

Atf İçin: Günde, M. ve Işık, G. (2026). Sınırlı Veriyle Bitki Hastalığı Tespiti: MAML++ ve ResNet Mimarileri ile Etkin Bir Meta-Öğrenme Yaklaşımı. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 16(1), 1-13.

To Cite: Günde, M. & Işık, G. (2026). Efficient Plant Disease Detection with Limited Data: A Meta-Learning Approach Using MAML++ and ResNet Architectures. *Journal of the Institute of Science and Technology*, 16(1), 1-13.

Sınırlı Veriyle Bitki Hastalığı Tespiti: MAML++ ve ResNet Mimarileri ile Etkin Bir Meta-Öğrenme Yaklaşımı

Metehan GÜNDE^{1*}, Gültekin IŞIK²

Öne Çıkanlar:

- MAML++ ile ResNet tabanlı modeller few-shot öğrenmede test edildi
- Shot artışı doğruluğu yükseltirken, fazla sınıf performansı düşürdü
- ResNet-18, 2-way 5-shot senaryosunda en iyi sonuçları verdi

Anahtar Kelimeler:

- Meta-öğrenme
- Az örnekle öğrenme
- ResNet
- PlantVillage
- Bitki hastalıklarının tespiti

ÖZET:

Bitki hastalıklarının tespiti, küresel gıda güvenliği için kritik öneme sahipken, bu alandaki derin öğrenme modelleri genellikle büyük etiketli veri kümelerine ihtiyaç duyar. Tarımsal uygulamalarda bu tür verilerin toplanmasındaki zorluklar, veri kısıtlı senaryolarda çalışabilen etkin yöntemlere olan ihtiyacı artırmaktadır. Bu çalışma, az sayıda örnekle öğrenme problemine çözüm olarak MAML++ meta-öğrenme algoritmasını ResNet-18, ResNet-34 ve ResNet-50 gibi farklı derinlikteki mimarilerle entegre etmektedir. PlantVillage veri kümesinin elma hastalıkları alt kümesinde yapılan deneylerde, model performansları 2-way/4-way görevler ve 1/3/5-shot konfigürasyonları altında değerlendirilmiştir. Sonuçlar, destek örneği (shot) sayısının artmasının doğruluğu artırdığını, ancak daha derin ağların her zaman daha iyi sonuç vermediğini göstermiştir. Özellikle daha hafif bir mimari olan ResNet-18, 2-way 5-shot senaryosunda %92,53 doğruluk oranıyla en yüksek performansı sergilemiş; daha derin olan ResNet-50 modeline yakın bir başarıyı daha düşük kayıp değeriyle elde etmiştir. Bu bulgular, veri kısıtlı tarımsal uygulamalarda, MAML++ gibi meta-öğrenme yaklaşımlarının hafif modellerle birleştirilmesinin hem verimli hem de yüksek performanslı bir çözüm sunduğunu ortaya koymaktadır.

Efficient Plant Disease Detection with Limited Data: A Meta-Learning Approach Using MAML++ and ResNet Architectures

Highlights:

- ResNet models combined with MAML++ were evaluated in few-shot learning
- Increasing shots improved accuracy, while more classes reduced performance
- ResNet-18 achieved the best results in the 2-way 5-shot scenario

ABSTRACT:

Plant disease detection is critical for global food security, yet deep learning models often depend on large annotated datasets that are scarce in agriculture. This scarcity necessitates efficient methods that can perform well under data-limited conditions. This study addresses the few-shot learning challenge by integrating the MAML++ meta-learning algorithm with ResNet backbones of varying depths: ResNet-18, ResNet-34, and ResNet-50. Using the apple disease subset of the PlantVillage dataset, we evaluated model performance across 2-way/4-way tasks and 1/3/5-shot configurations. Our findings reveal that while more support samples (shots) improved accuracy, network depth did not linearly correlate with better performance. Notably, the lightweight ResNet-18 architecture achieved the highest accuracy of 92.53% in the 2-way 5-shot scenario, matching the performance of the deeper ResNet-50 but with a lower loss value. These results demonstrate that combining meta-learning approaches like MAML++ with lighter architectures offers an efficient and high-performing solution for data-constrained agricultural applications.

Keywords:

- Meta-learning
- Few-shot learning
- ResNet
- PlantVillage
- Plant disease detection

¹ Metehan GÜNDE ([Orcid ID: 0000-0003-3323-7525](https://orcid.org/0000-0003-3323-7525)), İğdır Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, İğdır, Türkiye

² Gültekin IŞIK ([Orcid ID: 0000-0003-3037-5586](https://orcid.org/0000-0003-3037-5586)), İğdır Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İğdır, Türkiye

***Sorumlu Yazar/Corresponding Author:** Metehan GÜNDE, e-mail: metehan.gunde@igdir.edu.tr

GİRİŞ

Bitkiler, küresel ölçekte gıda güvenliğinin sağlanması ve tarımsal sürdürülebilirliğin korunması açısından hayati bir role sahiptir. Ancak, bitki hastalıkları ürün verimliliği ve kalitesi üzerinde ciddi tehditler oluşturmakta; nitekim bazı araştırmalar, dünya genelinde başlıca ürün gruplarında patojenler ve zararlıların önemli kayıplara yol açtığını ortaya koymaktadır (Savary ve ark., 2019). Bu bağlamda, hastalıkların erken aşamada tespiti hem ekonomik zararların azaltılması hem de çevresel etkilerin en aza indirgenmesi bakımından kritik önemdedir. Geleneksel teşhis yöntemleri çoğunlukla uzman görüşüne dayanmaktadır; ancak bu yöntemler geniş tarım alanlarında uygulanabilirlik açısından hem zaman hem de maliyet bakımından verimsiz olabilmekte ve yüksek hata oranları içerebilmektedir. Bu nedenlerle, modern tarımda otomatik ve güvenilir tanı sistemlerine olan ihtiyaç giderek artmaktadır.

Son dönemde derin öğrenme temelli görüntü işleme yöntemleri, yaprak görüntülerinden hastalıkların otomatik ve yüksek doğrulukla tanımlanmasına olanak tanıyan etkili bir çerçeve sunmaktadır. Özellikle, denetimli evrişimli sinir ağı (CNN) modelleri yeterli ve dengeli veriyle eğitildiklerinde oldukça yüksek sınıflandırma başarısı sergileyebilmektedir (Bayat ve Işık, 2022; Ferentinos, 2018; Mohanty ve ark., 2016). Ancak, bu başarı düzeyi büyük ölçüde geniş çaplı ve etiketlenmiş veri kümelerine olan bağımlılıkla sınırlıdır. Tarımsal uygulamalarda bu tür veri kümelerinin oluşturulması ise çoğu durumda hem zahmetli hem de yüksek maliyetlidir. Güncel literatürde, bu sorunu aşmak amacıyla hibrit derin öğrenme yaklaşımları ve açıklanabilir yapay zekâ (XAI) tabanlı sistemler de önerilmiştir (Özüpak, Alpsalaz, Aslan ve Uzel, 2025; Alpsalaz, Özüpak, Aslan ve Uzel, 2025).

