

TARIMSAL SENSÖR VERİLERİ KULLANILARAK BİTKİ HASTALIKLARININ ERKEN TESPİTİ İÇİN LSTM TABANLI DERİN ÖĞRENME MODELİ

Elif GENÇ^{1*}, Cem BAĞLUM², Osman ÇAĞLAR³, Yusuf KARTAL⁴, Erol SEKE⁵, Kemal ÖZKAN⁶

^{1,2,3,4,6} Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği, Eskişehir

⁵ Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği, Eskişehir

¹ ORCID No: <https://orcid.org/0009-0008-0889-9192>

² ORCID No: <https://orcid.org/0000-0001-9072-3664>

³ ORCID No: <https://orcid.org/0009-0000-2837-0861>

⁴ ORCID No: <https://orcid.org/0000-0002-0402-1701>

⁵ ORCID No: <https://orcid.org/0000-0002-4860-7130>

⁶ ORCID No: <https://orcid.org/0000-0003-2252-2128>

Anahtar Kelimeler	Öz
Bitki hastalıkları Erken Tespit Toprak Sensörleri LSTM Salatalık	<i>Bitki hastalıklarının güvenilir ve zamanında tanımlanması modern tarımda çok önemli bir zorluktur. Geleneksel yöntemler gözle görülür semptomların manuel olarak gözlemlenmesine dayanır. Görünür semptomlar, enfeksiyonun orta veya geç aşamalarında ortaya çıkma eğilimindedir; bu da yayılma veya verim azalması olasılığını artırır. Bitki hastalıkları gözle görülebilir hale geldikten sonra hastalık bulaşmış olmakta ve tedavi için geç kalınmış olmaktadır. Bu sebeplerden dolayı bitki hastalıklarının gözle görülmeden önce tespit edilebilmesi için daha düşük maliyetli olan çözümlere ihtiyaç vardır. Bu çalışmada, serada yetiştirilen hıyar bitkilerinde ortaya çıkabilecek virüs etkilerinin derin öğrenme ve yapay zeka uygulamaları yardımıyla erken dönemde tespit edilmesi hedeflenmiştir. Bu amaçla bitki hastalıklarının erken tespiti için LSTM tabanlı bir derin öğrenme modeli önerilmiştir. Bu modelde kullanılan veriler için, hastalık inoküle edilen ve sağlıklı bitkilerin bulunduğu iklim odaları kurulmuştur ve toprak sensörleri kullanılarak hıyar bitkisinden zamansal veriler toplanmıştır. Daha sonra veri hazırlama süreci içerisinde verilerin temizlenmesi, öz niteliklerinin çıkarılması ve etiketleme gibi işlemler yapılmıştır. Eğitim aşamasından sonra model, tarımsal sensörlerden gelen zaman serisi verilerini analiz ederek anomali tespiti yapabilmekte, bu sayede bitki hastalıklarının görsel belirtileri ortaya çıkmadan hastalıklı olduklarını söylemektedir. Modelin performansını değerlendirmek için doğruluk, sınıflandırma raporu, karışıklık matrisi gibi metrikler kullanılmıştır. Elde edilen sonuçlar oldukça başarılı; model %99.95 doğruluk sağlamış ve anomali tespiti konusunda yüksek başarı göstermiştir. Yapılan çalışma sonucunda bitki hastalıklarının erken tespiti ile minimum zirai ilaçlama ile maliyet düşürücü tedbirler en üst seviyede alınabilecek insan ve çevre maksimum seviyede korunmuş olacaktır.</i>

CROP DISEASES USING AGRICULTURAL SENSOR DATA LSTM-BASED DEEP LEARNING MODEL FOR EARLY DETECTION

Keywords	Abstract
Plant Diseases Early Detection Agricultural Sensors LSTM Cucumber	<i>Reliable and timely identification of plant diseases is a crucial challenge in modern agriculture. Traditional methods rely on manual observation of visible symptoms. Visible symptoms tend to appear in the middle or late stages of infection, which increases the likelihood of spread or yield reduction. Once plant diseases become visibly detectable, the infection has already occurred, and it may be too late for effective treatment. Therefore, cost-effective solutions are needed to detect plant diseases before they become visually apparent. This study aims to detect the effects of viruses on cucumber plants grown in greenhouses at an early stage using deep learning and artificial intelligence applications. For this purpose, an LSTM-based deep learning model for early detection of plant diseases is proposed. To collect data for the model, climate chambers housing both diseased and healthy plants were established, and temporal data were gathered from cucumber plants using soil sensors. During the data preparation process, steps such as data cleaning, feature extraction, and labeling were performed. After the training phase, the model can analyze time-series data from</i>



Bu eser, Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>) hükümlerine göre açık erişimli bir makaledir.

This is an open access article under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

agricultural sensors to detect anomalies, identifying diseased plants before visual symptoms appear. Metrics such as accuracy, classification report and confusion matrix were used to evaluate the performance of the model. The results obtained are quite successful; the model achieved 99.95% accuracy and showed high success in anomaly detection. As a result of the study, with the early detection of plant diseases, cost-reducing measures can be taken at the highest level with minimum pesticides, and humans and the environment will be protected at the maximum level.

