



AZ ATIŞLI ÖĞRENME: SAĞLIK VE TARIM ALANLARINDAKİ UYGULAMALARIN İNCELENMESİ

Emine VARGÜN¹

¹ Bilgisayar Teknolojileri ve Bilişim Sistemleri Bölümü, Gölhisar Uygulamalı Bilimler Yüksekokulu, Burdur Mehmet Akif Ersoy Üniversitesi, Burdur, Türkiye

ÖZET

Az atışlı öğrenme (AAÖ), sınırlı veri ile yüksek doğruluk sağlamayı amaçlayan bir makine öğrenimi yöntemidir. Bu çalışma, AAÖ'nün sağlık ve tarım gibi veri toplamanın zor olduğu alanlarda sunduğu çözümleri ele almaktadır. AAÖ, meta-öğrenme, aktarım öğrenmesi ve benzerlik tabanlı öğrenme yöntemlerini birleştirerek sınırlı veriyle yüksek doğruluk elde etmektedir. Sağlık alanında, cilt kanseri teşhisi ve göz hastalıkları gibi durumlarda AAÖ, teşhis süreçlerini hızlandırmakta ve doğruluğu artırmaktadır. Tarımda ise bitki hastalıklarının tanısını yaparak çiftçilere destek olmakta ve ürün verimliliğini artırmaktadır. Bu derleme, AAÖ'nün veri kısıtlılığı ile mücadelede sunduğu avantajları ve gelecekteki uygulama potansiyelini ayrıntılarıyla incelemektedir.

Anahtar Kelimeler: Az Atışlı Öğrenmenin, Meta-Öğrenme, Aktarım Öğrenmesi, Benzerlik Tabanlı Öğrenme, Veri Kısıtlılığı, Tıbbi Görüntüleme, Bitki Hastalığı Tanısı, Cilt Kanseri Teşhisi.

FEW-SHOT LEARNING: REVIEW OF APPLICATIONS IN HEALTH AND AGRICULTURE

ABSTRACT

Few-Shot Learning (FSL) is a machine learning method that aims to achieve high accuracy with limited data. This paper discusses the solutions that FSL offers in areas where data collection is difficult, such as healthcare and agriculture. FSL combines meta-learning, transfer learning and similarity-based learning to achieve high accuracy with limited data. In healthcare, FSL speeds up diagnosis processes and increases accuracy in cases such as skin cancer diagnosis and eye diseases. In agriculture, it supports farmers by diagnosing plant diseases and increases crop yields. This review details the advantages of FSL in tackling data limitations and its potential for future applications.

Keywords: Few-Shot Learning, Meta-Learning, Transfer Learning, Similarity-Based Learning, Data Limitation, Medical Imaging, Plant Disease Diagnosis, Skin Cancer Diagnosis.

1. GİRİŞ

Makine öğrenimi ve derin öğrenme yöntemleri, yüksek miktarda veri kullanarak karmaşık sorunları çözme yetenekleri sayesinde son yıllarda geniş bir kullanım alanı bulmuştur. Görüntü sınıflandırma, nesne tanıma, doğal dil işleme ve biyomedikal analiz gibi alanlarda kaydedilen başarılar, bu teknolojilerin sağlık, tarım, finans ve otomotiv gibi sektörlerde de hızla yaygınlaşmasına olanak sağlamıştır (Ngugi vd., 2021; Li ve Yang, 2020). Ancak derin öğrenme modellerinin başarısı, büyük oranda geniş veri setleriyle desteklenmiş, etiketlenmiş verilere dayanmaktadır. Yeterli sayıda

etiketlenmiş veri olmadan, bu modellerin performansı sınırlanmakta ve özellikle sağlık ve tarım gibi veri toplamanın maliyetli ve zaman alıcı olduğu alanlarda kullanımı zorlaşmaktadır (Camargo ve Smith, 2009).

Örneğin, tıbbi görüntüleme gibi alanlarda veri toplamak maliyetli ve zahmetli bir süreçtir. Cilt kanseri teşhisi için gerekli olan yüksek kaliteli, etiketlenmiş görüntülerin sağlanması zaman alıcıdır ve uzmanlar tarafından yapılması gerektiğinden maliyetlidir (Kaya ve Akgül, 2023). Tarım sektöründe ise bitki hastalıklarının tespiti için veri toplamak, çevresel faktörlerin etkisi ve farklı bitki türlerinin hastalık belirtilerindeki değişkenlik nedeniyle zorlayıcı olabilir. Bu gibi veri kısıtlılığı yaşanan alanlarda, Az atışlı öğrenme (AAÖ) adı verilen öğrenme paradigması, sınırlı veriyle yüksek performans elde etme hedefiyle önemli bir sonuç olarak ortaya çıkmaktadır (Sun vd., 2018; Argüeso vd., 2020).

AAÖ tıbbi görüntüleme gibi alanlarda büyük avantajlar sağlamaktadır. Özellikle sınırlı sayıda etiketlenmiş verinin olduğu durumlarda, bu yöntem, yeni hastalıkları öğrenme kapasitesini artırarak sağlık kuruluşlarının verimli bir şekilde teşhis yapmalarına olanak tanır. Meta-öğrenme gibi teknikler sayesinde, derin öğrenme modelleri çok sayıda örnek gerektirmeden yeni görevler için uyum sağlamaktadır. Tarımda, AAÖ bitki hastalıklarının tanısı için kullanılmaktadır. Çiftçiler, çevresel koşullardaki değişkenlik nedeniyle sınırlı sayıda veriyle hastalıkları tanımakta zorlanırlar. AAÖ, bu zorlukların üstesinden gelerek çiftçilere doğru ve hızlı sonuçlar sunmaktadır, böylece verimlilik artmakta ve kayıplar azalmaktadır.

Bu çalışmada, AAÖ'nün veri kısıtlılığı yaşanan çeşitli uygulama alanlarında nasıl etkili bir çözüm sunduğu, sağlık ve tarım gibi sektörlerdeki örneklerle açıklanmıştır. Çalışma, AAÖ teorik temelini, kullanılan teknikleri ve modelin dezavantajlarını inceleyerek veri kısıtlılığına karşı sağladığı çözümleri vurgulamaktadır. Geliştirilen AAÖ modellerinin avantajları ve gelecekteki araştırmalar için öneriler sunulurken, veri kısıtlılığı yaşanan alanlarda bu yöntemin etkinliği gösterilmiştir.

