

Bilgisayarlı Görmede Topluluk Öğrenimi (Ensemble Learning) Yaklaşımları

Musa Ataş^{1*} ve Bashar Alhajahmad²

¹ Bilgisayar Mühendisliği / Mühendislik Fakültesi, Siirt Üniversitesi, Türkiye

² Bilgisayar Mühendisliği / Mühendislik Fakültesi, Siirt Üniversitesi, Türkiye

*(hakmesyo@gmail.com)

Özet – Bilgisayarlı görme, makine öğrenimi ve yapay zeka alanlarında önemli bir araştırma konusu olmuştur. Görüntü işleme, nesne tanıma, yüz tanıma, nesne takibi ve daha birçok uygulama bilgisayarlı görme alanındaki gelişmeler ışığında büyük ilerlemeler kaydetmiştir. Ancak, bilgisayarlı görme sistemleri ile üretilen uygulamalarda halen tam anlamıyla insana yakın performans yakalanmamıştır. Özellikle bu performans düşüklüğü, fine-grained yani bir türün alt türlerinin içinde bulunduğu veri kümelerinde daha çok belirgindir. Fine-grained veri kümelerinde saha uzmanlarını dahi zorlayacak seviyede sınıf içi varyans ve sınıflar arası benzerliğin yüksek olması, problemi önemli ölçüde zorlaştırmaktadır. Bu noktada, topluluk öğrenimi (ensemble learning) yaklaşımları alternatif bir çözüm sunabilir. Bu bildiri, bilgisayarlı görme alanında topluluk öğrenimi yaklaşımlarını ele alarak, bu alandaki son gelişmeleri ve önemli konuları incelemektedir. Topluluk öğrenimi, birden fazla öğrenme modelinin bir araya getirilmesi ve birbirleriyle işbirliği yapmalarını içeren bir yaklaşımı ifade eder. Bu yaklaşım, özellikle karmaşık görevlerde ve sınırlı veri koşullarında daha etkili sonuçlar elde etmeye yardımcı olabilir. Bildirimizde, topluluk öğrenimi yaklaşımlarının çeşitleri, temel çalışma mekanizmaları, avantajları ve zorlukları ele alınacaktır. Ayrıca, bu yaklaşımların görüntü sınıflandırma, nesne tespiti, ve diğer bilgisayarlı görme görevlerinde nasıl kullanılabileceğine değinilecektir. Topluluk öğrenimi yöntemlerinin, model performansı ve veri verimliliğini artırmada nasıl kullanılabileceği de vurgulanacaktır. Bildiri ile hedeflenen, bilgisayarlı görmede topluluk öğrenimi yaklaşımlarının önemine vurgu yapılarak, bu alanda araştırma yapmak isteyenler için rehberlik edecek ve gelecekteki çalışmalarına ilham kaynağı olacak bir çalışma ortaya koymaktır.

Anahtar Kelimeler – Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme, Ensemble Learning, Topluluk Öğrenimi

I. GİRİŞ

Makine öğrenimi ve bilgisayarlı görme alanları, teknolojik gelişmelerin ve veri artışının hız kazandığı günümüzde büyük bir ivme kazanmıştır. Günümüzde, yapay zeka, makine öğrenmesi, bilgisayarlı görme ve derin öğrenme teknikleri ile farklı alanlarda yapılmış birçok uygulama rapor edilmiştir [1]-[6]. Görüntü işleme, nesne tanıma, yüz tanıma ve diğer görsel görevler, bu alanlardaki temel zorlukları oluştururken, bu görevlerin çoğu tek bir model veya algoritma ile tamamlanamayacak kadar karmaşık hale gelmiştir.

Bu bağlamda, topluluk öğrenimi (ensemble learning) yaklaşımı önemli bir rol oynamaktadır.


