duymayan bir evrişimli sinir ağı (CNN) modeli oluşturulmuştur. Bu model STM firması tarafından verilmiş olan yazılım yardımı ile mikrodenetleyici hafızasına gömülmüştür. Çalışmanın ilerleyen bölümlerinde bütün bu işlemler şu sırada ele alınmaktadır. İkinci bölümde önerilen gömülü sistem yapısı detaylı olarak incelenmektedir. Üçüncü bölümde bu gömülü sistem üzerinde çalışabilecek olan makine öğrenmesi yönteminin bileşenleri verilmektedir. Bu bölümde ayrıca elde edilen modelin gömülü sisteme nasıl yüklenebileceği de detaylı olarak anlatılmaktadır. Çalışmanın dördüncü bölümünde şu ana kadar yapılmış deneysel çalışmalardan elde edilen sonuçlar verilerek, performans deneyleri özetlenmektedir. Bu bölümde ayrıca gömülü sistem üzerinde kaynak kullanımı da irdelenerek, sistemin daha ne kadar geliştirilebileceği tartışılmaktadır. Son bölümde bu çalışmada elde edilen tüm sonuçlar incelenecek ve ileriki çalışmalar için olası bir yol haritası verilecektir.

II. ÖNERİLEN GÖMÜLÜ SİSTEM YAPISI

Bu bölümde önerilen gömülü sistemin yapısı detaylı olarak verilmektedir. Bu sayede okuyucu derin öğrenme modeli için bulunan kısıtları ve olası kullanım senaryolarını bilebilecektir. Ayrıca, önerilen sistem dışında bir gömülü sistem kullanılması için de bu bölüm gerekli bilgiyi verecektir. Bunun için, ilk olarak kullanılan geliştirme kartı özetlenmektedir. İkinci olarak da sineklerin tuzak içinde bulunabilmesi için gerekli olan görüntü elde etme yapısı anlatılmaktadır.

A. 32F746GDISCOVERY Geliştirme Kartı

Önerilen akıllı tuzak tarım arazilerinde kullanılacağı için, ana enerji hattına bağlanması mümkün değildir. Bu nedenle, sistemin bir pil veya enerji hasadı modülü ile beraber çalışması gerekmektedir. Burada da en önemli husus, tüm sistemin enerji tüketiminin en az seviyede olmasıdır ki, tuzak kendi başına uzun bir süre çalışsın. Bu nedenle, enerji tüketimi oldukça düşük olan Arm Cortex M mimarisine sahip bir işlemci kullanılması hedeflenmiştir. Bu çalışmada prototip bir sistem önerildiği için, STMicroelectronics firması tarafından üretilen 32F746GDISCOVERY geliştirme kartı kullanılmıştır.

STM32F746G geliştirme kartı üzerinde bulundurduğu bileşenler bakımından geniş kullanım alanı sunmaktadır. Üzerinde bulundurduğu STM32F746NG mikrodenetleyicisi 216 MHz saat hızında çalışabilen Arm Cortex M7 mimarisine sahiptir. Bu mikrodenetleyici dahili olarak 1 MB flash bellek ve 320 KB SRAM barındırmaktadır. Bunların dışında harici bellekleri

kontrol edebilmek için esnek bellek denetleyicisi (FMC) de bulundurmaktadır. Bu çevre birimi kart üzerindeki 64 Mbit (8 MB) harici SDRAM belleğini kontrol etmektedir. Buna ek olarak kart üzerinde 128 Mbit (16 MB) QUAD-SPI flash belleği, mikrodenetleyici içerisinde ise bu belleği sürecek çevre birimi mevcuttur. Mikrodenetleyicide görüntü işlemlerini hızlandırmak için DMA2D çevre birimi bulunmaktadır. Görüntüleri farklı formatlara dönüştürmekte kullanılabilen bu birim diğer DMA birimlerinden ve işlemciden bağımsız olarak çalışabilmektedir. Son olarak, harici kamera modüllerinden görüntü almakta kullanılan DCMI çevre birimi de mikrodenetleyicide bulunmaktadır. Bu birim bir DMA birimiyle birlikte kullanıldığında işlemciyi kesmeden görüntü alınmasına olanak tanır. Bu sırada işlemci eş zamanlı olarak gerekli verileri işleyebilir.