2. AZ ATIŞLI ÖĞRENME TÜRLERİ

AAÖ, makine öğrenimi modellerinin yalnızca birkaç örnekle öğrenmesini sağlama amacı güden bir öğrenme tekniğidir. AAÖ, veri kısıtlılığı yaşanan durumlarda sınıflandırma yapabilmek ve modellerin genelleme yeteneklerini artırabilmek için geliştirilmiştir (Fink, 2004). AAÖ, öğrenme sürecinde üç ana teknikten yararlanır: Meta-öğrenme, aktarım öğrenmesi ve benzerlik tabanlı öğrenme. Her bir teknik, sınırlı veriyle öğrenme hedefini farklı bir yaklaşımla ele almakta ve az veriyle yüksek performans elde edilmesine olanak tanımaktadır (Cheng vd., 2023).

Meta-öğrenme, bir modelin çeşitli görevler arasında deneyim kazanarak genel bir öğrenme stratejisi geliştirmesine olanak tanır. Bu teknik, özellikle farklı görevlerde modelin hızlı adaptasyonunu sağlamaktadır. Finn ve arkadaşlarının geliştirdiği Model-Agnostic Meta-Learning (MAML) yöntemi, modelin yalnızca birkaç örnekle yeni bir görevi öğrenebilmesi için başlangıç parametrelerini optimize etmektedir (Finn vd., 2017). MAML, derin öğrenme modellerini yeniden eğitmeye gerek kalmadan farklı görevlerde hızlı uyum sağlama yeteneği kazandırarak AAÖ'de yaygın bir şekilde kullanılmaktadır (Baik vd., 2021).

Meta-öğrenme teknikleri, biyomedikal veri analizi gibi alanlarda büyük avantaj sağlamaktadır. Örneğin, farklı hastalıkları sınıflandırmak için sınırlı sayıda tıbbi görüntü kullanılarak eğitim alan bir model, meta-öğrenme stratejileri sayesinde yeni bir hastalık türünü daha az sayıda örnekle öğrenebilir. Bu sayede, geniş veri kümelerine ulaşamayan sağlık kuruluşları, sınırlı veriyle bile etkili teşhis modelleri geliştirebilir (Liang, 2021; Ristaino vd., 2021).


Aktarım öğrenmesi, geniş veri kümelerinde eğitilmiş modellerin bilgisini yeni ve daha dar veri setleri için kullanma yeteneği sağlar. Bu teknik, büyük bir veri kümesinde eğitilen bir modelin, farklı fakat benzer bir görevde bilgi aktarımı yaparak daha hızlı ve etkili sonuçlar vermesini amaçlamaktadır (Li ve Chao, 2021).

Sağlık sektöründe aktarım öğrenmesi, AAÖ'nün önemli bir alt dalı olarak veri kısıtlılığına karşı etkili bir çözüm sunmaktadır. Örneğin, cilt kanseri teşhisinde kullanılan bir model, geniş bir cilt hastalıkları veri tabanında eğitildikten sonra nadir görülen cilt kanserleri gibi az veri içeren alanlarda etkin bir şekilde çalışabilmektedir. Bu şekilde, geniş bir veri tabanından elde edilen genel bilgilerin

aktarımı sayesinde nadir durumlarda bile yüksek doğruluk elde edilebilir (Kaya ve Akgül, 2023). Bu tür uygulamalar, teşhis sürecini hızlandırmakla kalmaz, aynı zamanda sağlık sistemindeki maliyetleri de düşürür (Hosny vd., 2018; Thomas vd., 2021).

Benzerlik tabanlı öğrenme yöntemleri, AAÖ kapsamında az veri ile yüksek doğruluk sağlamak için kullanılan değerli bir tekniktir. Bu yaklaşım, veri örnekleri arasındaki benzerliklere göre sınıflandırma yaparak sınırlı sayıda çalışan modeller için başarılı sonuçlar elde edilmesini sağlamaktadır (Khamparia ve Pandey, 2021). Benzerlik tabanlı öğrenme yöntemleri, özellikle görüntü sınıflandırma ve tanı süreçlerinde önemli avantaj sağlamaktadır. Örneğin, cilt kanseri gibi durumlarda az sayıda örnek ile hastalığın tanısı konulabilmektedir. Bu yöntemler, sınıflandırma görevlerinde veri örneklerini birbirine yakın konumlandırarak modelin sınıflandırma sürecinde veri yetersizliğini telafi etmektedir (Vinyals vd., 2016; Qiao vd., 2019). Bitki hastalıklarının tanısı için yapılan çalışmalarda da benzerlik tabanlı yöntemlerin kullanımı, sınırlı sayıda görüntü ile etkili tanılama yapılmasına olanak tanımaktadır (Sun vd., 2018).

Şekil 1. Few-Shot Öğrenmede Sınıf Prototiplerinin Belirlenmesi Süreci (Parnami ve Lee, 2022)



AAÖ'nün en yaygın kullanım alanları arasında sağlık, tarım ve biyomedikal analiz gibi veri kısıtlılığının belirgin olduğu alanlar bulunmaktadır. Sağlık alanında, AAÖ'nün kullanımı özellikle cilt kanseri, göz hastalıkları ve nadir görülen diğer hastalıkların teşhisinde etkili sonuçlar sunmaktadır. Bu alanlarda, yeterli sayıda etiketlenmiş veri sağlamak zor olduğundan, AAÖ veri yetersizliği sorununu aşarak güvenilir teşhis modellerinin geliştirilmesine olanak tanımaktadır (Li ve Chao, 2021; Ristaino vd., 2021).

Tarım sektöründe ise bitki hastalıklarının tanılanması, çevresel koşulların ve bitki türlerinin farklılık göstermesi nedeniyle zorluklar yaratmaktadır. AAÖ, bu sektörde sınırlı sayıda örnek ile bitki hastalıklarını tanıyan modellerin geliştirilmesine olanak tanıyarak çiftçilerin ürün kayıplarını azaltmasına yardımcı olur (Ngugi vd., 2021). Örneğin, farklı iklim ve ışık koşullarında alınan bitki hastalığı görüntüleri ile AAÖ modelleri sayesinde az veriyle doğru tanılama yapılabilir (Camargo ve Smith, 2009).

NLP alanında, genelleme kapasitesini artırmak amacıyla genellikle aktarım öğrenmesi tabanlı yaklaşımlar kullanılmaktadır. Özellikle, BERT, GPT ve T5 gibi önceden eğitilmiş büyük dil modelleri, az sayıda örnekle metin sınıflandırma, duygu analizi ve dil çevirisi gibi görevlerde başarılı sonuçlar elde edebilmektedir (Brown vd., 2020; Raffel vd., 2020). Bu modeller, genellikle büyük veri kümesiyle önceden eğitildiği için, yeni bir görevde sınırlı veriyle de etkili bir şekilde çalışabilmektedir. Bunun yanı sıra, meta-öğrenme tabanlı stratejiler, dil modellerinin daha iyi adapte olmasını sağlayan yöntemler arasında yer almaktadır (Schick ve Schütze, 2021).