Bitki hastalıklarına ilişkin görüntüler, farklı iklim koşulları, aydınlatma düzeyleri, kamera özellikleri ve yaprak morfolojisindeki çeşitlilik gibi etkenler nedeniyle önemli ölçüde heterojenlik göstermektedir. Bu çeşitlilik, geleneksel derin öğrenme modellerinin genelleme kapasitesini sınırlamakta ve özellikle farklı veri dağılımlarına sahip alanlarda model performansında belirgin düşüşlere neden olabilmektedir (Arnal Barbedo, 2019). Bu bağlamda, çeşitli çevresel ve teknik koşullara uyum sağlayabilen, daha esnek ve adaptif sistemlerin geliştirilmesi büyük önem arz etmektedir.

Araştırmacılar, söz konusu sınırlamaların üstesinden gelebilmek amacıyla veri artırma teknikleri ile transfer öğrenme yaklaşımlarını devreye almışlardır. PlantVillage gibi standart veri kümeleri üzerinde gerçekleştirilen çalışmalar, transfer öğrenmenin oldukça başarılı sonuçlar verebildiğini ortaya koymuştur. Ancak bu başarı, gerçek tarla koşullarına uygulandığında önemli ölçüde azalma göstermektedir (Too ve ark., 2019). Bu durum hem veri eksikliğinin üstesinden gelebilecek hem de daha yüksek genelleme yeteneğine sahip yöntemlere duyulan gereksinimi açıkça ortaya koymaktadır.

Bu zorlukların üstesinden gelmek için, öğrenmeyi öğrenme prensibine dayanan bu çerçevede, az örnekle öğrenme (few-shot learning) ve meta-öğrenme yaklaşımları giderek daha fazla ön plana çıkmaktadır. Az örnekle öğrenme yalnızca bilinen hastalıkların sınıflandırılmasında değil, aynı zamanda yeni ortaya çıkan bitki hastalıklarının hızlı ve etkili şekilde tanımlanmasında da önemli bir potansiyel sunmaktadır (Sun ve ark., 2024). Mevcut literatür, meta-öğrenmenin tarımsal hastalık tanısı bağlamında yeni sınıfları çok az sayıda örnekle öğrenerek dikkate değer başarılar elde ettiğini göstermektedir. Örneğin, Local Feature Matching – Conditional Neural Adaptive Processes modeli, daha önce karşılaşılmamış bitki hastalığı kategorilerini yalnızca birkaç örnek üzerinden tanıyabilmiştir (Chen ve ark., 2021). Benzer şekilde, Sample-Wise Efficient Model-Agnostic Meta-Learning adlı çalışma, az örnekle tanıma için ardışık ağırlıklı bir MAML topluluğu (ensemble) önererek, PlantVillage veri kümesi üzerinde güçlü ve etkileyici sonuçlar raporlamıştır (Li ve ark., 2025). Buna ek olarak, düşük veri koşullarına özel geliştirilen yöntemlerin, bitki hastalıklarının teşhisinde etkili olduğuna dair güncel araştırma bulguları da mevcuttur (Rezaei ve ark., 2024).

Meta-öğrenme algoritmaları, modelin farklı görevler üzerindeki deneyimlerinden yararlanarak yeni görevleri hızlı ve etkili biçimde öğrenmesini mümkün kılar. Bu yetenek, özellikle tarımsal uygulamalarda nadir rastlanan ya da sınırlı sayıda örnekle temsil edilen hastalıkların tanılanmasında önemli avantajlar sunmaktadır (Hospedales ve ark., 2022). Dahası, meta-öğrenme tekniklerinin tarım dışı alanlarda elde ettiği başarılı uygulamaların tarımsal bağlama uyarlanması, disiplinler arası yenilikçi katkılar sağlayarak alanlar arası bilgi aktarımını desteklemektedir.

Yöntemsel temelde, MAML, hızlı adaptasyon yeteneğini hedefleyen modelden bağımsız bir meta-öğrenme algoritması olarak öne çıkmaktadır (Finn ve ark., 2017). Bu algoritmanın geliştirilmiş bir versiyonu olan MAML++, hem eğitim sürecinde istikrarı artırmakta hem de genelleme performansını iyileştirmeye yönelik çeşitli optimizasyonlar sunmaktadır (Antoniou ve ark., 2018). Öte yandan, önceden eğitilmiş büyük ölçekli modellerden biri olan Vision Transformer (ViT), sınırlı veri koşullarında etkili temsiller sunabilmesine rağmen, yüksek hesaplama maliyetleri nedeniyle pratik uygulamalarda her zaman tercih edilemeyebilir (Pacal ve Işık, 2025; Aslan ve ÖZÜPAK, 2024). Bu nedenle, ResNet-18, ResNet-34 ve ResNet-50 gibi daha kompakt mimarilerin meta-öğrenme algoritmalarıyla entegre edilmesi, özellikle saha koşullarında daha uygulanabilir ve verimli bir çözüm yolu sunmaktadır (Dosovitskiy ve ark., 2020).

Diğer yandan, arazi koşullarında kullanılacak yapay zekâ tabanlı sistemlerin yalnızca yüksek doğruluk sunması yeterli değildir; bu sistemlerin aynı zamanda hesaplama verimliliği ve donanım uyumluluğu açısından da optimize edilmesi büyük önem taşımaktadır. Özellikle tarımsal uygulamalarda yaygın olan düşük maliyetli donanımlar ve mobil platformlar üzerinde çalışabilecek hafif meta-öğrenme çözümleri, bu teknolojilerin geniş çapta benimsenmesi ve pratikte sürdürülebilir biçimde uygulanabilmesi açısından kritik bir unsur olarak değerlendirilmektedir (Kamilaris ve Prenafeta-Boldú, 2018).

