

Periodogram ve Spektrogram Özellikleri Kullanarak Trafik Sesi Sınıflandırması

Mariem Mine Cheikh Mohamed Fadel^{1*}, Zeynep Özer²

¹Bandırma Onyedi Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Akıllı Ulaşım Sistemleri ve Teknolojileri, Balıkesir, Türkiye, minebeyah@gmail.com, ORCID: 0000-0003-2890-2666

²Bandırma Onyedi Eylül Üniversitesi, Ömer Seyfettin Uygulamalı Bilimler Fakültesi, Yönetim Bilişim Sistemleri, Balıkesir, Türkiye, zozer@bandirma.edu.tr, ORCID: 0000-0001-8654-0902

Kara yollarındaki araçlardan kaynaklanan gürültü problemi dünya genelinde her geçen gün artış göstermektedir. İstikrarlı kentleşme eğilimi ve nüfus artışı gibi faktörlerde bu problemi daha da zorlu hale getirmektedir. Buna bağlı olarak şehirlerdeki ses ortamlarını izlemeye yönelik çalışmalarda artış göstermiştir. Bu çalışmada trafikte yaygın olarak karşılaşılan 4 farklı araç türüne ait seslerin sınıflandırılması gerçekleştirilmektedir. Kullanılan yöntem kara yollarındaki trafikten kaynaklanan gürültünün değerlendirilmesi için kullanılabilmesi gibi trafik ölçümlerinde kullanılan mevcut sensörlere alternatif ucuz bir yöntem olarak da değerlendirilebilir. Bu doğrultuda spektrogram ve periodogram olmak üzere iki farklı 2 boyutlu temsil yönteminin sınıflandırma performansına olan etkisi değerlendirilmiştir. Ayrıca her iki özellikte hem lineer hem de logaritmik ölçek kullanılarak test edilmiştir. Konvolüsyonel sinir ağları ile yapılan testlerde IDMT-trafik veri seti üzerindeki 4 farklı sınıfta makro ortalama %94,75'lik bir başarımlık değeri ve %84,78'lik bir F1 skoru elde edilmiştir.

Anahtar Kelimeler: Spektrogram, Periodogram, Konvolüsyonel Sinir Ağları

© 2022 Published by AIntelia

1. Giriş

Dünya çapında yaşanan nüfus artışı, istikrarlı kentleşme eğilimi ve insanların kırsal alanlardan daha büyük şehirlere taşınması gibi faktörler şehirlerdeki nüfusu her geçen gün artırmaktadır. Buna bağlı olarak şehirlerdeki gürültü seviyeleri de rahatsız edici ve hatta insan sağlığına zarar verecek şekilde artmaktadır. Sonuç olarak gürültü problemi, şehir sakinlerinin en büyük şikayetleri arasında yer almaktadır [1]. Karayollarındaki taşıtlardan kaynaklanan gürültüler kentsel alanlardaki gürültünün önemli bir bölümünü oluşturur. Ayrıca kentleşmenin ve buna bağlı olarak nüfus yoğunluğunun artması araçlarla yapılan seyahat sürelerini, gürültü ve hava kirliliği seviyeleri de artırır.

Akıllı ulaşım sistemleri (ITS), yerel trafik durumlarına uyum sağlayarak trafik akışını azaltmak ve optimize etmek için etkili karşı önlemlerdir. Geçtiğimiz on yılda, trafik ışığı döngülerini kontrol etme, trafik kazası algılama, lojistik izleme ve diğer akıllı şehir uygulamaları gibi uygulama senaryoları için trafik izleme için çeşitli otomatik yöntemler geliştirilmiştir.

Trafik izleme sistemleri, görsel nesne algılama ve izleme için kamera sensörlerinden, geçen araçları saymak için manyetik döngü sensörlerinden radyo dalgalarına (Radar) ve ışık dalgalarına (Lidar) dayalı ölçüm sistemlerine kadar trafik akışını ölçmek için çeşitli sensör modalitelerini kullanır. Bu tür sistemler, geniş alanları kapsayacak şekilde dağıtılmış sensör ağları olarak kurulabilirken, kurulum ve bakım maliyetleri genellikle yüksektir. Akustik trafik izleme (ATM), müdahaleci olmayan trafik ölçümleri için daha ucuz bir alternatif sağlar ve bu makalenin odak noktasıdır.

