

FMCW Radar Sinyalleri ile LSTM Tabanlı Hedef Sınıflandırması

LSTM Based Classification of Targets using FMCW Radar Signals

Oytun GÜNEŞ
Elektrik Elektronik Mühendisliği
Bilkent Üniversitesi
Ankara, Türkiye
oytun@ee.bilkent.edu.tr

Ömer MORGÜL
Elektrik Elektronik Mühendisliği
Bilkent Üniversitesi
Ankara, Türkiye
morgul@ee.bilkent.edu.tr

Özetçe —Dünya Sağlık Örgütü'ne (WHO) göre, her yıl trafik kazalarından kaynaklı yaklaşık 20-50 milyon yaralanma olmaktadır. Yaralanmaların çoğu savunmasız yayalar, bisikletliler ve motosikletliler arasındadır. Otonom araçlar (OA) bu soruna mükemmel bir çözüm gibi görünmektedir. OA'lardaki radar sensörleri, hem hız ve menzili ölçtüğü, hem de kötü hava koşullarında çalışabildiği için etkili bir sensördür. Bu çalışmada ilk olarak, 24GHz FMCW radar sinyallerini simüle ederek 300 spektrogram içeren bir veri seti oluşturulmuştur. Bir 2 boyutlu simülasyon ortamında, orijine tek bir radar yerleştirildi ve bu dikdörtgen alana farklı parametrelerde diğer nesneler (örneğin yükseklik, yön, hız) yerleştirildi. Ardından, spektrogram görüntüleri üzerindeki Mikro-Doppler model özellikleri çıkarıldı ve Uzun Kısa Süreli Bellek Ağları (LSTM'ler) ile eğitildi. Önerilen yaklaşımın etkinliği test edildi, test setinde %95 ortalama doğruluk ve F1 skoru elde edildi, sonuçta diğer bazı yöntemlerden daha iyi performans gösterdi.

Anahtar Kelimeler—Radar Sinyal İşleme, Uzun Kısa Süreli Bellek Ağları, Derin Öğrenme, Otonom Araçlar

Abstract—According to the World Health Organization(WHO), every year around 20-50 million people are injured from road traffic accidents. Most of the injuries are among vulnerable pedestrians, cyclists, and motorcyclists. Autonomous vehicles (AVs) seem to be the perfect solution to this problem. Radar sensors in AVs is an effective sensor since it simultaneously measures speed and range while being robust in bad weather conditions. In this work first, a dataset which contains 300 spectrograms are created by simulating a 24GHz FMCW radar signals. In a 2D simulation environment, a single radar is placed to the origin, and other objects of varying parameters (e.g height, heading, speed) are placed in this rectangular area. Then, the features are extracted from the Micro-Doppler patterns on the spectrogram images and trained on Long Short Term Memory Networks(LSTMs). The average accuracy and F1 score of the proposed method on the test set is 95% which outperforms some existing methods.

Keywords—Radar Signal Processing, Long Short Term Memory Networks(LSTM), Deep Learning, Autonomous Vehicles

I. GİRİŞ

Güvenlik sistemlerindeki özelliklerin artması ve gelişmiş sürüş yardımı ile sensörlerin gereksinimi de artmaktadır. Örneğin karmaşık trafik durumlarında korunmasız olan yol kullanıcılarını tespit etmek ve böylece kazaların önlenmesine yardımcı olmak da sensörlerden beklenen yeni bir ihtiyaçtır. Radar sensörleri bu görev için iyi bir şekilde donatılmıştır. Çünkü radar sensörleri, radyal hız, menzil ve geliş açısı gibi özellikleri ölçebilir. Ayrıca yağış, sis ve toz gibi olumsuz çevre koşullarından fazlaca etkilenmezler. Mevcut radar sensörlerinde artan menzil ve hız çözünürlüğü, hem bir nesnenin toplu hareketini hem de tek bileşenlerinin hareketini ölçebilir. Örneğin hem yayanın hareketini hem de yayanın kol ve bacaklarının hareketini ayrıca ölçebilir. Mikro hareketlerden kaynaklanan bu ilave frekans modülasyonu, mikro-Doppler etkisi olarak da bilinir, bu özellikler [1]'de kapsamlı bir şekilde incelenmiştir. [2]'de 77 GHz radar ile yayalardan doppler spektrumları ölçülmüş ve bu m-D etkilerinin zor senaryolarda da gözlemlenebileceğini göstermiştir.

Yaya sınıflandırmasında genellikle zaman-frekans grafiğinden öznitelik çıkarma yaklaşımı kullanılır, bu sayede belirli bir zaman aralığında Doppler frekansı gözlemlenebilir [3]–[7].

Menzil-Doppler spektrumuna dayanan ve otomotiv senaryolarında yayalar, araçlar ve diğer objeleri ayırmayı hedefleyen başka yaklaşımlar da vardır. [8], [9]'da sınıflandırma için manuel olarak öznitelik seçimi gerekmektedir. [10]'da ise menzil-doppler-açı spektrumunu bir görüntü gibi kullanıp, evrişimli sinir ağları (CNN) ile eğitip yaya, bisikletli ve araba sınıflandırması yapılmıştır.