Görüntü sınıflandırma alanında, genellikle meta-öğrenme ve benzerlik tabanlı yaklaşımlar tercih edilmektedir. Prototip ağırları, ilişkilendirme temelli sınıflandırma ve uyarlanabilir nöronel ağırlar, az sayıda görüntü kullanarak nesne tanıma ve tıbbi teşhis gibi görevlerde etkin bir şekilde çalışmaktadır (Vinyals vd., 2016; Snell vd., 2017).

Sonuç olarak, AAÖ'nin farklı disiplinlerde kullanılan yöntemleri, çalışma alanına göre özelleşmiş stratejilere dayanmaktadır. NLP alanında aktarım öğrenmesi ve büyük dil modelleri öne çıkarken, görüntü sınıflandırmada meta-öğrenme ve benzerlik tabanlı yöntemler daha etkili olmaktadır.

3. SAĞLIK ALANINDA FEW-SHOT LEARNING UYGULAMALARI

Geleneksel yapay zekâ yaklaşımları, büyük ölçekte etiketlenmiş veri setlerine dayandığı için, veri toplamanın zor olduğu veya uzman bilgisinin gerektirdiği alanlarda sınırlılıkları vardır. Bu nedenle, sağlık alanında, veri toplamanın zorluğu ve maliyeti, yapay zekâ modellerinin etkinliğini sınırlamaktadır. Bu bölümde, sağlık alanında AAÖ'nün farklı uygulamaları incelenecektir.


Cilt kanseri, insanlar arasında en sık rastlanan ve ölümcül olabilen kanser türlerinden biridir. Melanosit adı verilen cilt hücrelerinin kontrolsüz çoğalması sebebiyle ortaya çıkan bu kanser türü, deri yüzeyindeki leke veya benlerde meydana gelen değişikliklerle kendini gösterebilir. Cilt kanserinin erken tespit edilmesi hayati önem taşırken, geleneksel tanı yöntemleri, uzman doktorlar tarafından yapılan gözlemler ve biyopsi gibi zahmetli ve maliyetli süreçlere dayanmaktadır. Bu süreçlerin maliyetli ve zaman alıcı olması, özellikle uzman eksikliği yaşanan bölgelerde erken teşhis imkanlarını kısıtlamaktadır (Ergün ve Kılıç, 2023).

AAÖ, cilt kanserinin tespitinde etkin bir çözüm olarak karşımıza çıkmaktadır. AAÖ, sınırlı sayıda etiketlenmiş veri ile modelin öğrenmesini sağlayarak, cilt kanseri gibi nadir görülen vakalarda etkili sonuçlar elde edilmesini mümkün kılmaktadır. Örneğin, VGGNet gibi derin öğrenme modelleri kullanılarak yapılan çalışmalarda, VGG-11 mimarisi %83 doğruluk oranı ile cilt kanserini başarıyla sınıflandırmıştır (Kaya ve Akgül, 2023). Bu başarı, cilt kanseri gibi nadir veri bulunabilen hastalıkların tespitinde AAÖ'nün çok değerli bir yöntem olduğunu ortaya koymaktadır. Ayrıca, hasta başvuru süreçlerinde hızlı tanı koyma şansı sağlamaktadır ve bu sayede hastaların tedaviye daha erken başlaması mümkün olur. Bu da kanserin ilerlemesini önleyerek sağlık çıktılarını iyileştirmektedir.

Sağlık alanındaki AAÖ uygulamalarında, meta-öğrenme tabanlı yöntemlerin kullanımı da yaygındır. Meta-öğrenme, bir öğrenme algoritmasının, önceden öğrenilmiş benzer görevlerden elde edilen bilgilerle yeni bir göreve hızlı bir şekilde uyum sağlamasını amaçlar. Bu yöntemler, özellikle tıbbi veri setlerinde, her bir hastalığın belirli bir tanımını yapmak için kullanılan veri sayısını azaltarak, tıbbi tanının maliyetini ve zamanını düşürmektedir. Örneğin, Metal (Meta-Learning with Task-Adaptive Loss) olarak adlandırılan bir meta-öğrenme çerçevesi, farklı tıbbi görevlerde adaptif kayıp fonksiyonları kullanarak genelleme performansını artırabilmektedir (Baik vd., 2021).

AAÖ'de az sayıda örneğin daha verimli öğrenilebilmesi için bu örnekler belirli bir "özellik uzayına" dönüştürülür. Şekil 2'deki gömme işlevi bunu temsil etmektedir. AAÖ'de model, yeni bir sınıfın öğreniminde mevcut sınıflara olan benzerliği değerlendirir. Şekildeki mesafe ölçümü fonksiyonu bu bağlamda önemlidir. Model, düşük mesafe/daha yüksek benzerlikle, yeni örnekleri mevcut kategorilere atamayı öğrenmektedir. AAÖ yöntemlerinden biri de prototip tabanlı yöntemdir. Diyagram, her sınıfın bir "prototip vektörü" ile temsil edilmesi ve yeni verilerin bu prototiplere göre sınıflandırılmasını göstermektedir. Bu tür yöntemler, özellikle az veriyle model eğitiminin gerektiği sağlık görüntüleme, dil işleme veya nadir görülen olayların sınıflandırılması gibi alanlarda yaygın olarak uygulanmaktadır.

Şekil 2. Embedding ve Mesafe Ölçümüyle Yapılan Sınıf Tahmini (Parnami ve Lee, 2022)



Tıbbi veriler, genellikle farklı cihazlarla veya farklı koşullarda toplanır ve bu da veri setinde heterojenlik yaratır. Bu durum, AAÖ modellerinin genelleme kabiliyetini sınırlandırabilir. Bunun yanı sıra, etik ve gizlilik endişeleri de tıbbi veri toplamanın önünde bir engel olarak durmaktadır. Tıbbi görüntü analizinde, veri dengesizliği büyük bir sorun oluşturabilir. Bu dengesizlikler, özellikle hastalık sınıfları arasındaki veri sayısı farklılıklarından kaynaklanır. AAÖ yaklaşımında Laplacian düzenlemesi, bu tür veri dengesizliklerinin üstesinden gelmek için kaliteli bir çözüm sunar. Laplacian Regularized AAÖ, etiketlenmemiş verilerin etiketli verilere yakın olmasını teşvik ederek sınıflandırma performansını artırır. LaplacianShot olarak bilinen bu yöntem, tıbbi görüntü analizi alanında çıkarım kullanarak sınırlı sayıda veriyle etkili sonuçlar sunmaktadır. Özellikle tıbbi veri setlerinin dengesiz olduğu durumlarda, Laplacian düzenlemesi, verilerin gruplanmasını sağlayarak modelin genelleme yeteneğini artırmaktadır. Bu, özellikle kanser veya nadir hastalıkların teşhisinde yüksek başarı oranları elde edilmesini sağlamaktadır (Ziko vd., 2021).