Bu çalışma, bitki yaprağı hastalıklarının az örnekle öğrenme senaryolarında otomatik olarak tespit edilmesini amaçlamakta ve bu doğrultuda ResNet-18, ResNet-34 ve ResNet-50 mimarilerini MAML++ meta-öğrenme algoritması ile entegre etmektedir. Deneysel aşamada ise, önerilen yaklaşımın etkinliği PlantVillage veri kümesindeki elma hastalıkları üzerinde kapsamlı bir şekilde değerlendirilmiştir.

MATERYAL VE METOT

Veri Kümesi

Bu çalışmada kullanılan veri kümesi, tarımsal yaprak hastalıklarının sınıflandırılmasına yönelik çalışmalarda yaygın biçimde başvuru PlantVillage veri setidir (Hughes ve Salathe, 2015). Söz konusu veri kümesi, toplam 38 farklı bitki türüne ait hem sağlıklı hem de hastalıklı yaprak görüntülerini içermektedir.

Deneysel tasarım çerçevesinde, kullanılan veri kümesi üç alt bölüme ayrılmıştır ve Çizelge 1’de verilmiştir. Meta-eğitim aşaması, her biri yaklaşık 1500 örnek içeren 20 farklı sınıftan oluşmaktadır. Meta-doğrulama kümesi ise eğitim aşamasında yer almayan 8 farklı sınıfı kapsamaktadır ve her bir sınıf için 500 görüntü kullanılmıştır. Meta-test aşaması, eğitim ve doğrulama veri kümelerinden tamamen bağımsız olacak şekilde, yalnızca elmaya ait dört ayrı sınıf üzerinde yürütülmüştür. Bu sınıflar; Apple Scab, Black Rot, Cedar Apple Rust hastalıkları ile sağlıklı yapraklardan oluşmakta olup, her bir sınıf 500 örnek içermektedir.

Çizelge 1. Veri kümesi dağılımı

Küme	Sıra	Sınıf (Bitki) Adı	Hastalık Adı	Örnek Sayısı
Eğitim	1	Blueberry	Healthy	1500
	2	Cherry	Healthy	1500
	3	Corn (Maize)	Cercospora Leaf Spot (Gray Leaf Spot)	1500
	4	Corn (Maize)	Common Rust	1500
	5	Grape	Healthy	1500
	6	Grape	Leaf Blight (Isariopsis Leaf Spot)	1500
	7	Orange	Haunglongbing (Citrus Greening)	1500
	8	Peach	Bacterial Spot	1500
	9	Pepper Bell	Healthy	1500
	10	Potato	Late Blight	1500
	11	Raspberry	Healthy	1500
	12	Squash	Powdery Mildew	1500
	13	Strawberry	Healthy	1500
	14	Tomato	Bacterial Spot	1500
	15	Tomato	Early Blight	1500
	16	Tomato	Healthy	1500
	17	Tomato	Late Blight	1500
	18	Tomato	Leaf Mold	1500
	19	Tomato	Target Spot	1500
	20	Tomato	Tomato Yellow Leaf Curl Virus	1500
Doğrulama	1	Cherry (incl. Sour)	Powdery Mildew	500
	2	Corn (Maize)	Healthy	500
	3	Grape (Esca)	Black Measles	500
	4	Pepper Bell	Bacterial Spot	500
	5	Potato	Early Blight	500
	6	Soybean	Healthy	500
	7	Strawberry	Leaf Scorch	500
	8	Tomato	Septoria Leaf Spot	500
Test	1	Apple	Apple Scab	500
	2	Apple	Black Rot	500
	3	Apple	Cedar Apple Rust	500
	4	Apple	Healthy	500


Bu yapılandırma, modelin yalnızca daha önce öğrenilen sınıflarda değil, aynı zamanda tamamen yeni sınıflarda da genelleme yeteneğinin değerlendirilebilmesini sağlamıştır. Veri kümesindeki sınıf dengesizliklerini azaltmak amacıyla çeşitli veri artırma teknikleri uygulanmıştır (Too ve ark., 2019).

ResNet Mimarisi

Derin sinir ağlarının performansı, genellikle ağın katman sayısı arttıkça artış göstermektedir. Ancak, çok katmanlı yapılar azalan gradyanlar ve aşırı uyum gibi sorunlara yol açarak öğrenme sürecini karmaşıktırmakta ve modelin etkin biçimde eğitilmesini zorlaştırmaktadır. Bu tür zorlukların üstesinden gelmek amacıyla geliştirilen ResNet (Residual Network) mimarisi, artık (residual) bağlantılar diğer adıyla “skip connections” aracılığıyla derin ağların daha verimli şekilde eğitilebilmesini mümkün kılmaktadır (He ve ark., 2016). Bu bağlantılar, katmanlar arası bilgi aktarımını kolaylaştırarak gradyan kaybını önlemekte ve böylece çok daha derin ağ yapılarına etkili biçimde optimizasyon uygulanmasına olanak sağlamaktadır.

ResNet mimarisinin temel çalışma prensibi, geleneksel ağ blokları ile artık blokların karşılaştırılması üzerinden daha açık şekilde kavranabilir. Geleneksel yapılarda her bir katman yalnızca kendisinden önceki katmandan aldığı çıktıyı işlerken, artık bloklarda giriş bilgisi doğrudan daha ileri katmanlara iletilmektedir. Bu mekanizma, öğrenme sürecini daha kararlı hâle getirirken, derin mimarilerde optimizasyonun daha etkili biçimde gerçekleştirilmesini mümkün kılmaktadır. Söz konusu yapının şematik gösterimi Şekil 1’de sunulmaktadır.

ResNet mimarisinin başlıca avantajlarından biri, ağın derinliği ve parametre sayısı artsa dahi öğrenme sürecini etkin şekilde sürdürebilmesidir. Bu nedenle, farklı derinlik düzeylerine sahip olan ResNet-18, ResNet-34 ve ResNet-50 gibi versiyonlar, özellikle görüntü sınıflandırma görevlerinde yaygın biçimde tercih edilmektedir. Daha az katmanlı olan ResNet-18, düşük hesaplama gereksinimi sayesinde hızlı eğitim imkânı sunarken; daha derin yapıya sahip ResNet-50, karmaşık görsel örüntüleri öğrenmede daha başarılı olmakta ve genellikle daha yüksek doğruluk oranlarına ulaşmaktadır. Bu ölçeklenebilir yapı, ResNet mimarilerinin çeşitli karmaşıklık düzeylerine sahip veri kümeleriyle meta-öğrenme algoritmalarının entegrasyonu için oldukça elverişli bir çözüm sunmasına olanak tanımaktadır (Rawat ve Wang, 2017; Alom ve ark., 2019; Işık ve Paçal, 2024). Bu çalışmada farklı derinlikteki ResNet versiyonlarının seçilme nedeni, az örnekle öğrenmede model karmaşıklığı ile genelleme performansı arasındaki ilişkiyi sistematik olarak incelemektir.