Son yıllarda gürültü kirliliğinin azaltılması amacıyla kentlerdeki ses ortamlarını izlemeye yönelik teknolojilerin gelişimi hızlandı[2, 3]. Sinyal işleme ve makine öğrenimi tekniklerini kullanan otomatik ses tanıma (ASR), bu alanda son yıllarda dikkat çekici bir şekilde gelişen bir teknoloji olarak öne çıkmaktadır. Bir ASR sisteminde, ses olayları, sinyal işleme ve makine öğrenimi yöntemleri kullanılarak otomatik olarak tanımlanır. ASR sistemlerinin bu

kabiliyetleri karayollarındaki akustik olayların kaynaklarını belirlemek için kullanılabilir. Öte yandan bu görev çeşitli zorlukları da bünyesinde barındırmaktadır. Bir yoldaki işitilebilir sesler, araçlar geçerken oluşan motorlar, egzozlar, tekerlekler ve hava türbülansı gibi çeşitli ses kaynaklarının birleşimidir [1]. Aynı tipteki ses kaynaklarının (örneğin arabalar) içsel değişkenliği ve farklı konumlar ve durumlar için akustik ortamın (örneğin yankılanma, mesafe) etkisi göz önüne alındığında, her sınıfın akustik özellikleri büyük çeşitlilik gösterebilir. Bu da ses kaynağının türünü sınıflandırmayı zorlaştırır.

Ses tanıma aslında sinyal ön işleme, özellik çıkarma ve sınıflandırma olmak üzere 3 temel aşamadan oluşan bir örüntü tanıma problemidir. Sinyal ön işleme aşamasında, giriş sinyali genellikle daha küçük segmentlere bölünür ve özellik çıkarımına hazır hale getirmek için hamming penceresi gibi bir pencere işlevi uygulanır. Özellik çıkarma, karmaşık verilerin boyutunu küçülterek bir özellik vektörü olarak temsilidir. Son olarak elde edilen özellikler bir sınıflandırma algoritması kullanılarak sınıflandırılır. Ses olaylarının sınıflandırılmasında el ile seçilmiş birçok geleneksel akustik özellik kullanılabilir. Bununla birlikte manuel olarak özelliklerin belirlenmesi hem uzmanlık gerektiren hem de zaman alan zorlayıcı bir süreçtir. Buna bağlı olarak son yıllarda ses olaylarının 2 boyutlu temsilleri üzerinden konvolüsyonel sinir ağları (Convolutional Neural Network - CNN) ile otomatik olarak çıkartılan özelliklerin ses olaylarının sınıflandırılmasında kullanılması giderek yaygınlaşmaktadır.

Bu çalışmada taşıt seslerini sınıflandırmak amacıyla iki ayrı 2 boyutlu temsil yöntemi kullanılmakta ve bunların sınıflandırma performansı üzerine olan etkisi incelenmektedir. 2 boyutlu temsil yöntemi olarak periodogram ve spektrogram özellikleri kullanılmıştır. Daha sonra her iki temsil yöntemi de aynı CNN modeline uygulanarak farklı sınıflandırma metrikleri ile performansları kıyaslanmaktadır. Aynı zamanda özellikler lineer ve logaritmik olmak üzere iki farklı ölçekte kullanılarak bunlarında sınıflandırma performansına olan etkisi değerlendirilmiştir.

2. Periodogram ve Spektrogram Özellikleri

Esasında hem periodogram hem de spektrogram yöntemi bir sinyalin frekans spektrumunun görsel bir temsiliyi vermektedir. Periodogram ile dikdörtgen bir pencere kullanılarak giriş sinyali x_n 'in güç spektral yoğunluğu hesaplanır. Periodogram, otokorelasyon dizisinin yanlı (biased) tahmininin Fourier dönüşümüdür. x_n giriş sinyali, w_n bir çerçeve fonksiyonu ve Δt örnekleme aralığı olmak üzere periodogram şu şekilde tanımlanabilir;

$$\hat{P}(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} w_n x_n e^{-j2\pi f \Delta t n} \right|^2, \quad -1/2\Delta t < f \leq 1/2\Delta t \quad (1)$$

