

TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

ÇEVRE VE ENERJİ TEKNOLOJİLERİ YARIŞMASI

PROJE DETAY RAPORU

TAKIM ADI: HIYUCAN

PROJE ADI: Görüntü İşleme ile Geri Dönüştürülebilir Atıkların
Belirlenmesine Yönelik Aracın Geliştirilmesi

BAŞVURU ID: #74047

1. Proje Özeti (Proje Tanımı)

Bilişim teknolojileri alanındaki donanımsal gelişmeler, artan yonga işleme yetenekleri ve artan veri kümesi boyutları yapay zekâ alanında oldukça ilerleme kaydedilmesine ve birçok problemin çözülmesine katkı sağlamıştır (Kurt, 2018). Yapay zekâ teknolojisi artık günümüzde insan hayatının çok önemli bir parçası haline gelmiştir (Ayyüce Kızrak & Bolat, 2018). Yapay zekanın farklı dalları vardır, bunlardan bir tanesi ise makine öğrenmesidir. Makine öğrenmesi algoritmaları arasında yer alan derin öğrenmenin bilgisayarla görme, konuşma ve ses işleme, doğal dil işleme, robotik, biyoinformatik ve kimya, video oyunları, arama motorları, çevrim içi reklamcılık ve finans dahil olmak üzere birçok alanda yararlı olduğu kanıtlanmıştır (Şeker, Diri & Balık, 2017). Bu çalışmada da derin öğrenme modellerinden bir tanesi olan Evrişimli Sinir Ağları (ESA / Convolutional Neural Network - CNN ya da ConvNet) (Avilov vd., 2020; İnik & Ülker, 2017) ile bir mimari oluşturulmuş ve görüntü işleme yöntemleri ile atıklardaki geridönüştürülebilir maddelerin belirlenmesinde ve sınıflandırılmasında kullanılacak bir uygulama geliştirilmesi hedeflenmiştir. ESA, görsel öğeleri analiz etmek için en yaygın olarak uygulanan derin sinir ağı mimarisidir. Böylece atıkların sınıflandırılmasında harcanacak emek minimize edilebilir. Yapılacak çalışma ile geri dönüşüm şirketlerinin ve belediyelerin atık yönetimi faaliyetlerinin geliştirilebileceği, uzun vadede ise ekosistem üzerindeki yükün hafifletilebileceği düşünülmektedir.

Bu çalışmada geri dönüşümlü atıkların sınıflandırılmasında kullanılması planlanan uygulamanın yanında bir de bu uygulama aracılığıyla eğitilen modeli okuyarak atık görüntülerini sınıflandıracak ve bu atıkları uygun kumbaralara ayıracak bir ayrıştırma hattının tasarımı yapılmıştır.

2. Problem/Sorun:

Günümüzde atıkların ayrıştırılarak toplanması ciddi miktarda emek gerektirmektedir (Maden, 2004) ancak uygulanabilecek otomasyon işlemleri ile geri dönüşüm açısından değerli materyallerin geri kazanımı artırılabilir. Gelişmekte olan görüntü işleme ve otomasyon teknolojileri çok sayıda güncel hayat probleminin çözümüne katkı sağlamıştır (Kurt, 2018) ve bu alanda da harcanan emek ve zamanı azaltabilir. Ülkemizde halen pek çok yerleşim yerinde geri dönüştürülebilir atıkların ayrı ayrı toplanabileceği atık kumbaraları bulunmamaktadır. Bulunanların büyük kısmı tüm geri dönüşümlü atık çeşitlerinin bir arada toplandığı türden kumbaralardır (Resim 1). Çalışmamızda önerilen çözüm, kaynağında ayrı toplanmayan atıkların sınıflandırılmasını sağlaması yönünden hiç atık kumbarası olmayan yerleşim yerlerinin hızla azaltılması konusunda da kolaylık sağlayacak niteliktedir.

3. Çözüm

Bu projede amaç, farklı alanlarda karşımıza çıkan geri dönüştürülebilir atıkların sınıflandırılması problemini bu atıkların görüntülerini bir derin öğrenme mimarisi olan ESA kullanarak tespit eden bir aracın geliştirilmesi ve bu aracın bir ayrıştırma hattında kullanılmasıdır. Bütünsel bir bakış açısı ile ambalaj atığı ve evsel atık sınıflandırması gibi benzer problemleri çözebilecek bir mimarinin tasarımı yapılmıştır (Resim 2). Geliştirilen aracın yapay sinir ağı Tensorflow kütüphanesi, arayüzü PyQt5 kütüphanesi kullanılarak ve Python programlama dilinde hazırlanmıştır.

