



Classification of Plant Species with Transfer Learning-Based Methods

Halit Çetiner

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

July 10, 2022

Transfer Öğrenme Tabanlı Yöntemler ile Bitki Türlerinin Sınıflandırılması

Halit Çetiner^{1*}

¹ Teknik Bilimler MYO, Isparta Uygulamalı Bilimler Üniversitesi, Türkiye

*(halitcetiner@isparta.edu.tr)

Özet – Bitki ilaç, tarım başta olmak üzere çevre, endüstriyel ve ekolojik alanlarda önemli bir rol oynamaktadır. Son yıllarda kentsel gelişim ve çevresel tahribat neticesinde küresel ısınma ve biyoçeşitlilik kaybı yaşanmaktadır. Küresel ısınma neticesinde ozon tabakasının incelmelerinden çok sayıda bitki türünün ölmesine kadar çok çeşitli olumsuz vaka meydana gelmektedir. Ozon tabakasının incelmeleri nasıl insanların zararlı güneş ışınlarını doğrudan görmesine neden olabiliyorsa aynı şekilde bitki türlerinin yok olması ile de farklı zararlar oluşmaktadır. Belirtilen nedenlerden dolayı doğa ile insan hayatı birbiri ile doğrudan ilişkilidir. Bu ilişkiyi koruyabilmek için insanlığa faydalı bitki türlerinin korunması gerekmektedir. İnsanlara faydalı bitki türlerini korumanın başlangıç adımı bitkileri tanımadır. Yeryüzünde isimlendirilmiş ya da isimlendirilmemiş binlerce bitki türü bulunmaktadır. Bu kadar bilgi çeşidini kategorize ederek sınıflandırmak da büyük bir bilgi işlem gücü istemektedir. Bitkiye ait çiçeği, kabuğu, meyvesi ve tohumu gibi ayırt edici özellikleri kullanılarak sınıflandırma yapılabileceği gibi yaprak özneliği kullanarak da sınıflandırma yapılabilir. Bitkiyi yaprak tabanlı olarak sınıflandırma yapmak için öznelik çıkarma tabanlı, seyrek temsili, alt uzay öğrenme tabanlı yöntemler bulunmaktadır. Ancak bu çalışmada son zamanlarda herhangi bir ön işleme dahi uygulamadan sınıflandırma görevlerinde güçlü bir yapı sağlayan derin öğrenme tabanlı yöntemler tercih edilmiştir. Bu çalışma kapsamında MobileNet V2 mimarisini temel alarak transfer öğrenme tabanlı bir derin öğrenme modeli önerilmiştir. Önerilen yapı, temel MobileNet V2 modeli ile performans ölçümleri ile karşılaştırılmıştır.

Anahtar Kelimeler – Yapay zeka, derin öğrenme, transfer öğrenme, MobileNet V2, bitki türleri

I. GİRİŞ

Bitki türlerinin korunması, tıp biliminden günlük yaşama, endüstriyel büyümeden çevre korumaya kadar çok farklı alanlarda gereklidir. İnsanların yaşam döngüsünün üretim odaklı devam edebilmesi için bitki türlerinin hayatlarını devam ettirmesi gerekmektedir. Çünkü bitkiler her şeyin de ötesinde yeryüzündeki karbondioksit ve oksijen dengesini koruma görevi görmektedir. Yapay zeka destekli olarak derin öğrenme tabanlı modeller ile otomatik bitki türlerinin tanınması, botanik bahçeleri, bitki taksonomisi, doğal rezervler ve yeni bitki türlerinin keşfinde büyük önem taşımaktadır.