Spektrogram, hızlı Fourier dönüşümü (HFD) ile elde edilen büyüklük spektrumundan oluşan bir yığından meydana gelir. HFD, belirli bir ses vektörünün, uzunlukları w_s olan yüksek oranda örtüşen parçalara bölünmesiyle gerçekleştirilir ve spektral vektör f elde edilir. Bu durumda, δ ardışık iki çerçeve arasındaki artış olmak üzere mevcut çerçeve F 'nin spektral büyüklük vektörü f_F aşağıdaki gibi elde edilir:

$$s_F(N) = s(F\delta + n)w_n \quad \text{için } n = 0 \dots (w_s - 1) \quad (2)$$

$$f_F(k) = \sum_{n=0}^{w_s-1} s_F(n) e^{-j\pi n k w_s} \quad \text{için } k = 1 \dots (w_s 2 - 1) \quad (3)$$

3. Konvolüsyonel Sinir Ağları

CNN hayvan görsel korteksinin organizasyonunu simüle eden [1] tipik bir çok katmanlı sinir ağıdır [2]. Görüntü ile ilgili uygulamalarda yaygın bir şekilde kullanılmaktadır [3-4]. CNN modellerinin çalışması özellik çıkarılması ve bu özelliklerin tam bağlı katmanlarda sınıflandırılması şeklinde iki aşamada gerçekleşir. CNN mimarileri genellikle konvolüsyon, havuzlama ve tam bağlı katmanların bir araya gelmesi ile oluşturulur.

Konvolüsyonel katman CNN'yi oluşturan en önemli yapıdır. Bu katmanda nöronlar girişin sadece küçük bir kısmına bağlanmakta ve girişin tüm derinliği boyunca uzanmaktadır. Bu katmanın tanımlanmasında filtre boyutu ve üretilen haritaların sayısı kullanılır. Giriş görüntülerinin üzerindeki çizgiler, köşeler ve kenarlara ilgili farklı özellikleri

çıkarmayı amaçlayan filtrelerden oluşur [5]. Pixel değerleri içeren bu filtreler görüntü üzerinde kaydırılır. Kaydırma işlemi esnasında filtre değerleri görüntüye ait değerler çarpılır. Sonrasında elde edilen değerler toplanarak net sonuç üretilir. Bu işlem görüntünün tamamına uygulanarak özellik haritaları elde edilir. Özellik haritası değerlerinin hesaplanması şu şekilde ifade edilebilir:

$$y_1 = \sum_{n=0}^{N-1} x_n h_{1-n} \quad (4)$$

burada, y özellik haritasıdır, x sinyaldir, h filtredir, N , x 'teki eleman sayısıdır ve n 'inci vektör değişkeni alt simgeleri gösterir.

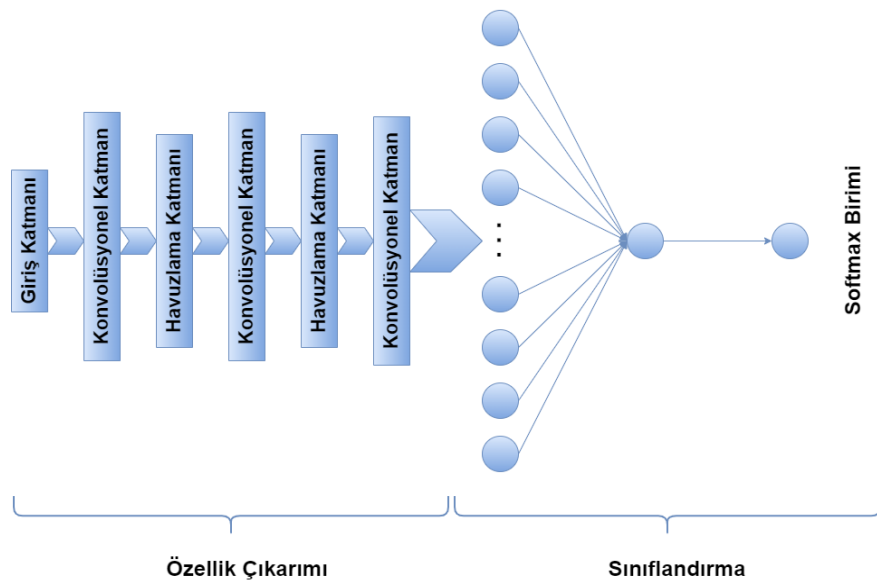
CNN'yi oluşturan bir diğer önemli yapı havuzlama katmanıdır. Bu katmanın ortalama havuzlama ve maksimum havuzlama gibi literatürde yaygın olarak kullanılan farklı türleri mevcuttur. Bu çalışmada maksimum havuzlama kullanılmıştır. Maksimum havuzlama işleminde görüntü örtüşmeyen bloklara bölünür ve her bir bloğun en büyük değeri alınır. Bu sayede hesaplama maliyetleri ve ezberleme olasılıkları büyük ölçüde azaltılmaktadır.

