

## AKUSTİK TEMELLİ ARAÇ TRAFİK YOĞUNLUĞU KESTİRİMİ

*Fikret ÖZTÜRK \**  
*Ali Köksal HOCAOĞLU \**

Alınma: 16.08.2018 ; düzeltme: 31.03.2019 ; kabul: 02.04.2019

**Öz:** Bu çalışmada, araçların oluşturduğu akustik gürültü sinyalinden trafik yoğunluğunun kestirimi yapılmıştır. Akustik gürültü sinyali, motor, hava türbülans, tekerlek, egzoz ve korna gürültü bileşenlerinden oluşmaktadır. Trafik yoğunluk durumuna göre bu bileşenlerin bulunma ağırlıkları değişmektedir. Örneğin trafiğin yoğun olduğu zaman motor ve korna gürültüsü yoğun, trafiğin akışkan olduğu zaman hava türbülans ve tekerlek gürültüsü daha yoğundur. Akustik gürültü sinyalindeki bu farklılıktan faydalanılarak trafik yoğunluğu yoğun, orta ve serbest akış olmak üzere üç sınıfa ayrılmıştır. Önerilen yöntem Mel-frekans kepstrum katsayıları (MFCC, Mel-Frequency Cepstral Coefficients) özneliklerini ve sınıflandırıcı olarak k-en yakın komşu yöntemini kullanmaktadır. E5 karayolunda özgün bir veri seti üretilmiş ve önerilen yöntem bu veri seti kullanılarak test edilmiştir. MFCC özneliklerine ilişkin parametrelerin trafik yoğunluğu tespitine etkisi incelenmiştir ve en önemli iki parametrenin kepstrum katsayı sayısı ve pencere süresi olduğu görülmüştür. Hava durumunu dikkate alarak sınıflandırıcı eğitimin performansı iyileştirdiği gösterilmiştir. Bu iyileştirmenin sebebi irdelenmiş ve iki boyutlu öznelik uzayında gösterilmiştir. E5 karayolunda trafik yoğunluğu yağışlı havalarda %90, yağış olmayan durumlarda ise %82 doğrulukla tespit edilmiştir.

**Anahtar Kelimeler:** Trafik yoğunluk kestirimi, karayolu araçları, akustik sinyal işleme, örüntü tanıma

### Acoustic Based Vehicular Traffic Density Estimation

**Abstract:** In this study, traffic density is estimated using acoustic noise signals formed by the land vehicles. The acoustic noise signals formed by the vehicles consist of engine noise, air turbulence, the noise of the wheels touching the floor, exhaust noise and the horn noise. The contributions of these different types of noise change according to the traffic density. For example, engine noise and horn noise are dense when the traffic is busy and when the traffic is free-flow, air turbulence and wheel noise are more dense. By taking advantage of this change in the acoustic noise signal, the traffic density is categorized into three classes; busy, normal and free-flow. The proposed method use Mel-Frequency Cepstral Coefficients (MFCC) to extract features and the k-Nearest Neighbor Rule to classify. A data set was formed on E5 roadway and it was used to evaluate the proposed method. The effect of MFCC attributes on the traffic density estimation was investigated and the number of cepstral coefficients and the duration of windows are found to be the most important ones. It is shown that the performance of the traffic density estimation is increased if the weather conditions are considered when training the classifiers. The reason behind this improvement is investigated and shown on a two dimensional feature space. The traffic density in the E5 roadway is determined by %90 and %82 accuracies when raining and not raining, respectively.

**Keywords:** Traffic density estimation, land vehicles, acoustic signal processing, pattern recognition

\* Elektronik Mühendisliği Bölümü, Gebze Teknik Üniversitesi, Gebze, Kocaeli, Turkey, 41400  
İletişim Yazarı: Ali Köksal Hocaoglu (khocaoglu@gtu.edu.tr)

## 1. GİRİŞ

Trafik yoğunluğu dünya genelinde önemli bir problemdir (Wang ve diğ., 2018; Xia ve diğ., 2016; Yang ve diğ., 2015; Tyagi ve diğ., 2012). Şehirlerde araç kullanımının artması, trafik yoğunluğu ve hava kirliliği problemlerini beraberinde getirmektedir (Borkar ve diğ., 2013a). Trafik yoğunluğu tespiti için hızölçer, manyetik detektör, radar, lazer ve görüntü sensörleri gibi sensörler ile çeşitli çözümler üretilmiş, ancak bunların maliyetli olması ve bazılarının kurulum ve bakım aşamasında trafiği engellemesinden dolayı çok fazla yaygınlaşamamışlardır (Borkar ve diğ., 2013a). Video kameralar trafik yoğunluğunu ölçmek üzere kullanılan sensörlerden biridir. Akustik sensörlere göre daha maliyetlidir. Gece-gündüz sebebiyle aydınlığın değişmesi, araçların farlarının görüntü üzerinde oluşturduğu olumsuz etkiler geliştirilen algoritmaların performansını azaltmaktadır (Beymer, ve diğ., 1997; Li, ve diğ., 2004; Tan ve diğ., 2007).