AAÖ'nün sağlık alanında etkili, hızlı ve başarılı bir şekilde uygulanabilmesi için, tıbbi verilerin toplanması ve etiketlenmesi süreçlerinin iyileştirilmesi, modellerin daha esnek ve adaptif hale getirilmesi önemlidir. Aynı zamanda, sağlık profesyonelleri ile iş birliği yapılarak, bu teknolojilerin klinik kullanıma uygun hale getirilmesi gerekmektedir. Bu sayede, AAÖ'nün sağlık hizmetlerine entegre edilmesi ile hastalıkların erken teşhisi ve buna istinaden tedavisi mümkün olabilir, bu da genel sağlık çıktılarının iyileşmesine katkı sağlayabilir.

Tablo 1, AAÖ yöntemlerinin tıbbi görüntüleme ve tıbbi metin işleme gibi çeşitli alanlardaki uygulamalarını özetlemektedir. Meta-Öğrenme ve derin öğrenme tabanlı modeller en sık kullanılan yöntemlerdir. Çoğu tıbbi görüntü sınıflandırma ve metin işleme uygulamalarında meta-öğrenme tabanlı yöntemler (Prototipik Ağlar, Model-Agnostic Meta-Learning - MAML) tercih edilmiştir. Derin öğrenme modellerinden DenseNet-121, VGGNet, Few-Shot U-Net ve ResNet gibi önceden eğitilmiş ağlar, özellikle görüntü sınıflandırma ve segmentasyon görevlerinde yaygın olarak kullanılmıştır. AAÖ, görüntü işleme ve doğal dil işleme (NLP) alanlarında sıkça kullanılmıştır. Kanser teşhisi ve sınıflandırması için histopatolojik görüntüler, PET/CT taramaları, ultrason görüntüleri ve dermoskopik görüntüler kullanılmıştır. MIMIC-III gibi büyük tıbbi metin veri setlerinden yararlanılarak AAÖ teknikleriyle tıbbi metin işleme çalışmaları yürütülmüştür. DenseNet-121 tabanlı meme kanseri sınıflandırması ile %96 doğruluk, Meta-DermDiagnosis modeli ile %86,8 doğruluk, KNN tabanlı endometrial kanser modeli ile %87,8 doğruluk, VGGNet ile cilt kanseri sınıflandırması ile %83 doğruluk elde edilmesi yüksek doğruluk sağlandığının göstergesidir.

Turning Point (TP) yöntemi, COVID-19 tanısında mevcut yöntemlere göre %12,96 daha iyi sonuç vermiştir. PMF yöntemi, akciğer kanseri metastazı sınıflandırmada transfer öğrenmeye kıyasla %6,2 daha yüksek doğruluk sağlamıştır. Few-Shot U-Net, PET/CT görüntülerinde akciğer kanseri segmentasyonu için diğer yöntemlere kıyasla %8,89 daha yüksek doğruluk göstermiştir. Bu başarı oranları geleneksel yöntemlere göre AAÖ'nin avantajı olarak karşımıza çıkmaktadır.


Tablo 1. Sağlık Alanında Few-Shot Learning Uygulamaları

UYGULAMA ALANI	KULLANILAN METOT	VERİ TABANI	AMAÇ	SONUÇ
COVID-19 Tanısı	Turning Point (TP) Yaklaşımı	COVID-19 Veri Seti	COVID-19 erken teşhisi için az örnekle öğrenme modelleri geliştirmek.	TP, mevcut yöntemlere göre %12,96 daha iyi sonuç verdi.
Meme Kanseri Sınıflandırması	DenseNet-121 ile Few-Shot Meta-Öğrenme	CBIS-DDSM, INbreast	Meme kanseri evrelerini doğru bir şekilde sınıflandırmak.	Yoğun veri eksikliği durumlarında %96 doğruluk sağlandı.
Tıbbi Metin İşleme	Meta-Öğrenme Tabanlı Prototipik Ağlar	MIMIC-III, Sentetik Veri Setleri	Tıbbi metin işleme için az örnekle öğrenme yöntemlerini sistematik olarak incelemek.	Meta-öğrenme yöntemleri tıbbi NLP için umut verici sonuçlar verdi.
Akciğer Kanseri Metastazı Sınıflandırması	Batch Spectral Regularization ve PMF	Cytological Imaging Veri Setleri	Akciğer metastazı hücre görüntülerini sınıflandırmak.	PMF, transfer öğrenmeye göre %6,2 daha yüksek doğruluk elde etti.
Akciğer Kanseri Segmentasyonu	Few-Shot U-Net	PET/CT Görüntüleri	Akciğer kanseri lezyonlarının PET/CT görüntülerinden segmentasyonu.	AAÖ, diğer yöntemlere göre %8,89 daha yüksek doğruluk sağladı.
Kanser Türleri Arasında Genom Çoğaltma Sınıflandırması	Model-Agnostic Meta-Learning (MAML)	17 Farklı Kanser Türünden Histopatolojik Görüntüleri	Kanser türleri arasında genom çoğaltma sınıflandırmasını otomatikleştirmek.	Meta-öğrenme, standart yöntemlere göre üstün sonuçlar verdi.
Cilt Kanseri Sınıflandırması	VGGNet	ISIC 2018 Veri Seti	Cilt kanseri türlerini sınıflandırmak.	VGG-11 mimarisi ile %83 doğruluk sağlandı.
Cilt Hastalıkları Sınıflandırması	Meta-DermDiagnosis	Derm7pt, SD-198	Az veri ile cilt hastalıklarını teşhis etmek.	Meta-DermDiagnosis, sınırlı veriyle %86,8 doğruluk sağladı.
Endometrial Kanseri Tanısı	Çift Ön Eğitimli ResNet50 V2 ve KNN	Trans vajinal Ultrason Görüntüleri	Endometrial hiperplazi ve kanser türlerini sınıflandırmak.	KNN tabanlı model %87,8 doğruluk ile en iyi performansı gösterdi.
Meme Kanseri Görüntülerinin Sınıflandırılması	Prototipik Ağlar ve MAML	BUSI Veri Seti	Meme kanseri tanısında doğruluğu artırmak için meta-öğrenme yöntemlerini kullanmak.	ProtoNet %7,1 iyileştirilmiş doğruluk oranı sundu.

