



# Convolutional Neural Networks for Automatic Modulation Classification

Osman Kaya<sup>1\*</sup>, Tansal Güçlüoğlu<sup>2</sup>

<sup>1\*</sup> Yıldız Teknik Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0003-4902-2166), [osmnkaya11@gmail.com](mailto:osmnkaya11@gmail.com)

<sup>2</sup> Yıldız Teknik Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0002-4090-005X), [tansal@yildiz.edu.tr](mailto:tansal@yildiz.edu.tr)

(6<sup>th</sup> International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1224925)

**ATIF/REFERENCE:** Kaya, O. & Güçlüoğlu, T. (2022). Convolutional Neural Networks for Automatic Modulation Classification. *European Journal of Science and Technology*, (44), 93-96.

## Abstract

Automatic Modulation Classification (AMC) is the process of determining the modulation type of the signal which is taken by receiver in a communication system. Deep learning is a machine learning method having recently attracted great attention due to its superior performance of classifying complex data structures. The automatic modulation classification process, having a critical role in both civil and military applications, is examined in this study by using Convolutional Neural Networks (CNN), one of the deep learning approaches. Within this scope, the performance of the changes made on the net has been interpreted for different signal-to-noise ratio (SNR) values.

**Keywords:** Automatic modulation classification, deep learning, convolutional neural networks

## Otomatik Modülasyon Sınıflandırmasında Evrimsel Sinir Ağları

### Öz


Otomatik modülasyon sınıflandırma (AMC) bir haberleşme sisteminde alıcıya gelen sinyalin modülasyon türünün belirlenmesi işlemidir. Derin öğrenme ise karmaşık veri yapılarını üstün performansla sınıflandırması nedeniyle son zamanlarda büyük ilgi gören bir makine öğrenmesi yöntemidir. Hem sivil hem de askeri uygulamalarda kritik bir rol oynayan otomatik modülasyon sınıflandırma işlemi, bu çalışmada derin öğrenme yaklaşımlarından biri olan Evrimsel Sinir Ağları (CNN) kullanılarak incelenmiştir. Bu kapsamda ağ üzerinde yapılan değişikliklerin başarımı farklı sinyal-gürültü oranı (SNR) değerleri için yorumlanmıştır.

**Anahtar Kelimeler:** Otomatik modülasyon sınıflandırma, derin öğrenme, evrimsel sinir ağları

\* Corresponding Author: [osmnkaya11@gmail.com](mailto:osmnkaya11@gmail.com)

## 1. Giriş

Bilgi işaretinin taşıyıcı adı verilen belli bir frekanstaki elektriksel işaret yardımıyla iletim ortamının özelliklerine uygun hale getirilmesi işlemine modülasyon adı verilmektedir. Bilginin iletişim sürecine dahil edilmeden önce biçiminin değiştirilmesi olarak da ifade edilmektedir (Avcı, 2008). Bir haberleşme sisteminde iletişimin başarılı sayılması verici tarafından gönderilen sinyal modülasyonunun alıcı tarafından demodüle edilmesine bağlıdır. Modülasyon türü bilgisinin saptanabilmesi için ihtiyaç duyulan ön bilgi başta askeri olmak üzere mahremiyet gerektiren uygulamalarda çoğunlukla bulunmamaktadır. Otomatik Modülasyon Sınıflandırma(AMC) herhangi bir ön bilgiye ihtiyaç duymadan alıcı tarafından algılanan sinyalin modülasyon formatının otomatik olarak tanınmasını ve kategorize edilmesini ifade etmektedir. AMC işlemi alıcı için sinyal algılama ve demodülasyon arasındaki ara adımdır (Dobre, Abdi, Bar-Ness ve Su, 2007). Bir haberleşme sistemine AMC'nin nasıl dahil edildiği Şekil 1'de gösterilmiştir.