Belirtildiği gibi, önerilen STM 32F746GDISCOVERY geliştirme kartı ve üzerindeki STM32F746NG mikrodenetleyicisi ufak boyutta bir CNN modelini üzerinde barındırabilecek hafıza alanına sahiptir. Her ne kadar enerji tüketimi alanında piyasada bulunan en tasarruflu mikrodenetleyici olmasa da, görüntü işleme için oldukça uygun bir platformdur. Ayrıca, bir sonraki bölümde detaylı olarak anlatılacağı gibi, geliştirilen CNN modeli STM tarafından ücretsiz olarak sunulan STM32CubeIDE yapısı ve bunun üzerindeki X-CUBE-AI paketi yardımı ile mikrodenetleyici üzerine gömülebilmektedir.

B. Görüntü İletimi

Akıllı tuzak içerisinde sineklerin sayısını bulabilmek için OV7670 gibi ucuz ve düşük güç tüketimli bir gömülü kamera bulunmalıdır. Çalışmanın bu aşamasında deneysel sonuçları elde edebilmek ve önerilen sistemin başarımını ölçebilmek için, tuzaklardan daha önceden elde edilmiş olan imgeler bilgisayardan 32F746GDISCOVERY geliştirme kartına Python yardımı ile UART haberleşmesi sayesinde iletilmiştir. Bunun için öncelikle mikrodenetleyici UART üzerinden bilgisayara 56×56 boyutlarında görüntü talebinde bulunmaktadır. Bilgisayardaki Python kodu etiketlenmiş bir sinek veya arka plan görüntüsünü 56×56 boyutlarında kırparak RGB888 formatında işler. Bu görüntü 2 Mbps veri iletim hızında pyserial kütüphanesi yardımıyla bilgisayarın seri bağlantı noktasından faydalanılarak mikrodenetleyiciye iletilir. Mikrodenetleyici tarafında UART kullanımında “polling” metodu tercih edilmiştir. Bu sayede, elde edilen görüntü verileri harici SDRAM üzerinde önceden ayrılan adreslere yazılır. Burada belirtmek gerekir ki, prototip sistemin geliştirilmesi ile görüntü alma işlemi tamamen gömülü kamera üzerinden de yapılabilecek durumdadır.

III. MAKİNE ÖĞRENMESİ BİLEŞENLERİ

Bilgisayarlı görü alanında nesne tespit ve tanıma aşamalarında derin öğrenme temelli CNN yapıları oldukça yüksek başarıma sahiptir. Bu çalışmada da Akdeniz meyve sineğini tuzak içinde tespit edebilmek için probleme özel bir CNN yapısı tasarlanmıştır. Burada en önemli nokta, kullanılan gömülü sistemin hafıza kısıtıdır. Bu nedenle, ilk olarak olabildiğince küçük bir model bilgisayar üzerinde eğitilip, test edilmiştir. Daha sonra, eğitilmiş olan bu modelin gömülü sistem üzerine eklenebilmesi için TensorFlow Lite kütüphanesinden yararlanılmıştır. Son olarak da bu yapıdan elde edilmiş olan modelin STM32F746NG mikrodenetleyicisi üzerine gömülebilmesi

için STM32CubeIDE yapısı ve bunun üzerindeki X-CUBE-AI paketi kullanılmıştır.