Şekil 1. ResNet mimarisinde klasik blok ile residual blok karşılaştırması

Modeller ve Deneysel Tasarım

Bu çalışmada, üç farklı ResNet mimarisi (ResNet-18/34/50) (He ve ark., 2016) kullanılmıştır. Söz konusu mimariler, MAML++ algoritmasıyla entegre edilerek az örnekle öğrenme senaryolarında kapsamlı şekilde test edilmiştir. Gerçekleştirilen model karşılaştırmaları, ağ derinliğinin meta-öğrenme performansı üzerindeki etkilerini analiz etmeye yönelik olarak tasarlanmıştır.

Deneyisel senaryolar, 2-way ve 4-way görevler şeklinde yapılandırılmış; her bir senaryo kapsamında 1-shot, 3-shot ve 5-shot konfigürasyonları uygulanmıştır. Bu bağlamda, "shot" terimi her sınıfa ait destek (support) örnek sayısını, "way" ise görevde yer alan toplam sınıf sayısını ifade etmektedir (Wang ve ark., 2021). Bu tasarım sayesinde, modelin hem tek bir sınıf üzerinde öğrenme yetkinliği hem de birden fazla sınıfı ayırt etme becerisi ayrıntılı biçimde değerlendirilmiştir.

Meta-Öğrenme ve Az Örnekle Öğrenme

Meta-öğrenme yaklaşımında eğitim süreci, geleneksel eğitim-test ayrımının ötesine geçerek “meta-eğitim” ve “meta-test” olmak üzere iki temel aşamadan oluşmaktadır (Şekil 2). Meta-eğitim aşamasında model, farklı görevler üzerinden edinilen deneyimler aracılığıyla yeni görevlere daha hızlı adapte olmayı öğrenir. Bu aşamada her görev, bir eğitim alt kümesi (support set) ile bir test alt

kümesinden (query set) oluşacak şekilde yapılandırılır. Meta-test aşamasında ise model, daha önce karşılaşmadığı sınıflarla test edilerek genelleme kabiliyeti değerlendirilir. Bu yapılandırma, az örnekle öğrenme senaryolarının temel çerçevesini oluşturmaktadır (Finn ve ark., 2017).




Şekil 2. Meta-öğrenmede eğitim ve test sürecinin, her biri küçük destek (support) ve sorgu (query) kümelerinden oluşan görevler üzerinden nasıl gerçekleştirildiğini gösteren şema (Ravi ve Larochelle, 2022)

MAML++, modelin yeni görevler karşısında hızlı bir şekilde uyum sağlayabilmesini amaçlayan MAML algoritmasının iyileştirilmiş bir versiyonudur. Orijinal MAML yaklaşımı, yalnızca birkaç gradyan güncellemesiyle yeni görevlere adapte olmayı hedeflemekle birlikte, eğitim sürecinde gradyan kararsızlığı, aşırı öğrenme ve sınırlı genelleme kapasitesi gibi çeşitli zorluklarla karşı karşıya kalmaktadır (Finn ve ark., 2017; Işık, 2023). Bu sınırlamaları aşmak amacıyla geliştirilen MAML++, eğitim sürecine hem yapısal hem de optimizasyon düzeyinde çeşitli iyileştirmeler entegre etmektedir. Özellikle derin ResNet mimarileriyle çalışırken eğitim istikrarını korumak kritik olduğundan, orijinal MAML yerine MAML++ algoritması tercih edilmiştir.

MAML++ algoritmasında, her katmanın kendi öğrenme dinamiğini geliştirebilmesini mümkün kılan katman bazlı öğrenme oranı optimizasyonu uygulanmaktadır. Bu yaklaşım, modelin daha hızlı ve istikrarlı şekilde adaptasyon sağlamasına önemli katkı sunmaktadır. Ayrıca, aşırı uyumu önlemek amacıyla stabilite artırıcı düzenleme teknikleri devreye alınmıştır. Buna ek olarak, görev örnekleme stratejilerinin iyileştirilmesi yoluyla eğitim sürecindeki görev çeşitliliği artırılmış ve böylece modelin daha geniş görev dağılımları üzerinde genelleme yeteneği güçlendirilmiştir (Yao ve ark., 2021).

Şekil 3'te, modelin farklı görevlerden örnekler alarak meta-eğitim sürecini gerçekleştirdiği ve her bir görev için iç döngü güncellemeleri uyguladığı süreç görselleştirilmiştir. Bu aşamada model, yalnızca tekil bir göreve uyum sağlamayı değil, çoklu görevler üzerinden ortak bir parametre başlangıç noktası (θ) öğrenmeyi hedeflemektedir. Takip eden meta-test aşamasında ise model, yalnızca birkaç örnekle karşılaştığı yeni bir göreve hızlı ve etkili biçimde uyum sağlayabilmektedir.



Şekil 3. MAML algoritmasının genel işleyiş şeması; farklı görevlerden öğrenilen deneyimler üzerinden modelin yeni bir göreve birkaç adımda uyum sağlaması

MAML++ algoritmasının bir diğer önemli katkısı, çoklu iç güncelleme adımları sırasında gerçekleşen gradyan hesaplamalarının stabilize edilmesidir. Bu iyileştirme sayesinde, özellikle derin mimariler (örneğin ResNet-50) ile gerçekleştirilen meta-öğrenme deneyimlerinde gradyan patlaması ya da sönmesi gibi yaygın problemler etkin biçimde önlenmiştir. Ayrıca, önceden eğitilmiş modellerle

entegrasyon kolaylığı sayesinde MAML++, transfer öğrenme ve az örnekle öğrenme senaryolarında daha işlevsel ve güçlü bir yöntem olarak öne çıkmaktadır (Raghu ve ark., 2019).

Sonuç olarak, MAML++ yalnızca MAML algoritmasının bir varyasyonu değil; daha istikrarlı bir optimizasyon süreci, artırılmış genelleme yeteneği ve düşük veri koşullarında daha tutarlı performans sergileyen kapsamlı bir meta-öğrenme çerçevesi olarak değerlendirilmektedir. Bu nitelikleri sayesinde, özellikle sınırlı veri ile karakterize edilen tarımsal hastalık tanısı gibi uygulama alanlarında önemli avantajlar sunmakta ve tercih edilmesi halinde yüksek etkililik potansiyeli taşımaktadır (Sun ve ark., 2024). Bu doğrultuda, MAML++ algoritması ile ResNet mimarilerinin kombinasyonu kullanılarak, PlantVillage veri kümesinde yer alan elma yaprağı hastalıklarının tanılanmasındaki performans ayrıntılı biçimde incelenmiştir.