İnsan ve hayvanların tedavisinde kullanılan ilaçların yarısından fazlası doğrudan bitkilerin sentezi sonucunda elde edilmektedir [1]. Bunların yanı sıra bitkiler, erozyonun engellenmesinden su

ve toprağın korunmasına kadar iklimi iyileştiren birçok konuda hayati öneme sahiptir [2], [3]. Ancak son zamanlarda artış gösteren hızlı kentsel gelişme ve sanayileşmenin yanı sıra küresel ısınma ve aşırı tarımsal ilaçlama neticesinde çok ciddi çevre zararları ve kirliliği oluşmuştur. Bunların neticesinde ise insanların gözü doymayan hedeflerine ulaşabilmek için çevreyi kirlettiği, bitkilerin tür kaybı ve insan hariç canlıların ekolojik tahribatının gerçekleştiği görülmektedir. Alan vd. yeryüzünde tanınan 250.000 bitkiden yaklaşık olarak 34.000 tanesinin yok olma eşiğinde olduğunu bildirmektedir [4]. Ekolojik tahribatın verdiği zarar içinde bulunduğumuz yüz yılın ortalarına doğru yeryüzündeki türlerin %15-17 arasındakinin yok olacağını bildirmektedir [5]. Yeryüzünde yaşayan bitki canlı türlerinin yok olması ise arazi çölleşmesi, heyelan artışları, ani

sel felaketleri, iklim değişiklikleri gibi insan ve yaşadığı ortam üzerinde hayati sonuçları olacaktır [6]. Bitki canlılarında ekosistem üzerinde yok olma olayı bir komşu bitkinin de tür kaybı ile sonuçlanmasına sebep olabilmektedir. İşte bu yönde gelen kanıtlar üzerine azalan biyoçeşitlilik neticesinde ekosistemler işlevlerini değiştirmektedir [7]. Belirtilen sebeplerden dolayı bitki türlerini etkili bir şekilde çevresel zararlardan korumak gerekmektedir. Bu anlamda ilk yapılması gereken bitki türlerini tanımadır. Bunun için de tarımsal bilgilendirmeden ziyade bitki türlerini sınıflandırmak gerekmektedir. Ancak 270.000'den fazla bitki türünün olduğu varsayıldığında temel bitkilerden başlamak gerekmektedir [1]. Her alanda olduğu gibi bitki türlerini belirlemede uzmanlar dışında tür belirlemek zor bir görevdir. Yapay zeka destekli olarak bitki tür sınıflarının belirlenmesi önemlidir. Bilgisayar görü alanında bitki türlerinin otomatik tanımlanması zor bir görev olarak tanımlanmaktadır [8]–[10]. Otomatik bitki tür belirlemesi medikal alanda araştırma yapan araştırmacılar ile birlikte birçok sektöre fayda getirmektedir [11].

Bilgisayar görü, doğal dil işleme, derin öğrenme algoritmalarının ilerlemesini sağlayan yazılım ve donanım mimarilerinin gelişmesiyle birlikte bitki türlerini tanımak ve sınıflandırmak mümkün hale gelmiştir [12]–[15]. Bitki türlerini otomatik olarak tanımlamak, sınıflandırmak, anlamak ve yönetmek için yapay zeka tabanlı algoritmalarından destek alınabilir. Literatür incelendiğinde bitki türlerinin bitkiye ait çeşitli organlar vasıtasıyla otomatik tanıma ve sınıflandırma yapıldığı görülmektedir [16]–[18]. Bitkiye ait yaprak organının çiçek, kök, gövde, kabuk, meyve ve tohum gibi organlarına göre şekil ve yapı açısından sabit olduğu görülmektedir. Yapraklar genel olarak bol bulunmakla birlikte çiçek sadece belirli bir dönemde değişkenlik gösteren formlarda görünmektedir. Kökler ise toprağın altında olmasından dolayı kolaylıkla erişilemediği gibi topraktan temizlenerek tanınması daha doğru olacaktır. Kökleri tanıma organı olarak belirlemek için binlerce kök görüntüsünü yakalamak gerekmektedir. Bu durumda hem bitkiye zarar verebilir hem de çok fazla zaman alabilir. Belirtilen sebeplerden dolayı hem gövde üstünde durması hem de bol olması gibi sebeplerden dolayı yapraklar bitki türü tanıma ve sınıflandırmada kullanılmaktadır. Herhangi bir botanik bilgide uzman olmaya gerek kalmadan yaprak temelli

olarak bitki türlerinin yapay zeka destekli olarak otomatik tanımlanması ve sınıflandırılması botanik tekniklerine göre avantajlıdır [19].