Topluluk yaklaşımı, birden fazla öğrenme modelinin bir araya getirilmesi ve bu modellerin birlikte çalışması fikrine dayanır [7]. Bu yaklaşım, farklı öğrenme algoritmalarını, veri alt kümelerini veya öğrenme stratejilerini birleştirerek daha güçlü ve daha isabetli kararlar elde etmeyi amaçlar. Her bir model, kendi güçlü yönleri ve zayıflıklarını barındırır, ancak topluluk öğrenmesi, bu farklılıkları kullanarak sınıflandırma performansı üzerinde genel bir iyileştirme sağlar. Topluluk yaklaşımının en önemli avantajlarından biri, çeşitli model türlerini birleştirerek genelleştirme yeteneğini iyileştirmesidir. Ayrıca, topluluk yaklaşımı, veri kümelerindeki gürültüyü azaltma,

aşırı uydurmayı engelleme ve model kararlarını daha güvenilir hale getirme gibi bir dizi probleme karşı da katkı sunabilir [7].

II. MATERYAL VE YÖNTEM

Topluluk öğrenimi, iki veya daha fazla modelin güçlü ve öne çıkan özelliklerini birleştirerek tahminlerde bir fikir birliğine varma yöntemidir. Nihai topluluk öğrenme modeli, topluluğu oluşturan bireysel modellerden daha güçlüdür çünkü topluluk oluşturma, tahmin hatalarındaki varyansı azaltır. Topluluk öğrenimi, katkıda bulunan farklı modellerden tamamlayıcı bilgileri kullanarak daha güçlü bir sınıflandırıcı üretmeye çalışır. Bunun nedeni, katkıda bulunan modellerin istatistiksel bağlamda çeşitlilik arz etmesidir [8]. Diğer bir ifadeyle, aynı veri kümesi üzerinde sınıflandırma başarısı çeşitliliği gösteren alt modeller bir topluluk öğrenimi oluşturmak için daha uygundur [8][9]. Uygulanacak strateji, genellikle topluluk öğreniminde temel veri kümesinden farklı örnek kümeleri üzerinde yanlış tahminler yapan farklı modellerin bir araya getirilmesi fikrine dayanır. İstatistiksel olarak benzer iki model bir araya getirilirse (aynı örnek kümesi üzerinde yanlış tahminler yapan modeller), ortaya çıkan model yalnızca katkıda bulunan modeller kadar iyi olacaktır. Böyle bir durumda bir topluluk sınıflandırma başarısında herhangi bir fark meydana getirmeyecektir [8][10]. Bir topluluğun katkıda bulunan modellerinin tahminlerindeki çeşitlilik, oldukça yaygın olarak bilinen Kullback-Leibler ve Jensen-Shannon Divergence metrikleri kullanılarak doğrulanır [8]. Kullback-Leibler (KL) Ayrışması (ıraksaması), bir olasılık dağılımının ikinci bir beklenen olasılık dağılımından ne kadar ayrıştığına bir ölçüsüdür ve aynı zamanda iki farklı olasılık dağılımını karşılaştırmanın da en kolay bir yoludur. Şekil 1'den de anlaşılacağı gibi KL, bu iki farklı dağılım arasındaki uzaklığı veya bir dağılımı diğer dağılıma çevirmek istediğimiz zaman teorik olarak ne kadar bilgi kaybedildiğini ölçmeye yarar [11].

Makine öğrenimi, derin öğrenme, bilgisayarlı görü, istatistik ve bilgi teorisi gibi birçok alanda, kullanılan veri kümesindeki karmaşık dağılımları net olarak bilmediğimiz için genellikle karmaşık dağılımları daha basit dağılımlara benzetme yoluna gideriz. Aynı zamanda KL ıraksama (divergence) tekniği, benzetme maliyetini ölçmemize yardımcı olmaktadır [11].

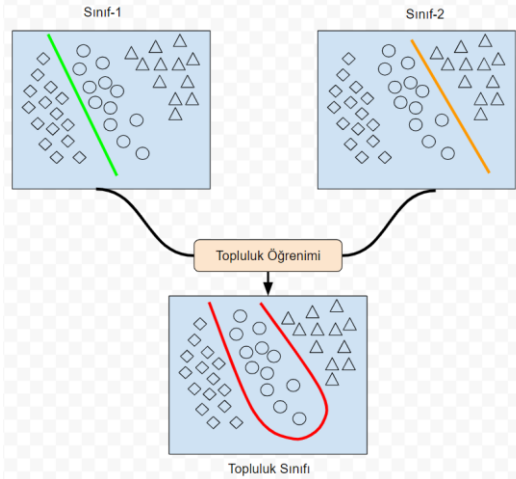


Şekil 1. Kullback-Leibler (KL) İraksaklığı [11]

Peki topluluk öğrenme yaklaşımları hangi durumlarda geleneksel makine öğrenmesi tekniklerine alternatif olarak kullanılabilir.