Şekil 1. Haberleşme sisteminde modülasyon tespiti blok diagramı

Otomatik Modülasyon Sınıflandırması(AMC) yapısının doğruluk değerinin yüksek, işlem karmaşıklığının düşük ve birden fazla amaca hizmet edebilir olması beklenilmektedir. Literatürde bu hususta yapılan çalışmaların ise olabilirlik tabanlı ve öznitelik tabanlı olmak üzere iki ana kategoriye ayrıldığı görülmektedir (Çukur ve Serbes, 2019; Zhang, Ding, Zhang, Xie, Li ve Han, 2018; Rajendran, Meert, Giustiniano ve Lenders ve Pollin, 2018). Olabilirlik tabanlı yöntem, alınan sinyalin tüm modülasyon türleri için olasılık fonksiyonunun hesaplanmasını ve daha sonra tüm olasılıkların karşılaştırılarak maksimum olasılığa (olabilirliğe) göre karar verilmesini sağlamaktadır (Xu, Su ve Zhou, 2011). Olabilirlik tabanlı yöntemin genellikle yüksek doğruluk elde etmesi ve hata olasılığını minimuma indirmesi gibi avantajları olsa da ön bilgi isteme ve işlem karmaşıklığı gibi çeşitli dezavantajları da bulunmaktadır. Öznitelik tabanlı makine öğrenmesi yöntemleri ise öznitelik çıkarımı ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Bu yöntem alınan sinyalden ayırt edici özniteliklerin çıkarılarak bir sınıflandırma yöntemi ile eğitilmesi esasına göre çalışır. Söz konusu iki yöntem mukayese edilecek olursa, son dönemde modülasyon tanıma ve sınıflandırma alanında yapılan araştırmaların ve çalışmaların birçoğu öznitelik tabanlı yöntemlerle gerçekleştirilmiştir. Bu durumun nedeni işlem karmaşıklığının olabilirlik tabanlı yöntemlere göre daha düşük seviyelerde olması ve

performansının daha yüksek olmasıdır. Belli bir bilgi kümesi için kurulan sistemin bir başka bilgi kümesi için uygulanabilirliğinin mümkün olmaması, bu iki yöntemin de genellenebilir olmadığını göstermektedir (Karahan ve Kalaycıoğlu, 2020).


Endüstri, tıp, finans, çeviri, robotik, görüntü işleme gibi alanlarda epeydir kullanılan derin öğrenme yaklaşımının haberleşme ve AMC algoritmalarında kullanımı son dönemlerde başlamıştır (Çukur ve Serbes, 2019; O'Shea, Roy ve Clancy, 2018). Derin öğrenme metotları herhangi bir ön bilgi ve ayırt edici nitelik çıkarımına gerek duymamaktadır. Otomatik Modülasyon Sınıflandırması (AMC) işleminde derin öğrenme yaklaşımları kullanıldığında olabilirlik tabanlı yöntem ve öznitelik tabanlı yöntemlere göre hem doğruluk düzeyinin daha yüksek olduğu hem de genellenebilirlik potansiyelinin daha yüksek olduğu bilinmektedir. Gerek askeri gerekse sivil maksatlı birçok uygulamada son derece önemli bir role sahip olan AMC işlemi (Xu, Su ve Zhou, 2011), bu çalışmada derin öğrenme tabanlı CNN yaklaşımıyla incelenmiştir. CNN, son dönemlerde görüntü ve ses işlemede ayrıca görüntülerin sınıflandırılması alanlarında doğruluk düzeyi yüksek, genellenebilir ve etkili bir yaklaşım olarak kabul görmüştür (Çalışır, 2022). Literatür incelendiğinde bu yaklaşımla ilgili başarılı çalışmalar yapıldığı görülmüştür.