Bitkileri tanımak için kullanılan yapraklara ait renk özellikleri sürekli değişmekle birlikte şekil yapısı değişmemektedir. Renk özelliği her bir mevsimde farklı bir özelliğe bürünmektedir. Bitki yapraklarına ait şekil özellikleri ise doğada oldukça karardır [1]. Yeryüzünde bulunan bitkilerin her birinin farklı yaprak şekline sahip olması bitki tanıma ve sınıflandırma da önemli bir temeldir [20]–[22]. İnsanların parmak izleri gibi her türe ait yaprak damar yapısı da sabittir. Ancak farklı her bir bitki türünün yaprak yapısı farklılık göstermektedir [20]. Zhang-Qui vd. yapraklara ait şekil, doku, uç ve yaprak tabanının bitki yapraklarında farklılık içerdiğini bildirmektedir [20].

Farabet vd. farklı veri setleri üzerinde bitki doku, şekil ve bağlamsal bilgiyi kullanarak bitki tür sınıflandırması yapmaktadır [23]. Gri seviye oluşum matrisleri olmak üzere yerel ikili desen gibi farklı istatistiksel yöntemler kullanarak bitki türlerinin analiz edildiği görülmektedir [24]–[26]. Singh vd. SVM, sinir ağları ve fourier momentleri kullanarak bitki türlerini sınıflandırmıştır [27]. Literatürde var olan klasik makine öğrenme yöntemlerine ek olarak bu makalede teknik ve model olarak kullanılan derin öğrenme tabanlı modeller ile de bitki tür sınıflandırması yapan çalışmalar incelenmiştir. Dyrmann vd. fide türlerini sınıflandırmak için Konvolüsyon Sinir Ağı (CNN) tabanlı bir yöntem öne sürmektedir [28]. Belirtilen çalışmada renkli görüntülü bitki yaprakları kullanarak CNN ile bitki sınıflandırması yapmaktadır. Bu sınıflandırmadan %86.2 değerinde bir sınıflandırma doğruluğuna ulaşmıştır.

Bu makalede, botanikçilere yardımcı olmak, el ile manuel olarak bitki türleri incelemenin önüne geçmek amacıyla bir temel bitki yaprak sınıflandırma sistemi önerilmiştir. Aynı zamanda, önerilen sistem, bitki ilaçlama gibi farklı tarımsal amaçlar için kullanılan otonom cihazların otomatik yönlendirilmesine de katkı sağlayacaktır. Önerilen sistem, bitki türlerine ait yaprak özelliklerini kullanarak 5 farklı bitki türünün sınıflandırılmasını sağlamaktadır.

Çalışmanın bu adımından sonraki kısımları üç bölüme ayrılmıştır. İkinci bölümde çalışma kapsamında kullanılacak veri seti ayrıntılı olarak detaylandırılmıştır. Üçüncü bölümde ise çalışma sonucunda elde edilen araştırma bulguları

sunulmuştur. Dördüncü bölüm olan son bölümde ise çalışma elde edilen neticeler ile sonuçlandırılmıştır.

II. MATERYAL VE YÖNTEM

Yatay kaydırma, döndürme, yatay çevirme ve dikey kaydırma veri çoğaltma teknikleri kullanarak mısır, buğday, hint keneviri, pirinç ve şeker kamışı