CNN mimarilerinde yaygın olarak kullanılan bir diğer yapıda tam bağlı katmandır. Bu katman tipik bir yapay sinir ağı katmanıdır. Kendisinden önceki ve sonraki tüm nöronlarla bağlantıya sahiptirler.

CNN'nin çözmeye çalıştığı işlemlerin büyük çoğunluğu doğrusal değildir. Öte yandan matris çarpımı ve toplamı gibi işlemler doğrusaldır. CNN'de doğrusal olmayanlık sağlamak için yaygın olarak doyum olmayan aktivasyon fonksiyonu kullanılır. Bu işlem matematiksel olarak şu şekilde ifade edilebilir:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & \text{diğer durumlarda} \end{cases} \quad (5)$$

Bu çalışmada kullanılan CNN mimarisi Şekil 1'de de görüldüğü gibi dört öğrenilebilir katmandan meydana gelmektedir. Bu çalışmada 1D CNN mimarisi kullanılmıştır. MEG verisi 128x17 boyutlarına ayarlanarak giriş katmanına uygulanmaktadır. Giriş katmanından sonra ilk konvolüsyonel katman yer alır. Bu katmanın filtre sayısı 512 ve çekirdek boyutu 4'tür. Bu katmandan sonra boyutu 2 olan maksimum-havuzlama (max-pooling) katmanı gelir. Sonrasında ise ikinci konvolüsyonel katman bulunur. Bu katmanın değerleri de birinci konvolüsyonel katman ile aynıdır. İkinci konvolüsyonel katmandan sonra da boyutu 2 olan maksimum-havuzlama katmanı bulunur. Sonrasında ise 50 nörondan oluşan tam bağlı katman yer alır. Bu katmandan düğüm seyreltme (dropout) işlemi de uygulanır. Düğüm seyreltme değeri 0.2'dir. Son olarak tek nörondan oluşan tam bağlı katman bulunmaktadır.



Şekil 1. CNN Mimarisi

4. Performans Değerlendirme Metrikleri

Makine öğrenimi modellerini kıyaslamak için seçilen metrikler oldukça önemlidir. Bu çalışmada, farklı makine öğrenimi algoritmalarının performansını kıyaslamak amacıyla birkaç farklı metot kullanıldı. Sınıflandırma doğruluğu (ACC), hassasiyet (SENS), özgüllük (SPEC), kesinlik (PREC) ve F-skoru kullanılan kıyaslama metrikleridir.

ACC değeri doğru sınıflandırılmış örneklerin sayısının toplam örnek sayısına olan oranını verir. Sınıflandırma çalışmalarında yaygın olarak kullanılan bir kıyaslama metriğidir. ACC değeri şu şekilde hesaplanabilir:

$$ACC = \frac{TN + TP}{TN + TP + FP + FN} \quad (6)$$

ACC performans kıyaslaması için tek başına yeterli bir parametre olmayabilir. Bu nedenle, istatistiksel performans ölçüleri olan özgüllük, duyarlılık, kesinlik ve F-skor terimlerinin kullanılması birçok durumda doğru bir performans kıyaslaması için faydalı olur. "özgüllük" terimi, doğru tahmin edilen gerçek negatiflerin oranını ifade eder. Öte yandan "duyarlılık" terimi, doğru tahmin edilen gerçek pozitiflerin oranını gösterir. Doğru olan pozitif tahminlerin oranı ise "kesinlik" olarak ifade edilir. F skoru, SENS ve PREC değerlerinin harmonik ortalamasıdır. SPEC, SENS, PREC ve F-skorunu hesaplamak için kullanılan formüller şu şekildedir:

$$SPEC = \frac{TN}{TN + FP} \quad (7)$$

$$SENS = \frac{TP}{TP + FN} \quad (8)$$

$$PREC = \frac{TP}{TP + FP} \quad (9)$$

$$F - skor = \frac{2TP}{2TP + FP + FN} \quad (10)$$

Burada, gerçek pozitif (TP), doğru sınıflandırılmış pozitif örneklerin sayısını, gerçek negatif (TN) ise doğru şekilde sınıflandırılan negatif örneklerin sayısını ifade eder. Öte yandan yanlış pozitif (FP), pozitif olarak sınıflandırılan negatif örneklerin sayısı ve yanlış negatif (FN): negatif olarak sınıflandırılan pozitif örneklerin sayısıdır.

5. Araç Sesleri Veri Seti

Çalışmada IDMT-Trafik veri seti kullanılmıştır [IDMT]. Veri seti, Almanya Ilmenau içinde ve çevresinde üç şehir trafiği konumu ve bir köy yolu konumu dahil olmak üzere dört farklı kayıt konumundan hem yüksek kaliteli sE8 mikrofonları hem de düşük bütçeli mikroelektro-mekanik sistem (MEMS) mikrofonları ile yapılan zamanla senkronize edilmiş stereo ses kayıtlarını içerir. Kayıt senaryoları, farklı hız limitlerini (30, 50 ve 70 km/s) ve ayrıca ıslak ve kuru yol koşullarını içerir.

Veri seti dört sınıf içerir: arabalar (3903 olay), kamyonlar (511 olay), otobüsler (53 olay) ve motosikletler (251 olay). Bu dağılım, yaygın trafik senaryolarında araç türlerinin doğal dengesizliğini yansıtır. Tablo 1'de veri setindeki örneklerin dağılımı görülmektedir.

Tablo 1. Veri setinin dağılımı

Veri Seti	Araba	Kamyon	Motosiklet	Taşıt Yok
Eğitim Seti	2471	290	132	2393
Doğrulama Seti	275	32	15	266
Test Seti	1157	189	99	1412