A. Problem Uzayının Karmaşıklığı

Bazen ilgilendiğimiz problemin karmaşıklık düzeyi o kadar yüksek olur ki tek bir sınıflandırıcı sınıflar arasında uygun ayrımsallığı yapmakta zorlanabilir. Örneğin, doğrusal bir sınıflandırıcı ile parabolik (polinom) karar sınırı olan bir problemin üstesinden gelemeyeceği açıktır. Ancak, birden fazla doğrusal sınıflandırıcıdan oluşan bir topluluk (ensemble) herhangi doğrusal olmayan bir polinom karar sınırı oluşturabilir. Şekil 2, burada anlatılan yüksek karmaşıklık problemini basit olarak betimlemektedir. Dolayısıyla veri kümesinin belirli bir alanında uzmanlaşacak birden fazla modelin tüm veri kümesini daha doğru sınıflandıracığı problemler için topluluk öğrenimi yaklaşımı uygun bir seçenek olacaktır.



Şekil 2. Veri kümesinin farklı alanlarında uzmanlaşan zayıf sınıfların topluluk öğrenimi sonucunda doğrusal olmayan ve yüksek karmaşıklığa sahip güçlü bir modeli üretmesi

B. Sınıf Uyumu

Bazı durumlarda veri kümesindeki sınıflara uyum noktasında problemlerle karşılaşabiliriz. Örnek olması açısından diyelim ki hedef sınıflandırıcı

portakal ile elma'yı çok iyi ayırabildiği halde portakal ile greyfurtu ayıramayabilir. Diğer taraftan, başka bir sınıflandırıcı elma ve greyfurtu çok iyi sınıflandırıyor. Şekil 2'deki gibi bu iki sınıftan meydana gelebilecek topluluk öğrenmesi modelinin daha az hata yapması mümkündür.

C. Düşük Model Performansı

Topluluk öğrenimi, zayıf performans sergileyen tek bir modelin yerine birden fazla modelin birleştirilmesini içerir. Bu, her bir modelin güçlü yönlerini öne çıkarırken, zayıf yönlerini baskılayabilir. Örneğin, birden fazla karar ağacını bir araya getiren "Random Forest" gibi yöntemlerin, tek bir karar ağacından daha güçlü sonuçlar üretebildiği rapor edilmiştir [12][13].

D. Aşırı Uydurma (Ezberleme)

Aşırı uydurma (overfitting), bir modelin eğitim verilerine çok fazla uyum sağlayarak yeni verilere (test veya doğrulama) karşı kötü bir genelleme performansı sergilemesine verilen teknik bir ifadedir. Topluluk öğrenimi, bu sorunu yapısında bir çok sınıflandırıcı kullanarak engellemeye çalışır. Boosting, genellikle farklı tipte zayıf öğrenme modellerini bir araya getirir. Bu, her bir modelin farklı örnekler veya özellikler üzerinde çalışmasını sağlar. Farklı modellerin bir araya gelmesi, aşırı uydurmanın etkilerini azaltır ve daha genel bir model oluşturur. Literatürde, özellikle "Boosting" yönteminin, aşırı uydurmayı azaltmada etkili olduğuna dair birçok çalışma bulunmaktadır [14]-[16].


E. Fine-grained veri kümeleri

Ensemble learning, fine-grained sınıflandırma görevlerinde etkili olur çünkü bu tür görevler, sınıflar arası benzerliğin yüksek ve sınıf içi varyansın büyük olduğu zorlu görevleri içerir. Geleneksel veri kümelerinde örneğin Mnist, Cifar vb., gibi bu durum tam tersidir. Yani sınıflar arası benzerlik düşük ve sınıf içi benzerlik yüksektir. Diğer bir ifadeyle sınıf içi varyans düşüktür. Şekil 3 klasik bir veri kümesinden olan mnist verisetinden iki sınıfı ve Şekil 4, fine-grained verisetinden nabirds'e ait iki farklı sınıfın iki farklı örneğini göstermektedir. Şekil 3'e dikkat edilir ise aynı sınıfa ait örneklerin çok farklı olmadıkları, diğer taraftan farklı sınıflara ait örneklerin bir birinden oldukça farklı göründükleri anlaşılmaktadır. Öte yandan, Şekil-4 fine-grained veri kümesi örneklerini inceleyecek olursak; 295

sınıfına ait örneklerde sınıf-içi varyansın çok yüksek olduğu ancak sınıflar arası benzerliğin de fazla olduğu görülecektir.