A. Tasarlanan CNN Yapısı

Bu çalışmada, Akdeniz meyve sineğini tespit edebilmek amacıyla bir CNN modeli geliştirilmiştir. Gömülü sistemlerin bilgisayarlara göre kısıtlı hafızası vardır. Bu nedenle, geliştirilen modelin hem hafıza boyutunun küçük olması, hem de yüksek performanslı olması beklenmektedir. Literatürde bulunan SqueezeNet [10] ve MobileNet [11] gibi yapılar düşük boyutlarda yüksek performans sağlamaktadır. Ancak STM32F746NG mikrodenetleyicisinde bulunan hafıza bu modelleri gerçeklemeye yetmemektedir. Bu nedenle, SqueezeNet tarafından kullanılan sıkıştırma-genişletme yapısı daha küçük bir model üzerinde gerçekleştirilmiştir. Her bir ateşleme (fire modülü) sıkıştırma-genişletme içeren evrişim katmanından oluşmaktadır. Sıkıştırma katmanları 1×1 evrişim katmanlarını temsil etmektedir. Diğer yandan genişletme katmanları, 3×3 evrişim katmanlarından oluşmaktadır. Bu katmanlar sayesinde model içerisinde eğitilecek parametre sayısı büyük oranda düşürülebilmektedir.

B. TensorFlow Lite Kullanımı

Bilgisayar üzerinde eğitilen CNN modelini gömülü sistemlere aktarmak üzere TensorFlow Lite kütüphanesinden faydalanılmıştır. Bu kütüphane yardımıyla model içerisinde eğitilen ağırlıklar 32-bit kayan nokta (float) veri tipinden 8-bit tam sayı (int8) haline dönüştürülerek ağırlıkların boyutu düşürülmüştür. Bunun yanında iki ateşleme modülü de modelden atılmıştır. Bu sayede 1.4 MB olan model boyutu yalnızca 194 KB olmuştur.

C. Gömülü Sistem Üzerinde Gerçekleme

Hazırlanan TensorFlow Lite model dosyası X-CUBE-AI paketine girdi olarak verilmiştir. X-CUBE-AI paketinin bu işlemi sonrasında modelin flash bellek üzerinde kapladığı alan modelin tflite dosya boyutundan farklı olabilir. Bu paket girdinin ve çıktının bellekte kapladığı alan, çıkarım (inference) sırasında kullanılacak bellek alanı gibi parametrelerle beraber gerekli fonksiyonları tanımlar. Çıkarım sırasında gerekli ara değerleri saklamak için harici SDRAM üzerinde aktivasyon dizisi (buffer) adı verilen bir alan ayrılmıştır. Aynı zamanda görüntülere ön işlem uygulanması için üç farklı dizi de SDRAM üzerinde ayrılmıştır. Bu diziler LCD üzerinde görüntüleri göstermek, UART üzerinden gelen RGB888 formatındaki görüntüyü saklamak ve RGB888 formatını modelin kabul ettiği kayan nokta veri tipine dönüştürünce oluşan verileri tutmak amacıyla oluşturulmuştur. Belirtilen bütün bu işlemler için öncelikle yaklaşık saniyede bir kesme üreten bir zamanlayıcı kesmesi (timer interrupt) ayarlanmıştır. Burada yapılan işlemler şu şekildedir. Mikrodenetleyici bilgisayardan görüntü talebinde bulunur. Aktarılan görüntü, belirtilen RGB888 dizisine yazılır. Sonrasında LCD üzerinde bu görüntüyü göstermek amacıyla DMA2D tarafından ARGB8888 formatında LCD dizisine (buffer) yazılır. RGB888 dizisindeki her değer 255 sayısına bölünerek, kayan nokta tipinde ilgili SDRAM adresine yazılır. Böylece ön işlem bitmiş olur. X-CUBE-AI üzerindeki çıkarım fonksiyonuna ise SDRAM üzerinde kayan nokta veri tipinde tutulan dizinin adresi verilmiştir. Fonksiyon ise çıktı olarak 0 ve 1 arasında bir kayan nokta değeri önceden belirtilen adrese yazar. Son olarak bu değer LCD ekran üzerine

yazılır. Burada belirtmek gerekir ki çekirdekteki MPU birimi harici SDRAM için doğru şekilde kurulması gerekmektedir. Aksi takdirde çıkarım süresi olumsuz etkilenebilmektedir.