Trafik yoğunluğu tespitinde maliyetinin ve kurulumunun basit olmasından dolayı son 10 yıldır akustik sinyal tabanlı çözümlere olan ilgi artmıştır (Tyagi ve diğ., 2012). Karayolunda ilerleyen araçlar çeşitli akustik gürültüler üretmektedir. Bunlar aracın hızına, yüküne, mekanik durumuna ve aynı zamanda çevre şartlarına bağlıdır (Koch ve diğ., 2006). Bu çevre şartları rüzgâr, rüzgârın yönü, yağış, hava sıcaklığı, aracın temas ettiği yüzeyin türü ve yaya kullanımının sıklığı gibi unsurlardır. Aracın ürettiği ses sinyali motor sesi, teker sesi, türbülans sesi, egzoz gürültüsü ve korna seslerinin toplamından oluşmaktadır (Vijaj ve diğ., 2015). Aracın hızına bağlı olarak araç farklı motor sesleri üretmektedir (Borkar ve diğ., 2013b). Tekerlek sesi, araç tekerleğinin temas ettiği yüzey ile etkileşimi sonucu meydana gelmektedir. Tekerlek sesi, hava gürültüsü ve titreşim gürültüsü olmak üzere iki bileşenden oluşmaktadır. Hava gürültüsü tekerleğin lastikleri arasına havanın sıkışması sonucu oluşmaktadır. Hava gürültüsü 1 kHz ile 3 kHz aralığında baskındır. Titreşim gürültüsü, tekerlek ile yüzeyin etkileşimi ile oluşmaktadır. Titreşim gürültüsü, 100 Hz ile 1000 Hz aralığında baskındır. Tekerlek sesi, araç hızı 50 km/s ve üstü olduğu zaman toplam sinyal içinde daha baskın olmaktadır (Sandberk, 2001). Hava türbülans sesi aracın dış kısmının hava ile teması sonucu oluşmaktadır. Araç hızlandıkça hava türbülans sesi şiddeti artmaktadır (Eskridge, 1979). Hava türbülans sesi aracın aerodinamik yapısına, aracın hızına, rüzgar hızına ve rüzgarın yönüne bağlıdır (Borkar ve diğ., 2013a). Egzoz sesi araçtaki egzoz aparatından çıkmaktadır. Aracın yükü arttıkça egzoz sesi büyür (Tyagi ve diğ., 2012). Egzoz sesi güç spektrumunda düşük frekansa sahiptir (Borkar ve diğ., 2013a). Akustik sinyal tabanlı çözümler trafik yoğunluğuna bağlı olarak bu gürültülerin oluşturduğu toplam gürültüdeki değişimden yararlanmaktadır.

Tyagi ve diğ. (2012), akustik verileri şehir içinde ve 5-8 şeritli bir yolda toplamıştır. Verilerin toplandığı ortamda, trafik yoğunluğunun sıkışık olduğu saatlerde araçlar 8 şerit oluşturmakta ve korna seslerinin çok fazla olmaktadır. Trafik yoğunluğunun fazla olduğu saatlerdeki yoğun korna sesleri bu veri seti için trafik yoğunluğunu ayırt edici bir özellik olmuştur. Yapılan çalışmada 30 saniyelik örnekler 500 ms. çerçeve süresi ve 100 ms. çerçeve örtüşme süresi olacak şekilde MFCC yöntemi ile öznitelikler hesaplanmıştır. Bayes ve SVM sınıflandırıcı kullanılarak her sınıf için doğruluk oranı yaklaşık %95 - %100 aralığında bulunmuştur.

Borkar ve diğ. (2013a), akustik verileri şeritsiz ve kaotik bir yolda toplamıştır. Öznitelik olarak doğrusal kestirim katsayıları (LPC, Linear Predictive Coefficient) kullanarak düşük (40km/s ve üstü), orta (20-40 km/s) ve yoğun (0-20 km/s) olmak üzere üç sınıfı Destek Vektör Makinası (SVM, Support Vector Machine ) sınıflandırıcı ile %96-%98 arasında bir performans ile sınıflandırmıştır.

Literatürde akustik sinyal temelli sistemlerinin tasarımında genellikle MFCC ve LPC öznitelik çıkarma yöntemleri kullanılmıştır. Bu yöntemlerin parametre değerleri amaca göre farklılık göstermiştir (Eskidere ve diğ., 2009; Tyagi ve diğ., 2012; Bhave ve diğ., 2001; Borkar ve diğ. 2013a). Ancak yöntemlerin sınırlı sayıda parametresinde değişiklik yaparak analiz yapmışlardır. Kullanılan veri setleri de şeritsiz, kaotik ve/veya yan yana 8 şerit araç sığacak kadar geniş bir yolda toplanmıştır. Veri seti bazı çalışmalarda hep aynı lokasyondan, bazı

çalışmalarda hep aynı hava koşullarında toplanmıştır. Bu özellikleri itibariyle E5 karayolundan toplanan Gebze Teknik Üniversitesi (GTÜ) Trafik Yoğunluk Veri Seti ile benzeşmemektedirler.

Bu çalışmada kullanılan veri seti literatürde bahsedilen veri setlerine göre farklılıklara sahiptir. Çalışmada kullanılan veri seti farklı günlerde, farklı lokasyonlarda ve yağmurlu-yağmursuz, rüzgarlı-rüzgarsız, sıcak-soğuk gibi farklı hava koşullarında E5 karayolundan toplanmıştır. E5 karayolu, her biri 3 şeritli, çift yönlü, tamamıyla asfalt, emniyet şeridine sahip ve bazı lokasyonlarda yan yola sahip bir karayoludur. Veri setinin en önemli özelliği farklı hava koşullarında toplanmasıdır. Bu sebeplerle, bu veri setinde yapılan analizler diğer çalışmalardan farklı sonuçlar üretmektedir.