Şekil 3. Mnist veri kümesindeki iki farklı sınıfa ait görüntüler. "7" sınıfı üst satırda ve "3" sınıfı alt satırda.



Şekil 4. Nabirds fine-grained veri kümesindeki iki farklı sınıfa ait görüntüler. "295" sınıfı üstte ve "296" sınıfı alt satırda.

Her bir alt sınıfın farklı ve benzersiz özelliklere sahip olduğu bu görevlerde, tek bir modelin tüm ayrıntıları yakalayarak doğru sonuçları elde etmesi oldukça zor olabilir. Ensemble learning, birden fazla öğrenme modelinin bir araya getirilmesini içerir ve bu modellerin farklı alt sınıflar veya özellikler üzerinde çalışmasına izin verir. Bu çeşitlilik, farklı modellerin alt sınıfları daha iyi tanımlayabilmesini sağlar. Ayrıca, ensemble learning, veriye eklenen gürültülere veya aykırı değerlere karşı daha dirençli olabilir çünkü her bir modelin hataları farklıdır ve bu hatalar birleştirildiğinde dengelenir. Sonuç olarak, ensemble learning, fine-grained sınıflandırma görevlerinde daha iyi ayırım yapabilen ve modelin daha güvenilir sonuçlar üretebilmesine yardımcı olan bir yöntem olarak öne çıkar. Bu, özellikle her bir alt sınıfın ayrıntılarına odaklanılması gereken görevlerde çok güçlü bir avantaj sağlar [18][19].

Toplu öğrenme (ensemble learning), farklı sınıflandırıcıların öğrendiği eşleştirme fonksiyonlarını (mapping-functions) birleştirerek bütünleşik bir sınıflandırıcı oluşturur. Bu amaçla yıllar içinde farklı stratejilerle çeşitli yöntemler önerilmiştir. Aşağıda, literatürde sıkça kullanılan ve popüler hale gelmiş olan yöntemler ele alınmıştır.

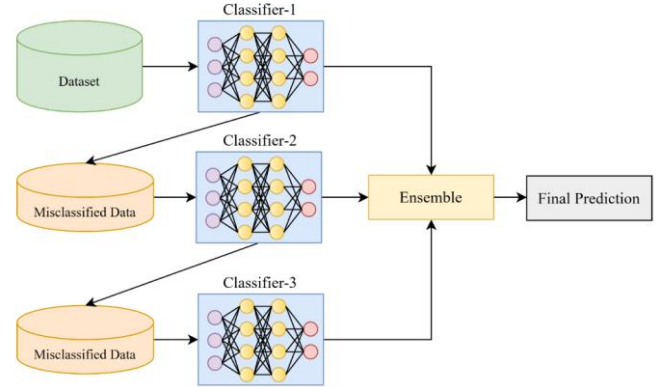
A. Bagging (Torbalama)

Bagging ensemble tekniği, 'bootstrap aggregating'in kısaltmasıdır ve ilk kullanılan ensemble yöntemlerinden biridir. Bu yaklaşımda, alt kümeler bir veri setinden 'bootstrap örnekleme' olarak bilinen bir süreçle oluşturulur. Daha basit bir ifadeyle, veri kümesinin rastgele alt kümeleri değiştirilerek oluşturulur, yani aynı veri noktası birden fazla alt kümede görünebilir. Bu alt kümeler daha sonra her biri çeşitli Makine Öğrenimi modellerini eğitmek için kullanılan bağımsız veri kümeleri olarak ele alınır. Test aşamasına gelindiğinde, aynı verilerin farklı alt kümeleri üzerinde eğitilen bu modeller tarafından yapılan tahminler dikkate alınır. Nihai tahmini hesaplamak için bir toplama yöntemi kullanılır. Bagging mekanizmasında paralel işlem akışı mevcuttur. Bagging işleminin temel amacı, topluluk tahminlerinin varyansını azaltmaktır. Bu nedenle, seçilen topluluk sınıflandırıcıları genellikle yüksek varyansa ve düşük önyargıya sahiptir (birçok eğitilebilir parametreye sahip karmaşık modeller). Bu yaklaşıma dayanan popüler topluluk yöntemleri arasında Torbalı Karar Ağaçları (Bagged Decision Trees), Rastgele Orman Sınıflandırıcıları (Random Forests Classifiers) ve Ekstra Ağaçlar (Extra Trees) sayılabilir.