Bu bildiride öncelikle radar sinyallerinden spektrogram elde edilmesinden bahsedilmiş, sonrasında spektrogram üzerinden öznitelik çıkarımı açıklanmış, kullanılan ve karşılaştırılan sinir ağ modelleri verilmiştir. Son olarak LSTM modelinin nasıl eğitildiği açıklanmış ve karşılaştırma sonuçları verilmiş ve sonuçlar tartışılmıştır.

II. ZAMAN- FREKANS GÖSTERİMİ

Kullanılan simülasyon ortamında tek bir radar, orijine yerleştirilmiş ve diğer objeler (yürüyen insan, araba ve bisikletli)

her seferinde değişen parametre uzayı ile yaratılabilmektedir. Radardan alınan sinyal üzerinde mikro-doppler özelliğini görmek için, zaman-frekans gösterimi yapılmaktadır. Spektrogram bu zaman-frekans gösterimlerinden biridir. N uzunluğunda bir ayrık zamanlı sinyalin $s(n)$ spektrogramı verinin kısa süreli fourier dönüşümü (STFT) ve büyüklüğünün karesi ile alınmaktadır. Bu formül aşağıdaki gibidir:

$$S(n, k) = \left| \sum_{m=0}^{L-1} s(n+m)h(m) \exp(-j2\pi mk/N) \right|^2 \quad (1)$$

burada $n = 1, 2, \dots, N$, zaman endeksi, $k = 1, 2, \dots, K$ ise ayrık frekans endeksidir, L pencere fonksiyonunun uzunluğu ve $h(\cdot)$ ise pencere fonksiyonudur. Bu çalışmada Kaiser pencere fonksiyonu ve parametresi $\beta = 6$ ve $L = 400$ olarak alınmıştır. Spektrogram elde edildikten sonra, logaritmik fonksiyondan geçirilir ve normalizasyon yapılır. Bu normalizasyondan sonra spektrogram görüntüsündeki değerler 0 ile 1 arasına yerleşir.

III. ÖNERİLEN ÖZNİTELİK ÇIKARIMI

Bu çalışmada öncelikle radar ham verisinden spektrogram sinyalleri oluşturulmuştur. Oluşturulan spektrogram sinyalleri üzerinden zaman serisi öznitelikleri çıkarılmıştır. Bunlar sırasıyla 1- Pozitif Frekans Zarfı, 2- Negatif Frekans Zarfı ve 3- Eşik düzleminin üzerinde kalan enerji olarak belirlenmiştir. İlk iki öznitelik daha önce [11] makalesinde önerilmişti. Bu çalışmada yeni bir öznitelik olarak eşik düzleminin üzerinde kalan enerji kullanılacaktır.

IV. POZİTİF VE NEGATİF FREKANS ZARFI


[11]'de pozitif ve negatif frekans zarf özniteliklerinin veri tabanlı öznitelik çıkarma tekniklerinin temel bileşen analizlerine (TBA) göre üstün başarı gösterdiği gösterilmiştir. Pozitif frekans zarfı için öncelikle (2)'deki gibi enerji vektörü çıkartılır. Burada, her bir zaman değerinde eşiği geçen değerler üzerinden en yüksek frekansta olan seçilir, bu değere maksimum anlık frekans değeri de denir. Benzer yöntem negatif frekans zarfında da uygulanır. Şekil 1'de bu yöntemle veri setinde kullandığımız bazı spektrogramlardan bu yöntemle elde edilen pozitif ve negatif frekans zarfları örnekleri gösterilmiştir. Buradaki K değeri ayrık frekans indeksini kabaca (-1700Hz ile 1700Hz) frekansını ifade etmektedir.

$$E_P(n) = \sum_{k=1}^{K/2} S(n, k)^2, \quad (2)$$

$$E_N(n) = \sum_{k=K/2+1}^K S(n, k)^2 \quad (3)$$

V. EŞİK DÜZLEMİNİN ÜZERİNDEKİ ENERJİ

Bu çalışmada, yeni bir öznitelik olarak eşik düzleminin üzerindeki enerji kullanılacaktır. Eşik düzlemi $A(n, k)$ 'nın üzerinde kalan endekslerdeki değerler $T(n, k)$ olarak belirlenmiştir. Burada eşiği geçenler 1 geri kalanlar 0 olarak alınmıştır. Bu şekilde spektrogram bilgileri sıkıştırılarak anlamlı bir veri elde edilmiştir. $A(n, k)$ parametresi 0 ile 1 arasında 0.1'lik



Şekil 1: Pozitif ve Negatif Frekans Zarfları

aralıklarla denenmiş ve spektrogram üzerine m-D etkisinin en iyi gözlemlenebildiği parametre değeri olan 0.70 seçilmiştir.

$$T(n, k) = \begin{cases} 1 & S(n, k) > A(n, k) \\ 0 & \text{değilse} \end{cases}$$


$$E_e(n) = \sum_{k=1}^K T(n, k)^2 \quad (4)$$

Şekil 2'de bu özneliğin ayırtediciliği gösterilmiştir. Araba spektrogramında yüksek frekansta bir sinyal varken, yaya spektrogramında sinüzoidal ve bisikletlide azalan bir desen vardır.