Şekil 1. Veri setindeki bitki tür örnekleri

A. MobileNet V2

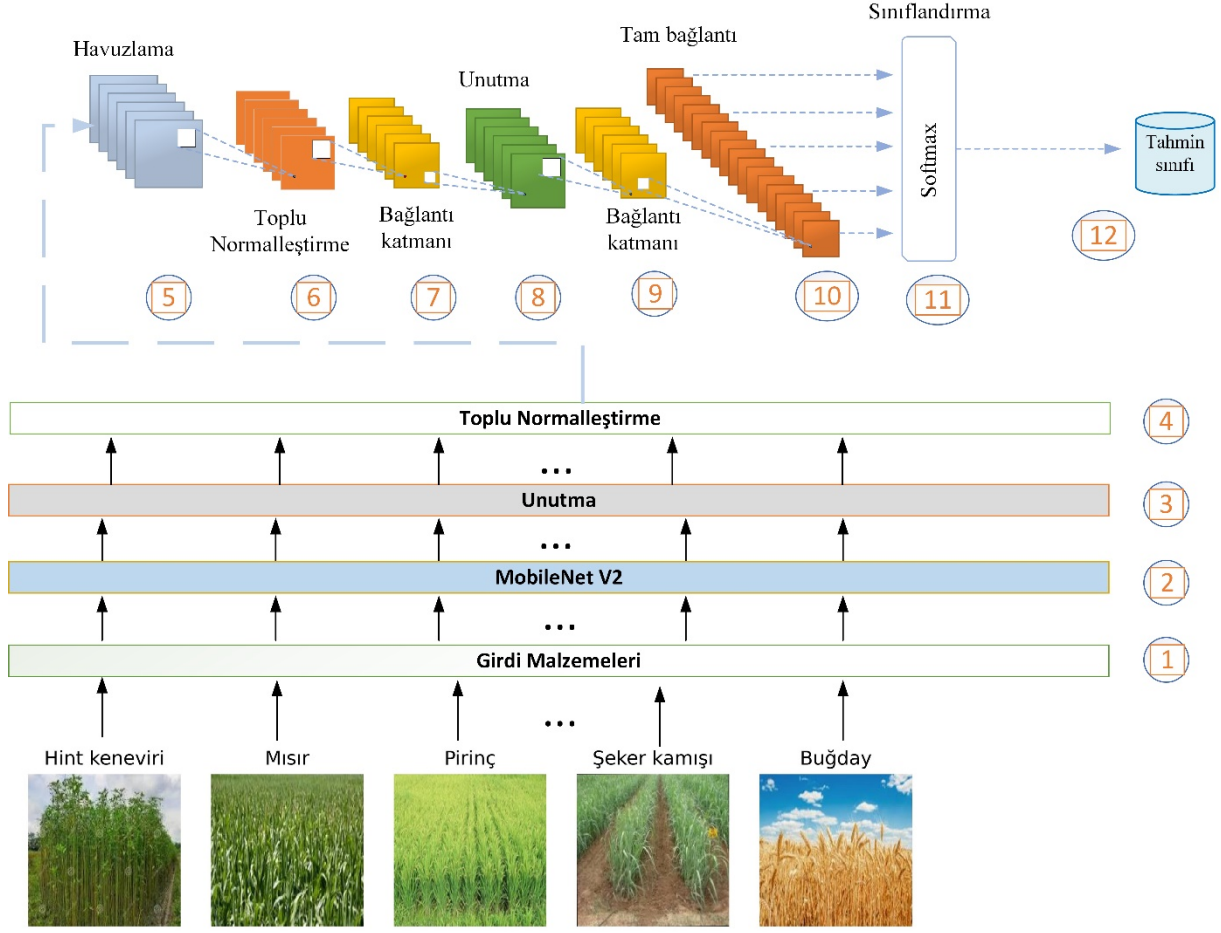
MobileNet V2, mobil cihazlarda kullanılabilen hafif bir model olmasından dolayı yoğun olarak kullanılmaktadır [29]. Taşınabilir cihazlar içerisindeki yapay zeka ve bilgisayar görü tabanlı uygulamaların geliştirilebilmesi için geliştirilen bir mimaridir. MobileNet V2 mimarisi DWC adı verilen derinlemesine ayrılabilir konvolüsyon yapısı kullanılmaktadır. Derinlemesine konvolüsyon (DC) adı verilen yapının haricinde DWC 1x1 boyutlarında ek bir filtreleme uygulamaktadır. MobileNet mimarisinin MobileNet V1

bitkilerine ait toplam 804 adet görüntü elde edilmiştir. Şekil 1’de gösterilen bitki türlerinin her birinden buğday hariç 160 adet bitki görüntüsü bulunmaktadır. Buğday bitkisinden ise 164 adet bitki görüntü örneği bulunmaktadır. Bu görüntülerin %20’si test eğitimde kullanılacak şekilde deneysel çalışmalar gerçekleştirilmiştir.

versiyonundan sonra geliştirilen mimarisi olan MobileNet V2, ilk versiyona göre ağırlık sayısı azaltılmış bir mimaridir. DWC yapısının DC yapısı haricinde gerçekleştirdiği 1x1 boyutlarındaki filtrelemeye noktasal konvolüsyon denilmektedir. MobileNet V2 noktasal konvolüsyona izin vererek ilk versiyona göre performansı artırmaktadır. MobileNet V2 mimarisini tanımlayan blok diyagramı t , c , n ve s parametreleri ile birlikte Şekil 2’de sunulmuştur. Bu t , c , n ve s parametreleri sırasıyla genişleme değeri, çıkış kanal sayısı ve atlama değerlerini göstermektedir.