Bu çalışmanın çeşitli katkısı olmakla birlikte öncelikle araştırmacıların kullanımına sunulmuş kapsamlı bir trafik yoğunluk veri seti üretilmiştir. Akustik sinyallerin analizinde sık olarak kullanılan bazı öznelikler trafik yoğunluğu kestirimi problemi açısından karşılaştırılmıştır. MFCC özneliklerine ilişkin parametrelerin trafik yoğunluğu tespitine etkisi incelenmiştir ve en önemli iki parametrenin kepsrum katsayı sayısı ve pencere süresi olduğu gösterilmiştir. Hava koşullarını dikkate alarak hava durumuna özel sınıflandırıcı eğitmenin araç trafik yoğunluğu kestirim performansını iyileştirdiği gösterilmiştir.

Bu çalışmanın devamı şu şekilde organize edilmiştir. Bölüm 2’de bu çalışmada üretilen GTÜ Trafik Yoğunluk Veri Seti hakkında bilgi verilmektedir. Bölüm 3’te akustik sinyaller için öznelik çıkartma ve sınıflandırma tekniklerinin bazıları ele alınmış ve trafik yoğunluğunun kestirimi için önerilen yaklaşım açıklanmıştır. Bölüm 4’te önerilen yöntemle ilişkin parametrelerin en iyilemesi ve önemli parametrelerin tespiti verilmekte ve önerilen sistemin performansı önceki çalışmalarla karşılaştırıp farkları analiz edilmektedir. Ayrıca, önerilen sistemin performansını artırmaya yönelik olarak farklı hava durumlarına göre sınıflandırıcı tasarlama yaklaşımı sunulmaktadır. Bölüm 5’te çalışmanın sonuçları özet olarak verilmektedir.

## 2. VERİ SETİ

Akustik sensörlerin trafik yoğunluğu tespitinde kullanılmasına yönelik çok sayıda çalışma olmasına rağmen araştırmacıların kullanımına açık bir veri seti bulunmamaktadır. Ayrıca, önceki çalışmalarda kullanılan veri setleri kısıtlı çeşitliliğe sahiptir ve hava koşullarına göre bir analize imkan verecek şekilde toplanmamıştır. Bu çalışmada, trafik yoğunluğunu ölçmeye yönelik olarak özgün bir akustik veri seti oluşturulmuştur. Sözkonusu veri seti GTÜ Trafik Yoğunluk Veri Seti olarak adlandırılmıştır ve araştırmacıların kullanımına açıktır (Gtü, 2018). Verilerin toplanması aşamasında STM32F4 Discovery kiti üzerindeki çok yönlü mikrofondan alınan veriler 16 kHz. örnekleme frekansı, 16 bit ve mono formatında kaydedilmiştir. Veriler E5 karayolunda 3 ay boyunca farklı günlerde ve farklı hava koşullarında toplanmıştır. Toplanan veri “yoğun”, “orta” ve “açık (serbest akış)” olmak üzere üç farklı trafik yoğunluğunu kapsadığı gibi, yağmurlu, yağmursuz, rüzgârlı ve rüzgârsız hava koşullarını da kapsamaktadır. Veri toplama etkinliği yoğunlukla trafik yoğunluğunun açık-orta-yoğun-orta-açık şeklinde değiştiği zaman dilimi olan 16:00-20:00 arasında yapılmış olmakla birlikte sabah saatlerini de kapsamaktadır. Veriler Gebze-Pendik E-5 karayolu arasındaki farklı yerlerden toplanmıştır.

Akustik veri kaydı yapılırken eş zamanlı olarak İstanbul Büyükşehir Belediyesi (İBB) Trafik Yoğunluk Haritası’ndan verilerin toplandığı zamana ait trafik yoğunluk durumu ve ortalama hızlar da kayıt altına alınmıştır. Eş zamanlı olarak ayrıca yolun kamera görüntüsü de kayıt altına alınarak analizler sırasında beklenmeyen durumların olması durumunda görüntü kayıtlarına bakabilme imkanı sağlanmıştır. Ses verisi 15’er dakikalık aralıklarla kayıt altına alınmıştır ve toplamda 1200 dakika toplanmıştır. 1200 dakikalık ses verisi 1 dakikalık örneklere bölünerek veri setini oluşturmuştur. İlgili örnekler belli bir isimlendirme kuralı ile kayıt altına alınmıştır. Dosya isimlerine bakıldığında sesin hangi tarihte, saatte, hangi hava koşullarında toplandığı ve trafik yoğunluk durumlarından hangisine ait olduğu anlaşılmaktadır. Örneğin TR11-10-2017-10-03-YYRYSY-FFAC\_01.wav isimli dosya ile erişilen veri 11.10.2017 tarihinde 10:03’te toplanmış. Hava koşulları ‘Yağmur Var/Yok ( YV/YY )’,

‘Rüzgâr Var/Yok ( RV/RY )’ ve ‘Sıcak/Sıcak Değil ( SV/SY )’ olarak görünmektedir. Trafik yoğunluğu hakkında iki veri içermektedir. ‘FF’, ‘Serbets-Akış ( FreeFlow )’ durumunu ifade etmektedir. ‘AC’ ise İBB Trafik Yoğunluk Haritasında ‘Açık’ı ifade etmektedir. En sonda bulunan ‘01’ verinin toplanmaya başlandığı 10:03 saatinden itibaren birinci dakikayı ifade etmektedir. Dosya adının başındaki TR bunun eğitim setinde olduğunu, TS ise test setinde olduğunu ifade etmektedir. Bu sayede yapılacak tüm deneylerde eğitim ve testler farklı durumları dikkate alarak kolayca yapılabilir.