Performans Ölçütleri

Deneyisel sonuçların değerlendirilmesinde, sınırlı veri koşullarında modellerin genelleme kapasitesini bütüncül bir biçimde ölçebilmek amacıyla farklı aşamalarda çeşitli performans metrikleri kullanılmıştır (Çizelge 2). Eğitim ve doğrulama süreçlerinde, modelin öğrenme dinamiklerini ve dengeleme yeteneğini izleyebilmek adına doğruluk (Accuracy), kayıp (Loss), kesinlik (Precision), duyarlılık (Recall) ve F1-Skoru gibi sınıflandırma odaklı göstergelere ek olarak, modelin ayırt edici gücünü yansıtan Receiver Operating Characteristic – Area Under the Curve değeri de hesaplanmıştır. Test aşamasında, genel sınıflandırma başarısını yansıtan doğruluk (Accuracy) ölçütünün yanı sıra, her bir sınıf için ayrı ayrı ROC eğrileri oluşturulmuş ve bu eğrilere karşılık gelen AUC değerleri raporlanmıştır. Buna ek olarak, özellikle tarımsal hastalık tanısı gibi kritik uygulama alanlarında önem arz eden en iyi duyarlılık (Best Sensitivity) ve en iyi özgüllük (Best Specificity) değerleri de hesaplanarak tablo formatında sunulmuştur. Bu sayede, modelin hem sınıflar arasında ayırt etme kabiliyeti hem de yanlış pozitif ve yanlış negatif oranlarına karşı duyarlılığı bütüncül bir şekilde analiz edilmiştir.

Eğitim Ortamı ve Hiperparametreler

Tüm deneysel çalışmalar, PyTorch kütüphanesi (Paszke ve ark., 2019) kullanılarak yürütülmüş olup eğitim süreci NVIDIA RTX 3070Ti GPU donanımıyla hızlandırılmıştır. Modelin meta-öğrenme performansını eniyilemek amacıyla belirli hiperparametre ayarları tercih edilmiştir. İç güncelleme adım sayısı 8 olarak belirlenmiş; dış döngü öğrenme oranı 0.0001, iç döngü öğrenme oranı ise 0.002 olarak yapılandırılmıştır. Her görevde, destek (support) ve sorgu (query) örneklerinin dağılımı sırasıyla 5 ve 15 olarak düzenlenmiştir. Ayrıca, modelin aşırı öğrenmesini önlemek ve eğitim sürecini daha verimli hâle getirmek amacıyla, doğrulama kaybında ardışık beş epok boyunca iyileşme gözlemlenmediği durumlarda erken durdurma stratejisi uygulanmıştır.

Çizelge 2. Eğitim, doğrulama ve test işlemlerinde sonuçları değerlendirmek için kullanılan metrikler


Metrik	Açıklama	Formül
TP (True Positive)	Modelin, hastalıklı yaprağı doğru şekilde hastalıklı olarak tahmin etmesidir.	$TP = \sum_{i=1}^n [y_i = 1] \cdot [\hat{y}_i = 1]$
TN (True Negative)	Modelin, sağlıklı yaprağı doğru şekilde sağlıklı olarak tahmin etmesidir.	$TN = \sum_{i=1}^n [y_i = 0] \cdot [\hat{y}_i = 0]$
FP (False Positive)	Modelin, sağlıklı yaprağı yanlışlıkla hastalıklı olarak tahmin etmesidir.	$FP = \sum_{i=1}^n [y_i = 0] \cdot [\hat{y}_i = 1]$
FN (False Negative)	Modelin, hastalıklı yaprağı yanlışlıkla sağlıklı olarak tahmin etmesidir.	$FN = \sum_{i=1}^n [y_i = 1] \cdot [\hat{y}_i = 0]$
Kayıp (Cross-Entropy Loss)	Bir modelin tahmin ettiği olasılık dağılımı ile gerçek etiketler arasındaki farkı ölçen bir hata fonksiyonudur.	$L = -\frac{1}{N} \sum_{i=1}^N \log(p_i, y_i)$

Çizelge 3. Eğitim, doğrulama ve test işlemlerinde sonuçları değerlendirmek için kullanılan metrikler (devamı)

Doğruluk	Modelin yaptığı doğru tahminlerin toplam tahmin sayısına oranını belirleyen bir performans ölçütüdür.	$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN}$
F1 Skor	Kesinlik (precision) ve duyarlılık (recall) ölçütlerinin harmonik ortalamasıdır.	$F1 \text{ Skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}}$
Kesinlik (Precision)	Modelin doğru pozitif tahminlerinin, toplam pozitif tahminlere oranını ölçen bir performans metriğidir.	$\text{Kesinlik} = \frac{TP}{TP + FP}$
Duyarlılık (Recall, True Positive Rate (TPR), Sensitivity)	Modelin doğru pozitif tahminlerinin, toplam gerçek pozitif örneklerle oranını ölçer.	$\text{Duyarlılık} = \frac{TP}{TP + FN}$
Yanlış Pozitif Oranı (FPR)	Modelin yanlış bir şekilde pozitif tahmin ettiği negatif sınıfların oranıdır.	$FPR = \frac{FP}{FP + TN}$
Alıcı İşletim Karakteristiği ve Eğri Altındaki Alan (ROC-AUC)	Modelin sınıflandırma performansını ve pozitif ile negatif sınıfları ayırt etme yeteneğini değerlendiren bir metriktir.	$AUC = \sum_{i=1}^{n-1} \frac{(TPR_i + TPR_{i+1})}{2} \times (FPR_{i+1} - FPR_i)$
En İyi Özgüllük (Specificity)	Modelin gerçek negatif örnekleri doğru bir şekilde tahmin etme oranını ölçen bir performans metriğidir.	$\text{Specificity} = \frac{TN}{TN + FP}$
En İyi Duyarlılık (Sensitivity)	Modelin gerçek pozitif örnekleri doğru bir şekilde tahmin etme oranını ölçen performans metriğidir.	$\text{Sensitivity} = \frac{TP}{TP + FN}$