IV. DENEYLER

Bu bölümde belirli bir bölgedeki Akdeniz meyve sineği yoğunluğunu bulmak için önerilen gömülü sistem yapısı ve üzerinde çalışan derin öğrenme modelinin başarılarını incelenmiştir. Bunun için ilk olarak, deneysel sonuçların elde edildiği veri seti hakkında bilgi verilmiştir. İkinci olarak da önerilen CNN yapısı ile Akdeniz meyve sineği tespit başarımı verilmiştir. Son olarak, CNN yapısının üzerinde çalıştığı gömülü sistemin kullanım özellikleri verilmiştir.

A. Veri Seti

Literatürde verilen çalışmalarda ve genel olarak internet üzerinde Akdeniz meyve sineği imgelerini içeren standart bir veri tabanı bulunmamaktadır. Bu sineklerin yılın yalnızca belli dönemleri aktif olması ve her meyve için farklı zamanlarda etkili olması nedeni ile, istenildiği zamanda bir veri seti oluşturmak da mümkün değildir. Bu zorluklara rağmen, Çukurova Üniversitesi aracılığı ile çiftçilerden tuzak üzerinde yakalanmış Akdeniz meyve sineği görüntüleri elde edilmiştir. Bu görüntüler çoğunlukla farklı cep telefonu kameraları ile elde edilmiş ve sabit olmayan uzaklıklardan elde edilmiştir. Bütün bu değişimleri en aza indirmek için eldeki görüntülerden 59 tanesi bu çalışmada kullanılmıştır. Örnek bir görüntü Şekil 1'de verilmiştir. Bu görüntüde sarı renkli Akdeniz meyve sinekleri, bir kara sinek ve kırmızı feromon maddesi bulunan bir tuzak kartı bulunmaktadır. Tuzak kartı yapısı gereği karelidir.



Şekil 1. Örnek tuzak kartı ve üzerinde yakalanmış Akdeniz meyve sinekleri.

Deneylede kullanılacak olan 56×56 boyutundaki sinek içeren görüntü parçaları tuzağa yakalanan sinekler kullanılarak oluşturulurken, sinek olmayan görüntü parçaları tuzaktaki arka plan öğeleri kullanılarak oluşturulmuştur. Görüntülerde sineklerin çok sık olması sebebiyle kısıtlı sayıda arka plan imgesi elde edilebilmiştir. Bu nedenle, tuzaklarındaki arka plan görüntüleri, ± 40 derece döndürme, yatay ve dikey simetri yöntemleri ile çoğaltılmıştır. Bu sayede 441 adet olan görüntü parçası sayısı 2742'ye çıkartılmıştır. Eldeki veri seti eğitim ve validasyon olmak üzere iki farklı parçaya ayrılmıştır. Eğitim seti 2170 adet sinek, 2742 adet sinek olmayan görüntü parçasından oluşmaktadır. Validasyon seti 340 adet sinek görüntü parçası ve 330 adet sinek olmayan görüntü parçasından oluşmaktadır.

B. Akdeniz Meyve Sineği Tespit Başarımı

Geliştirilmiş olan CNN yapısının gömülü sistem üzerine yüklenmesi ile oluşturulan akıllı tuzak bir önceki veri seti ile denenmiştir. Bunun için önceki bölümde özetlendiği şekilde görüntüler parça parça bilgisayardan gömülü sisteme aktarılmıştır. Her görüntü parçası sınıflandırıldıktan sonra, sınıflandırma sonucu gömülü sistemden bilgisayara aktarılmıştır. Elde edilen başarımların bu bölümde iki şekilde verdik. İlk olarak tespit başarımını verirken STM 32F746GDISCOVERY geliştirme kartının LCD biriminden yararlandık ve örnek tespit sonucunu Şekil 2’de verdik.



