

Parçacık sürü optimizasyonu destekli derin öğrenme ile gül yaprağı hastalık tespiti

Burak Gülmez^{1*}

¹Leiden Institute of Advanced Computer Science, Leiden University, Netherlands

*(b.gulmez@liacs.leidenuniv.nl)

Özet – Hem tüketici talebi hem de küresel ticaret açısından güller oldukça önemli bitkilerdir. Tıpta, kozmetikte ve mutfakta çeşitli uygulamaları vardır. Bununla birlikte, güllerin gelişimi, kalitesi ve verimi bir takım hastalıklardan olumsuz etkilenebilir. Gül yapraklarını ciddi şekilde tahrip edebilen en yaygın ve zarar verici mantar hastalıklarından ikisi siyah nokta ve tüylü küftür. Başarılı hastalık yönetiminin ve güllerde başka salgınların önlenmesinin anahtarı, hastalığın erken ve kesin olarak tanımlanmasıdır. Bununla birlikte, gözle tespit ve laboratuvar testleri dahil olmak üzere geleneksel hastalık teşhis prosedürleri zahmetli, zaman alıcı ve uzman düzeyindedir. Sonuç olarak, en son teknoloji, gül yapraklarındaki hastalıkları tanımlamak için otomatik ve güvenilir bir yöntemin oluşturulmasını gerektiriyor. Bu çalışmada, gül yapraklarındaki hastalıkları tanımlamak için evrişimli sinir ağlarını (CNN) kullanan derin bir öğrenme yöntemi sunulmaktadır. Evrişimli sinir ağları (CNN) olarak bilinen yapay sinir ağları, resimlerden gelişmiş özellikleri öğrenebilmekte ve sınıflandırma ve tanımlama gibi zor görevleri yerine getirebilmektedir. Üç kategoriye ayrılmış bir veri setinden gül yaprakları görüntüleri kullanılmıştır. Siyah nokta, tüylü küf ve hastaliksız üç kategoridir. Gül yaprağı hastalık sınıflandırması çeşitli CNN mimarilerinin etkinliği ile değerlendirilebilir. Çok sayıda farklı CNN mimarileri vardır. Bunlar içinden en uygununu bulmak için parametre optimizasyonu yapmak gerekebilir. Bu da zorlu bir iştir. Bunun için metasezgisel algoritmalar kullanılabilir. Bu çalışmada bunun için Parçacık Sürü Optimizasyonu (PSO) kullanılmıştır. PSO ile hiper parametre optimizasyonu yapılmış ve en optimum ağ yapısı bulunmaya çalışılmıştır. Elde edilen sonuçlar Xception, VGGNet, ResNet gibi farklı CNN modelleriyle test edilmiştir. PSO ile optimize edilmiş model en iyi sonucu elde etmiştir.

Anahtar Kelimeler – Parçacık Sürü Optimizasyonu, Derin Öğrenme, Gül Yaprağı Hastalık Tespiti, Hiper Parametre Optimizasyonu

I. GİRİŞ

Gül bitkisi dünyadaki en önemli bitkilerden birisidir. Kozmetik, gıda, sağlık gibi sektörler için oldukça önemli bir bitkidir [1]. Türkiye’de genellikle Isparta gülleri ve gülden üretilen ürünleri ile meşhurdur. Ticari değeri yüksek bir bitkidir. Bunun için yetiştirirken dikkatli ve özenli davranmak gereklidir. Hastalıklara karşı önlem almak gereklidir. Gül yetiştiriciliği yapılan yerlerde yapay zeka kullanılarak güllerdeki hastalıklar erkenden teşhis edilebilir. Erkenden teşhis edilen hastalıklar bu sayede önlenip zararın büyümesinin önüne geçilebilir [2].

Yapay zeka tarımda, bitki yetiştiriciliğinde kullanılmaktadır. Görüntülerden çıkarımlar yapan yapay zeka sistemleri mevcuttur. Genellikle CNN kullanılmaktadır. CNN ile pamuk, domates, mısır gibi bitkilerin yapraklarından hastalık tespiti yapılabilmektedir [3]. Bu çalışma gül yaprakları için bu uygulanmıştır.

II. MATERYAL VE YÖNTEM

Yapay zeka sistemlerinin farklı türleri mevcuttur. Klasik olarak yapay sinir ağları kullanılmaktadır. Görüntü sistemleri için CNN’ler kullanılmaktadır. Zaman serisi şeklindeki

sistemlerde, yinelemeli sinir ağı (recurrent neural network, RNN), uzun kısa süreli bellek (long short term memory, LSTM) kullanılmaktadır [4]–[8].