6. Bulgular ve Tartışma

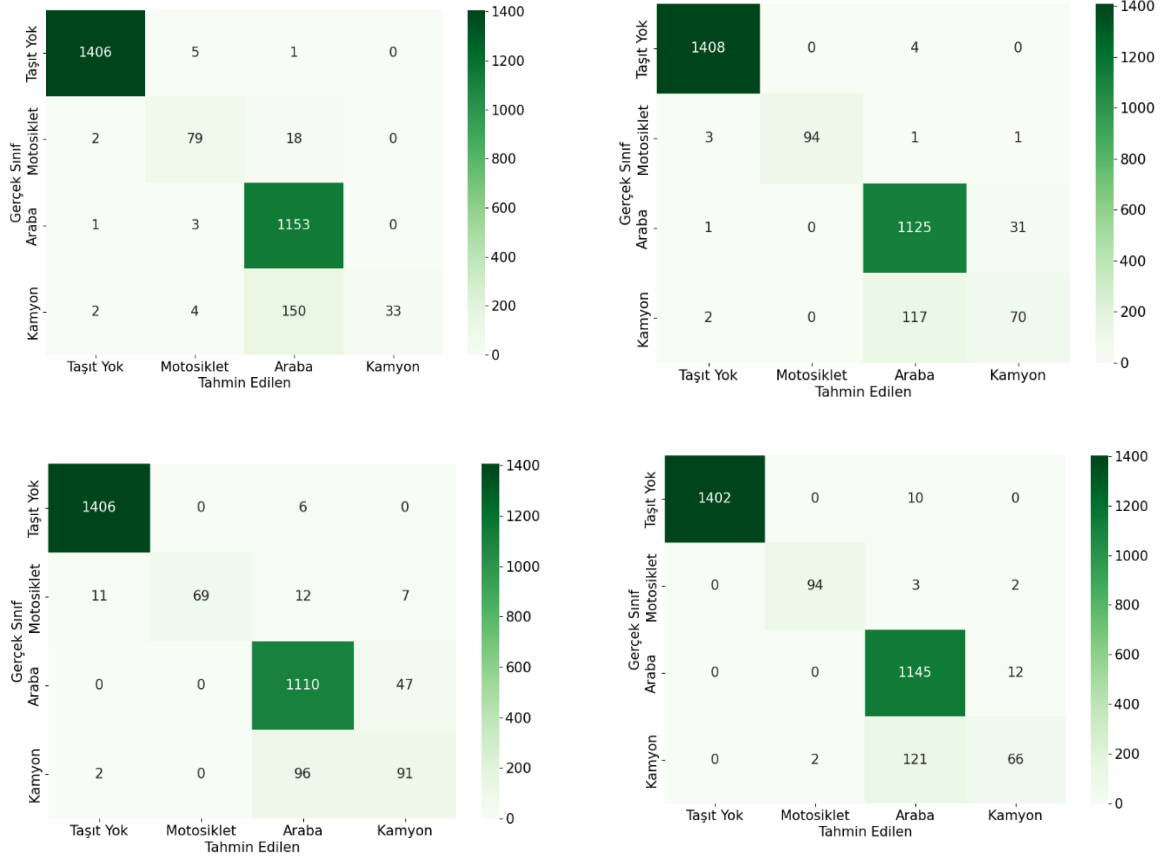
Çalışma kapsamında 4 farklı model test edilmiştir. Çalışmada kullanılan veri seti stereo olduğu için iki ayrı ses kanalına ait veri içermektedir. Bu çalışmadaki tüm modellerde ikinci ses kanalına ait veriler kullanılmıştır. Ses kanalının seçilmesinin ardından ilgili kanaldaki veriye denormalizasyon işlemi uygulanmıştır. Sonra da periodogram ve spektrogram özellikler çıkarılmıştır. Her iki özellik çıkarma işleminde de çerçeve fonksiyonu olarak Hamming kullanılmıştır. Spektrogram özelliklerinin elde edilmesi aşamasında çerçeve uzunluğu 1024 ve örtüşme oranı %50 olarak kullanılmıştır. Her iki özellikle de hem lineer hem de logaritmik ölçekte testler gerçekleştirilmiştir. Tüm modeller ile 50 devir boyunca eğitim gerçekleştirilmiştir. Bunların içerisinde doğrulama veri setinde en yüksek başarımları gösteren ağırlık değerleriyle test işlemi gerçekleştirilmiştir. Eğitim, doğrulama ve test setine ayırma aşamasında orijinal çalışmayla [IDMT] birebir aynı örnekler kullanılmıştır. Bu bölümde rapor edilen sonuçlar test setine ait değerlerdir.

Tablo 2’de sınıf bazlı elde edilen sonuçlar görülmektedir. Tüm modeller için Sens sonuçları incelendiğinde örnek sayılarının az olduğu motosiklet ve kamyon sınıflarında elde edilen skorların taşıt yok ve araba sınıflarına kıyasla belirgin bir şekilde düşük olduğu görülmektedir. Dört model içinde en düşük Sens değerleri kamyon sınıfında elde edilmiştir. Burada en düşük değer lineer periodogram modelinde %17.46 olarak gerçekleşmiştir. Motosiklet sınıfında spektrogram modellerinin Sens değeri taşıt yok ve araba sınıflarına kıyasla yaklaşık olarak %3-5 daha düşük olarak gerçekleşmiştir. Bununla birlikte periodogram modellerinde motosiklet sınıfının Sens performansı taşıt yok ve araba sınıfına kıyasla belirgin bir şekilde daha düşüktür. Burada motosiklet ve kamyon sınıfları için Sens performansının düşük olmasının nedeni azınlık sınıf olmalarından kaynaklandığı değerlendirilmektedir. Makine öğrenmesi modelleri geneli itibarıyla çoğunluk sınıfına eğilimlidir [7].