Şekil 2. STM 32F746GDISCOVERY geliştirme kartı üzerinde örnek sonuç.

Şekil 2’den görülebileceği üzere içinde sinek bulunan pencere CNN modeli sayesinde yüksek güvenilirlikle sinek olarak sınıflandırılmıştır. İkinci olarak tespit başarımının tüm test seti üzerinde elde edilmesi irdelenmiştir. Bunun için oluşturulan deney düzeneği üzerinde Akdeniz meyve sineği tespit sonuçları şu şekildedir. Eldeki test verisinde bulunan 340 Akdeniz meyve sineği görüntü parçasından 292 adedi doğru olarak tespit edilmiştir. Arkaplan olarak adlandıracağımız 330 tuzak görüntüsü veya diğer böcekleri içeren görüntü parçalarından 35 adedi geliştirilmiş olan sistem tarafından Akdeniz meyve sineği olarak adlandırılmıştır. Sonuçlardan görülebileceği üzere, sistemin sinek tespit performansı %85,55 düzeyindedir. Arka plan tespit performansı ise %89,39 seviyesindedir. Bu başarımların değerleri kısıtlı hafıza alanına sahip bir gömülü sistem üzerinden elde edildiği için, oldukça iyidir. Belirli bir tuzak kartı üzerinde bulunan sinek sayısını elde etmek için kayan pencere uygulaması ile tüm kart imgesi taranabilir. Zira tarafta, bu sayının belirli bir zarar eşliğini aşması durumunda pestisit kullanımı yapılması gerekmektedir.

C. Gömülü Sistem Kullanım Özellikleri

Bu çalışmada ana amaç gömülü sistem üzerinde CNN yapısının gerçekleştirilmesi olduğu için, prototip olarak oluşturulmuş olan sistemde detaylı kullanım bilgileri bu bölümde verilmiştir. Önerilen prototip sistemde STM32F746NG mikrodenetleyicisi üzerindeki 320 KB olan dahili RAM alanının yaklaşık 215 KB kadarı kullanılmıştır. Burada genellikle modelin ağırlık ve bias değerleri tutulmuştur. STM 32F746GDISCOVERY geliştirme kartı üzerinde bulunan 8 MB olan harici SDRAM’dan ise 1.21 MB kadarı kullanılmıştır. Burada görüntü dizileri (array) ve çıkarım sırasında oluşan ara değerler saklanmıştır. Sistemde STM32F746NG mikrodenetleyicisi üzerindeki 1 MB dahili flash belleğin yaklaşık 727 KB kadarı kullanılmıştır. Burada model yaklaşık olarak 640 KB yer kaplamaktadır. Geri kalan kısmı ise kod tarafından kullanılmıştır. Sistem gerçekleştirilmesi aşamasında STM32F746NG mikrodenetleyicisinin çekirdek hızı 216 MHz olarak ayarlanmıştır. Çıkarım süresini ölçmek için 1 milisaniye hassasiyetinde ayarlanan systick zamanlayıcı kullanılmıştır. Buradan ölçülen değere göre CNN modelinden bir imge için sonuç çıkarımı yaklaşık 170 milisaniye sürmektedir.