CNN’ler görüntü şeklindeki girdilerden çıktı elde eden yapay zeka sistemidir. Girdi bir resim veya fotoğraf olabilir. CNN bu girdiden resimdeki nesnenin ne olduğunu tespit edebilir. Eğer girdi sağlıklı alakalı bir girdi ise hastalık tespit edebilir. Buna benzer farklı kullanım amaçları vardır [9]–[11].

Yapay sinir ağının bir versiyonu olan CNN’de üç farklı katman türü vardır. Bunlar evrişimli katman (convolutional layer), havuzlama katmanı (pooling layer) ve tam bağlantılı yapay sinir ağı (fully connected neural network) katmanlarıdır [12].

Evrişimli katman girdiden farklı kalıplar kullanarak nitelikler çıkarır. Bu sayede girdideki şekiller, renkler anlamlandırılmaya çalışılır.

Havuzlama katmanı boyut düşürmeye yarar. Bu sayede işlemler kolaylaşır ve sistemin doğru çalışması artırılır.

Tam bağlantılı yapay sinir ağında ise veri tek boyuta indirgenir ve çıktı katmanında hangi sınıfa ait olduğu saptanır.

Veri olarak RoseNet [13] verisi kullanılmıştır. Bu veride üç farklı hastalık türü mevcuttur. Bu hastalıklara ait örnek resimler

Şekil 1’de görülebilir.



Siyah nokta Tüylü küf Sağlıklı

Şekil 1 Veri kümesi örnek resimler

Veri kümesi dağılımı Tablo 1’de görülmektedir.

Tablo 1 Veri kümesi dağılımı

Sınıf	Eğitim kümesi	Test kümesi	Toplam
Siyah nokta	251	62	313
Tüylü küf	160	40	200
Sağlıklı	324	80	404
Toplam	735	182	917

ResNet, Xception ve VGGNet farklı CNN mimarileridir. Bu mimariler gül yaprağı hastalık tespitinde kullanılmıştır [14]–[16].

Parçacık sürüsü optimizasyonu (PSO), metasezgisel algoritmalarından biridir ve çözüm uzayında optimal bir çözüm aramak için basit bir

algoritmadır. Metasezgisel algoritmalar çok farklı uygulama alanlarına sahiptir [17].

Parçacık Sürüsü Optimizasyonu, 1995 yılında Kennedy ve Eberhart tarafından geliştirilmiştir. Hayvan bilimciler, bir grup içinde hareket eden bir balık sürüsünün veya bir kuş sürüsünün diğer tüm üyelerin deneyimlerinden yararlanabileceğine inanıyor. Başka bir deyişle, örneğin bir kuş uçarken ve rastgele yiyecek ararken, sürüdeki tüm kuşlar keşiflerini paylaşabilir ve tüm sürünün en iyi avı almasına yardımcı olabilir. Bu algoritma bunlardan esinlenmiştir [18].

$X^i(t)$ bir parçacığın pozisyonunu temsil etmektedir. Formül (1)’de x ve y koordinatları olarak gösterilmektedir. Formül (2)’de ise hızlar gösterilmektedir. Her bir iterasyonda parçacık konumları değişir ve gelişir. Formül (3)’te konum değişimleri gösterilmiştir. Formül (4) ve (5)’te x ve y olarak koordinat bazlı olarak bir gösterimi

$X^i(t) = (x^i(t), y^i(t))$	(1)
$V^i(t) = (v_x^i(t), v_y^i(t))$	(2)
$X^i(t+1) = X^i(t) + V^i(t+1)$	(3)
$x^i(t+1) = x^i(t) + v_x^i(t+1)$	(4)
$y^i(t+1) = y^i(t) + v_y^i(t+1)$	(5)
$V^i(t+1) = wV^i(t) + c_1r_1(pbest^i - X^i(t)) + c_2r_2(gbest - X^i(t))$	(6)
$X^i(t) = (x^i(t), y^i(t))$	(1)
$V^i(t) = (v_x^i(t), v_y^i(t))$	(2)
$X^i(t+1) = X^i(t) + V^i(t+1)$	(3)
$x^i(t+1) = x^i(t) + v_x^i(t+1)$	(4)
$y^i(t+1) = y^i(t) + v_y^i(t+1)$	(5)
$V^i(t+1) = wV^i(t) + c_1r_1(pbest^i - X^i(t)) + c_2r_2(gbest - X^i(t))$	(6)

yapılmıştır. Hız değişimleri ise Formül (6)’da verilmiştir [19].