4. TARIM ALANINDA FEW-SHOT LEARNING UYGULAMALARI

Tarım sektörü, bitki hastalıklarının erken teşhisi ve ürün verimliliğinin artırılması gibi konularda büyük veri ihtiyaçları olan bir alandır. Ancak, tarımsal veri toplamanın zorlukları ve maliyetleri, geleneksel derin öğrenme yöntemlerinin uygulanmasını sınırlamaktadır. AAÖ, bu noktada tarımda yenilikçi bir çözüm olarak karşımıza çıkmaktadır. Sınırlı sayıda örnekle bitki hastalıklarını tanımlamak veya ürün sınıflandırmak gibi görevlerde AAÖ kullanımı, ekonomi ve zaman açısından büyük avantajlar sunmaktadır. Bu bölümde, tarım alanında AAÖ'nün farklı uygulamaları incelenecektir.

Şekil 3. Metric Learning Stratejisinin Genel İşleyişi (Parnami ve Lee, 2022)



Bitki hastalıkları, tarımsal üretimi tehdit eden ve ciddi verim kayıplarına yol açabilen en önemli sorunlardan biridir. Geleneksel olarak bitki hastalıklarının tanısı, uzmanların gözlemleri ve laboratuvar analizleri gibi zaman alıcı ve maliyetli yöntemlerle yapılmaktadır. Ancak, bu yöntemlerin uygulanabilirliği büyük ölçüde uzmanların bilgi ve deneyimine bağlıdır. AAÖ, sınırlı sayıda veri ile bitki hastalıklarını tanımlayarak bu süreci hızlandırmayı ve maliyetleri düşürmeyi amaçlamaktadır (Esen ve Onan, 2022).

AAÖ, özellikle bitki hastalıklarının erken teşhisi için derin öğrenme modelleri ile birlikte kullanıldığında, etkili sonuçlar sunmaktadır. Örneğin, bitki hastalıklarını sınıflandırmak için kullanılan bir AAÖ modeli, sadece birkaç örnek görüntü kullanarak farklı hastalıkları %90'a varan doğrulukla tanımlayabilmektedir (Argüeso vd., 2020). Bu da AAÖ'nün tarımda erken uyarı sistemleri ve hastalık yönetimi gibi alanlarda önemli bir gizli potansiyele sahip olduğunu göstermektedir.


AAÖ'nin eğitim stratejisinin genel yapısının ve süreçlerinin görselleştirildiği Şekil 4'te bir modelin yalnızca birkaç örnekle yeni görevleri öğrenebilmesi hedeflenir ve bu süreçte iki ana aşama öne çıkar: Meta-öğrenme ve meta-test. Meta-Öğrenme, eğitim sırasında verilen küçük bir destek seti üzerinde çalışarak belirli bir göreve ilişkin genel bir öğrenme stratejisi geliştirir. Bu aşamada, model yalnızca sınırlı sayıda etiketli örnek görür. Bu süreç, AAÖ'nin temel taşıdır çünkü model az miktardaki veriden genellemeyi öğrenir. Meta-Test aşamasında model, daha önce görmediği veri üzerinde test edilir. Amaç, meta-öğrenme sırasında edindiği bilgileri kullanarak sorgu setindeki verileri doğru sınıflandırmaktır. Bu aşama, modelin "transfer" yeteneğini ölçmek için önemlidir, yani öğrendiği genel kuralları yeni durumlara nasıl uyguladığı değerlendirilir.

AAÖ, transfer öğrenme ve meta-öğrenme yöntemleri ile birleştirildiğinde, tarımsal hastalıkların teşhisinde büyük avantajlar sunmaktadır. Transfer öğrenme, önceden öğrenilmiş bir modelin bilgi birikimini kullanarak yeni bir görevde daha hızlı ve etkin öğrenme sağlar. Tarımsal uygulamalarda, farklı bitki türleri üzerinde eğitilmiş bir model, başka bir bitki türündeki hastalığı tanımlamak için kullanılabilir. Bu şekilde, veri sınırlamalarının üstesinden gelinerek hızlı ve etkili bir tanı süreci elde edilmektedir (Aybar vd., 2024).


Meta-öğrenme ise modelin farklı tarımsal görevlerde hızlı bir şekilde adapte olmasını sağlamaktadır. Örneğin, farklı bitki türlerindeki hastalıkların teşhisi için kullanılan bir meta-öğrenme

modeli, her bitki türü için özel olarak optimize edilmiş kayıp fonksiyonları kullanarak daha yüksek doğruluk oranları elde edebilir. Bu sayede, tarımda hastalık yönetimi ve ürün verimliliği artırılabilir (Argüeso vd., 2020).

Şekil 4. Few-Shot Öğrenme ile Yapılan Bitki Hastalığı Tanısı Örneği (Parnami ve Lee, 2022)



Şekil 5. Few-Shot Öğrenmede Overfitting ve Fitting Farkı Görseli (Yang vd., 2022)



Tarım alanında uygulanan AAÖ uygulamaları ile ilgili verilen Tablo 2 incelendiğinde, Meta-öğrenme ve Sinirsel Mimari Arama (METANAS) yöntemi, genelleme yeteneği yüksek, çok sayıda sınıflı öğrenebilen ve farklı görevler için hızla uyum sağlayabilen modellerin geliştirilmesine olanak tanır. Burada önemli olan, verilen sınırlı veri ile iyi sonuçlar elde edilmesidir. Tarım Hastalık Sınıflandırması (Üçlü Kayıp ile Azörnekli Öğrenme), azörnekli öğrenme yöntemlerinin tarım alanında kullanımı, verilerin sınırlı olduğu ancak hızlı ve doğru teşhislerin gerektiği alanlarda önemli bir başarıdır. Bu sonuç, gerçek dünya problemlerine yönelik etkili uygulamaları işaret etmektedir. Dinamik Görsel Öğrenme (Dikkat Temelli Ağırlık Üretici), yeni kategorilerin hızlı öğrenilmesi, temel kategorilerde performans kaybı yaşamadan yeni kategorilerin öğrenilebilmesidir. İnsan Seviyesinde Kavram Öğrenimi (Bayesci Program Türetimi), bu tür bayesci yaklaşımlar, insan benzeri öğrenme süreçlerini taklit etmeye yönelik önemli bir adımdır. İnsan seviyesinde genelleme yapmak, yapay zekanın daha esnek ve adaptif olmasını sağlamaktadır. Karşıt Özellik Halüsinasyon Ağı, modelin daha geniş bir özellik setini öğrenmesine olanak tanır, bu da daha ayırıcı ve çeşitliliği artıran sonuçlara yol açmaktadır. Nesne Tanıma için Örnek Sentezi (Delta-kodlayıcı), bu metodun, sınırlı sayıda örnek ile yüksek doğruluk sağlaması, örnek üretme ve sentezleme süreçlerinin önemini vurgulamaktadır. Eşleme Ağları ile Tekörnekli Öğrenme (Eşleme Ağları), tek bir örnekle yeni sınıfların öğrenilmesini sağlayarak önemli bir adım atmaktadır. Prototip Ağları sınıflar arasındaki temsil ilişkilerini daha etkili şekilde öğrenerek, az örnekle yüksek doğruluk sağlamaktadır. İlişki Ağları, örnekler arasındaki ilişkileri öğrenerek, az veya sıfır örnekle öğrenmeyi