B. Boosting (Güçlendirme)

Boosting topluluk mekanizması, Bagging topluluk mekanizmasından farklı bir işleyiş mekanizmasına sahiptir. Burada, veri kümesi paralel olarak işlenmek yerine sıralı bir şekilde işlenir. İlk sınıflandırıcı, tüm veri kümesi kullanılarak eğitilir ve tahminler üretir. Ardından, Sınıflandırıcı-1'in hatalı tahminler yaptığı örnekler (yani özellik uzayının özellikle karar sınırına yakın olanları) ikinci sınıflandırıcıya aktarılır. Bu, Sınıflandırıcı-2'nin daha çok problemlili bölgelere odaklanabilmesini ve daha doğru bir karar sınırı tanımlamasını sağlar. Benzer şekilde, diğer adımlar da aynı fikri izler ve sonuç olarak test verileri üzerinde nihai tahmin yapmak için tüm bu önceki

sınıflandırıcıların bir topluluğu (ensemble) oluşturulur. Şekil 5 burada anlatılan safhaları özetlemektedir [8].



Şekil 5. Boosting topluluk öğrenme yaklaşımının çalışma mantığı [8]

C. Stacking (İstifleme)

Stacking, ensemble learning yöntemlerinden biri olan model istifleme (model stacking) tekniğini ifade eder. Model stacking, farklı öğrenme modellerinin tahminlerini birleştirerek bir üst düzey öğrenme modeli oluşturur ve bu nedenle bir "meta-model" olarak ta adlandırılır. Stacking, farklı modellerin birleştirilmesiyle her bir modelin zayıf yönlerini dengelemek suretiyle bir üst düzeyde daha güçlü tahminler yapılmasına olanak tanır. Bu, topluluk öğrenmesi'nin genel performansını artırabilir. Ancak, stacking, daha fazla hesaplama kaynağı gerektirebilir ve nihai karar verme süresini uzatabilir. Stacking, özellikle yapay zeka yarışmalarında, sağlık ve medikal görüntülerin analizinde ve tahminleme problemleri gibi rekabetçi ortamlarda tercih edilmektedir, çünkü bu tür problemlerde küçük bir performans artışı büyük bir katkı anlamına gelmektedir.

III. SONUÇLAR

Bu çalışmada, topluluk öğrenimi yaklaşımlarının, bilgisayarlı görme alanında önemli bir rol oynadığı ve araştırmacılar için çeşitli avantajlar sunduğu anlaşılmıştır. Günümüzdeki teknolojik gelişmeler ve büyük veri artışı, bilgisayarlı görme ve makine öğrenimi alanlarını ivmelendirmiştir. Ancak, bazı karmaşık görevlerde, tek bir model veya algoritma yeterli olmayabilir. Topluluk öğrenimi, birden fazla öğrenme modelini bir araya getirerek daha güçlü ve genelleyici sınıflandırıcılar oluşturmanın bir yolunu bize sunmaktadır. Bu durum, özellikle problem uzayının karmaşıklığı, sınıf uyumsuzluğu, düşük model performansı, aşırı uydurma ve fine-

grained veri kümeleri gibi senaryolarda etkili olabilir. Özellikle fine-grained sınıflandırma görevlerinde, farklı öğrenme modellerinin bir araya getirilmesi, her bir alt sınıfın benzersiz özelliklerini daha iyi tanımlayabilme yeteneği sunar. Bu bildiride, topluluk öğrenimi yaklaşımlarının, bilgisayarlı görme alanında daha iyi sonuçlar elde etmek isteyen araştırmacılar için önemli bir yaklaşım olduğu vurgulanmaktadır. Ayrıca, bu yaklaşımların farklı modellerin çeşitliliği, genelleme yeteneği, gürültü azaltma ve aşırı uydurmayı önleme gibi avantajlarına odaklanılmıştır.