Literatür incelendiğinde çalışma alanının öncülerinden O'Shea vd. (O'Shea, Corgan ve Clancy, 2016), IQ veri ifadesi üzerinde eğitilen CNN'lerin genel makine öğrenmesi algoritmalarına göre otomatik modülasyon sınıflandırmada önemli ölçüde üstün olduklarını göstermiştir. Selim vd. (Selim, Paisana, Arokkiam, Zhang, Doyle ve DaSilva, 2017) çalışmasında genlik ve faz farkı verisinin CNN sınıflandırıcılar ile radar sinyallerinin varlığının yüksek tutarlılık ile saptandığı bir yöntem önermiştir. Akaret vd. (Akeret, Chang, Lucchi ve Réfrégier, 2017) bir radyo teleskopundan elde edilen 2 boyutlu zaman bölgesi verilerinin CNN'ler ile eğitilerek, radyo frekans girişimlerini yüksek doğrulukta saptayabildikleri özgün bir yöntem önermişlerdir. Meng vd. (Meng, Chen, Wu ve Wang, 2018) çalışmasında en çok olabilirlik yöntemi ve CNN'ler ile AMC başarımını karşılaştırmışlardır. Kumar vd. (Kumar, Sheoran, Jajoo ve Yadav, 2020) çalışmasında ASK, PSK ve QAM modülasyon türlerinin yıldız küme yoğunluk matrislerini ResNet-50 ve Inception ResNet-V2 derin öğrenme modelleri ile sınıflandırılmıştır. Huang vd. (Huang, Jiang, Gao, Feng ve Zhang, 2019) çalışmasında kontrastlı CNN ile yıldız küme diyagramları kullanılarak AMC işlemi gerçekleştirilmiştir.

Derin öğrenme yaklaşımlarından, CNN yaklaşımını kullanarak 7 farklı modülasyon türünün farklı ağ derinlikleri için sınıflandırma doğruluğunun karşılaştırılmasını amaçlayan bu çalışmanın 2. bölümünde çalışma kapsamında incelenen CNN hakkında kısaca bilgi verilmektedir. 3.bölümde ise deneysel sonuçlar paylaşılmış olup, 4.bölümde sonuçlar incelenmektedir.

## 2. Materyal ve Metot

Derin öğrenme, üzerinde çalışılan veriden katmanlı yapısı sayesinde istatistiksel çıkarımlar yaparak model türeten verigüdümlü bir yöntemdir. Bu yöntemde alan bilgisi yerine ham veriden yararlanılmaktadır. Verinin yapısı, sayısı, gösterimi ve ağırlık çeşidi, derinliği gibi değişkenler modelin doğruluğu üzerinde büyük etkiye sahiptir. Katmanları içerisinde evrişim işlemi kullanan CNN yapısı sıklıkla kullanılan bir derin öğrenme yöntemidir. Görüntü, zaman serisi, ses, sinyal gibi farklı veri çeşitlerinde yüksek başarıma sahip olmasından dolayı literatürde CNN kullanımına sıklıkla rastlanılmaktadır. Bir CNN mimarisi her biri verinin farklı özelliklerini öğrenmeyi amaçlayan birden fazla katmana sahiptir. Katmanlar boyunca evrişim işleminden geçirilerek ilerleyen veri, her katmanda aranılan çıktıya daha da yaklaşmaktadır. Her katmanda farklı özellikler ile kısmen tanımlanan veri bir sonraki katmanın girişi olmaktadır. En sonda bulunan tam bağlantılı katman ile de CNN temsil ettiği sınıflandırma işlemi gerçekleştirilmiş olur. CNN mimarisi içerisinde evrişim katmanı, havuzlama katmanı ve tam bağlantı katmanı içermektedir. İşlemlerin büyük çoğunluğu evrişim katmanında kullanılan filtreler aracılığıyla gerçekleştirilir. Çalışma kapsamında evrişim ve tam bağlantı katmanı sayısı ile evrişim katmanı filtre sayısının AMC işlemi başarımları incelenmiştir.