Araştırma Makalesi

Başvuru Tarihi : 06.08.2024

Kabul Tarihi : 05.03.2025

Research Article

Submission Date : 06.08.2024

Accepted Date : 05.03.2025

* Sorumlu yazar: eelfgnc@gmail.com

<https://doi.org/10.31796/ogummf.1529025>

1. Giriş

Tarım sektörü, dünya nüfusunun beslenme gereksinimlerini karşılamak için vazgeçilmez bir rol oynar. Ancak, bitki hastalıkları tarımsal üretimde önemli bir tehdit oluşturarak verim kaybına, kalite düşüşüne ve ekonomik zararlara yol açar (Akbaş, 2019). Bu durum, sürdürülebilir tarım uygulamalarının gerekliliğini ve bitki sağlığının korunmasının kritik önemini gözler önüne sermektedir. Bitki hastalıklarının erken teşhisi ve etkin yönetimi, sadece tarımsal üretimin sürekliliğini sağlamakla kalmaz, aynı zamanda ekosistem dengelerini koruyarak gıda güvenliğine de katkıda bulunur (Kelman, Pelczar, Pelczar ve Shurtleff, 2023). Son yıllarda, makine öğrenimi ve derin öğrenme tekniklerinin hızla gelişmesi, bitki hastalıklarının tespiti ve yönetiminde devrim niteliğinde ilerlemeler kaydedilmesini sağlamıştır (Patel, 2023; Jackulin ve Murugavalli, 2022). Bu teknolojiler, hastalıkların erken evrede tespit edilmesine olanak tanıyarak kimyasal ilaç kullanımını minimize etmekte ve daha sürdürülebilir tarım uygulamalarını teşvik etmektedir (Bischoff, Farias, Menzen ve Pessin, 2021). Çoğu durumda bitki hastalığı salgınlarıyla başa çıkmak için hastalıkların klasik yöntemlerle önceden tespit edilmesi zorlu bir problemidir. Bu nedenle, bir bitkinin sağlıklı olup olmadığını veya hangi hastalığa sahip olduğunu belirlemek için çiftçiler için otomatik bir bitki hastalık tanıma sistemi önemlidir. Son zamanlarda bilgisayarlar, kameralar (RGB, 3D, termal, yakın kızıl ötesi, multi ve hiper spektral kamera vb.) ve görüntü işleme / yapay zeka tekniklerindeki gelişmeler ile birlikte bir bitkinin hastalığını teşhis etmek için pek çok araştırma yapılmıştır (Abade, Ferreira ve Vidal, 2021; Barbedo, 2016). Bilgisayarlı görme ve yapay zekanın gelişmesiyle birlikte, birçok derin öğrenme yöntemi bitki hastalıklarının tanınmasında uygulamalar bulmuştur.

Ancak yapılan çalışmaların birçoğunda görüntü işleme teknikleri kullanılmaktadır. Bu durum ise hastalık belirtilerin ortaya çıktıktan sonra tespit edilebilmesi gibi sorunları ortaya çıkarmaktadır. Şöyle ki bitki hastalıkları gözle görülebilir hale geldikten sonra hastalık bulaşmış olmakta ve tedavi için geç kalınmış

olmaktadır. Bu problemin önüne geçilebilmesi adına hiper ve / veya multi spektral kameralar kullanmak mümkündür. Ancak görünür ışık dalga boyu dışında ölçümler alabilen ve daha detaylı bilgi sunan bu tür yüksek çözünürlüklü algılayıcıların hem maliyeti yüksek olmakta hem de ölçümlerin alınması sırasında örtüşme problemi, ortamdaki ışık faktörleri ve en önemlisi de örneklemenin tüm sahada yapılamaması gibi halen çözülmesi gereken problemleri içermektedir. Bu sebeplerden dolayı bitki hastalıklarının gözle görülmeden önce tespit edilebilmesi için daha düşük maliyetli olan çözümlere ihtiyaç vardır. Bu amaçla bu çalışmada, toprak sensör verilerini kullanarak bitki hastalıklarını erken tespit etmek amacıyla LSTM (Long Short-Term Memory) tabanlı bir derin öğrenme modeli önerilmiştir. LSTM, özellikle uzun süreli bağımlılıkları öğrenmede etkili olan bir tür tekrarlayan sinir ağıdır. Geliştirilen model, sıcaklık, pH, iletkenlik ve nem gibi zaman serisi verilerini analiz ederek anomali (bitki hastalıkları) tespiti yapmaktadır. Önerilen yöntem, verilerin geçmiş değerlerini kullanarak gelecekteki olası anormallikleri tahmin etmeye yönelik olarak tasarlanmış ve gerçek saha koşullarında uygulanmıştır.

2. Bilimsel Yazın Taraması

Ürünlerin uzmanlar tarafından görsel olarak değerlendirilmesi, bitki hastalıklarının tespiti ve teşhisi için en sık kullanılan yöntemdir. Öte yandan, bitki patojenlerinin insan gözü semptomları algılamadan önce tespit edilmesi, etkili bir hastalık kontrol stratejisinin zamanında uygulanmasında çok önemli olmaktadır (Cohen, Edan, Levi ve Alchanatis, 2022). Bitkilerde yaprak morfolojisi ve renginde değişiklikler olarak belirgin semptomlar gelişir; ancak görsel bir teşhis yapıldığında, patojenin konakçı popülasyonlarında iyi bir şekilde yerleşmiş olması muhtemeldir ve bu durumda hastalığın tedavisi için geç kalınması muhtemeldir. Bu nedenle, belirgin semptomlar göstermeyen gizli enfeksiyon bilgisinin bilinçli ve etkili bir hastalık yönetimi sağlamada anahtar rol olabileceğini yazarlar bildirmişlerdir (Dyussebayev ve diğ., 2021). Hiperspektral görüntüleme ve yüksek çözünürlüklü spektrometri gibi