Tablo 2. Sınıf bazlı sonuçlar

		Spektrogram (Lineer)	Spektrogram (Logaritmik)	Periodogram (Lineer)	Periodogram (Logaritmik)
Sens	Taşıt Yok	99.72	99.29	99.58	99.58
	Motosiklet	94.95	94.95	79.80	69.70
	Araba	97.23	98.96	99.65	95.94
	Kamyon	37.04	34.92	17.46	48.15
Spec	Taşıt Yok	99.58	100.00	99.65	99.10
	Motosiklet	100.00	99.93	99.56	100.00
	Araba	92.82	92.12	90.06	93.29
	Kamyon	98.80	99.48	100.00	97.98
Prec	Taşıt Yok	99.58	100.00	99.65	99.08
	Motosiklet	100.00	97.92	86.81	100.00
	Araba	90.22	89.52	87.22	90.69
	Kamyon	68.63	82.50	100.00	62.76
F1	Taşıt Yok	99.65	99.64	99.61	99.33
	Motosiklet	97.41	96.41	83.16	82.14
	Araba	93.59	94.01	93.02	93.24
	Kamyon	48.11	49.07	29.73	54.49

Spec metriği için tüm modellerde elde edilen skorlar Sens metriğine kıyasla daha dengelidir. Burada tüm modeller için araba sınıfında elde edilen değerlerin diğer sınıflara kıyasla düşük olduğu görülmektedir. Grafik 1’de verilen karışıklık matrisleri incelendiğinde araba sınıfı için HP değerlerinin belirgin bir şekilde yüksek olduğu görülmektedir. Buna bağlı olarak bu sınıf için Spec değeri daha düşük olarak gerçekleşmiştir.



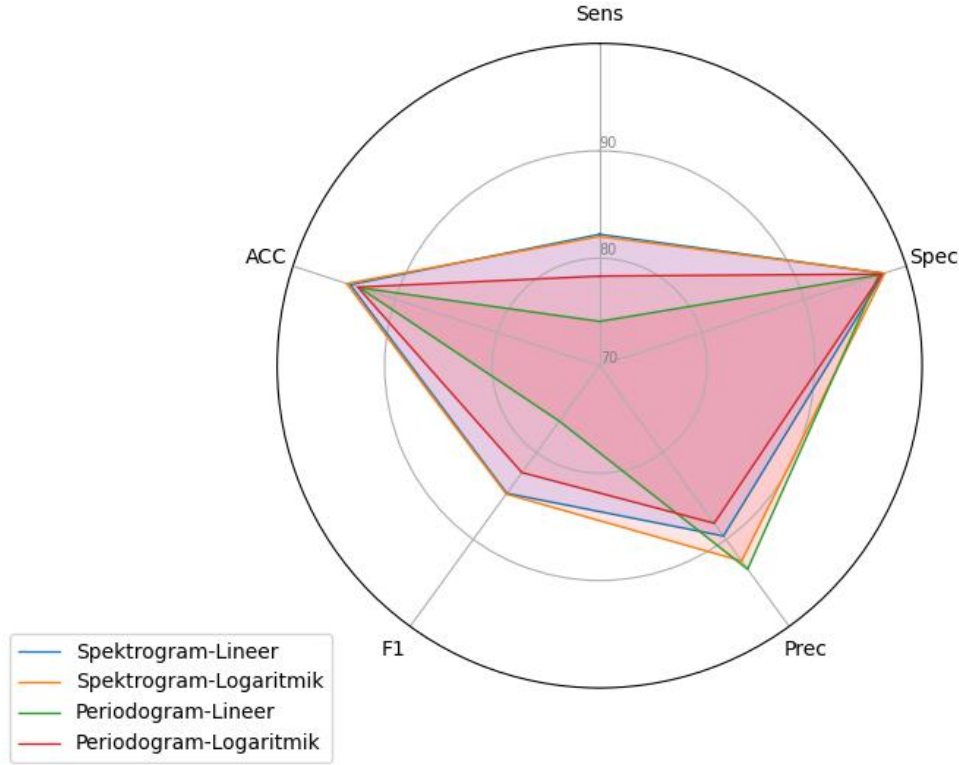
Grafik 1. Karışıklık matrisleri

Prec metriği için her bir modelin davranışı birbirinden ayrılmıştır. Öte yandan yine taşıt yok ve araba sınıfları için tüm modellerde diğer sınıflara kıyasla birbirine yakın skorlar sağlanmıştır. Bu metrik için elde edilen değerler %62.76 ile %100 arasında değişim göstermektedir.