Giriş	Operatör	t	c	n	s
224 x 224 x 3	Konvolüsyon 2D	-	32	1	2
112 x 112 x 32	bottleneck	1	16	1	1
112 x 112 x 16	bottleneck	6	24	2	2
56 x 56 x 24	bottleneck	6	32	3	2
28 x 28 x 32	bottleneck	6	64	4	2
14 x 14 x 64	bottleneck	6	96	3	1
14 x 14 x 96	bottleneck	6	160	3	2
7 x 7 x 160	bottleneck	6	320	1	1
7 x 7 x 320	Konvolüsyon 1 2D 1 x 1	-	1280	1	1
7 x 7 x 1280	Havuzlama (Ortalama) 7 x 7	-	-	1	-
1 x 1 x 1280	Konvolüsyon 2D 1 x 1	-	k	-	-

Şekil 2. MobileNetV2 modeli [29]



Şekil 3. Bitki türlerini sınıflandırmak için önerilen MobileNet V2 tabanlı derin öğrenme modeli


Şekil 3'te 12 adımdan oluşan bitki türlerini sınıflandırma modeli görülmektedir. Bu modelin her bir adımı bir araya gelerek önerilen model oluşturulmuştur. Birinci adımda 224x224 boyutlarında renkli görüntüye sahip yaprak görüntüleri girdi olarak sunulmuştur. İkinci adımda ise belirtilen renk kanalı ve görüntü boyutuna göre transfer öğrenme için yapılandırılan MobileNet V2 katmanına girdi sunulmuştur. Üçüncü adımda 0.9 oranında nöron bırakma gerçekleştiren unutma katmanı uygulanmıştır. Dördüncü adımda ise katmanlar arasındaki girdileri düzenleme gerçekleştiren toplu normalleştirme gerçekleştirilmiştir.

Beşinci adımda maksimum havuzlama gerçekleştirilerek elde edilen özneliklerin en değerli olanları seçilmiştir. Altıncı adımda ise yine katmanlar arasındaki girdileri düzenleme gerçekleştiren toplu normalleştirme gerçekleştirilmiştir. Yedinci adımda ise 1000 nöronlu ReLU aktivasyon fonksiyonlu bağlantı katmanı uygulanmıştır. Sekizinci adımda ise tekrar 0.9 oranında bırakma katmanı uygulanmıştır. Dokuzuncu adımda ise 256 nöronlu ReLU

aktivasyon fonksiyonuna sahip bağlantı katmanı uygulanmıştır. Onuncu adımda ise tüm katmanlar arasındaki bağlantıyı sağlanarak sınıf katmanı ile bağlantı sağlayan tam bağlantı katmanı uygulanmıştır. On birinci adımda ise softmax aktivasyon fonksiyonuna sahip sınıflandırma katmanı uygulanmıştır. Son katmanda ise tahmin edilen etiket belirlenmiştir.

III. BULGULAR


Belirtilen özelliklere sahip önerilen modelin başarı performansını ölçebilmek için adım sayısı 30 iterasyonlu olacak şekilde $1e-3$ öğrenme oranı ile Adam optimizasyon yöntemi kullanılmıştır. Parça sayısı tüm örneklerde 16 olarak belirlenmiştir. Bu çalışmada bulgularda araştırdığımız temel nokta önerilen modelin, temel MobileNet V2 modeline yüzde olarak eğitim ve test grafiklerinde ne kadar etkisi olduğunun ortaya çıkartılmasıdır. Şekil 4'te verilen eğitim performans grafiğine göre önerilen MobileNet V2 modeli, temel MobileNet V2 modeline göre %13 puan fark atmıştır. Önerilen model %96.26 başarı oranına ulaşırken, temel model %83.20 başarı oranına ulaşmıştır.