uzaktan algılama yaklaşımlarının, patojen saldırısı değişiklikleri tespit edebildiği gösterilmiştir (Thomas ve diğ., 2024). Bu nedenle, hassas tarım bağlamında bitki hastalıklarını zamanında tespit etmek ve erken ürün koruma önlemleri uygulamak mümkündür (Thomas ve diğ., 2024; Terentev, Dolzhenko, Fedotov ve Eremenko, 2022). Örneğin, Mohanty, Hughes ve Salathé (2016), akıllı telefon destekli hastalık teşhisi yapmıştır. Kontrollü koşullarda toplanan 54.306 bitki yaprağı görüntüsünü kullanarak 14 mahsul türü ve 26 hastalığı tanımlayan derin öğrenme modeli %99.35 doğruluk oranına ulaşmıştır. Nguyen ve diğ. (2021), 400-1000 nm hiperspektral sensörle elde edilen görüntüler üzerinde sınıflandırma yapmışlardır. Sağlıklı ve hastalıklı bitkilerin yansıma spektrumlarını ayırt etmek için istatistiksel yöntemler kullanmış ve hastalık merkezli bitki indeksleri oluşturmuşlardır. Derin öğrenme ve geleneksel makine öğrenme yöntemleri ile piksel ve görüntü bazlı sınıflandırmalar gerçekleştirmişlerdir. Bir diğer çalışmada ise Abdu, Mokji ve Sheikh, hassas tarımda bitki hastalıklarının görüntü tabanlı tespiti için kullanılan destek vektör makineleri (DVM) ve derin öğrenme (DL) modellerinin karşılaştırmalı bir analizini sunmaktadır. Bitki hastalıklarının %70-80'i patojenlerden kaynaklanmakta olup, bunların %60-70'i yapraklarda görülmektedir. Çalışmada, geniş bir bitki yaprağı hastalık görüntü veri seti kullanılarak, her iki modelin performansı, mimarisi, hesaplama gücü ve eğitim verisi miktarı gibi faktörler göz önünde bulundurularak karşılaştırılmıştır. Ferentinos (2018) ise, bitki hastalıklarının tespiti ve teşhisi için yaprak görüntüleri kullanarak derin öğrenme yöntemleriyle evrimsel sinir ağı (ESA) modelleri geliştirmiştir. Modeller, 87.848 görüntüden oluşan ve 25 farklı bitkiyi kapsayan, 58 farklı bitki, hastalık kombinasyonunu içeren açık bir veri tabanı ile eğitilmiştir. En iyi performansa sahip model, ilgili bitki, hastalık kombinasyonunu (veya sağlıklı bitkiyi) %99.53 başarı oranıyla tanımlamıştır. Radovanović ve Đukanović (2020), bitkilerde hastalık tespiti amacıyla bitki hastalıkları içeren imgeleri derin öğrenme yaklaşımının klasik makine öğrenme algoritmalarıyla karşılaştırmasını sunmaktadır. Yazarlar yaptıkları karşılaştırma sonucunda DVM, k-en yakın komşuluk, tam bağlamli sinir ağı ve ESA modellerinin sırasıyla 0.894, 0.72, 0.892 ve 0.99 F1 skorları raporlamışlardır. Chin, Ng ve Palanichamy (2024) tarafından yapılan çalışma, YOLOv8 modelini kullanarak bitki hastalıklarının tespit ve sınıflandırılmasını incelemiştir. YOLOv8, nesne tespiti için hızlı ve doğru sonuçlar veren bir derin öğrenme modelidir. Çalışmada, YOLOv8 modeli dikkat mekanizması yaklaşımıyla entegre edilmiştir. Bu entegrasyon, modelin doğruluğunu artırırken hesaplama maliyetini düşürmeyi amaçlamaktadır. Araştırma sonucunda, YOLOv8s modeli ile %72.2 doğruluk elde edilmiştir. Smetanin,

sırasında bitkilerin metabolizmasındaki ince Uzhinskiy, Ososkov, Goncharov ve Nechaevskiy (2021) tarafından geliştirilen çalışma, derin öğrenme ve transfer öğrenme tekniklerini kullanarak bitki hastalıklarının tespitini incelemiştir. Çalışmada, MobileNetV2 ile transfer öğrenme ve üçlü kayıp (triplet loss) fonksiyonu kullanılarak eğitilmiş bir görüntü sınıflandırma modeli kullanılmıştır. Model, %98 sınıflandırma doğruluğuna ulaşmıştır.

Bitki hastalıkları, zamanla değişen olgular olduğu için derin öğrenme modelleri arasında son yıllarda sıklıkla kullanılan LSTM modelleri zamansal veri analizi için uygun bir çözüm olarak ortaya çıkmaktadır. Örneğin, Pattle ve diğ. (2022), yaptıkları çalışmada LSTM ağı kullanarak bitki hastalıklarının tahmini için akıllı sensör sisteminin saha değerlendirmesini yapmış ve %96 doğruluk oranı elde ettiklerini raporlamışlardır. Benzer şekilde, mısır yaprağındaki hastalıkların tahmini için LSTM modelinin kullanıldığı bir başka çalışma Ashwini ve Sellam tarafından yapılmıştır. Bu çalışma, %90'ın üzerinde bir başarı oranıyla hastalıkları tespit edebildiklerini göstermektedir (Ashwini ve Sellam, 2024).