daha etkili hale getirmektedir. Görüntü Sınıflandırması için Toprak Taşıma Mesafesi (DerinEMD), görsel benzerlikleri daha derinlemesine analiz ederek azörnekli görevlerde başarılı sonuçlar elde edilmesini sağlamaktadır. Bu yöntemler, sınırlı veri ile yüksek doğruluk elde etmek amacı gütmekte ve her bir çalışma, farklı alanlarda (tarım, görsel öğrenme, nesne tanıma vb.) önemli başarılar elde etmiştir. Bu da azörnekli öğrenme metodlarının özellikle veri sınırlı ortamlarda güçlü performans gösterdiğini ve çeşitli alanlarda potansiyel kullanım alanları sunduğunu göstermektedir.

Tablo 2. Tarım Alanında Few-Shot Learning Uygulamaları

UYGULAMA ALANI	KULLANILAN METOT	VERİ TABANI	AMAÇ	SONUÇ
Meta-öğrenme ve Sinirsel Mimari Arama	METANAS	Mini-ImageNet, Omniglot	Meta-öğrenme ve göreve özgü mimari adaptasyonu.	Azörnekli sınıflandırma benchmarklarında son teknoloji sonuçlar elde edilmiştir.
Tarım Hastalık Sınıflandırması	Üçlü Kayıp ile Azörnekli Öğrenme	PlantVillage Dataset	Küçük veri setleriyle bitki hastalıklarını sınıflandırmak.	Minimum veri ile %94 doğruluk oranına ulaşılmıştır.
Dinamik Görsel Öğrenme	Dikkat Temelli Ağırlık Üretici	Mini-ImageNet	Yeni görsel kategorileri dinamik olarak öğrenmek.	5-örnekli görevlerde %73 doğruluk sağlanmış ve temel kategorilerde performans kaybı yaşanmamıştır.
İnsan Seviyesinde Kavram Öğrenimi	Bayesci Program Türetimi	Omniglot, MNIST	Bayesci modellerle insan benzeri genelleme yapmak.	Omniglot sınıflandırma görevlerinde insan seviyesinde performans elde edilmiştir.
Karşıt Özellik Halüsinasyon Ağı	Karşıt Özellik Halüsinasyon Ağları	Multiple Benchmarks (e.g., CIFAR-100)	Azörnekli öğrenmede çeşitlilik ve ayrımcılığı artırmak.	Standart benchmarklarda diğer azörnekli öğrenme yöntemlerinden daha iyi sonuçlar alınmıştır.
Nesne Tanıma için Örnek Sentezi	Delta-kodlayıcı	Standard Few-Shot Classification Benchmarks	Yeni kategoriler için delta dönüşümleri kullanarak örnekler üretmek.	Tekörnekli tanıma görevlerinde performans artırılmıştır.
Eşleme Ağları ile Tekörnekli Öğrenme	Eşleme Ağları	Omniglot, ImageNet	Yeni sınıflar için hızlı öğrenme sağlamak.	Omniglot'ta tekörnek doğruluğu %93.8'e yükseltilmiştir.
Prototip Ağları ile Azörnekli Öğrenme	Prototip Ağları	CU-Birds, Mini-ImageNet	Azörnekli sınıflandırma için küme tabanlı temsil.	CU-Birds ve Mini-ImageNet üzerinde son teknoloji sonuçlar elde edilmiştir.
İlişki Ağları ile Azörnekli Öğrenme	İlişki Ağları	Mini-ImageNet, CUB	Sorgu görsellerini az örnekli örneklerle ilişkisel olarak karşılaştırmak.	Az ve sıfır örnekli öğrenme için birleşik bir yaklaşım sunulmuştur.
Görüntü Sınıflandırması için Toprak Taşıma Mesafesi	DerinEMD	Mini-ImageNet, CIFAR-100, CUB	Yapılandırılmış görüntü sınıflandırması için en uygun eşleşmeyi hesaplamak.	1 ve 5 örnekli görevlerde yeni son teknoloji performanslara ulaşılmıştır.

AAÖ'nün tarımda başarılı bir şekilde uygulanabilmesi için, veri toplama süreçlerinin iyileştirilmesi ve modellerin daha esnek hale getirilmesi önemlidir. Çiftçiler ve tarım uzmanları ile iş birliği yapılarak, AAÖ tabanlı sistemlerin tarımsal üretimde kullanılabilirliği artırılmalıdır. Bu sayede, bitki hastalıklarının erken teşhisi, ürün verimliliğinin artırılması ve tarımsal süreçlerin optimize edilmesi mümkün olabilir. Geliştirilen meta-öğrenme, kendiliğinden denetimli öğrenme ve Laplacian düzenlemeli yaklaşımlar, tarımda AAÖ'nün etkinliğini artırmakta ve bu alanda yenilikçi çözümler sunmaktadır (Argüeso vd., 2020).

4. SONUÇ

AAÖ, sınırlı veriyle yüksek doğruluk elde etmeyi amaçlayan, makine öğrenimi ve yapay zekanın sınırlarını yeniden tanımlayan bir yöntemdir. Sağlık, tarım ve diğer veri kısıtlı alanlarda çözüm sunma kabiliyeti ile dikkat çeken AAÖ, son yıllarda hızla gelişmekte ve uygulanmaktadır. Bu sonuç bölümünde, elde edilen bulgular ışığında AAÖ'nün genel potansiyeli, sınırlamaları ve gelecekteki uygulama alanları değerlendirilecektir.

Sağlık sektörü, yüksek doğruluk ve güvenilirlik gereksinimleri nedeniyle yapay zekâ yöntemlerine büyük ölçüde ihtiyaç duymaktadır. Ancak, veri toplamının zorluğu ve maliyetli olması, özellikle nadir hastalıkların teşhisinde geleneksel yöntemlerin yetersiz kalmasına neden olmaktadır. AAÖ, bu kısıtlılıkları aşarak sağlık alanında yenilikçi çözümler sunmaktadır.