BULGULAR VE TARTIŞMA


Bu çalışmada, ResNet tabanlı mimarilerin MAML++ algoritması ile entegre edilerek az örnekle öğrenme senaryolarındaki performansları kapsamlı biçimde değerlendirilmiştir. Elde edilen bulgular, eğitim ve doğrulama aşamalarında modelin genelleme yeteneğinde belirgin bir gelişme sağlandığını ortaya koymaktadır. Özellikle düşük örnek (shot) konfigürasyonlarında bile hızlı adaptasyon kapasitesinin sergilenmesi, meta-öğrenme yaklaşımının geleneksel derin öğrenme yöntemlerine kıyasla önemli avantajlar sunduğunu göstermektedir. Eğitim ve doğrulama süreçlerinden elde edilen doğruluk ve kayıp değerleri, modelin istikrarlı bir öğrenme eğrisi izlediğini ve aşırı öğrenme eğiliminin etkin biçimde kontrol altına alındığını göstermektedir. Bu sonuçlar, MAML++ algoritmasıyla optimize edilen ResNet mimarilerinin, sınırlı veri ortamlarında dahi güvenilir şekilde uygulanabilir olduğunu güçlü biçimde desteklemektedir.



Şekil 4. MAML++ ile ResNet-18 modelinin Eğitim ve doğrulama aşamalarına ait kayıp (loss) ve doğruluk (accuracy) değerlerinin epoklara göre değişimi

Şekil 4, eğitim sürecinde modelin performansını doğruluk ve kayıp metrikleri üzerinden görselleştirmektedir. Kayıp grafiği incelendiğinde, epok sayısındaki artışa paralel olarak hem eğitim hem de doğrulama kaybının düzenli biçimde azaldığı ve modelin artan bir genelleme kapasitesi sergilediği gözlemlenmektedir. Doğruluk grafiği ise, eğitim doğruluğunun her epokta istikrarlı bir şekilde arttığını, doğrulama doğruluğunun ise başlangıçta dalgalı bir seyir izlemekle birlikte genel eğilim itibarıyla yükseldiğini ortaya koymaktadır.

Şekil 5'te sunulan sonuçlar, ResNet-18 + MAML++ modelinin 2-way 5-shot test senaryosu kapsamındaki bulguları yansıtmaktadır. Grafikler incelendiğinde, iterasyon sayısındaki artışa bağlı olarak test kaybının sürekli azaldığı ve modelin giderek daha kararlı bir öğrenme eğilimi sergilediği gözlemlenmektedir. Doğruluk grafiği, ikinci iterasyondan itibaren doğruluk oranlarının %90 seviyesinin üzerine çıktığını ve son iterasyonda %94,67 düzeyine ulaştığını göstermektedir. Ayrıca, modelin ağırlıklı ortalama doğruluk değerinin %92,53 olarak hesaplanması, sınırlı sayıda örnekle gerçekleştirilen test senaryolarında dahi yüksek düzeyde güvenilir bir performans sergilediğini ortaya koymaktadır.



Şekil 5. ResNet-18 + MAML++ modeli için 2-way 5-shot test senaryosunda kayıp ve doğruluk grafikleri


Çizelge 3'te, ResNet-18 omurgası ile MAML++ algoritmasının entegrasyonu sonucunda gerçekleştirilen test deneylerine ilişkin bulgular sunulmaktadır. Elde edilen sonuçlar, 2-way görevlerde modelin 4-way görevlere kıyasla daha yüksek performans sergilediğini açıkça ortaya koymaktadır. Özellikle 2-way 5-shot senaryosunda, doğruluk (%92.53), F1 skoru (0.9248), kesinlik (0.9267) ve duyarlılık (0.9253) gibi temel sınıflandırma metrikleri en yüksek düzeylere ulaşmıştır. Buna ek olarak, aynı senaryoda elde edilen ROC-AUC değeri (0.9884), modelin sınıflar arasındaki ayırt edicilik kapasitesinin son derece yüksek olduğunu göstermektedir.

Çizelge 4. ResNet-18 + MAML++ çalışmasına ait test sonuçları

way-shot	Kayıp	Doğruluk	F1 Skor	En İyi Kesinlik	En İyi MSE	En İyi ROC-AUC	En İyi Duyarlılık	En İyi Özgüllük
2-way 1-shot	0.5460	86.67%	0.8652	0.8734	0.3661	0.9638	0.8677	0.9555
2-way 3-shot	0.4233	89.88%	0.8990	0.9011	0.2583	0.9809	0.8988	0.9663
2-way 5-shot	0.4150	92.53%	0.9248	0.9267	0.1687	0.9884	0.9253	0.9751
4-way 1-shot	0.6162	82.71%	0.8218	0.8267	0.5500	0.9487	0.8271	0.9424
4-way 3-shot	0.5248	85.77%	0.8570	0.8585	0.5125	0.9685	0.8577	0.9526
4-way 5-shot	0.4399	88.60%	0.8844	0.8889	0.3787	0.9784	0.8860	0.9620

Buna karşın, 4-way görevler model açısından daha zorlu bir yapı sunmuş ve doğruluk oranları görece düşük seviyelerde kalmıştır. Örneğin, 4-way 1-shot senaryosunda doğruluk %82.71 düzeyine gerilemiş; buna paralel olarak, F1 skoru da 0.8218 olarak kaydedilmiştir. Ancak shot sayısının artırılmasıyla birlikte (3-shot ve 5-shot konfigürasyonlarında), doğruluk ve diğer performans metriklerinde anlamlı iyileşmeler gözlemlenmiştir. Bu bulgular, destek örnek sayısındaki artışın modelin genelleme yeteneğini olumlu yönde etkilediğini ve az örnekle öğrenme bağlamında performansın doğrudan bu sayıya bağlı olarak güçlendiğini göstermektedir.

Genel olarak elde edilen sonuçlar, MAML++ algoritması ile ResNet-18 omurgasının birleşiminin, az örnekle öğrenme senaryolarında etkili ve uygulanabilir bir yaklaşım sunduğunu ortaya koymaktadır. Özellikle sınıf sayısının düşük olduğu görevlerde (2-way) ve destek örneği sayısının artırıldığı durumlarda (5-shot), modelin performansında belirgin artışlar gözlemlenmiştir. Bu bulgular, veri kısıtlılığına sahip alanlarda MAML++ tabanlı çözümlerin güçlü bir alternatif olabileceğini göstermektedir. Şekil 6’da en başarılı senaryoya ait karmaşıklık matrisi sunularak modelin sınıflar arası ayırt etme yeteneği görsel olarak da desteklenmiştir.