Bununla birlikte, hiperspektral görüntüleyiciler ve yüksek çözünürlüklü spektrometreler hala maliyetlidir ve hiperspektral görüntüleme durumunda büyük miktarda çok boyutlu verinin işlenmesi karmaşık olmaya devam etmektedir. Gerçek saha ortamında bu tür geniş spektrumlu kameraların maliyetinin fazla olması nedeniyle şu an ki teknolojik duruma göre ticari uygulamalarda (özellikle küçük ve orta büyüklükte seralarda) kullanılması ekonomik ve kullanışlı değildir. Ayrıca bu tür kameraların maliyetinin fazla olması nedeniyle sahanın her tarafında konumlandırılması mümkün olmayıp sahanın her tarafını örneklemesi sağlanamamaktadır. Bu tür kameraların konumlandırılmış olduğu ve çekim alabildiği alan dışındaki bir koordinatta oluşabilecek hastalıkları tespit edebilmesi mümkün değildir. Seranın her tarafından örnek alınabilmesi için bu tür algılayıcıların seranın tüm bölgelerine taşınması ve örnek görüntülerin alınması gerekmektedir. Son zamanlarda otomatik robot, dron vb. yöntemler ile taşınma işlemi veya bir kişinin taşınması ile mümkün olabilmektedir. Ancak robot, dron vb. sistemlerle taşınması sera ortamı düşünüldüğü zaman şu an için gerçek saha uygulamaların da kullanışlı değildir. İnsan tarafından taşınma işi ise insana bağımlı olduğu için alınan örneklerin doğruluk problemini ortaya çıkardığı gibi zaman ve maliyet olarak yine gerçek saha uygulamalarında gerçekçi bir çözüm değildir. Bu tür geniş spektrumlu kameraların şu an sadece laboratuvar ortamlarında veya kontrollü ortamlarda kullanılması mümkündür.

3. Yöntem


Derin öğrenmeye dayalı mevcut bitki hastalığı tanıma yöntemi, derin ağlar oluşturarak özellikleri otomatik olarak öğrenebilir (Thakur, Khanna, Sheorey ve Ojha, 2022; Gao, Wang, Lu, Li ve Wu, 2021; Shin ve diğ., 2021). Bu, özellik çıkarma işleminde manuel müdahale gerektiren geleneksel yapay görme teknolojisine göre otomatik sorununu etkili bir şekilde çözmektedir. Bununla birlikte, derin öğrenmeye dayalı yöntemler, eğitim veri setinin boyutuna yüksek oranda bağımlıdır (Jadon, 2020; Argüeso vd., 2020). Aynı zamanda, karmaşık uygulama senaryoları ve yüksek veri etiketleme maliyeti nedeniyle tarımsal alanda büyük miktarda yüksek kaliteli etiketli veri elde etmek zordur. Veri eksikliği, tarımsal otomatik tanımlama sürecinin gelişimini de sınırlamaktadır (Lu, Chen, Olaniyi ve Huang, 2022; Sharma, Tripathi ve Mittal, 2022). Hastalıklı veriyi toplamak hemen hemen tüm çalışmaların karşılaştığı en büyük sorundur. Hastalıklı veri toplamak için ürünün izlenmesi ve hastalığın ortaya çıkmasının beklenmesi gerekmektedir. Bu süreç her zaman can sıkıcı olmuştur. Çoğu zaman sağlıklı veri kadar hastalıklı veri toplanamamakta ve toplanan veriler uzmanlar tarafından doğru olarak etiketlenememektedir. Bunun temel sebebi her ürün için farklı çok sayıda hastalık olması, hastalık belirtilerin çoğu zaman birbirine benzer olması, hastalığın ortaya çıkma süresinin uzun olması, hastalığı etiketleyecek uzmanların yeterli sayıda olmaması vb. sayılabilir. Bu çalışmada örnek uygulama ürünü olarak örtü altı yetiştiricilik uygulamalarıyla yıl boyu yetiştirilebilen kabakgiller familyasından tek yıllık bitki olan hıyar tercih edilmiştir. Çalışma kapsamında birbirinden izole ve farklı alanlarda birbirinin ikizi iki üretim hattı oluşturulmuştur.



Şekil 1. Birbirinin ikizi Üretim Hatları

Her bir üretim hattında bitkiler 4 litre hacme sahip torf içeren tekli saksılarda yetiştirilmiştir. İlk üretim ortamında sağlıklı ürün üretilmiştir (Şekil 1. a). Sağlıklı hıyarda önemli verim ve kalite kayıplarına neden olan Cucumber mosaic virüs hastalıklı odada bulunan saksılardaki bitkilere bulaştırılmıştır (Şekil 1b). Her bir saksıda sıcaklık, pH, iletkenlik ve nem değerleri Cucumber mosaic virüs bulaştırıldığı zamandan itibaren hem sağlıklı hem de hastalık bulaştırılmış bitkilerden her beş dakikada bir toplanmıştır. Veri toplama işlemi bahse konu olan virüse ait belirtilerin yapraklarda görülmesine kadar devam etmiştir.

Sağlıklı üretim yapılan ortamın ikizinde ise yapay hastalıklandırma sayesinde ürünün hangi hastalığa uğradığı bilindiği için etiketleme (hastalıklı olup olmadığının tespiti) işlemine gerek kalmamıştır. Ayrıca ürünün ilk dikiminden hastalık belirtisi olasıya kadar geçen sürede algılayıcılarla izlenmesi mümkün olmuştur. Böylece çoğu çalışmada hastalık belirtisine göre çalışan sistemlerin aksine baştan itibaren izlenen hastalıklı üründen elde edilen veriler analiz edilerek hastalık belirtisi ortaya çıkmadan tespit edilebilmesi için gerekli çalışmaların / analizlerin yapılması mümkün hale gelmiştir.



Şekil 2. Hastalıklı ve Sağlıklı Bitkilere Ait Sensör Verileri

Veri seti, topraktan alınan sıcaklık, pH, iletkenlik ve nem ölçümlerini içermektedir. Bu ölçümler, sıcaklık, pH, iletkenlik ve nem bilgilerini aynı anda ölçebilen bir toprak sensörü kullanılarak toplanmıştır. Sensörlerinden alınan bilgilerin iş istasyonu üzerindeki veri tabanına kaydedilmesi için öncelikle LoRaWAN ağı oluşturulmuştur.