Tüm veri içinde trafik yoğunluğu durumuna göre tüm gruplar mevcut olduğu gibi farklı hava koşullarına göre de örnekler bulunmaktadır. Tablo 1’de GTÜ Trafik Yoğunluk Veri Seti’nde hangi hava durumunda hangi sınıftan kaç veri olduğu gösterilmektedir. Toplam 1200 dakikalık verinin, 600 dakikası eğitim verisi, 600 dakikası test verisi rastgele belirlenmiştir. Tablo 1’ de gösterildiği gibi her sınıfa ait eğitim ve test örnek sayısı yaklaşık aynıdır. Ancak, yağmurlu havalarda trafik yoğunluğu genellikle arttığı için veri toplama etkinliklerinde orta ve açık trafik durumlarına yönelik daha az veri toplanabilmiştir.

**Tablo 1. GTÜ trafik yoğunluk veri seti**

	Hava Koşulu	Yoğun	Orta	Açık	Toplam
Eğitim Seti	Yağmurlu	108	45	47	600
	Yağmursuz	110	111	179	
	Toplam	218	156	226	
Test Seti	Yağmurlu	119	49	41	600
	Yağmursuz	114	107	170	
	Toplam	233	156	211	

### 3. TRAFİK YOĞUNLUĞUNUN TESPİTİ

Literatürde akustik sinyal temelli trafik yoğunluğu tespitinde sık kullanılan öznelik çıkarma yöntemlerinden birisi mel-frekans kepstral katsayıları (MFCC)’dir (Zhao ve diğ., 2011; Sumithira ve diğ., 2012). MFCC öznelikleri farklı parametrelerle oluşturularak basit Bayes, k-en yakın komşu (k-NN) ve destek vektör makinası (SVM) sınıflandırıcıları kullanılarak trafik yoğunluğu tespit başarıları irdelenmiştir.

#### 3.1. Öznelik Çıkartımı

İnsan, duyu organı vasıtasıyla dışarıdan aldığı verileri kullanarak trafiğin yoğun olup olmadığını kestirebilmektedir. MFCC özneliği, insan kulağının frekans algılamasını model alan ve Fourier tabanlı sayısal teknik analizidir. MFCC öznelik çıkartma işleminin aşamaları Şekil 1’ de gösterilmektedir. Ses işaretine ilk olarak ön-vurgulama işlemi uygulanır. Bu işlem için sistem fonksiyonu Denklem (1) ile gösterilen sayısal bir filtre kullanılır.

$$H(z) = 1 - \alpha z^{-1} \quad (1)$$


Buradaki  $\alpha$  parametresi konuşmacı tanıma vb. uygulamalarda tipik olarak 0.97 olarak kullanılır ve bu durumda bir yüksek geçiren filtre olarak davranır. Bu parametrenin sıfır olarak seçilmesi durumunda ise sinyal hiçbir değişikliğe uğramaz; filtre bir tüm-geçiren olarak davranır. Ön vurgulamadan sonra ise ses işareti ilk olarak N örnekten oluşan çerçevelere ayrılıp, takip eden çerçeve örtüşme olacak şekilde M örnekten itibaren alınmaktadır. Fourier Dönüşümü (FT) uygulanmadan önce spektral sızıntıyı indirmek için Hamming, Hanning vb. bir pencere ile pencereleme işlemi uygulanır. Hanning penceresi,  $k = 0, \dots, N - 1$  olmak üzere, Denklem (2) ile ifade edilir.

$$w[k + 1] = 0,5 \left( 1 - \cos \left( 2\pi \frac{k}{N - 1} \right) \right) \quad (2)$$

Pencerelenmiş ses işaretinin ayrık Fourier dönüşümü alınır ve Mel frekans ölçeğine göre dizilmiş süzgeç dizilerinden geçirilip logaritması alınır. Mel frekans ölçeği Denklem (3)'de tanımlanmıştır (Eskidere ve diğ., 2009).

$$\text{mel}(f) = 2595 \left[ \log_{10} \left( 1 + \frac{f}{700} \right) \right] \quad (3)$$

Son olarak, logaritmik Mel spektrumuna Ayrık Kosinüs Dönüşümü (AYD) uygulanır. Elde edilen katsayılara Mel frekansı keprstrum katsayıları denir (Tyagi ve diğ., 2012).



**Şekil 1:**  
*MFCC Algoritma Adımları*


Hilbert-MFCC (MHCC) öznitelik çıkartma algoritması MFCC algoritmasından türetilmiştir. MFCC algoritmasında FT yerine Hilbert Dönüşümü (HT) spektrum kullanılmıştır (Zhao ve diğ., 2011). Bark-MFCC (BFCC) öznitelik çıkartma algoritması da MFCC algoritmasından türetilmiştir. Tek farklılık FT sonrasında elde edilen sinyalin Bark frekans ölçeğine göre dizilmiş süzgeç dizilerinden geçirilmesidir (Sumithira ve diğ., 2012). Doğrusal Öngörü ile Kodlama (LPC) öznitelik çıkartma algoritması Şekil 2' de görüldüğü gibi pencerleme aşamasına kadar MFCC ile aynı aşamaları içermektedir. Pencerleme adımından sonra oto-korelasyon ve LPC keprstrum analiz aşamaları ile LPC öznitelik vektörü elde edilmiştir (Bhave ve diğ., 2001; Borkar ve diğ. 2013a).