F1 skoru dengeli dağılım göstermeyen veri setlerinin sınıflandırma performanslarının kıyaslanmasında yaygın olarak kullanılan bir metriktir. Burada kamyon sınıfının skorları diğer tüm sınıflara göre daha düşük olarak gerçekleşmiştir. Grafik 2’de tüm metrikler için elde edilen makro ortalama değerleri görülmektedir. Lineer spektrogram, logaritmik spektrogram, lineer periodogram ve logaritmik periodogram modelleri için ACC skorları sırasıyla %94,40, %94,75 %93,49 ve %93,66 olarak gerçekleşmiştir. F1 değerleri de yine sırasıyla %84,69, %84,78, %76,38 ve %82,30 olarak gerçekleşmiştir. Elde edilen sonuçlar spektrogram modellerinin performansının periodogram modellerine kıyasla bir miktar daha iyi olduğunu göstermektedir. Spektrogram yönteminde sinyal küçük parçalara bölünerek HFT işlemi gerçekleştirilmektedir. Periodogram yönteminde ise HFT işlemi sinyalin tamamına tek seferde uygulanmaktadır. Buda ses olaylarında yerelliğin kaybolmasına neden olur. Buna bağlı olarak periodogram yönteminde performansın bir miktar daha düşük olarak gerçekleştiği değerlendirilmektedir. Ayrıca her iki yöntemde de logaritmik ölçek lineer ölçeğe kıyasla bir miktar daha iyi sonuç sağlamıştır. Burada da özellikler arasındaki varyansı azaltmanın sınıflandırma performansına olumlu katkı sağladığı değerlendirilebilir[8].

7. Sonuçlar

Trafikle ilgili seslerin sınıflandırılması hem akustik izleme hem de kentsel alanlardaki gürültü kaynaklarının değerlendirilmesi bakımında oldukça önemlidir. Bu çalışmada 4 farklı model kullanılarak IDMT-Trafik veri seti üzerinde testler gerçekleştirilmiştir. Veri setinde bulunan 4 farklı sınıfa ait sesler üzerinde spektrogram ve periodogram ile elde edilen görsel temsiller CNN kullanılarak sınıflandırılmıştır.



Grafik 2. Makro ortalama değerler

Makro ortalama ACC ve F1 değerlerinde spektrogram modelleri periodogram modellerine kıyasla daha iyi bir performans göstermiştir. Burada spektrogram özelliklerinin periodograma kıyasla yerellikleri koruyabilmesinin sınıflandırma performansını etkilediği değerlendirilmektedir. Ayrıca logaritmik ölçekte elde edilen skorların da lineer ölçüğe kıyasla bir miktar daha iyi olduğu görülmüştür. Burada da özellikler arasında ki varyansı azaltmanın sınıflandırma performansına olumlu katkı sunduğu değerlendirilmektedir. Sonuç olarak logaritmik spektrogram modeliyle makro ortalama ACC ve F1 değerleri için sırasıyla %94,75 ve %84.78 skoları elde edilmiştir.

REFERENSLAR

- [1] Hubel, David H., and Torsten N. Wiesel. "Receptive fields and functional architecture of monkey striate cortex." *The Journal of physiology* 195.1 (1968): 215-243.
- [2] Ozer, Ilyas, Zeynep Ozer, and Oguz Findik. "Noise robust sound event classification with convolutional neural network." *Neurocomputing* 272 (2018): 505-512.
- [3] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [4] J. Ma, F. Wu, J. Zhu, D. Xu, and D. Kong, "A pre-trained convolutional neural network based method for thyroid nodule diagnosis," *Ultrasonics*, vol. 73, pp. 221–230, 2017.
- [5] K. Gorur, M. Bozkurt, M. Bascil, and F. Temurtas, "GKP Signal Processing Using Deep CNN and SVM for Tongue-Machine Interface," *Trait. du Signal*, vol. 36, no. 4, pp. 319–329, Oct. 2019.
- [6] Abeßer, Jakob, et al. "IDMT-traffic: an open benchmark dataset for acoustic traffic monitoring research." *2021 29th European Signal Processing Conference (EUSIPCO)*. IEEE, 2021.
- [7] Ozer, Ilyas, et al. "Improved machine learning performances with transfer learning to predicting need for hospitalization in arboviral infections against the small dataset." *Neural Computing and Applications* 33.21 (2021): 14975-14989.
- [8] Ilyas, O. Z. E. R. "Pseudo-colored rate map representation for speech emotion recognition." *Biomedical Signal Processing and Control* 66 (2021): 102502.