Şekil 4. Temel ve önerilen MobileNet V2 modellerinin eğitim doğruluk grafiği

Şekil 5'te ise eğitim grafiklerinde elde edilen doğrulukların kayıp grafikleri sunulmuştur. Önerilen modelin kayıp grafiği %11.15 seviyesinde iken temel modelin kayıp değeri %61.76 seviyesindedir. Temel model %50 seviyesinde fazla kayıp vermekte olduğu görülmektedir.

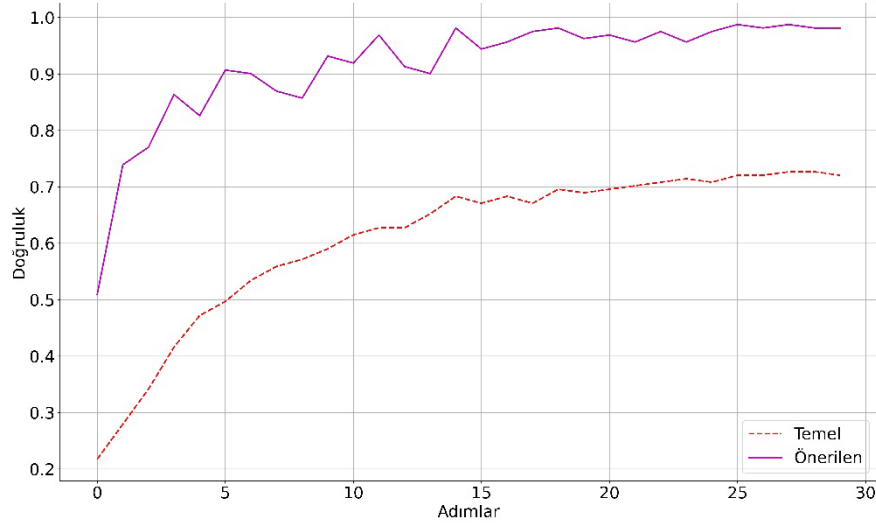
Şekil 6'da ise temel ve önerilen MobileNet V2 modellerinin test doğruluk grafikleri görülmektedir. Bu grafiğe göre ise önerilen model %98.75 başarı oranına ulaşırken, temel model %72.67 başarı oranında kalmıştır. Her iki model arasında yaklaşık olarak %26 oranında başarı farkı bulunmaktadır.




Şekil 5. Temel ve önerilen MobileNet V2 modellerinin eğitim kayıp grafiği

Şekil 7'de ise temel ve önerilen modellerinin test kayıp grafikleri gösterilmektedir. Önerilen modelin kayıp değeri %0.03 iken, temel modelin kayıp değeri %0.74 seviyesindedir. Belirtilen performans

ölçütlerinde her iki model karşılaştırma yapılmıştır. Yapılan karşılaştırmalar neticesinde önerilen modelin performansı tatmin edici seviyededir.



Şekil 6. Temel ve önerilen MobileNet V2 modellerinin test doğruluk grafiği



Şekil 7. Temel ve önerilen MobileNet V2 modellerinin test kayıp grafiği

IV. SONUÇLAR

Farklı bitki türlerinin otomatik olarak sınıflandırılması çok farklı amaçlar için kullanılabilir. Bu amaçla iki farklı model kullanılmıştır. Birincisinde 12 adımdan oluşan bir MobileNet V2 tabanlı bir model önerilmiştir. Diğerinde ise temel MobileNet V2 modeli özelliklerine sahip bir model kullanılmıştır. Önerilen ve temel modelin eğitim ve test doğruluk/kayıp grafikleri karşılaştırmalı olarak sunulmuştur. Sunulan bu veriler üzerinden önerilen modelin temel modele göre eğitim doğruluğunda %13, test doğruluğunda %26 fark verdiği görülmektedir.