### 3.2. Sınıflandırma Yöntemleri

Basit Bayes, SVM ve k-NN yöntemleri kullanılarak bir önceki bölümde belirtilen özniteliklerin trafik yoğunluğunu ölçme başarısı test edilmiştir. Bu testlerde k-NN, diğer iki yöntemle göre çoğunlukla en iyi performansı vermiştir. Bu çalışmada farklı sınıflandırıcıların performansının karşılaştırılması özellikle ele alınan bir husus olmadığı için diğer sınıflandırıcılara ve performanslarının tartışmasına burada yer verilmemektedir.

K-en yakın komşu kuralı, görüntü bölütleme, konuşmacı tanıma, trafik yoğunluğu kestirimi vb. pek çok alanda kullanılan sınıflandırma yöntemlerinden biridir. Sorgulanan örneğin sınıfını, örneğe en yakın k adet eğitim örneğinin sınıflarına göre belirler. Mesafe ölçüsü için genellikle Öklid mesafesi kullanılır. K adet eğitim örneği içinde en çok elemana sahip olan sınıf, sorgulanan örneğin de sınıfı kabul edilir (Tyagi ve diğ., 2012).

Tüm çalışma boyunca k değeri 5, 10 ve 15 olacak şekilde sınıf performansı gözlemlenmiştir. Çalışmada belirtilen performanslar analiz sonucunda en yüksek çıkan performanstır.



**Şekil 2:**  
LPC Algoritma Adımları

#### 4. TEST VE ANALİZ

Bu çalışmanın ilk aşamasında MFCC, BFCC, LPC ve MHCC ile elde edilen özniteliklerin performansı karşılaştırılmıştır. Öznitelikler üretilirken pencere genişliği, katsayı sayısı vb. parametreler aynı alınmıştır. Tablo 2’de MFCC, BFCC, LPC, MHCC algoritmalarına ait özniteliklerin trafik yoğunluğu performansları gösterilmektedir. Elde edilen sonuçlar E5 karayolu trafik yoğunluk tespiti için en etkili özniteliklerin MFCC ile elde edildiğini göstermektedir. Testlerin devamında bu nedenle MFCC ile elde edilen öznitelikler kullanılmıştır.

**Tablo 2. Frekans düzlemi yöntemleri-kNN performans**

Öznitelik Çıkarım Algoritması	Sınıflandırıcı Performansı
MFCC	% 77
BFCC	% 76
MHCC	% 58
LPC	% 67

Tablo 2’ de elde edilen MFCC performansında Tablo 3’te belirtilen parametre değerleri kullanılmıştır.

**Tablo 3. MFCC parametre adı ve değerleri (Performans: % 77)**

Parametre adı	Parametre değeri
Ön işleme (a)	0,0 (Yok)
Çerçeve Süresi	25 ms
Çerçeve Örtüşme Süresi	10 ms
Pencere Fonksiyonu	Hanning
Mel Filtre Bant Sınırı	0 – 8000 Hz
Mel Filtre Bant Sayısı	40
Kepstrum Sayısı	12
Kepstrum Katsayıları Kuvveti	0.0
FFT Kuvveti	1,0
Ortalama Enerji Öznitelik Vektörü	Var

##### 4.1. MFCC Parametre Optimizasyonu

Konuşmacı tanıma vb. uygulamalarda MFCC öznitelikleri çıkartılırken kullanılan tipik parametreleri kullanmak yerine trafik yoğunluğu tespiti için optimum MFCC parametrelerini bulmak üzere parametrelerin değerleri belli bir sıra ile ve aralıkta değiştirilerek MFCC ile elde edilen performansın artması sağlanmıştır.

Ön işleme aşamasında uygulanan sayısal filtrenin parametresi [0-0.95] aralığında değiştirilmiştir ve performans açısından önemli bir fark oluşturmadığı gözlenmiştir.

Çerçeveleme işleminde çerçeve uzunluğu spektral bilginin kayıpsız elde edilmesi için yeterince uzun ve sinyalin tipik özelliğini barındırması açısından da yeterince kısa seçilmelidir. Konuşma tanıma vb. uygulamalarda tipik olarak 20 ms. olarak seçilmektedir. Çerçeve uzunluğunun %30'u ile %75' i arasında bir örtüşme uygulanarak çerçeve geçişlerindeki hızlı değişimin önüne geçilir (Bolat ve diğ., 2004). Akustik sinyalin çerçeveleme süresi ve çerçeve örtüşme süresi Tablo 4'te gösterilenden daha fazla sayıda değiştirilmiş ve elde edilen öznelikler, sınıflandırıcıya giriş olarak verilmiştir. Çerçeve süresi ve örtüşme süresinin performansa etkisini göstermek üzere yapılan testlerin bir alt kümesi Tablo 4'te özetlenmiştir. Tablodan görüldüğü üzere çerçeve süresinin 100 ms.'den fazla seçilmesi durumunda trafik yoğunluğu tespit performansı azalmaktadır. Çerçeve örtüşme süresinin performans açısından önemli olmadığı görülmüştür.