Şekil 2. Evrişimsel Sinir Ağlarının (CNN) temel yapısı

Tablo 1: Çalışmada kullanılan senaryo özellikleri

Senaryo	Katman Özellikleri	Filtre Sayısı
1	Conv2D	32
2	Conv2D	64
3	Conv2D	128
4	Conv2D	128
	Conv2D	64
5	Conv2D	128
	Conv2D	64
	Conv2D	32
6	Conv2D	256
	Conv2D	64
7	Conv2D	256
	Conv2D	64
	Dense	256


## 3. Deneysel Sonuçlar

Çalışma kapsamında RadioML 2016.10a Modulation veri seti kullanılmıştır (O'Shea, Corgan ve Clancy, 2016). Bu veri seti içerisinde BPSK, QPSK, CPFSK, GFSK, 4-PAM, AM-DSB, QAM64 olmak üzere etiketlenmiş veri vektörleri halinde 7 tane modülasyon formatı bulunmaktadır. Veri vektörleri  $\mathbf{x}_k$ , 1MS/s örnekleme oranı ile  $N = 128$  örnekleme yığını içinde toplanmışlardır. Her modülasyon formatı -20 db ve +18 db SNR oranına sahip olacak şekilde rastgele gürültü ile bozulmuşlardır. Veri seti toplamda 140000 veri vektörü  $\mathbf{x}_k \in \mathbb{R}^{2 \times 128}$  olacak şekilde, I ve Q ifadesine sahiptir. Her SNR değerinde her modülasyon formatı için 1000 tane örnek bulunmaktadır. 7 modülasyon sınıf etiketini oluşturmak için ikili kodlama kullanılmıştır, sonuç olarak modülasyon tanıma 7 kategoriyi sınıflandırma problemine dönüşmüştür.

Çalışmada benzetimler Python programlama diliyle Keras kütüphanesi kullanılarak gerçekleştirilmiştir.

Çalışma kapsamında Tablo 1'de gösterildiği üzere yedi farklı senaryo oluşturulmuş olup, senaryolarda birbirinden farklı katman özellikleri ve filtre sayıları kullanılmıştır. Bu senaryolar kapsamında AMC başarımları incelenmiştir.


Şekil 3'te Senaryo 1, 2, 3, 4 ve 5 karşılaştırılmıştır. Senaryo 1, 2 ve 3'te olduğu gibi bir tane evrişim katmanı kullanıldığında %60 seviyelerinde doğruluk oranı elde edilmiştir. Senaryo 3'ün başarımları filtre sayısının daha büyük olmasından dolayı Senaryo 1 ve 2'ye kıyasla daha yüksektir. Tablo 1'de Senaryo 4 ve 5'in doğruluğu incelendiğinde diğer senaryolardan oldukça yüksek başarımlar elde edildiği gözlemlenmektedir. Senaryo 5'te üçüncü bir evrişim katmanı kullanımı başarımları daha da artırmıştır.



Şekil 3: Farklı filtre sayıları ve CNN ağ derinliği için başarımların incelenmesi

Şekil 4'te farklı filtre büyüklükleri ve tam bağlantı katmanı sayısı açısından Senaryo 4, 6 ve 7 incelenmiştir. Senaryo 4 ve 6 incelendiğinde filtre sayısının artışının başarımları olumlu yönde

etkilendiği gözlemlenmektedir. Senaryo 6 ve 7 karşılaştırıldığında ise aynı yapıya fazladan bir tam bağlantı katmanı eklenmesinin başarımı bir miktar daha artırdığı gözlemlenmiştir.



Şekil 4. Farklı filtre sayıları ve tam bağlantılı ağ derinliği için başarımların SNR ile doğru ilişkisini gösteren bir grafik.

## 4. Sonuçlar

Çalışmada derin öğrenme tabanlı farklı özelliklere sahip CNN yöntemleri kullanılarak modülasyon verisi tanıma ve sınıflandırma başarımları incelenmiştir. Sonuçlar incelendiğinde SNR seviyesinin başarımla doğru ilişki olduğu gözlemlenmiştir, SNR seviyesi arttıkça başarımlar yükselmiştir. Ayrıca filtre sayısı ve ağ derinliğinin doğruluk üzerindeki etkisi araştırılmıştır. Hem filtre sayısının hem de ağ derinliğinin artırılması doğruluk düzeyini yükseltici bir etki yapmıştır.