Belirtilen performans ölçütleri içerisinde ilaç, tarım başta olmak üzere endüstriyel ve ekolojik alanlarda önemli rol oynayan bitkilere ait yaprak

öznitelikleri yüksek doğrulukla sınıflandırılmıştır. Bu çalışma ile insanlara faydalı bitki türlerini korumanın başlangıç adımı olan bitki tanıma ve sınıflandırma işlemi derin öğrenme tabanlı bir yöntem ile gerçekleştirilmiştir.

KAYNAKLAR

- [1] S. Zhang, W. Huang, Y. Huang, and C. Zhang, "Plant species recognition methods using leaf image: Overview," *Neurocomputing*, vol. 408, pp. 246–272, 2020, doi: <https://doi.org/10.1016/j.neucom.2019.09.113>.
- [2] J. O. Botany, "Retracted: Phytoliths as Emerging Taxonomic Tools for Identification of Plants: An Overview," *J. Bot.*, vol. 2014, p. 231914, 2014, doi: [10.1155/2014/231914](https://doi.org/10.1155/2014/231914).
- [3] I. M. Sussex and N. M. Kerk, "The evolution of plant architecture," *Curr. Opin. Plant Biol.*, vol. 4, no. 1, pp. 33–37, 2001.
- [4] A. K. Knapp, P. A. Fay, S. L. Collins, M. D. Smith, J. D. Carlisle, C. W. Harper, B. T. Danner, M. S. Lett, and J. K. McCarron, "Rainfall variability, carbon cycling,