Örneğin, cilt kanseri teşhisi için kullanılan AAÖ tabanlı modeller, yalnızca birkaç etiketlenmiş görüntüyle %83 doğruluk oranına ulaşmıştır. Benzer şekilde, meme kanseri sınıflandırmasında DenseNet-121 gibi derin öğrenme modelleri ile %96 doğruluk oranı elde edilmiştir (Tablo1). Bu başarı, sağlık sektöründe erken teşhis ve tanının önemini vurgulamaktadır. AAÖ modelleri, özellikle meta-öğrenme teknikleri ile birleştğinde, veri sınırlamalarıyla başa çıkmada oldukça etkili bir yöntem sunmaktadır.

AAÖ'nün sağlık alanındaki diğer bir önemli katkısı, maliyet ve zaman tasarrufudur. Uzman gerektiren tanı süreçlerini hızlandırarak, daha geniş bir hasta kitlesine hizmet verme potansiyelini artırır. Bununla birlikte, sağlık verilerinin heterojenliği ve etik kaygılar, AAÖ'nün sağlık uygulamalarında karşılaşılabileceği zorluklar arasında yer almaktadır.

Tarım sektöründe, ürün verimliliğini artırmak ve bitki hastalıklarını erken teşhis etmek için büyük veri setlerine olan ihtiyaç belirgindir. Ancak, çevresel değişkenlikler ve veri toplamının zorlukları, geleneksel yapay zekâ yöntemlerinin etkinliğini sınırlamaktadır. AAÖ, tarımda sınırlı veri ile yüksek doğruluk sağlayarak bu sorunların üstesinden gelmektedir.

AAÖ tabanlı modeller, bitki hastalıklarının sınıflandırılması gibi görevlerde %94 doğruluk oranlarına ulaşmış ve bu alandaki veri dengesizliklerini gidermede etkili bir araç olarak öne çıkmıştır (Tablo2). Özellikle Laplacian düzenlemeleri ve kendiliğinden denetimli öğrenme gibi yenilikçi yöntemler, sınırlı veri ile daha geniş kapsamlı uygulamalar gerçekleştirilmesini sağlamaktadır. Bu da tarımsal üretimde hastalık yönetimini optimize ederken, çiftçilere daha verimli bir üretim süreci sunmaktadır.

AAÖ, yüksek potansiyeline rağmen belirli sınırlamalara sahiptir. Sağlık ve tarım gibi sektörlerde veri toplama zorlukları, AAÖ modellerinin yaygınlaşmasını sağlamaktadır. Özellikle, heterojen veri setlerinin standartlaştırılması ve etik kaygıların giderilmesi, AAÖ'nün daha geniş ölçekte benimsenmesini sağlayacak önemli adımlardır.

Gelecekteki araştırmalar, AAÖ'nün performansını artırmayı ve daha fazla uygulama alanına erişimini sağlamayı hedeflemelidir. Özellikle, farklı sektörlerdeki veri dengesizliklerinin giderilmesi için yeni algoritmaların geliştirilmesi büyük önem taşımaktadır. Ayrıca, sağlık ve tarım gibi kritik sektörlerde AAÖ'nün entegrasyonu, bu teknolojinin gerçek dünya sorunlarına çözüm sunabilmesi açısından önemlidir.

AAÖ, sağlık ve tarım gibi veri kısıtlı alanlarda sunduğu yenilikçi çözümler ile geleceğin yapay zekâ uygulamalarına yön verecek bir yöntemdir. Gerek erken teşhis ve tanı süreçlerindeki katkıları, gerekse tarımsal üretimde sağladığı verimlilik artışı ile AAÖ, veri kısıtlılığına karşı etkili bir alternatif

sunmaktadır. Bu teknolojinin daha etkili bir şekilde benimsenmesi için araştırmaların devam etmesi ve model iyileştirmelerine odaklanması gerekmektedir.

Literatürdeki benzer çalışmalar incelendiğinde, bitki hastalıklarını sınıflandırmak için az sayıda örnekle öğrenme yöntemlerinin kullanıldığını, görev-adapte kayıp fonksiyonu ile meta-öğrenme yaklaşımının ele alındığını, bitki hastalıkları için yarı denetimli az atışlı öğrenmenin kullanıldığını görülmektedir. Bu çalışmada ise transfer öğrenme ve derin öğrenme tabanlı modellerin kullanılmasına yönelik bir inceleme yapılmıştır. Literatürdeki benzer çalışmalarla kıyaslandığında, özellikle bitki hastalıkları ve tarım teknolojileri üzerine yapılan çalışmalara katkı sağlandığını göstermektedir. Özellikle uygulama odaklılık, modelin gerçek dünya koşullarında kullanımı noktasında daha yüksek bir genellenebilirlik sunması ve sınırlı etiketli veriyle çalışma zorluklarını aşma noktasında önemli bir fark yaratmaktadır.

Bu sonuç bölümü, AAÖ'nün sunduğu fırsatları ve karşılaşılan zorlukları detaylandırarak, bu yöntemin gelecekteki gelişimi için bir rehber sunmaktadır. AAÖ'nün potansiyeli, yalnızca teknolojik yeniliklerle sınırlı kalmayıp, insan yaşamını iyileştiren somut katkılar sunma kapasitesine sahiptir.

KAYNAKÇA

- Argüeso, D., Picon, A., Irusta, U., Medela, A., San-Emeterio, M. G., Bereciartua, A. ve Alvarez-Gila, A. (2020). Few-shot learning approach for plant disease classification using images taken in the field. *Computers and Electronics in Agriculture*, 175: 105542.
- Aybar, M. Talaş, U. ve Çubukçu, B. (2024). Transfer öğrenme modelleri ile elma yapraklarında hastalık tespiti. *ESTUDAM Bilişim*, 5(2): 57–63. doi: 10.53608/estudambilisim.1556425.
- Baik, S., Yu, H. ve Rusu, A. A. (2021). Meta-learning with task-adaptive loss function for few-shot learning. *International Conference on Computer Vision (ICCV)*, 8500-8509.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... ve Amodi, D. (2020). Language models are few-shot learners. *Advances In Neural Information Processing Systems*, 33: 1877-1901.
- Camargo, A. ve Smith, J. S. (2009). An image-processing based algorithm to automatically identify plant disease visual symptoms. *Biosystems Engineering*, 102(1): 9-21.
- Chao, S. ve Belanger, D. (2024). Generalizing whole-genome doubling classification. *Harvard University*.
- Cheng, H., Wang, Y., Li, H., Kot, A. C. ve Wen, B. (2023). Disentangled feature representation for few-shot image classification. *IEEE Transactions On Neural Networks And Learning Systems*.
- Elsken, T., Staffler, B., Metzen, J. H. ve Hutter, F. (2020). Meta-learning of neural architectures for few-shot learning. *CVPR*.
- Ergün, E. ve Kılıç, K. (2021). Derin öğrenme ile artırılmış görüntü seti üzerinden cilt kanseri tespiti. *Black Sea Journal of Engineering and Science*, 4(4): 192-200. <https://doi.org/10.34248/bsengineering.938520>
- Esen, F. A. ve Onan, A. (2022). Derin öğrenme yöntemleri ile bitki yaprakları üzerindeki hastalıkların sınıflandırılması. 40: 151-155.
- Ge, Y., Guo, Y., Yang, Y., vd. (2024). Few-shot learning for medical text: A systematic review. *Emory University*.
- Gidaris, S. ve Komodakis, N. (2019). Boosting few-shot visual learning with self-supervision. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 8040-8050.
- Hosny, K. M., Kassem, M. A. ve Foad, M. M. (2018). Skin cancer classification using deep learning and transfer learning: 9th Cairo International Biomedical Engineering Conference (CIBEC) (pp. 90-93). Cairo. <https://doi.org/10.1109/CIBEC.2018.8641762>
- Işık, G. ve Paçal, İ. (2024). Meta-learning for breast cancer ultrasound classification. *Neural Computing*.
- Kaya, V. ve Akgül, İ. (2023). Classification of skin cancer using VGGNet model structures. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 13(1): 190-198.
- Khamparia, A. ve Pandey, B. (2021). Hybrid deep learning model for predicting plant diseases using image processing techniques. *Journal of Ambient Intelligence and Humanized Computing*, 12(2): 2023-2032. <https://doi.org/10.1007/s12652-020-02366-8>