Toprak sensörleri, LoRaWAN ağına radyo frekansları aracılığıyla bağlanabilmek için bir modül ile donatılmıştır. Bu modül, sensörlere kablo ile bağlanarak verilerin LoRaWAN ağına iletilmesini sağlamaktadır. LoRaWAN ağına gelen bilgiler, benzersiz cihaz kimlik bilgileri (cihaz ID) ile LoRa sunucularına aktarılmakta ve ardından iş istasyonu üzerinde koştan PostgreSQL veri tabanına kaydedilmektedir. Verilerin toplanması ve işlenmesi için Java programlama dili ile geliştirilmiş web tabanlı bir uygulama yer almaktadır. Veri seti, 2024 yılı Mayıs ve Haziran ayları arasında kaydedilen sıcaklık, pH, iletkenlik ve nem ölçümlerini içermektedir. Toprak sensöründen elde edilen verilerin ham hali örnek olması açısından Şekil 2’de resmedilmiştir. Veriler, belirli zaman aralıklarında kaydedilerek zaman serisi formatında sunulmuştur. Hastalık belirtilerin görsel olarak tespit edilebilmesi amacıyla her ürün kameralarla izlenmiş ve aynı toprak sensörlerinde olduğu gibi her beş dakikada yakalanan görüntüler zaman damgasıyla birlikte veri tabanına kaydedilmiştir. Şekil 3’te hastalık inoküle edilmiş bitkilere ait örnek fotoğraflar gösterilmektedir.



Şekil 3. Hastalık İnoküle Edilmiş Bitki Örnekleri

Ön işlemler kapsamında, zaman damgaları kontrol edilerek veri seti zaman serisi analizine uygun hale getirilmiştir. Elde edilen veriler, modelin daha hızlı ve stabil öğrenmesini sağlamak için standart hale getirmek ve normalize edilmesi amacıyla scikit-learn kütüphanesindeki StandardScaler¹ kullanılmıştır. StandardScaler aykırı değerlere karşı duyarlıdır ve aykırı değerlerin varlığında özellikler birbirinden farklı ölçeklenebilir. Ayrıca, veriler belirli bir zaman adımı kullanılarak sekanslar halinde düzenlenmiş ve anomalilerin tespiti için etiketlenmiştir. Verilerin etiketlenmesi aşamasında, görsel olarak sunulan veri setinde bitki üzerinde virüs görünümünün tespit edildiği tarih baz alınarak, veri seti içerisindeki


verilerde ilgili tarihten itibaren sunulan veriler virüslü olarak etiketlenmiştir.

Ön işlemde geçirilmiş sıcaklık, pH, iletkenlik ve nem zaman serisi verilerini analiz etmek amacıyla bu çalışmadaki problem ve girdi verilerine en uygun olan derin öğrenme mimarisi olan LSTM tercih edilmiştir. LSTM birimi, tekrarlanan modüllerde hiçbir etkinleştirme işlevini kullanmamasından dolayı uzun veya kısa zaman periyotlarını hatırlar. Dolayısıyla, depolanan değer yinelemeli olarak değiştirilmez. Yalnızca anlık veriyi (resim gibi) değil, veri dizilerini (konuşma ve video gibi) de işleyebilir. Örneğin Fischer ve Krauss (2018) karmaşık ve dinamik piyasa veriler finansal zaman serisi tahmininde LSTM modellerinin kullanılabilirliğini göstermişlerdir. Bununla birlikte doğal dil işleme alanında, metin verilerinin dil modellerini oluşturmak ve dil çevirisi gibi uygulamalarda LSTM modelleri etkin bir şekilde kullanılmaktadır (Sutskever, Vinyals ve Le, 2014). Ayrıca, medikal zaman serisi analizinde, LSTM modelleri kalp atış hızı veya EEG sinyalleri gibi biyomedikal sinyallerin analizinde kullanılmakta ve hastalık teşhisinde önemli roller oynamaktadır. Lipton, Kale, Elkan ve Wetzel (2015), LSTM modellerinin geniş bir uygulama yelpazesine sahip olduğunu ve çeşitli zaman serisi verilerinde başarılı sonuçlar verdiğini göstermektedir. Bu çalışma kapsamında elde edilen veriler sürekli zamanda (her ne kadar beş dakikada bir veri toplanmış olsa da bitkilerdeki değişimlerin beş dakikalık periyotta fazla değişmeyeceği kabullenmesi ile sürekli zaman serisi olarak ele alınabilir) elde edilmesinden dolayı LSTM mimarisi için uygundur. Çalışmada, zaman serisi veri yapısının oluşturulması için veriler belirli bir zaman adımı kullanılarak sekanslar halinde düzenlenmiştir. Bu sayede model, geçmiş bilgileri kullanarak tahmin yapabilmektedir. Modelin aşırı öğrenmesini önlemek amacıyla erken durdurma tekniği kullanılmıştır. Erken durdurma, doğrulama kaybı belirli bir süre iyileşmediğinde eğitimi durdurarak en iyi model ağırlıklarını geri yüklemektedir. Önerilen model mimarisi, iki katmanlı bir LSTM yapısından oluşmaktadır. İlk LSTM katmanı, 32 birim ile yapılandırılmış olup geri dönüşlü olarak ayarlanmıştır. Bu katman, sonraki LSTM katmanına tüm zaman adımlarının çıktısını sağlamaktadır. İlk LSTM katmanının ardından %30 sönümleme (dropout) uygulanarak modelin aşırı öğrenmesi önlenmiştir. İkinci LSTM katmanı ise 16 birim ile yapılandırılmış olup sadece son zaman adımının çıktısını vermektedir. Bu katmanın ardından da %30 sönümleme (dropout) uygulanmıştır. Çıkış katmanı olarak tek bir nörona sahip Dense katmanı, sigmoid aktivasyon fonksiyonu ile anomali tespiti için kullanılmıştır. Model, Adam optimizasyon algoritması ve binary_crossentropy kayıp fonksiyonu ile derlenmiş ve doğrulama veri setindeki performansa göre erken durdurma geri çağırması ile eğitilmiştir. Çalışmada kullanılan mimari Şekil 4’te

¹ <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>

resmedilmiştir. Şekil 4'te görüleceği üzere genel mimari üç bölümden oluşmaktadır. İlk bölüm genel itibari ile verilerin hazırlanması ve ön işleme adımlarından oluşmaktadır. LSTM mimarisi için hazır

hale getirilen veriler LSTM mimarisine girdi olarak verilmiştir. En son bölüm ise modelin eğitimi ve test sonuçlarının elde edildiği bölümdür.