Ürünün kullanımı iki ana aşamadan oluşmaktadır. Uygulama aracılığıyla sınıflandırıcı model eğitilir ve eğitilen model RaspberryPi adı verilen minibilgisayar üzerine kopyalanır. Ardından ayrıştırma hattı çalıştırılır, geri dönüşümlü atıklar ayrı kumbaralarda biriktirilir ve

geri dönüştürülemeyen atıklar ise sistemin çıkışında ayrıca depolanır. RaspberryPi, ayrıştırma hattı üzerinde bulunan kameralar aracılığıyla atıkların görüntülerini sınıflandırır ve atıkların yol aldığı ayrıştırma hattını kontrol eder. Önceden eğitilen modellerin yetersiz kaldığı düşünülen durumlarda kullanıcılar kendi durumlarına daha uygun veri setleri toplayarak uygulama aracılığıyla yeni modeller eğitebilir.

Çalışma sonunda elde edilen ürünler şu şekildedir: sınıflandırıcı modelin eğitilmesini ve test edilmesini sağlayan uygulama (Resim 3), ayrıştırma hattı tasarımı (Resim 4). Uygulama kullanıcı tarafından belirlenen verisetinden modelin eğitildiği ve eğitilmiş modelin test edildiği iki kısımdan oluşmaktadır. Ayrıştırma hattı ise taşıma bandı; kağıt, plastik, metal, cam ve geri dönüşümsüz atık kumbaraları; kumbaraların girişini kapatan kapılar ve bunları kontrol eden servo motorlar; hattı kontrol eden RaspberryPi ve buna bağlı kameralardan oluşmaktadır.

4. Yöntem

Geliştirilen yapay sinir ağı birbirini takip eden evrişim ve havuzlama katmanlarından oluşmaktadır. Evrişim katmanlarında aktivasyon fonksiyonu olarak ReLu (Rectified Linear Unit Activation Function – Düzeltilmiş Linear Aktivasyon Fonksiyonu) seçilmiştir. Havuzlama katmanı için ise için MaxPooling süreci (Maksimum Havuzlama) tercih edilmiştir. İki boyutlu yapıda olan evrişim ve havuzlama katmanlarının iki kere uygulanmasının ardından tek boyutlu yapıda olan Flatten (düzleştirme) katmanı uygulanmış ve bu katman da çıkış katmanına bağlanmıştır. Düzleştirme katmanının aktivasyon fonksiyonu “ReLu” olarak seçilmiştir. Çıkış katmanı ise kullanılan veri setindeki sınıf sayısı iki adet olduğunda “sigmoid” aktivasyon fonksiyonunu kullanan tek nöron, ikiden daha fazla sınıf olduğu durumda ise “softmax” aktivasyon fonksiyonunu kullanan sınıf sayısı kadar nöron bulunacak şekilde tanımlanmıştır. Bu sayede aktif duruma geçen nörona göre sinir ağına sağlanan fotoğrafın hangi sınıfa ait olduğu belirlenebilmektedir.

Modelin eğitilmesinde ve model aracılığıyla tahminler yapmada kullanılan fonksiyonlar arayüzdeki butonlar ile kullanılabilir hale getirilmiştir. Kullanıcılar öğrenme oranı, öğretici (optimizer), kayıp fonksiyonu (loss function), batchsize, epoch sayısı gibi hiperparametre denen değişkenleri kolaylıkla değiştirebilmektedir. Bunun yanı sıra eğitilen model ve modele ait hiperparametreler kaydedilebilmekte ve daha sonrasında kaydedilmiş model geri çağırılarak tahmin işlemleri yapılabilmektedir. Ayrıca modeller, farklı bilgisayarlar arasında da kopyalanabilir formda kaydedilir. Böylece güçlü donanıma sahip bilgisayarlar üzerinde geliştirilen modeller gerekli kütüphanelerin kurulabildiği her bilgisayarda kullanılabilir. Arayüz tasarım olarak iki kısımdan oluşmaktadır. Sol kısımda sinir ağının eğitilmesiyle ilgili parametrelerin ve hiper parametrelerin seçimi ile ilgili alanlar bulunurken sağ tarafta modelin eğitilmesinden sonra tahmini yapılacak kullanıcı resimleri, çıktı resimleri ve modelin kaydedileceği konum değişkenlerin belirlendiği kısımdır. Arayüz tasarlanırken programlama bilgisi ve kod yazmayı gerektirmeden her kullanıcının kullanabileceği ve kullanıcı tarafından oluşturulan verisetlerinden zahmetsizce modeller eğitilebileceği şekilde olmasına dikkat edilmiştir.