**Tablo 4. Çerçeve süresi ve çerçeve örtüşme süresinin performansa etkisi**

Çerçeve Süresi	Çerçeve Örtüşme Süresi	Performans
25 ms	10 ms	%77,8
100 ms	50 ms	%77,9
100 ms	75 ms	%77,8
200 ms	10 ms	%77,2
200 ms	150 ms	%77,2
400 ms	100 ms	%76,3
400 ms	300 ms	%76,3

Mel frekansı kepstrum katsayılarını elde etmek için üçüncü adım pencerelemedir. Hamming, Hanning, Blackman, Gauss, dikdörtgen ve üçgen pencereleme fonksiyonları sık olarak kullanılan fonksiyonlar arasındadır (Eskidere ve diğ., 2009). Onsekiz pencereleme fonksiyonunun performansı test edilmiş ve dikdörtgen pencerenin en düşük performansı verdiği gözlenmiştir. Diğer pencereler arasında önemli bir fark olmamasına rağmen Hanning penceresi en yüksek performansı sağlamış, Hamming ve Gauss pencereleri ise en yüksek performansı sağlayan diğer iki pencere tipi olmuştur.

Ön işleme aşamasında uygulanan sayısal filtrenin parametresi ile MFCC Mel filtre bant sınırı farklı kombinasyonlarda test edilmiş ve performans açısından çok önemli bir fark oluşturmadığı gözlenmiştir.

Benzer şekilde diğer parametreler de test edilmiş ve Mel frekansı kepstrum katsayısının performansı en fazla etkileyen parametre olduğu görülmüştür. En yüksek performans %80,2 ile 17 kepstrum katsayısı kullanılarak elde edilmiştir.


#### 4.2. Önceki Çalışmalarla Karşılaştırma

Tyagi vd. çalışmasında verileri şehir içinde ve 5-8 şeritli bir yolda toplamıştır. Yaptığı çalışmada 30 saniyelik örneklerin 500 ms pencere süresi ve 100 ms kaydırma süresi olacak şekilde MFCC işleminden geçirerek 12 öznelik hesaplamıştır. Bayes ve SVM sınıflandırıcı kullanarak her sınıf için doğruluk oranını yaklaşık %100 bulmuştur. GTÜ trafik yoğunluk veri seti kullandığımızda aynı parametrelerle MFCC öznelikleri hesaplanarak ve basit Bayes ve SVM sınıflandırıcıları kullanıldığında %65 ile %68 arasında bir sınıflandırma başarısı elde edilmektedir. Bu oranı Tyagi'nin elde ettiği başarı oranından çok düşüktür. Bunun temel farklarından biri veri setlerinin toplandığı ortamda sürücülerin davranış farklılığıdır. İlgili çalışmada, trafik yoğunluğunun olma sıklığı çoğunlukla fazladır ve yoğunluğun fazla olduğu durumlarda sürücüler kornalarını çok fazla kullanmaktadır. Trafik yoğunluğunun sıkışık olduğu andaki korna sesleri ayırt edici özellik oluşturarak sınıflandırma performansının artmasına yol açmaktadır. Tyagi'nin veri setinden farklı olarak E5 karayolunda araçlar nadiren korna çalması veri setleri arasındaki sonuca etki edecek en belirgin özelliktir. E5 karayolunda daha az korna olmasının yanı sıra trafik yavaş ilerlerken bazı sürücülerin emniyet şeridine girerek trafiğin

olağan akışından çok daha yüksek hızla araçlarını kullanması gibi sık yaşanan durumlar veri setinden özel olarak ayıklanmadığı için bu veri setindeki başarı oranının düşmesinde etkisi bulunmaktadır.

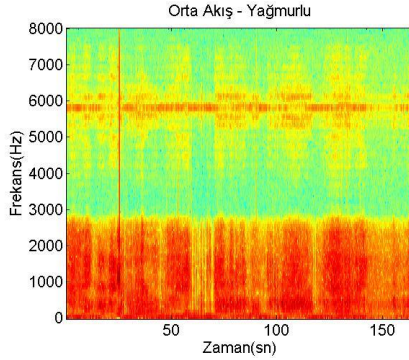
### 4.3. Hava Durumuna Bağlı Sınıflandırma Performansı

Verilerin toplanması aşamasında yağmurlu havada tekerleğin yer ile temasında oluşan gürültü ile yağmursuz havada tekerleğin yer ile temasında oluşturduğu gürültünün farklı olduğu gözlenmiştir. Bu gözlemi doğrulamak, akustik sinyalin özelliklerinin hava koşullarına göre değişip değişmediğini görmek için yağmurlu havada toplanan veriler ile yağmursuz havada toplanan veriler için zaman-frekans analizi yapılmıştır. Şekil 3'te orta akış için yağmursuz ve Şekil 4'te orta akış için yağmurlu hava durumu için zaman-frekans grafikleri gösterilmektedir. Yağmurlu ve yağmursuz havada elde edilen işaretlerin spektral özelliklerinde farklılık olduğu görülmektedir.



**Şekil 3:**

*Yağmursuz havada orta akış için tipik bir zaman-frekans grafiği*



**Şekil 4:**

*Yağmurlu bir havada orta akış için tipik bir zaman-frekans grafiği*

Hava koşullarının dikkate alınması durumunda trafik yoğunluğu tespit performansının artıp artmayacağına yönelik çalışmalar yapılmıştır. Bu maksatla, yağmurlu ve yağmursuz hava durumları için iki ayrı sınıflandırıcı tasarlanmıştır. Elde edilen sonuçlar Tablo 5'te verilmiştir. Havanın yağışlı olduğunun uygun bir sensör tarafından tespit edildiğinde yağışlı hava durumu için eğitilen sınıflandırıcının kullanılması durumunda trafik yoğunluğu tespit performansı %80'den %90'a çıkmaktadır. Yağışsız hava durumuna özel olarak eğitilen sınıflandırıcı ise hava durumu gözlemlenmeden eğitilen sınıflandırıcıya göre yalnızca %1,4 iyileştirme göstermektedir. Performansta en fazla iyileşme yağışlı hava durumu için olmaktadır.