Şekil 4. Çalışmada Kullanılan Mimarinin Blok Diyagramı

Bu çalışma kapsamında yapılan testler ve sonuçların sunulmasında araştırma ve yayın etiğine uyulmuştur.

4. Bulgular ve Tartışma

Bu çalışmada, sağlıklı ürünlerden toplanan eğitim verileri ile eğitilen sistemin hastalık/zararlı inokülasyonu yapılan ürünlerden algılayıcılarla elde edilen veriler test edilerek erken uyarı verecek sistem geliştirilmiştir. Buradaki erken uyarı sistemi hastalık belirtisinin insan gözü ile tespit edilmesinden önceki zamanı belirtmektedir.

Sınıflandırma problemlerin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atanan örnek sayısı nicelikleri ile alakalıdır. Test sonucunda ulaşılan sonuçların başarımları bilgileri karışıklık matrisi ile ifade edilmektedir (Tablo 1).

Tablo 1. Karışıklık Matrisi

		Gerçek Sonuçlar	
		Doğru	Yanlış
Tahminlenen Sonuçlar	Doğru	DP	YN
	Yanlış	YP	DN

Tablo 1'de yer alan;

DP: Gerçekte hastalıklı olan örnekleri doğru bir şekilde hastalıklı olarak tahmin etme durumunu ifade eder.

DN: Gerçekte sağlıklı olan örnekleri doğru bir şekilde sağlıklı olarak tahmin etme durumunu ifade eder.

YP: Gerçekte hastalıklı olan örnekleri yanlış bir şekilde sağlıklı olarak tahmin etme durumunu ifade eder.

YN: Gerçekte sağlıklı olan örnekleri yanlış bir şekilde hastalıklı olarak tahmin etme durumunu ifade eder.

Karışıklık matrisinde satırlar test kümesindeki örneklerle ait gerçek sayıları, kolonlar ise modelin tahminlenmesini ifade etmektedir. Doğruluk

ölçmesinin en yaygın kullanımlarından doğru bir şekilde sınıflandırılan verinin bütüne oranının bir raporu olan yüzde doğruluğudur. Çoğunlukla yüzde doğruluk bir hata matrisi olmaksızın basit bir doğruluk ölçmesi olarak tek başına kullanılır. Yüzde doğruluk tek başına bir sınıflandırmanın göreceli olarak faydası hakkında fikir verebilir. Ancak bütün hata matrisini inceleme fırsatının olmaması durumunda sınıflandırma doğruluğunu kanıtlayacak kadar ikna edici değildir. Tam bir değerlendirme sınıflandırmada kullanılan kategorileri içermelidir. Ayrıca belirli sınıfların doğruluklarındaki değişimlere sınıfların hassasiyetlerinde olduğu gibi dikkat edilmelidir. Sadece genel sınıfların kullanıldığı bir sınıflandırmada yüksek doğruluk elde edilebilir. Model başarımının ölçülmesinde kullanılan en popüler ve basit yöntem, modele ait doğruluk oranıdır. Doğru sınıflandırılmış örnek sayısının (DP+DN), toplam örnek sayısına (DP+DN+YN+YP) oranıdır ve aşağıdaki eşitlik (Eşitlik 1) ile ifade edilmektedir.

$$\text{doğruluk} = \frac{DP+DN}{DP+DN+YN+YP} \quad (1)$$

Hata oranı ise bu değer 1'e tamlayanıdır. Diğer bir ifadeyle yanlış sınıflandırılmış örnek sayısının (YP+YN), toplam örnek sayısına (DP+DN+YN+YP) oranıdır. Kesinlik ise hastalıklı olan verilerin hangi oranda tespit edilebildiğini göstermektedir. Hastalıklı olarak doğru sınıflanmış (DP) veri sayısının, hastalıklı olarak tahminlenmiş tüm örnek sayısına oranıdır ve matematiksel olarak gösterimi Eşitlik 2'de verilmiştir.

$$\text{kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

Doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısı oranı duyarlılık olarak isimlendirilmekte ve formülü aşağıdaki eşitlikte sunulmuştur (Eşitlik 3);

$$\text{duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

Kesinlik ve duyarlılık ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. Bunun için f-ölçütü tanımlanmıştır. F-ölçütü, kesinlik ve duyarlılığın harmonik ortalamasıdır ve Eşitlik 4'te gösterilmektedir.

$$F \text{ Skoru} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

Çalışma kapsamında elde edilen karışıklık matrisi Tablo 2'de, kesinlik, doğruluk ve F Skoru ise Tablo 3'te gösterilmiştir.

Tablo 2. Elde Edilen Karışıklık Matrisi

		Gerçek Sonuçlar	
		Hastalıklı	Sağlıklı
Tahminlenen	Hastalıklı	1142	0
Sonuçlar	Sağlıklı	2	2646

Tablo 2'de 1144 adet olan hastalıklı verilerin sadece 2 tanesinin yanlışlıkla sağlıklı olarak tahmin edildiği, buna karşılık 2646 adet olan sağlıklı verinin hepsinin doğru olarak tahmin edildiği görülmektedir.