Geliştirilen uygulama açık erişimli bir veri ambarı olan “Trashnet” (Trashnet, 2017) üzerinde denenmiştir. 2527 görüntüden oluşan verisetiyle eğitilen model %80 eğitim ve %54 tahmin başarısı elde edilmiştir (Resim 5). Toplanacak farklı verisetleri ve evrişimli sinir ağında yapılacak geliştirmelerle daha yüksek tahmin başarıları elde edilebilir.

5. Yenilikçi (İnovatif) Yönü

Literatürde derin öğrenmenin kullanıldığı ve güncel hayat problemlerinin çözüldüğü çok sayıda çalışma yer almaktadır (Zheng vd., 2017; Coşkun vd., 2017; Boddapati vd., 2017; Shang vd., 2018) ancak bu çalışmalar tek bir problemin çözülmesine yöneliktir ve hedef kitlenin tüm problemlerine hitap etmemektedir. Geliştirilen uygulama, kullanıcılara kendi oluşturdıkları verisetleri üzerinde çalışma imkânı da sağlamaktadır.

Alanda yapılan literatür taraması sonucu benzer bir işlevi robot kol ile sağlamaya çalışan çalışmalar vardır ancak kullanılacak bir robot kolun ayrıştırma hızını düşüreceği ve kurulacak tesislerin maliyetini arttıracacağı tahmin edilmektedir (Kim vd., 2019).

6. Uygulanabilirlik

Yerel yönetimlerle varılabilecek anlaşmalar ile özel atık sınıflandırma tesisleri kurulabilir. Bu çalışmada geliştirilen uygulama ve sunulan bakış açısı kullanılarak eğitilen yapay zeka modelleri, uygun otomasyon sistemlerinin kurulması ile tamamlanarak otonom geri dönüşüm tesisleri kurulabilir. Kurulabilecek otonom ayrıştırma tesisleri sayesinde işçi ücretlerinden kar edilip (Maden, 2014) atık ayrıştırma tesisi halen olmayan şehirlere (Sayar, 2012) de tesisler kurulabilir. Geliştirilen matematiksel modeller üzerinde yapılabilecek iyileştirmeler sayesinde önerilen ayrıştırma tesisleri yatırımcılar için daha cazip hale getirilebilir.

Önerilen bakış açısıyla kurulabilecek ayrıştırma tesisleri ile doğaya bırakılan sanayi, çiftlik, evsel atıklar da ayrıştırılıp yeniden değerlendirilerek ekonomiye kazandırılabilir ile toprak ve su ekosistemleri korunabilir.

7. Tahmini Maliyet ve Proje Zaman Planlaması

Gider Hesabı	Maliyet
Raspberry Pi Model 4	700 TL
Kamera (5 adet)	750 TL
Taşıma Bandı	320 TL
Servo Motor (16 adet)	224 TL
Plastik Aksam	120 TL

Hesaplanan maliyet yalnızca prototipin maliyetini içermektedir. Literatür taraması sonucu bir ayrıştırma tesisinin yıllık giderinin 1.152.952 TL olduğu ve en önemli gider kalemlerinin işçi ve kira olduğu belirlenmiştir (Maden, 2014). Tasarımlar daha kompakt hale getirilerek kira masrafından da kısmen tasarruf edilebileceği tahmin edilmektedir.