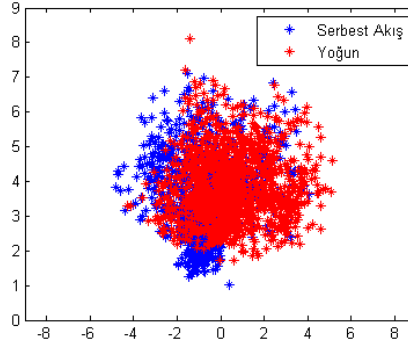


**Tablo 5. Hava durumuna göre eğitilen sınıflandırıcı performansları**

Sınıflandırıcı Tipi	Sınıflandırıcı Performansı
Yağışlı hava	%90,1
Yağışsız hava	%81,6
Hava durumunu dikkate almayan sınıflandırıcı	%80,2

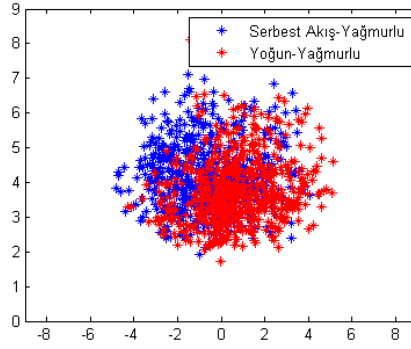
Hava koşullarının yağmurlu olup olmamasının dikkate alınması halinde başarı oranının artmaktadır. Hava durumunun dikkate alınmadan sınıflandırıcı tasarlanması ve hava durumunun dikkate alınarak sınıflandırıcı tasarlanması durumunda öznelik uzayında oluşacak farklılıkların sebebini görmek için şu prosedür izlenmiştir:

- Mel frekans katsayısı olarak 17 alındığı için 17 boyutlu uzayda MFCC'nin farklı trafik yoğunlukları için nasıl öbekler oluşturduğu doğrudan gösterilemez; MFCC özneliklerini temsil etmek üzere MFCC'nin ortalama değeri ve standart sapması alınmıştır. Aras ve diğ. (2017) akciğer sesini tanımak için MFCC katsayılarının ortalama değerini ve standart sapmasını öznelik olarak kullanmıştır; benzer uygulamalar konuşmadan duygu tanıma vb. problemlerde de yaygın olarak kullanılmaktadır (Durukal ve diğ., 2015). Her bir pencere için bulunan MFCC katsayılarının ortalama değeri ve standart sapmaları alınmıştır. Ortalama değer birinci öznelik, standart sapma ise ikinci öznelik olarak kullanılmıştır.
- Hava durumundaki farklılıklar dikkate alınmadan, serbest akış ve yoğun trafik durumlarına ilişkin herbir pencereden elde edilen özneliklerin nasıl bir öbek oluşturduğu Şekil 5'te gösterilmektedir.
- Sadece yağışlı hava durumunda serbest akış ve yoğun trafik durumları için herbir pencereden elde edilen özneliklerin nasıl bir öbek oluşturduğu Şekil 6'da gösterilmektedir.



**Şekil 5:**

*Hava durumu dikkate alınmadığı durumda serbest akış ve yoğun sınıflarına ait özneliklerin oluşturduğu öbek*



**Şekil 6:**

*Hava durumu dikkate alındığında, sadece yağmurlu durum için serbest akış ve yoğun sınıflarına ait özneliklerin oluşturduğu öbek*

Elde edilen öbeklerin örtüşme durumları dikkate alındığında fark edileceği üzere sadece yağışlı hava duruma ait özneliklerle eğitilmiş bir sınıflandırıcının serbest akış-yoğun trafik durumunu ayırt etmesi, yağış olup olmadığını dikkate almadan eğitilecek tek bir sınıflandırıcıya göre daha kolaydır. Elde edilen sonuçlar da bu gözlemi desteklemektedir.

## 5. SONUÇLAR

Bu çalışmada, trafik yoğunluğunu ölçmeye yönelik olarak özgün bir akustik veri seti oluşturulmuştur ve araştırmacıların kullanımına açıktır. MFCC, BFCC, LPC ve MHCC ile elde edilen öznelikleri trafik yoğunluğunu tespit performansı açısından karşılaştırılmıştır. MFCC ve BFCC diğer iki yöntemle göre daha iyi sonuç vermiştir. MFCC yöntemine ilişkin parametrelerin sınıflandırma performansı etkisi incelenmiş ve pencere boyu ile kepsrum katsayı sayısının en önemli iki parametre olduğu görülmüştür. Konuşma tanıma vb. uygulamalarda pencere genişliği tipik olarak 20 ms. alınmaktadır ve bu değerden daha fazla seçilmesi durumunda performans düşmektedir. Trafik yoğunluğunu tespit probleminde ise pencere genişliğinin 200 ms'ye kadar çıkmasının sınıflandırma performansını çok etkilemediği görülmüştür. Hava durumuna bağlı olarak sınıflandırıcı eğitiminin performansı artırdığı gösterilmiştir. Önerilen yöntem ile yağışın olmadığı zamanlarda %82 oranında, yağışlı havalarda ise %90 oranında bir trafik yoğunluk performansı elde edilmiştir. Hava durumuna bağlı sınıflandırıcı eğitiminin performansta neden artış sağladığı gösterilmiştir.