V. SONUÇLAR

Zararlılarla mücadele tarımsal uygulamalarda olmazsa olmazlardandır. Bu çalışmada Akdeniz meyve sineği tespiti ve sayısının bulunabilmesi için akıllı bir tuzak geliştirilmiştir. Bu tuzak Arm Cortex M7 mimarisine sahip STM32F746NG mikrodenetleyicisi barındırmaktadır. Bu mikrodenetleyici üzerinde probleme özel olarak oluşturulmuş CNN modeli çalışmaktadır. Burada önemli hususlardan birisi mikrodenetleyicinin hafıza sınırlarını göz önüne alarak tüm tasarımı yapılmış olmasıdır. İkinci önemli husus ise, düşük enerji tüketimli Arm mikrodenetleyicisinin tüm sistemi kendi başına bir pil veya enerji hasadı modülü yardımı ile uzun süre çalışabilir halde tutmasıdır. Önerilen sistem şu aşamada prototip durumdadır. Ancak, gömülü kamera kullanımı, probleme özgün enerji hasadı yapısının sisteme eklenmesi ve tüm sistemi içerecek bir şekilde baskı devre kartının oluşturulması sayesinde prototip seviyesinden ilk üretim aşamasına geçebilme potansiyeline sahiptir. Yapılan deneysel çalışmalar sonucunda elde edilen tespit başarımı ve gömülü sistem kaynak kullanımı başarımları ile çalışan bir sistemin gerçekleştirilmesinin mümkün olduğunu göstermektedir.

KAYNAKLAR

- [1] A. Segalla, G. Fiacco, L. Tramarin, M. Nardello, and D. Brunelli, “Neural networks for pest detection in precision agriculture,” in *2020 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)*, 2020, pp. 7–12.
- [2] V. A. M. Martins, L. C. Freitas, M. S. de Aguiar, L. B. de Brisolar, and P. R. Ferreira, “Deep learning applied to the identification of fruit fly in intelligent traps,” in *2019 IX Brazilian Symposium on Computing Systems Engineering (SBESC)*, 2019, pp. 1–8.
- [3] B. Shaked, A. Amore, C. Ioannou, F. Valdés, B. Alorda, S. Papanastasiou, E. Goldshtein, C. Shenderey, M. Leza, C. Pontikakos, D. Perdakis, T. Tsiligriris, M. R. Tabilio, A. Sciarretta, C. Barceló, C. Athanassiou, M. A. Miranda, V. Alchanatis, N. Papadopoulos, and D. Nestel, “Electronic traps for detection and population monitoring of adult fruit flies (diptera: Tephritidae),” *Journal of Applied Entomology*, vol. 142, no. 1-2, pp. 43–51, 2018.
- [4] Y. Zhong, J. Gao, Q. Lei, and Y. Zhou, “A vision-based counting and recognition system for flying insects in intelligent agriculture,” *Sensors*, vol. 18, no. 5, 2018.
- [5] M. Preti, F. Verheggen, and S. Angeli, “Insect pest monitoring with camera-equipped traps: strengths and limitations,” *J Pest Sci*, vol. 94, p. 203–217, 2021.
- [6] M. Cardim Ferreira Lima, M. E. Damascena de Almeida Leandro, C. Valero, L. C. Pereira Coronel, and C. O. Gonçalves Bazzo, “Automatic detection and monitoring of insect pests—a review,” *Agriculture*, vol. 10, no. 5, 2020.
- [7] M. Martineau, D. Conte, R. Raveaux, I. Arnault, D. Munier, and G. Venturini, “A survey on image-based insect classification,” *Pattern Recognition*, vol. 65, pp. 273–284, 2017.
- [8] P. Tirelli, N. A. Borghese, F. Pedersini, G. Galassi, and R. Oberti, “Automatic monitoring of pest insects traps by zigbee-based wireless networking of image sensors,” in *2011 IEEE International Instrumentation and Measurement Technology Conference*, 2011, pp. 1–5.
- [9] O. López, M. M. Rach, H. Migallon, M. P. Malumbres, A. Bonastre, and J. J. Serrano, “Monitoring pest insect traps by means of low-power image sensor technologies,” *Sensors*, vol. 12, no. 11, p. 15801–15819, 2012.
- [10] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, “Squeezenet: Alexnet-level accuracy with 50x fewer parameters and <0.5 MB model size,” 2016.
- [11] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. We- yand, M. Andreetto, and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” 2017.