Her iterasyonda bu işlemler tekrar edilmektedir.

III. BULGULAR


ResNet, VGGNet ve Xception ile sonuçlar alınmıştır. Bunlara ilaveten PSO ile de derin öğrenme modeli bulunmuştur ve bu model sonuçları da alınmıştır.

Şekil 2, 3, 4 ve 5’te modellerin sonuçları görülmektedir.

ResNet




Şekil 2 ResNet sonuçları



Şekil 4 VGGNet sonuçları

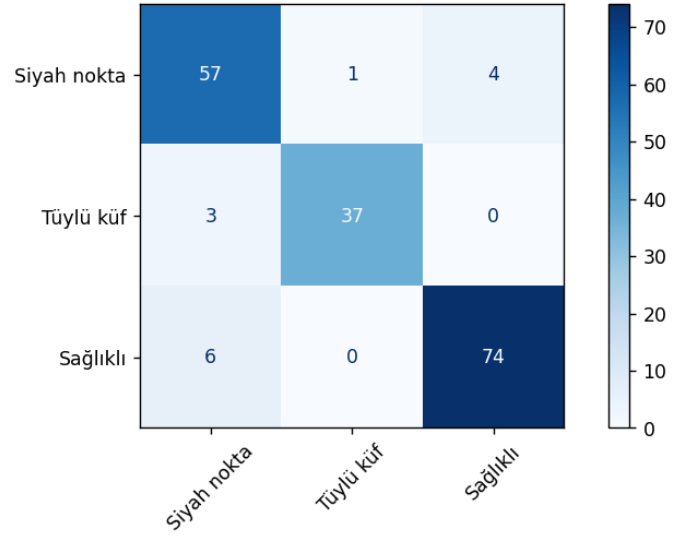
Xception



Şekil 3 Xception sonuçları

VGGNet

PSONet



Şekil 5 PSONet sonuçları

Tablo 2 her bir model için doğruluk, F1, kesinlik ve duyarlılık değerlerini göstermektedir. Tablo incelendiğinde bütün kıstaslar içerisinde PSONet modelinin en iyi sonuçları verdiği gözlemlenmiştir.

Tablo 2 Model sonuçları

	Doğruluk (Accuracy)	F1 değeri (F1 score)	Kesinlik (Precision)	Duyarlılık (Recall)
PSONet	0.923	0.924	0.925	0.923
ResNet	0.764	0.785	0.794	0.782
Xception	0.879	0.882	0.898	0.871
VGGNet	0.830	0.836	0.871	0.823

IV. TARTIŞMA

Gül bitkisinin hastalıklarını erken tespiti için yapay zeka destekli sistemler kullanılabilir.

Özellikle son yıllarda tarımda yapay zeka kullanımı popüler bir hal almıştır. Kullanılacak olan yapay zeka modeli PSONet ile çalışabilir. Bu model oldukça başarılı sonuç vermiştir.

V. SONUÇLAR

Bu çalışmada gül yapraklarından gül bitkisinin hastalıkları tespit edilmeye çalışılmıştır. Bunun için literatürde bulunan ResNet, Xception, VGGNet gibi modeller denenmiştir. Fakat bu modellerden daha başarılı modeller de bulunabilir. Bunun için PSO ile bir model optimizasyonu gerçekleştirilmiştir. Elde edilen sonuçlar göstermektedir ki PSONet çok kullanışlı bir modeldir.

İleriki çalışmalarda farklı CNN ağ yapıları denenebilir. Bunun için genetik algoritma [20], [21] gibi klasik metasezgisel algoritmalar veya son yıllarda çıkmış yeni metasezgisel algoritmalar [22] denenebilir. Bu sayede daha yeni ve farklı ağ yapıları ortaya çıkar. Bu yeni yapılar çok daha iyi sonuçlar verebilirler.

TEŞEKKÜR

Bu çalışmada algoritmaların ve modellerin sonuçlarını almak için TRUBA(Türk Ulusal Bilim e-Altyapısı) kullanılmıştır. Bundan dolayı yazar TÜBİTAK'a teşekkür etmektedir.