AYLAR							
İşin Tanımı	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül
Sorunun ve Proje Fikrinin Belirlenmesi	X	X					
Literatür Taraması	X	X	X	X	X	X	X
Verilerin Toplanması ve Analizi		X	X	X	X	X	X

Gerekli Yazılımın Geliştirilmesi		X	X	X	X		
Örnek Ayırıştırma Hattının Yapımı				X	X		
Proje Raporu Yazımı	X	X	X	X			

8. Proje Fikrinin Hedef Kitlesi (Kullanıcılar):

Yapılan çalışma hedef kitle olarak atık yönetimi çözümleri arayan yerel yönetimleri ve kamu kurumlarını ve bu hizmeti sunan özel sektör kuruluşlarını kapsamaktadır. Düşecek maliyetlerin yeni ayırıştırma tesisleri kurulmasında teşvik edici rol oynayacağı düşünülmektedir. Proje hayata geçirildikten sonra şehirde yaşayan vatandaşların, maliyeti düşen hammaddeleri kullanan imalathanelerin, doğal yaşam alanı temiz kalan canlıların faydalanıcı olacakları tahmin edilmektedir.


9. Riskler

Önceden eğitilen matematiksel modellerin kurulan tesise uygun gelmemesi durumunda yeni bir veriseti toplanıp geliştirilen uygulamanın arayüzü sayesinde tek satır kod yazmadan yeni bir model eğitilebilecektir. Proje hayata geçirilince kurulacak otonom tesisler istihdamda azalmaya yol açabilir ancak verilebilecek hizmet içi eğitimler aracılığıyla bu çalışanlara yeni beceriler kazandırılıp ihtiyaç olan yeni alanlara yerleştirilebilirler. Yeni sistem teknolojik arızalardan daha çok etkileneceği için yeni teknisyenlere ihtiyaç duyulacaktır. Şehirlerde atık kağıt gibi geri dönüşümlü malzeme toplayarak geçimini sağlayan insanlar kurulacak otonom ayırıştırma tesislerinden olumsuz etkileneceklerdir.

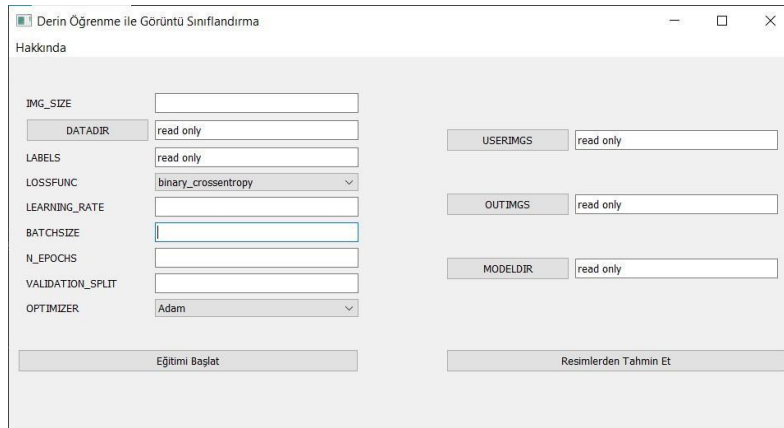
Etki \ Olasılık	Düşük olasılık	Yüksek olasılık
Düşük etki	Tesislerde yaşanabilecek teknik arızalar	Atık toplayarak geçinen insanların iş kaybetmesi
Çözüm önerisi	Yazılıma yamalar yapılması ve hattın mekanik olarak geliştirilmesi	Ayırıştırma yerine toplama alanında istihdam edilmeleri
Yüksek etki	Tesislere yapılabilecek siber saldırılar	İstihdam kaybı
Çözüm önerisi	Merkezi bir siber güvenlik ekibi kurulması	Meslek içi eğitimlerle çalışanlara yeni beceriler kazandırılması




Resim 1. Geri dönüşüm kutusu



Resim 2. Geliştirilen sinir ağının yapısı



Resim 3. Sınıflandırıcı modelin eğitilmesini ve test edilmesini sağlayan uygulama



Resim 4. Tasarlanan atık ayrıştırma hattı

```

2274/2274 [=====] - 29s 13ms/sample - loss: 0.7476 - accuracy: 0.7199 - val_loss: 1.2901 - val_accuracy: 0.5178
Epoch 16/30
2274/2274 [=====] - 29s 13ms/sample - loss: 0.6623 - accuracy: 0.7564 - val_loss: 1.3571 - val_accuracy: 0.5138
Epoch 17/30
2274/2274 [=====] - 29s 13ms/sample - loss: 0.5935 - accuracy: 0.7762 - val_loss: 1.4160 - val_accuracy: 0.4901
Epoch 18/30
2274/2274 [=====] - 29s 13ms/sample - loss: 0.5574 - accuracy: 0.7836 - val_loss: 1.3370 - val_accuracy: 0.5138
Epoch 19/30
2274/2274 [=====] - 29s 13ms/sample - loss: 0.5344 - accuracy: 0.7990 - val_loss: 1.3224 - val_accuracy: 0.5455
Epoch 00019: early stopping