- and plant species diversity in a mesic grassland,” *Science* (80-.), vol. 298, no. 5601, pp. 2202–2205, 2002.
- [5] J. A. Pounds and R. Puschendorf, “Clouded futures,” *Nature*, vol. 427, no. 6970, pp. 107–109, 2004, doi: 10.1038/427107a.
- [6] P. Canuti, “Landslides - Disaster Risk Reduction,” *Springer*, vol. 72, pp. 31–61, 2009.
- [7] S. C. Chang, “Landslides and their environmental impacts in northern Taiwan (1968-1986).,” *J. Geogr. Sci.*, no. 14, pp. 11–27, 1990.
- [8] A. Sabu and K. Sreekumar, “Literature review of image features and classifiers used in leaf based plant recognition through image analysis approach,” in *2017 International Conference on Inventive Communication and Computational Technologies (ICICCT)*, 2017, pp. 145–149. doi: 10.1109/ICICCT.2017.7975176.
- [9] S. Purohit, R. Viroja, S. Gandhi, and N. Chaudhary, “Automatic plant species recognition technique using machine learning approaches,” in *2015 International Conference on Computing and Network Communications (CoCoNet)*, 2015, pp. 710–719. doi: 10.1109/CoCoNet.2015.7411268.
- [10] J. J. Wiens, “Climate-Related Local Extinctions Are Already Widespread among Plant and Animal Species,” *PLOS Biol.*, vol. 14, no. 12, p. e2001104, Dec. 2016. doi: <https://doi.org/10.1371/journal.pbio.2001104>
- [11] H. Goëau, A. Joly, P. Bonnet, S. Selmi, J. Molino, D. Barthélémy, and N. Boujemaa, “LifeCLEF Plant Identification Task 2014,” in *CLEF: Conference and Labs of the Evaluation Forum*, 2014, vol. CEUR Works, no. 1180, pp. 598–615.
- [12] J. Zhang, D.-S. Huang, T.-M. Lok, and M. R. Lyu, “A novel adaptive sequential niche technique for multimodal function optimization,” *Neurocomputing*, vol. 69, no. 16, pp. 2396–2401, 2006, doi: <https://doi.org/10.1016/j.neucom.2006.02.016>.
- [13] W. Jiang, D.-S. Huang, and S. Li, “Random Walk-Based Solution to Triple Level Stochastic Point Location Problem,” *IEEE Trans. Cybern.*, vol. 46, no. 6, pp. 1438–1451, 2016, doi: 10.1109/TCYB.2015.2446198.
- [14] D.-S. Huang and W. Jiang, “A general CPL-AdS methodology for fixing dynamic parameters in dual environments,” *IEEE Trans. Syst. Man, Cybern. Part B Cybern.*, vol. 42, no. 5, pp. 1489–1500, 2012, doi: 10.1109/TSMCB.2012.2192475.
- [15] W.-B. Zhao, D.-S. Huang, J.-Y. Du, and L.-M. Wang, “Genetic optimization of radial basis probabilistic neural networks,” *Int. J. Pattern Recognit. Artif. Intell.*, vol. 18, no. 8, pp. 1473–1499, 2004, doi: 10.1142/S0218001404003824.
- [16] P. Bonnet, A. Joly, H. Goëau, J. Champ, C. Vignau, J. F. Molino, D. Barthélémy, and N. Boujemaa, “Plant identification: man vs. machine,” *Multimed. Tools Appl.*, vol. 75, no. 3, pp. 1647–1665, 2016, doi: 10.1007/s11042-015-2607-4.
- [17] A. Joly, H. Goëau, P. Bonnet, V. Bakić, J. Barbe, S. Selmi, I. Yahiaoui, J. Carré, E. Mouysset, J. Molino, N. Boujemaa, and D. Barthélémy, “Interactive plant identification based on social image data,” *Ecol. Inform.*, vol. 23, pp. 22–34, 2014, doi: <https://doi.org/10.1016/j.ecoinf.2013.07.006>.
- [18] M. Seeland, M. Rzanny, N. Alaqraa, J. Wäldchen, and P. Mäder, “Plant species classification using flower images—A comparative study of local feature representations,” *PLoS One*, vol. 12, no. 2, p. e0170629, Feb. 2017, [Online]. Available: <https://doi.org/10.1371/journal.pone.0170629>
- [19] X.-F. Wang, D.-S. Huang, J.-X. Du, H. Xu, and L. Heutte, “Classification of plant leaf images with complicated background,” *Appl. Math. Comput.*, vol. 205, no. 2, pp. 916–926, 2008, doi: <https://doi.org/10.1016/j.amc.2008.05.108>.
- [20] Z.-Q. Zhao, L.-H. Ma, Y. Cheung, X. Wu, Y. Tang, and C. L. P. Chen, “ApLeaf: An efficient android-based plant leaf identification system,” *Neurocomputing*, vol. 151, pp. 1112–1119, 2015, doi: <https://doi.org/10.1016/j.neucom.2014.02.077>.
- [21] N. Valliammal and S. N. Geethalakshmi, “An optimal feature subset selection for leaf analysis,” *Int. J. Comput. Inf. Eng.*, vol. 6, no. 2, pp. 191–196, 2012.
- [22] Y. Mingqiang, K. Kidiyo, and R. Joseph, “A survey of shape feature extraction techniques,” *A Surv. Shape Featur. Extr. Tech.*, pp. 43–90, 2008.
- [23] C. Farabet, C. Couprie, L. Najman, and Y. LeCun, “Learning hierarchical features for scene labeling,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35, no. 8, pp. 1915–1929, 2012.
- [24] M. Lukic, E. Tuba, and M. Tuba, “Leaf recognition algorithm using support vector machine with Hu moments and local binary patterns,” in *2017 IEEE 15th International Symposium on Applied Machine Intelligence and Informatics (SAMII)*, 2017, pp. 485–490.
- [25] H. X. Kan, L. Jin, and F. L. Zhou, “Classification of medicinal plant leaf image based on multi-feature extraction,” *Pattern Recognit. image Anal.*, vol. 27, no. 3, pp. 581–587, 2017.
- [26] J. K. Patil and R. Kumar, “Analysis of content based image retrieval for plant leaf diseases using color, shape and texture features,” *Eng. Agric. Environ. food*, vol. 10, no. 2, pp. 69–78, 2017.
- [27] K. Singh, I. Gupta, and S. Gupta, “Svm-bdt pnn and fourier moment technique for classification of leaf shape,” *Int. J. signal Process. Image Process. Pattern Recognit.*, vol. 3, no. 4, pp. 67–78, 2010.
- [28] M. Dyrmann, H. Karstoft, and H. S. Midtby, “Plant species classification using deep convolutional neural network,” *Biosyst. Eng.*, vol. 151, pp. 72–80, 2016, doi: <https://doi.org/10.1016/j.biosystemseng.2016.08.024>.
- [29] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, “Mobilenetv2: Inverted residuals and linear bottlenecks,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.