Tablo 3. Model Sonucu Elde Edilen Başarım Metrikleri

	Doğruluk	Kesinlik	Duyarlılık	F-Skoru
Başarım (%)	0.9994	0.9982	1.0000	0.9990

Yukarıdaki başarım metrikleri tablosu incelendiği zaman çalışma kapsamında sensör verilerin kullanılarak başarılı bir şekilde bitkilerin hastalıklı olup olmadığı tespit edilebilmektedir.

5. Sonuçlar

Bu çalışmada serada yapılan hıyar yetiştiriciliğinde ortaya çıkabilecek virüs etkisinin derin öğrenme ve yapay zeka uygulamaları yardımıyla erken dönemde tespit edilmesi amaçlanmıştır. Gelişen teknoloji ile algılayıcıların artık kolay ulaşılabilmesi hem de bu algılayıcılardan gelen çok boyutlu bilgiyi analiz edebilen yapay zeka destekli çözümler bitkilerin başlangıç aşamasından hasata kadar olumsuz durumların hassasiyetle ve hızlı bir şekilde tespit edilmesini kolaylaştırmak için gereklidir. Bu çalışmada sağlıklı ve yapay hastalık oluşturulabilecek iki üretim merkezi algılayıcılar ile sürekli izlenerek hastalıkların erken tespitini gerçekleştirilebilmek adına bir sistem mimarisi oluşturma, algılayıcıların birleştirilerek veriden elde edilecek bilgi miktarını artırmak ve uçtan uca eğitim yapabilecek ve gerçek saha ortamında çalışabilecek özgün bir yaklaşım önerilmiştir. Çalışmada Beit Alpha tipi standart bir hıyar çeşidi kullanılmıştır. Fide dönemindeki hıyar bitkilerine

Cucumber mosaic virusünü (CMV) hastalıklı bitki elde edebilmek için yapraktan zararlı nematod için bitkinin yetiştirme ortamına inoküle edilerek verilmiş ve belirti oluşumu gözlemlenmiştir. Bitki hastalık yönetimi için yerinde örnekleme sağlayan hassas, spesifik, kullanıcı dostu ve hızlı yöntemlere duyulan ihtiyaç giderek daha belirgin hale gelmektedir. Bu sayede hastalık serada yetiştirilen bitkilerin birkaçında yayılmaya başladığında aksiyon almak mümkün olacaktır. Bu çalışmada zaman serilerini analizi için kullanılan LSTM mimarisi yerine ARIMA gibi istatistiksel yöntemlerin kullanılması ve toprak sensörlerinden elde edilen verilerin görüntülerle füzyon edilerek yeni derin öğrenme mimarileri oluşturulması planlanmaktadır. Hastalık ve zararlıların sonraki yapılacak çalışmalar kapsamında geliştirilecek yenilikçi ve sürdürülebilir teknoloji sayesinde erken dönemde tespit edilmesiyle zirai mücadele uygulamalarının zamanında ve etkin bir şekilde uygulanmasıyla olası verim ve kalite kayıplarının önüne geçilebilecektir. Ayrıca minimum zirai ilaçlama ile maliyet düşürücü tedbirler en üst seviyede alınabilecek insan ve çevre maksimum seviyede korunmuş olacaktır.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 1230928 Numaralı proje ile desteklenmiştir. Projeye verdiği destekten ötürü TÜBİTAK'a teşekkürlerimizi sunarız.

Araştırmacıların Katkısı

Bu çalışmada; Elif GENÇ, Yusuf KARTAL ve Erol SEKE sera ortamının kurulması ve verilerin elde edilmesi, verilerin bilgisayar ortamına aktarılması; Cem BAĞLUM ve Osman ÇAĞLAR derin öğrenme mimarilerin kodlanması ve sonuçların elde edilmesi, uygulanması, bilgisayara ortamına aktarılması; Erol SEKE, bilimsel yayın araştırması, makalenin oluşturulması, istatistiki analizler, Kemal ÖZKAN ise çalışmanın her aşamasında katkı sağlamıştır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

- Abade, A., Ferreira, P. A. ve Vidal, F. B. (2021). Plant diseases recognition on images using convolutional neural networks: A systematic review. *Computers and Electronics in Agriculture*, 185, 106125. doi: <https://doi.org/10.1016/j.compag.2021.106125>
- Abdu, A. M., Mokji, M. M. ve Sheikh, U. U. (2020). Machine learning for plant disease detection: An investigative comparison between support vector machine and deep learning. *IAES International*