```

Resim 5. Trashnet veriseti üzerinde elde edilen eğitim başarısı

10. Kaynakça ve Rapor Düzeni

- Avilov, O., Rimbart, S., Popov, A., & Bougrain, L. (2020). Deep Learning Techniques to Improve Intraoperative Awareness Detection from Electroencephalographic Signals. In 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). (pp. 142-145). IEEE.
- Ayyüce Kızrak, M , Bolat, B . (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. Bilişim Teknolojileri Dergisi, 11 (3), 263-286. DOI: 10.17671/gazibtd.419205
- Blum, A. L., & Langley, P. (1997). Selection of relevant features and examples in machine learning. Artificial intelligence, 97(1-2), 245-271.
- Boddapati, V., Petef, A., Rasmusson, J., & Lundberg, L. (2017). Classifying environmental sounds using image recognition networks. Procedia computer science, 112, 2048-2056.
- Bukhari, S. U. K., Bukhari, S. S. K., Syed, A., & Shah, S. S. H. (2020). The diagnostic evaluation of Convolutional Neural Network (CNN) for the assessment of chest X-ray of patients infected with COVID-19. medRxiv.
- Coşkun, M., Uçar, A., Yildirim, Ö., & Demir, Y. (2017). Face recognition based on convolutional neural network. In 2017 International Conference on Modern Electrical and Energy Systems (MEES) (pp. 376-379). IEEE.

- Çalik, R. C., & Demirci, M. F. (2018, October). Cifar-10 image classification with convolutional neural networks for embedded systems. In 2018 IEEE/ACS 15th International Conference on Computer Systems and Applications (AICCSA) (pp. 1-2). IEEE.
- Endüstri 4.0 Platformu (2018). Yapay Zeka, Makine Öğrenimi ve Derin Öğrenme Arasındaki Farklar. <https://www.endustri40.com/yapay-zeka-makine-ogrenimi-ve-derin-ogrenme-arasindaki-farklar/> Erişim tarihi: 21 Aralık 2020
- Hiremath, T., & Rajarajeswari, S. (2019). A Survey on Existing Convolutional Neural Networks and Waste Management Techniques. *Emerging Research in Computing, Information, Communication and Applications: ERCICA 2018*, Volume 2, 906, 45.
- I. Goodfellow, Y. Bengio, & A. Courville. (2016). "Deep learning", The MIT Press, Cambridge, Massachusetts.
- Iandola, F. N., Shen, A., Gao, P., & Keutzer, K. (2015). Deeplogo: Hitting logo recognition with the deep neural network hammer. arXiv preprint arXiv:1510.02131.
- İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104
- Kim, J., Nocentini, O., Scafuro, M., Limosani, R., Manzi, A., Dario, P., & Cavallo, F. (2019). An Innovative Automated Robotic System based on Deep Learning Approach for Recycling Objects. In *ICINCO (2)* (pp. 613-622).
- Ko, H., Chung, H., Kang, W. S., Kim, K. W., Shin, Y., Kang, S. J., Lee, J. H., Kim. Y. J., Kim, N. Y., Jung, H., & Lee, J. (2020). COVID-19 Pneumonia Diagnosis Using a Simple 2D Deep Learning Framework With a Single Chest CT Image: Model Development and Validation, *Journal of Medical Internet Research*, 22 (9):e19569.
- Komar, M., Yakobchuk, P., Golovko, V., Dorosh, V., & Sachenko, A. (2018). Deep neural network for image recognition based on the caffe framework. In 2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP) (pp. 102-106). IEEE.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kurt, F. (2018). Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi (Master's thesis, Eğitim Bilimleri Enstitüsü) Hacettepe Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı.
- L. Deng & D. Yu. (2014). "Deep Learning: Methods and Applications", *Foundations and Trends® in Signal Processing: Vol. 7: No. 3-4*, pp 197-387.
- Lai, Y. L., Lai, Y. K., Shih, S. Y., Zheng, C. Y., & Chuang, T. H. (2020, July). Deep-learning Object Detection for Resource Recycling. In *Journal of Physics: Conference Series (Vol. 1583, No. 1, p. 012011)*. IOP Publishing.
- M. Pak & S. Kim. (2017). "A review of deep learning in image recognition," 4th International Conference on Computer Applications and Information Processing Technology (CAIPT), Kuta Bali, 2017, pp. 1-3, doi: 10.1109/CAIPT.2017.8320684.
- Maden, S. (2014). Ambalaj atıkları toplama ayırma tesislerinin kurulması, maliyet analizleri ve işletilmesi. (Yayınlanmış yüksek lisans tezi.) Yıldız Teknik Üniversitesi: Fen Bilimleri Enstitüsü.
- Modarres, M. H., Aversa, R., Cozzini, S., Ciancio, R., Leto, A., & Brandino, G. P. (2017). Neural network for nanoscience scanning electron microscope image recognition. *Scientific reports*, 7(1), 1-12.