## KAYNAKLAR

1. Aras, S. ve Gangal, A. (2017), Comparison of different features derived from mel frequency cepstrum coefficients for classification of single channel lung sounds, *40th International Conference on Telecommunications and Signal Processing Barcelona, 2017*, pp. 346-349. doi: 10.1109/TSP.2017.8076002
2. Beymer, D., Mclauchlan, P., Coifman, B., ve Malik J., (1997), A real-time computer vision system for measuring traffic parameters, *IEEE Conference on Computer Vision and Pattern Recognition*, San Juan, Puerto Rico, USA, pp. 495-501. doi: 10.1109/CVPR.1997.609371
3. Bolat, B., Küçük, Ü. Yıldırım, T. (2004), Aktif Öğrenen PNN ile Konuşma/Müzik Sınıflandırma, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, İstanbul, 187-189.

4. Borkar P., Malik L., (2013b), “Review on vehicular speed, density estimation and classification using acoustic signal”, *International Journal for Traffic and Transport Engineering*, 3 (3), 331-343. doi: 10.7708/ijtte.2013.3(3).08
5. Borkar, P. Malik, L. G. (2013a), Cumulative Acoustic Signal Based Traffic Density State Estimation, *Third International Conference on Advances in Computing and Communications*, Cochin, India, 2013, pp. 169-172. doi: 10.1109/ICACC.2013.40
6. Durukal, M. ve Hocoğlu, A. K. (2015), Performance optimization on emotion recognition from speech, *23rd Signal Processing and Communications Applications Conference*, Malatya, pp. 308-311. doi: 10.1109/SIU.2015.7129820
7. Eskidere, Ö., Ertaş, F. (2009), Mel Frekansı Kepstrum Katsayılarındaki Değişimlerin Konuşmacı Tanımaya Etkisi, *Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, Cilt 14, sayı 2. doi: 10.17482/uujfe.11784
8. Eskridge R., Hunt J., (1979), “Highway modeling. Part I: Prediction of velocity and turbulence fields in the wake of vehicles”, *Journal of Applied Meteorology*, 18 (4), 387-400. doi: 10.1175/1520-0450(1979)018<0387:HMPIPO>2.0.CO;2
9. Gtü (2018), <http://goo.gl/QFwkWY>, Erişim Tarihi: 01.07.2018, Konu: GTU Traffic Density Data Set
10. Hanilçı, Ç. (2007), Konuşmacı Tanıma Yöntemlerinin Karşılaştırmalı Analizi, Yüksek lisans tezi, Uludağ Üniversitesi - Elektronik Mühendisliği Anabilim Dalı, BURSA.
11. Koch W., Koller J., Ulmke M., (2006), Ground target tracking and road map extraction, *Transportation ISPRS Journal of Photogrammetry and Remote Sensing*, 61 (3), 197-208. doi: 10.1016/j.isprsjprs.2006.09.013
12. Li, X., Porikli, F.M., (2004), A hidden markov model framework for traffic event detection using video features, in *Int'l Conference on Image Processing*, Singapore, vol. 5, pp. 2901–2904. doi: 10.1109/ICIP.2004.1421719
13. Sandberg U., (2001), “Tyre/road noise - myths and realities”, *The International Congress and Exhibition on Noise Control Engineering*, Hague, Netherlands, 35-56, 27-30 August
14. Sumithra, M.G., Devika, A.K. (2012), A Study on Feature Extraction Techniques for Text Independent Speaker Identification, *International Conference on Computer Communication and Informatics*, Coimbatore, India, 10-12, January. doi: 10.1109/ICCCI.2012.6158791
15. Tan, E. ve Chen, J., (2007), Vehicular traffic density estimation via statistical methods with automated state learning, *Proceedings of the IEEE Conference on Advanced Video and Signal Based Surveillance*, pp. 164–169, IEEE, London. doi: 10.1109/AVSS.2007.4425304
16. Tyagi, V., Kalyanaraman, S. ve Krishnapuram, R., (2012) Vehicular Traffic Density State Estimation Based on Cumulative Road Acoustics, *IEEE Transactions on Intelligent Transportation Systems*, vol. 13, no. 3, pp. 1156-1166. doi: 10.1109/TITS.2012.2190509
17. Vijay, R., Sharma, R., Chakrabarti, T. ve Gupta, R. (2015), Assessment of honking impact on traffic noise in urban traffic environment of Nagpur, India, *Journal of Environmental Health Science and Engineering*. doi:10.1186/s40201-015-0164-4
18. Wang, Q, Zheng, J, Xu, H., Xu, B. ve Chen, R. (2018), Roadside Magnetic Sensor System for Vehicle Detection in Urban Environments, *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 5, pp. 1365-1374. doi: 10.1109/TITS.2017.2723908

19. Xia, Y., Shi, X., Song, G. Geng, Q., Liu (2016), Towards improving quality of video-based vehicle counting method for traffic flow estimation, *Signal Processing*, vol. 120, pp. 672-681. doi: 10.1016/j.sigpro.2014.10.035.
20. Yang B., ve Lei, Y. (2015), Vehicle Detection and Classification for Low-Speed Congested Traffic With Anisotropic Magnetoresistive Sensor, *IEEE Sensors Journal*, vol. 15, no. 2, pp. 1132-1138. doi: 10.1109/JSEN.2014.2359014
21. Zhao, H, Liu, H., Zhao, K., Yang, Y. (2011), Robust Speech Feature Extraction Using the Hilbert Transform Spectrum Estimation Method, *International Journal of Digital Content Technology and its Applications*, Volume 5, Number 12. doi:10.4156/jdcta.vol5.issue12.11