Şekil 6. ResNet-18 + MAML++ deneyinde 2-way – 5-shot için karmaşıklık matrisi

Çizelge 4’te sunulan veriler, farklı ResNet mimarilerinin (ResNet-18, ResNet-34 ve ResNet-50) MAML++ algoritması ile entegre edilerek 2-way 5-shot senaryosunda gösterdikleri performansları karşılaştırmalı olarak ortaya koymaktadır. Elde edilen bulgular, ağ derinliğindeki artışın her zaman doğrusal bir performans iyileşmesi sağlamadığını açıkça göstermektedir.

Çizelge 5. Resnet 18, 34 ve 50 modellerinin 2-way 5-shot deney sonuçları

Model	way-shot	Kayıp	Doğruluk	F1 Skor	En İyi Kesinlik	En İyi MSE	En İyi ROC-AUC	En İyi Duyarlılık	En İyi Özgüllük
ResNet18	2-way 5-shot	0.4150	92.53%	0.9248	0.9267	0.1687	0.9884	0.9253	0.9751
ResNet34	2-way 5-shot	0.5858	89.40%	0.8936	0.8943	0.1960	0.9794	0.8940	0.9647
ResNet50	2-way 5-shot	0.5499	92.40%	0.9237	0.9244	0.1900	0.9873	0.9240	0.9747

Özellikle ResNet-18 mimarisi, en düşük kayıp değeri (0.4150) ve en yüksek doğruluk oranı (%92.53) ile dikkat çekici bir performans sergilemiştir. Ayrıca F1 skoru (0.9248), kesinlik (0.9267) ve duyarlılık (0.9253) gibi önemli sınıflandırma metriklerinde de üstün sonuçlar elde edilmiştir. Bu bulgular, görece daha sığ bir mimariye sahip olan ResNet-18’in, az örnekle öğrenme senaryolarında daha hızlı ve etkili bir genelleme yeteneğine sahip olabileceğini göstermektedir.

ResNet-34 mimarisi, diğer iki modele kıyasla daha düşük bir performans sergileyerek %89.40 doğruluk ve 0.8936 F1 skoru elde etmiştir. Daha derin bir yapıya sahip olan ResNet-50 ise %92.40 doğruluk oranı ile ResNet-18’e oldukça yakın sonuçlar üretmiş; ancak bu mimaride kaydedilen daha yüksek kayıp değeri (0.5499) dikkat çekmiştir. Bununla birlikte, tüm modellerde ROC-AUC değerlerinin 0.97’nin üzerinde seyretmesi, sınıflar arasında güçlü bir ayırt edicilik sağlandığını ve modellerin sınıflandırma görevlerinde yüksek ayırım kapasitesine sahip olduğunu ortaya koymaktadır.

Bununla birlikte, tablo yalnızca performans metriklerini değil, aynı zamanda model karmaşıklığının getirdiği hesaplama yükü ve genelleme davranışlarını da dolaylı biçimde yansıtmaktadır. ResNet-18’in yaklaşık 11.7 milyon parametreye sahip olması, ResNet-34 (21.8 milyon) ve ResNet-50 (25.6 milyon) modellerine göre belirgin biçimde daha hafif bir yapıya işaret etmektedir.

Parametre sayısındaki bu fark, küçük örnek boyutlarında (örneğin 5-shot senaryolarında) overfitting riskini azaltmakta ve ResNet-18'in daha kararlı bir öğrenme dinamiği sergilemesine katkı sağlamaktadır. Buna karşılık, derin modellerin artan katman sayısı ve parametre yoğunluğu, sınırlı veri altında aşırı uyum (overfitting) eğilimini güçlendirebilir; bu da ResNet-34 ve ResNet-50'de gözlemlenen daha yüksek kayıp değerleriyle tutarlıdır.

Sonuç olarak, ResNet-18'in elde ettiği dengeli doğruluk-kayıp profili, model karmaşıklığı ile genelleme performansı arasında optimal bir denge kurduğunu göstermektedir. Bu durum, az örnekle öğrenme ortamlarında daha kompakt ve hesaplama açısından verimli modellerin tercih edilmesinin, hem eğitim süresi hem de donanım uyumluluğu açısından pratik avantajlar sağlayabileceğini ortaya koymaktadır.

Bu çalışma, sınırlı veri koşullarında bitki hastalıklarının tespitinde meta-öğrenme tabanlı yaklaşımların etkinliğini ortaya koymuştur. MAML++ algoritmasının ResNet mimarileriyle entegrasyonu, az örnekle öğrenme senaryolarında yüksek genelleme kapasitesi sunmuştur. Bulgular, destek örnek sayısının (shot) başarıyı artırdığını, sınıf sayısının (way) ise görevin zorluk düzeyini belirlediğini göstermektedir. En yüksek doğruluk 2-way 5-shot senaryosunda elde edilirken, daha karmaşık görevlerde performans azalmıştır. Ayrıca, ağ derinliğinin tek başına başarıyı garanti etmediği; daha sık ve düşük parametrelili ResNet-18'in bazı durumlarda ResNet-50'den üstün sonuçlar verdiği görülmüştür. Bu durum, sınırlı veri ve donanım koşullarında kompakt mimarilerin daha uygun bir seçenek olduğunu ve Kamilaris ve Prenafeta-Boldú (2018) tarafından vurgulanan hesaplama verimliliği ilkesini desteklemektedir.

SONUÇ

Bu çalışma, sınırlı veri koşullarında bitki hastalığı tespitinde ağ derinliğinin her zaman performansı artırmadığını göstermiş ve MAML++ ile entegre edilen hafif ResNet-18 mimarisinin, daha derin modellere kıyasla hem daha verimli hem de benzer doğrulukta bir alternatif sunduğunu kanıtlamıştır. Bu durum, sınırlı veri altında daha derin ağların yüksek parametre sayısı nedeniyle aşırı uyum (overfitting) eğilimine girmesi, buna karşılık ResNet-18'in daha az parametrelili yapısının genelleme açısından avantaj sağlaması ile açıklanabilir. Ayrıca, artan ağ derinliği optimizasyon sürecini zorlaştırarak meta-öğrenme döngüsünde istikrarsız güncellemeler oluşturabilir. Bulgular, farklı shot ve way yapılandırmalarının model performansını doğrudan etkilediğini ve meta-öğrenme yöntemlerinin sınırlı veri koşullarında kayda değer avantajlar sunduğunu göstermektedir.