## Kaynakça

- Avcı, E. (2008). Sayısal Modülasyon Tanıma Sistemleri İçin Bayes Karar Kuralları Sınıflandırıcısının Kullanımı. *Engineering Sciences*,3(1),<https://dergipark.org.tr/tr/pub/nwsaeng/issue/19871/212968>.
- Dobre, O. A., Abdi, A., Bar-Ness, Y., & Su, W. (2007). Survey of automatic modulation classification techniques : classical approaches and new trends. *IET Communications*, 1(2), 137–156. <https://doi.org/10.1049/iet-com:20050176>
- Çukur, H. & Serbes, A. (2019). A Survey of Automatic Modulation Classification Algorithms for Cognitive Radio Applications. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi* , vol.25, no.4, pp.1-15.
- Zhang, D., Ding, D., Zhang, B., Xie, C., Li, H. & Han, J. (2018). Automatic Modulation Classification Based on Deep Learning for Unmanned Aerial Vehicles. *Sensors (Basel)*, (3):924. doi: 10.3390/s18030924. PMID: 29558434; PMCID: PMC5876703.
- Rajendran, S., Meert, W., Giustiniano, D., Lenders, V. & Pollin, S. (2018). Deep Learning Models for Wireless Signal Classification With Distributed Low-Cost Spectrum Sensors. *IEEE Transactions on Cognitive Communications and e-ISSN: 2148-2683*

- Networking, vol. 4, no. 3, pp. 433-445, doi:10.1109/TCCN.2018.2835460.
- Xu, J. L., Su, W. & Zhou, M. (2011). Likelihood-Ratio Approaches to Automatic Modulation Classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 41, no. 4, pp. 455-469, July 2011, doi: 10.1109/TSMCC.2010.2076347.
- Karahan, S. N. & Kalaycıoğlu, A. (2020). Deep Learning Based Automatic Modulation Classification With Long-Short Term Memory Networks. *2020 28th Signal Processing and Communications Applications Conference (SIU)*, pp. 1-4, doi: 10.1109/SIU49456.2020.9302280.
- O'Shea, T. J., Roy, T. & Clancy, T. C. (2018). Over-the-Air Deep Learning Based Radio Signal Classification. *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 168-179, doi: 10.1109/JSTSP.2018.2797022.
- Çalışır, B. (2022). Radyo Haberleşmesinde Evrişimli Sinir Ağı Kullanılarak Yapılan Modülasyon Sınıflandırması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*,34 (2) , 867-877 . DOI: 10.35234/fumbd.1141515
- O'Shea, T. J., Corgan, J. & Clancy, T. C. (2016). Convolutional Radio Modulation Recognition Networks. *Proc. Int. Conf. Eng. Appl. Neural Netw.*, pp. 213226.
- Selim, A., Paisana, F., Arokkiyam, J. A., Zhang, Y., Doyle, L. & DaSilva, L. A. (2017). Spectrum Monitoring For Radar Bands Using Deep Convolutional Neural Networks. Available: <https://arxiv.org/abs/1705.00462>. 2017.
- Akeret, J., Chang, C., Lucchi, A., & Réfrégier, A. (2017). Radio frequency interference mitigation using deep convolutional neural networks. *Astron. Comput.*, 18, 35-39.
- Meng, F., Chen, P., Wu, L. & Wang, X. (2018). Automatic Modulation Classification: A Deep Learning Enabled Approach. *IEEE Transactions on Vehicular Technology*, vol. 67, no. 11, pp. 10760-10772, doi: 10.1109/TVT.2018.2868698.
- Kumar, Y., Sheoran, M., Jajoo, G. & Yadav, S. K. (2020). Automatic Modulation Classification Based on Constellation Density Using Deep Learning. *IEEE Communications Letters*, vol. 24, no. 6, pp. 1275-1278, doi: 10.1109/LCOMM.2020.2980840.
- Huang, S., Jiang, Y., Gao, Y., Feng, Z. & Zhang, P. (2019). Automatic Modulation Classification Using Contrastive Fully Convolutional Network. *IEEE Wireless Communications Letters*, vol. 8, no. 4, pp. 1044-1047, doi: 10.1109/LWC.2019.2904956.