- Mohapatra, R.K., Majhi, B., & Jena, S.K. (2015). Classification Performance Analysis of MNIST Dataset utilizing a Multi-resolution Technique, 2015 International Conference on Computing, Communication and Security (ICCCS).
- Nejadgholi, M., & Yang, J. (2019). A study of oracle approximations in testing deep learning libraries. In 2019 34th IEEE/ACM International Conference on Automated Software Engineering (ASE) (pp. 785-796). IEEE.
- Palvanov, A., & Im Cho, Y. (2018). Comparisons of deep learning algorithms for MNIST in real-time environment. *International Journal of Fuzzy Logic and Intelligent Systems*, 18(2), 126-134.
- Roelofs, R., Shankar, V., Recht, B., Fridovich-Keil, S., Hardt, M., Miller, J., & Schmidt, L. (2019). A meta-analysis of overfitting in machine learning. *Advances in Neural Information Processing Systems*, 32, 9179-9189.
- Sayar, Ş. (2012). Sakarya ili entegre atık yönetimi ve ambalaj atıklarının geri dönüşümü. (Yayımlanmış yüksek lisans tezi). T.C. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Sayed, A, "1st Place Solution for Intel Scene Classification Challenge", towards data science, <https://towardsdatascience.com/1st-place-solution-for-intel-scene-classification-challenge-c95cf941f8ed>. Erişim tarihi: 24 Ocak 2021.
- Shang, L., Yang, Q., Wang, J., Li, S., & Lei, W. (2018). Detection of rail surface defects based on CNN image recognition and classification. In 2018 20th International Conference on Advanced Communication Technology (ICACT). pp. 45-51. IEEE.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Smith, J.W., Everhart, J.E., Dickson, W.C., Knowler, W.C., & Johannes, R.S. (1988). Using the ADAP learning algorithm to forecast the onset of diabetes mellitus. In *Proceedings of the Symposium on Computer Applications and Medical Care*, (pp. 261--265). IEEE Computer Society Press.
- Şahin, D. Ö., Ateş, N., & Kiliç, E. (2016). Feature selection in text classification. In 2016 24th signal processing and communication application conference (SIU), (pp. 1777-1780). IEEE.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Toğaçar, M., & Ergen, B. (2019). Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat University Journal of Engineering*, 31(1).
- Trashnet. (2017). Erişim adresi <https://github.com/garythung/trashnet>.
- Qt Documentation, "Qt Designer Manual", <https://doc.qt.io/qt-5/qt designer-manual.html>, Son erişim tarihi: 10 Şubat 2021
- Yang, K., Liu, H., Wang, P., Meng, Z., & Chen, J. (2018). Convolutional neural network-based automatic image recognition for agricultural machinery. *International Journal of Agricultural and Biological Engineering*, 11(4), 200-206.
- Yang, M., & Thung, G. (2016). Classification of trash for recyclability status. CS229 Project Report, 2016.
- Zheng, H., Fu, J., Mei, T., & Luo, J. (2017). Learning multi-attention convolutional neural network for fine-grained image recognition. In *Proceedings of the IEEE international conference on computer vision* (pp. 5209-5217).