Gelecekte yapılacak çalışmalar, topluluk öğrenimi yöntemlerini daha fazla bilgisayarlı görme görevine uygulamayı, bu yöntemlerin veri verimliliğini artırmak için nasıl kullanılabileceğini ve daha fazla özelleştirilmiş ve etkili topluluk öğrenme stratejilerini geliştirme üzerine kurgulanmalıdır. Bu sayede ilgili alanda yaşanacak ilerlemeler, bilgisayarlı görme sistemlerinin daha güçlü ve güvenilir hale gelmesine katkı sağlayabilecektir.

KAYNAKLAR

- [1] Li, Ying, et al. "TireNet: A high recall rate method for practical application of tire defect type classification." *Future Generation Computer Systems* 125 (2021): 1-9.
- [2] Ataş, Musa. "Hand tremor based biometric recognition using leap motion device." *IEEE Access* 5 (2017): 23320-23326.
- [3] Bhamare, Mr Harshal, and Ajitkumar Khachane. "Quality Inspection of tyre using Deep Learning based Computer Vision." *Learning* 6.11 (2019).
- [4] Ataş, Musa. "Fıstık sınıflandırma sistemi için Siirt fıstığı imgelerinden gürbüz özniteliklerin çıkarılması." *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi* 7.1 (2016): 93-102.
- [5] Fadhel., Yasser. et.al (2017). "Miniaturization Of A Planar Strip-Shaped Monopole Antenna For Wlan Application". *Journal of Duhok University*, 77-89.
- [6] Zheng, Zhouzhou, et al. "Defect inspection in tire radiographic image using concise semantic segmentation." *IEEE Access* 8 (2020): 112674-112687.
- [7] Dong, Xibin, et al. "A survey on ensemble learning." *Frontiers of Computer Science* 14 (2020): 241-258.
- [8] (2023) H7 Ensemble Learning website. [Online]. Available: <https://www.v7labs.com/blog/ensemble-learning#:~:text=Ensemble%20learning%20combines%20the%20mapping,commonly%20used%20in%20the%20literature.>
- [9] Zhang, Cha, and Yunqian Ma, eds. *Ensemble machine learning: methods and applications*. Springer Science & Business Media, 2012.
- [10] Kundu, Rohit, et al. "COVID-19 detection from lung CT-Scans using a fuzzy integral-based CNN ensemble." *Computers in Biology and Medicine* 138 (2021): 104895.
- [11] (2023) Medium website. [Online]. Available: <https://medium.com/@hosamedwee/kullback-leibler-kl-divergence-with-examples-part-2-9123bff5dc10>
- [12] Zhao, Lingran, et al. "Using the rotation and random forest models of ensemble learning to predict landslide susceptibility." *Geomatics, Natural Hazards and Risk* 11.1 (2020): 1542-1564.
- [13] Mishra, Amit Kumar, and Shweta Paliwal. "Mitigating cyber threats through integration of feature selection and stacking ensemble learning: the LGBM and random forest intrusion detection perspective." *Cluster Computing* 26.4 (2023): 2339-2350.
- [14] Yang, Senyan, et al. "Ensemble learning for short-term traffic prediction based on gradient boosting machine." *Journal of Sensors* 2017 (2017).
- [15] Polikar, Robi. "Ensemble learning." *Ensemble machine learning: Methods and applications* (2012): 1-34.
- [16] Avnimelech, Ran, and Nathan Intrator. "Boosted mixture of experts: An ensemble learning scheme." *Neural computation* 11.2 (1999): 483-497.
- [17] Xu, Qin, et al. "Fine-grained visual classification via internal ensemble learning transformer." *IEEE Transactions on Multimedia* (2023).
- [18] Rajaraman, Sivaramakrishnan, et al. "A Systematic Evaluation of Ensemble Learning Methods for Fine-Grained Semantic Segmentation of Tuberculosis-Consistent Lesions in Chest Radiographs." *Bioengineering* 9.9 (2022): 413.
- [19] Okamoto, Naoki, et al. "Deep Ensemble Learning by Diverse Knowledge Distillation for Fine-Grained Object Classification." *European Conference on Computer Vision*. Cham: Springer Nature Switzerland, 2022.