Gelecekteki araştırmalar açısından, PlantVillage gibi kontrollü ortamlarda elde edilen verilerin yanı sıra gerçek tarla koşullarında yapılacak testler, modellerin genelleme yeteneğini daha kapsamlı biçimde ortaya koyacaktır. Bununla birlikte, Vision Transformer (ViT) gibi yeni nesil mimarilerin meta-öğrenme algoritmalarıyla entegrasyonu ve model sıkıştırma teknikleri, düşük donanım gereksinimleriyle daha yüksek performans elde edilmesine katkı sağlayabilir. Bu çerçevede, ilerleyen çalışmalarda meta-öğrenme tabanlı yaklaşımların saha koşullarına uyarlanması, tarımsal hastalık tespitinde daha yaygın ve uygulanabilir yapay zekâ çözümlerinin geliştirilmesini destekleyecektir.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

KAYNAKLAR

- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., ... Asari, V. K. (2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics* 2019, Vol. 8, Page 292, 8(3), 292. doi:10.3390/ELECTRONICS8030292
- Alpsalaz, F., Özüpak, Y., Aslan, E. ve Uzel, H. (2025). Classification of maize leaf diseases with deep learning: Performance evaluation of the proposed model and use of explicable artificial intelligence. *Chemometrics and Intelligent Laboratory Systems*, 262, 105412. doi:10.1016/J.CHEMOLAB.2025.105412
- Antoniou, A., Storkey, A. ve Edwards, H. (2018). How to train your MAML. *7th International Conference on Learning Representations, ICLR 2019*. <https://arxiv.org/abs/1810.09502v3> adresinden erişildi.
- Arnal Barbedo, J. G. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180, 96-107. doi:10.1016/J.BIOSYSTEMSENG.2019.02.002
- Aslan, E. ve ÖZÜPAK, Y. (2024). Diagnosis And Accurate Classification of Apple Leaf Diseases Using Vision Transformers. *Computer and Decision Making: An International Journal*, 1, 1-12. doi:10.59543/COMDEM.V1I.10039
- Chen, L., Cui, X., Li, W., Zandonadi, R. P., Braz, R. ve Botelho, A. (2021). Meta-Learning for Few-Shot Plant Disease Detection. *Foods* 2021, Vol. 10, Page 2441, 10(10), 2441. doi:10.3390/FOODS10102441
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... Houlsby, N. (2020). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *ICLR 2021 - 9th International Conference on Learning Representations*. <https://arxiv.org/abs/2010.11929v2> adresinden erişildi.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. doi:10.1016/J.COMPAG.2018.01.009
- Finn, C., Abbeel, P. ve Levine, S. (2017). Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. *34th International Conference on Machine Learning, ICML 2017*, 3, 1856-1868. <https://arxiv.org/abs/1703.03400v3> adresinden erişildi.
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep Residual Learning for Image Recognition. <http://image-net.org/challenges/LSVRC/2015/> adresinden erişildi.
- Hospedales, T., Antoniou, A., Micaelli, P. ve Storkey, A. (2022). Meta-Learning in Neural Networks: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(9), 5149-5169. doi:10.1109/TPAMI.2021.3079209
- Hughes, David. P. ve Salathe, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics. <https://arxiv.org/abs/1511.08060v2> adresinden erişildi.
- Kamilaris, A. ve Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90. doi:10.1016/J.COMPAG.2018.02.016
- Li, J., Feng, Q., Yang, J., Zhang, J. ve Yang, S. (2025). Few-shot crop disease recognition using sequence-weighted ensemble model-agnostic meta-learning. *Frontiers in Plant Science*, 16, 1615873. doi:10.3389/FPLS.2025.1615873/BIBTEX
- Mohanty, S. P., Hughes, D. P. ve Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7(September), 215232. doi:10.3389/FPLS.2016.01419/BIBTEX

- Özüpak, Y., Alpsalaz, F., Aslan, E. ve Uzel, H. (2025). Hybrid deep learning model for maize leaf disease classification with explainable AI. *New Zealand Journal of Crop and Horticultural Science*, 53(5), 2942-2964. doi:10.1080/01140671.2025.2519570
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury Google, J., Chanan, G., ... Chintala, S. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Advances in Neural Information Processing Systems*, 32.
- Raghu, A., Raghu, M., Bengio, S. ve Vinyals, O. (2019). Rapid Learning or Feature Reuse? Towards Understanding the Effectiveness of MAML. *8th International Conference on Learning Representations, ICLR 2020*. <https://arxiv.org/pdf/1909.09157> adresinden erişildi.
- Ravi, S. ve Larochelle, H. (2022, 21 Temmuz). Optimization as a Model for Few-Shot Learning.
- Rawat, W. ve Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural Computation*, 29(9), 2352-2449. doi:10.1162/NECO_A_00990
- Rezaei, M., Diepeveen, D., Laga, H., Jones, M. G. K. ve Sohel, F. (2024). Plant disease recognition in a low data scenario using few-shot learning. *Computers and Electronics in Agriculture*, 219, 108812. doi:10.1016/J.COMPAG.2024.108812
- Savary, S., Willocquet, L., Pethybridge, S. J., Esker, P., McRoberts, N. ve Nelson, A. (2019). The global burden of pathogens and pests on major food crops. *Nature Ecology and Evolution*, 3(3), 430-439. doi:10.1038/S41559-018-0793-Y;SUBJMETA=1143,2808,449,631,706;KWRD=AGRICULTURE,GEOGRAPHY,PLANT+SCIENCES
- Sun, J., Cao, W., Fu, X., Ochi, S. ve Yamanaka, T. (2024). Few-shot learning for plant disease recognition: A review. *Agronomy Journal*, 116(3), 1204-1216. doi:10.1002/AGJ2.21285;JOURNAL:JOURNAL:14350645;PAGE:STRING:ARTICLE/CHAPTER
- Too, E. C., Yujian, L., Njuki, S. ve Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272-279. doi:10.1016/J.COMPAG.2018.03.032
- Wang, Y., Yao, Q., Kwok, J. T. ve Ni, L. M. (2021). Generalizing from a Few Examples: A Survey on Few-shot Learning. *ACM Computing Surveys*, 53(3). doi:10.1145/3386252;WEBSITE:WEBSITE:DL-SITE;REQUESTEDJOURNAL:JOURNAL:CSUR;TAXONOMY:TAXONOMY:ACM-PUBTYPE;PAGEGROUP:STRING:PUBLICATION
- Yao, H., Wang, Y., Wei, Y., Zhao, P., Mahdavi, M., Lian, D. ve Finn, C. (2021). Meta-learning with an Adaptive Task Scheduler. *Advances in Neural Information Processing Systems*, 9, 7497-7509. <https://arxiv.org/pdf/2110.14057> adresinden erişildi.