- Lake, B. M., Salakhutdinov, R. ve Tenenbaum, J. B. (2015). Human-level concept learning through probabilistic program induction. *Science*.
- Li, K., Zhang, Y., Li, K. ve Fu, Y. (2020). Adversarial feature hallucination networks for few-shot learning. *CVPR*.
- Li, Y. ve Chao, X. (2021). Semi-supervised few-shot learning approach for plant diseases recognition. *Plant Methods*, 17: 68. <https://doi.org/10.1186/s13007-021-00770-1>
- Li, Y. ve Yang, J. (2020). Few-shot cotton pest recognition and terminal realization. *Computers and Electronics in Agriculture*, 169: 105240. <https://doi.org/10.1016/j.compag.2020.105240>
- Lin, C., Wei, D., Cheng, Y., vd. (2024). Few-shot learning for lung cancer metastasis classification. *NYCU*.
- Liu, H., Wang, C., Jiang, X. ve Khishe, M. (2024). A few-shot learning approach for COVID-19 diagnosis. *JAISCR*.
- Mahajan, K., Sharma, M. ve Vig, L. (2024). Meta-DermDiagnosis for skin disease identification. *CVPRW*.
- Munkhdalai, T. ve Yu, H. (2017). Meta Networks. *International Conference on Machine Learning (ICML)* içinde 70: 2554-2563.
- Ngugi, L. C., Abelowahab, M. ve Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. *Information Processing in Agriculture*, 8: 27–51. <https://doi.org/10.1016/j.inpa.2020.04.004>
- Parnami, A. ve Lee, M. (2022). Learning from few examples: A summary of approaches to few-shot learning. *arXiv preprint arXiv:2203.04291*. <https://arxiv.org/abs/2203.04291>
- Protonotarios, N., Katsamenis, I., Sykiotis, S., vd. (2024). A few-shot U-Net deep learning model. *Biomedical Physics*.
- Qiao, L., Shi, Y., Li, J., Wang, Y., Huang, T. ve Tian, Y. (2019). Transductive episodic-wise adaptive metric for few-shot learning. *International Conference on Computer Vision (ICCV)*. Retrieved from [source](9Laplacian Regularized ...).
- Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., ... ve Liu, P. J. (2020). Exploring the limits of transfer learning with a unified text-to-text transformer. *Journal of Machine Learning Research*, 21(140): 1-67.
- Ravi, S. ve Larochelle, H. (2017). Optimization as a model for few-shot learning. *International Conference On Learning Representations (ICLR)*.
- Ren, M., Triantafillou, E., Ravi, S., Snell, J., Swersky, K., Tenenbaum, J. B., Larochelle, H. ve Zemel, R. S. (2018). Meta-learning for semi-supervised few-shot classification. *International Conference on Learning Representations (ICLR)*.
- Ristaino, J. B., Anderson, P. K., Bebbler, D. P., Brauman, K. A., Cunniffe, N. J., vd. (2021). The persistent threat of emerging plant disease pandemics to global food security. *Proceedings of the National Academy of Sciences*, 118(23): e2022239118. <https://doi.org/10.1073/pnas.2022239118>
- Santoro, A., Bartunov, S., Botvinick, M., Wierstra, D. ve Lillicrap, T. (2016). Meta-learning with memory-augmented neural networks. *International Conference on Machine Learning (ICML)*, 1842-1850.
- Schick, T. ve Schütze, H. (2021). It's not just size that matters: Small language models are also few-shot learners. *arXiv preprint arXiv:2009.07118*.
- Schwartz, E., Karlinsky, L., vd. (2018). Delta-encoder: An effective sample synthesis method. *NeurIPS*.
- Snell, J., Swersky, K. ve Zemel, R. (2017). Prototypical networks for few-shot learning. *Advances in Neural Information Processing Systems (NeurIPS)*, 30: 4077-4087.
- Sun, Q., Liu, Y., Chua, T. S. ve Schiele, B. (2018). Meta-transfer learning for few-shot learning. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 403-412.
- Sung, F., Yang, Y., vd. (2018). Relation networks for few-shot learning. *CVPR*.
- Upadhyay, N., Bhargava, A., Singh, U., vd. (2024). Enhancing breast cancer classification with DenseNet-121. *medRxiv*.
- Vinyals, O., Blundell, C., Lillicrap, T., Kavukcuoglu, K. ve Wierstra, D. (2016). Matching networks for one shot learning. *Advances in Neural Information Processing Systems (NeurIPS)*, 3630-3638.
- Wang, M., Liu, W., Gu, X., vd. (2024). Few-shot learning for endometrial cancer detection. *Heliyon*.

Yang, J., Guo, X., Li, Y., Marinello, F., Ercisli, S., ve Zhang, Z. (2022). A survey of few-shot learning in smart agriculture: developments, applications, and challenges. *Plant Methods*, 18(28). <https://doi.org/10.1186/s13007-022-00866-2>

Zhang, C., Cai, Y., Lin, G. ve Shen, C. (2020). DeepEMD for few-shot image classification. *CVPR*.

Ziko, I. M., Boudiaf, M., Dolz, J., Granger, E. ve Ayed, I. B. (2021). Transductive few-shot learning: Clustering is all you need?. *arXiv preprint arXiv:2106.09516*