KAYNAKLAR

- [1] M. N. Waghmare and P. N. Shendage, "Economic Analysis of Production of Cut Roses under Polyhouses in Western Maharashtra," *Int.J.Curr.Microbiol.App.Sci.*, vol. 8, no. 02, pp. 234–241, Feb. 2019.
- [2] A. Karanfil, "Prevalence and molecular characterization of Turkish isolates of the rose viruses," *Crop Protection*, vol. 143, p. 105565, May 2021.
- [3] B. Gülmez, "A novel deep learning model with the Grey Wolf Optimization algorithm for cotton disease detection," *J. Univers. Comput. Sci.*, vol. 6, no. 29, pp. 595–626, 2023.
- [4] B. Gülmez, "Prediction of retail prices of roasted coffee by time series analysis," in *International Anatolian Congress on Coffee and Cocoa*, Malatya, Turkey, 2021, p. 63.
- [5] B. Gülmez, "Zaman serisi analizi ile talep tahmini ve bir fabrikadaki üretim planlama," in *Mühendislik Alanında Uluslararası Araştırmalar*, vol. 2, Konya: Eğitim Yayınevi, 2022, pp. 57–74.
- [6] B. Gülmez, "Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm," *Expert Systems with Applications*, vol. 227, p. 120346, Oct. 2023.
- [7] B. Gülmez and S. Kulluk, "Social spider algorithm for training artificial neural networks," *International Journal of Business Analytics (IJBAN)*, vol. 6, no. 4, pp. 32–49, 2019.
- [8] B. Gülmez and S. Kulluk, "Türkiye'de ikinci el araçların büyük veri ve makine öğrenme teknikleriyle analizi ve fiyat tahmini," *GUMMFD*, vol. 38, no. 4, pp. 2279–2290, Apr. 2023.
- [9] B. Gülmez, "MonkeypoxHybridNet: A hybrid deep convolutional neural network model for monkeypox disease detection," in *International Research in Engineering Sciences*, vol. 3, Konya: Eğitim Publishing, 2022, pp. 49–64.
- [10] B. Gülmez, "A novel deep neural network model based Xception and genetic algorithm for detection of COVID-19 from X-ray images," *Ann Oper Res*, Dec. 2022.
- [11] B. Gülmez, "İşyeri güvenliği için derin öğrenme ile baret takılması tespiti," in *International Conference on Engineering and Applied Natural Sciences*, Konya, 2023, p. 284.
- [12] A. A. Ahmed, S. M. S. Darwish, and M. M. El-Sherbiny, "A novel automatic CNN architecture design approach based on genetic algorithm," in *International Conference on Advanced Intelligent Systems and Informatics*, 2019, pp. 473–482.
- [13] S. Sazzad, A. Rajbongshi, R. Shakil, B. Akter, and M. S. Kaiser, "RoseNet: Rose leave dataset for the development of an automation system to recognize the diseases of rose," *Data in Brief*, vol. 44, p. 108497, Oct. 2022.
- [14] D. Theckedath and R. R. Sedamkar, "Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks," *SN COMPUT. SCI.*, vol. 1, no. 2, p. 79, Mar. 2020.
- [15] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1251–1258.
- [16] K. Shaheed, A. Mao, I. Qureshi, M. Kumar, S. Hussain, I. Ullah, and X. Zhang, "DS-CNN: A pre-trained Xception model based on depth-wise separable convolutional neural network for finger vein recognition," *Expert Systems with Applications*, vol. 191, p. 116288, Apr. 2022.
- [17] B. Gülmez, "Improved discrete queuing search algorithm for traveling salesman problem," in *International Research in Engineering Sciences*, vol. 7, Konya: Eğitim Publishing, 2023.
- [18] B. Cheng, H. Lu, Y. Huang, and K. Xu, "Particle swarm optimization algorithm based on self-adaptive excellence coefficients for solving traveling salesman problem," *J. Comput. Appl.*, vol. 37, no. 3, pp. 750–754, 2017.
- [19] A. Tam, "A Gentle Introduction to Particle Swarm Optimization," *MachineLearningMastery.com*, 15-Sep-2021. .
- [20] B. Gülmez, "Market zinciri ürün dağıtım probleminin farklı genetik algoritma versiyonları ile çözümü ve karşılaştırması," *Osmaniye Korkut Ata Üniversitesi*

Fen Bilimleri Enstitüsü Dergisi, vol. 6, no. 1, pp. 180–196, Mar. 2023.

- [21] B. Gülmez and E. Korhan, “COVID-19 vaccine distribution time optimization with Genetic Algorithm,” in *The International Conference on Engineering, Natural and Applied Science*, Osmaniye, Turkey, 2021, p. 100.
- [22] B. Gülmez, “Yapay Tavşan Algoritmasıyla araç rotalama problemi optimizasyonu,” in *International Conference on Smart Logistics*, Istanbul, 2022, pp. 86–87.