- Journal of Artificial Intelligence (IJ-AI), 9(4), 670-683. doi: <https://doi.org/10.11591/ijai.v9.i4.pp670-683>
- Akbaş, B. (2019). Bitki sağlığının sürdürülebilir tarımdaki yeri. Ziraat Mühendisliği (368), 6-13. doi: <https://doi.org/10.33724/zm.606199>
- Ashwini, C. ve Sellam, V. (2024). An optimal model for identification and classification of corn leaf disease using hybrid 3D-CNN and LSTM. Biomedical Signal Processing and Control, 92, 106089, ISSN 1746-8094. doi: <https://doi.org/10.1016/j.bspc.2024.106089>
- Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. Biosystems Engineering, 144, 52-60. doi: <https://doi.org/10.1016/j.biosystemseng.2016.01.017>
- Bischoff, V., Farias, K., Menzen, J. P. ve Pessin, G. (2021). Technological support for detection and prediction of plant diseases: A systematic mapping study. Computers and Electronics in Agriculture, 181, 105922. doi: <https://doi.org/10.1016/j.compag.2020.105922>
- Chin, P.-W., Ng, K.-W. ve Palanichamy, N. (2024). Plant disease detection and classification using deep learning methods: A comparison study. Journal of Informatics and Web Engineering, 3(1), 156-167. doi: <https://doi.org/10.33093/jiwe.2024.3.1.10>
- Cohen, B., Edan, Y., Levi, A. ve Alchanatis, V. (2022). Early detection of grapevine (vitis vinifera) downy mildew (peronospora) and diurnal variations using thermal imaging. Sensors, 22, 3585. doi: <https://doi.org/10.3390/s22093585>
- Dyussebayev, K., Sambasivam, P., Bar, I., Brownlie, J. C., Shiddiky, M. J. A. ve Ford, R. (2021). Biosensor technologies for early detection and quantification of plant pathogens. Frontiers in Chemistry. doi: <https://doi.org/10.3389/fchem.2021.636245>
- Gao, R., Wang, R., Lu, F., Li, Q. ve Wu, H. (2021). Dual-branch, efficient, channel attention-based crop disease identification. Computers and Electronics in Agriculture, 190, 106410. doi: <https://doi.org/10.1016/j.compag.2021.106410>
- Ferentinos, K. (2018). Deep learning models for plant disease detection and diagnosis. Computers and Electronics in Agriculture, 145, 311-318. doi: <https://doi.org/10.1016/j.compag.2018.01.009>
- Fischer, T. ve Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. European Journal of Operational Research, 270(2), 654-669. doi: <https://doi.org/10.1016/j.ejor.2017.11.054>
- Kelman, A., Pelczar, M. J., Pelczar, R. M. ve Shurtleff, M. C. (2023, December 28). Plant disease. Encyclopedia Britannica. Erişim adresi: <https://www.britannica.com/science/plant-disease>.
- Lipton, Z. C., Kale, D. C., Elkan, C. ve Wetzell, R. (2015). Learning to diagnose with LSTM recurrent neural networks. arXiv Preprint arXiv:1511.03677. doi: <https://doi.org/10.48550/arXiv.1511.03677>
- Lu, Y., Chen, D., Olaniyi, E. ve Huang, Y. (2022). Generative adversarial networks (gans) for image augmentation in agriculture: A systematic review. Computers and Electronics in Agriculture, 200, 107208. doi: <https://doi.org/10.1016/j.compag.2022.107208>
- Jackulin, C. ve Murugavalli, S. (2022). A comprehensive review on detection of plant disease using machine learning and deep learning approaches. Measurement: Sensors, 24, 100441, ISSN 2665-9174. doi: <https://doi.org/10.1016/j.measen.2022.100441>
- Mohanty, S. P., Hughes, D. P. ve Salathé, M. (2016). Using deep learning for image-based plant disease detection. Frontiers in Plant Science, 7, 1419. doi: <https://doi.org/10.3389/fpls.2016.01419>
- Nguyen, C., Sagan V., Maimaitiyiming, M., Maimaitijiang, M., Bhadra, S. ve Kwasniewski, M. (2021). Early detection of plant viral disease using hyperspectral imaging and deep learning. Sensors, 21, 742. doi: <https://doi.org/10.3390/s21030742>
- Patel, P. (2021). A review on plant disease diagnosis through biosensor. International Journal of Biosensors and Bioelectronics, 7, 50-52. doi: <https://doi.org/10.15406/ijbsbe.2021.07.00212>
- Radovanović, D. ve Đukanovic, S. (2020), Image-based plant disease detection: a comparison of deep learning and classical machine learning algorithms, 24th International Conference on Information Technology (IT), Zabljak, Montenegro, 2020, 1-4. doi: <https://doi.org/10.1109/IT48810.2020.9070664>
- Sharma, V., Tripathi, A.K. ve Mittal, H., (2022). Technological revolutions in smart farming: current trends, challenges and future directions. Computers

and Electronics in Agriculture 201, 107217. doi: <https://doi.org/10.1016/j.compag.2022.107217>

Shin, J., Chang, Y. K., Heung, B., Nguyen-Quang, T., Price, G. W. ve Al-Mallahi, A. (2021). A deep learning approach for RGB image-based powdery mildew disease detection on strawberry leaves. Computers and Electronics in Agriculture 183, 106042. doi: <https://doi.org/10.1016/j.compag.2021.106042>

Smetanin, A., Uzhinskiy, A., Ososkov, G., Goncharov, P. ve Nechaevskiy, A. (2021). Deep learning methods for the plant disease detection platform. AIP Conference Proceedings, 2377, 060006. doi: <https://doi.org/10.1063/5.0068797>

Sutskever, I., Vinyals, O. ve Le, Q. V. (2014). Sequence to sequence learning with neural networks. Advances in Neural Information Processing Systems, 27. doi: <https://doi.org/10.48550/arXiv.1409.3215>

Terentev, A., Dolzhenko, V., Fedotov, A. ve Eremenko, D. (2022). Current state of hyperspectral remote sensing for early plant disease detection: A review. Sensors 22, 757. doi: <https://doi.org/10.3390/s22030757>

Thakur, P.S., Khanna, P., Sheorey, T. ve Ojha, A. (2022). Trends in vision-based machine learning techniques for plant disease identification: A systematic review. Expert Syst Appl 208, 118117. doi: <https://doi.org/10.1016/j.eswa.2022.118117>

Thomas, V., Maria, B., Patricia, G., Guillem, S., Isabel, T., Iker, A., Shawn, K. ve Araus, J. (2024). Comparing high-cost and lower-cost remote sensing tools for detecting pre-symptomatic downy mildew (*Pseudoperonospora cubensis*) infections in cucumbers. Computers and Electronics in Agriculture, 218, 108736. doi: <https://doi.org/10.1016/j.compag.2024.108736>