VI. KULLANILAN YAPAY SİNİR AĞI

Tekrarlı Sinir Ağ Modeli (RNN), el yazısı ve konuşma tanıma [12], makine çevriminde [13], dil modellemede [14] ve kinayeli metin tespitinde [15] önemli bir rol oynamaktadır. İlerlemeli sinir ağlarından farklı olarak RNNler geribildirim döngüleri bulundurur ve zamana bağlı serileri işlemeye kullanılır. RNN'in problemi eğitim sırasında türevlerin yok olmasına (vanishing gradient) veya çok yüksek değerlere çıkmasına (exploding gradient) neden olmasıdır [16]. RNN'e benzer yapıda olan Uzun Kısa Vadeli Hafıza Ağı (LSTM) RNNlerin bu problemini ortadan kaldırmak üzere araştırmacılar tarafından önerilmiştir [17]. Bunu yapısında bulunan bellek hücreleri ve kapılar aracılığıyla yapmaktadır. Şekil 3 de kullanılan tekrarlı sinir ağ yapısının diyagramı gösterilmektedir.

Sırasıyla girdi katmanında girdi verisi öğrenilir, LSTM katmanında verideki zamansal bilgi öğrenilir, tam bağlantılı



Şekil 2: Eşik Düzleminin Üzerindeki Enerji



Şekil 3: Önerilen(sol) ve Karşılaştırılan(sağ) Sinir Ağı Yapısı

katmanda öznitelikleri birleştirilir. Softmax katmanıysa tam bağlantılı katmanın çıktılarını normalize eder ve sınıflandırma olasılıklarına çevirir. Sınıflandırma katmanı da en son kararı verir. Herhangi bir zamanda girdiler 3 boyutlu bir vektörden oluşmaktadır. Her bir boyutta kullanılan M uzunluğunda zaman serisi, sırasıyla pozitif frekans zarfı (E_P), negatif frekans zarfı (E_N) eşik düzleminin üzerindeki enerji (E_e) yer alır. Buradaki girdi vektörü x_t (5) deki gibi gösterilebilir.

$$x_t = [X_1 X_2 \dots X_M] = \begin{bmatrix} E_{P1} & E_{P2} & \dots & E_{PM} \\ E_{N1} & E_{N2} & \dots & E_{NM} \\ E_{e1} & E_{e2} & \dots & E_{eM} \end{bmatrix} \quad (5)$$

LSTM hücreleri içerisinde hangi bilgilerin unutulacağı hangilerinin hatırlanacağına karar veren kapılar bulunmaktadır. Bu kapılar sırasıyla girdi kapısı (i_t), çıktı kapısı (o_t), unutma kapısı (f_t) olarak adlandırılır. Girdi kapısı, bellek hücresine giriş aktivasyonunu kontrol ederken, çıktı kapısı bellek hücresinin çıktı aktivasyonunu kontrol eder. Unutma

kapısı bellek hücresinden ne kadar bilginin unutulacağına karar verir. Örnek vermek gerekirse, unutma kapısının çıktısında sigmoid aktivasyonunun çıktısı 0 ile 1 arasında değer alır. 1 bilgiyi tamamen tutmayı, 0 ise tamamen unutmayı temsil eder.

VII. KARŞILAŞTIRILAN YAPAY SİNİR AĞI (CNN-LSTM)

CNN-LSTM sinir ağı orijinal olarak [18] makalesinden ortaya çıkmıştır. Resim üzerinden yazı çıkarma, aktivite tespiti, video tarifi gibi görevlerde kullanılmaktadır. Radar ile hedef sınıflandırması alanındaysa [19]'da spektrogramlar öncelikle her biri 0.25s olacak şekilde zamanda segmentlere bölünmüştür ve sırasıyla zaman dağılımlı evrişimsel katmana, zaman dağılımlı maksimum örnekleme katmanına, zaman dağılımlı düzleştirme katmanına, LSTM katmanına, tam bağlantılı katmana ve sınıflandırma katmanından geçirilerek eğitilmiştir. Bu sinir ağı yapısı da Şekil 3'de gösterilmiştir.

VIII. OLUŞTURULAN VERİSETİ VE YAPAY SİNİR AĞI MODELİ EĞİTİMİ

Oluşturulan verisetinde 300 spektrogram vardır ve her bir sınıftan 100 tane içermektedir. Bu verisetinin %80'i eğitim seti, %10u geçerlilik seti, %10u ise test seti olarak rastgele ayrılmıştır. Yukarıdaki LSTM modelinin eğitiminde kullanılan parametre seti Tablo 1'de gösterilmiştir. Ağırlık İklendirme Tipi olarak Glorot (Xavier) İklendirme kullanılmıştır. Glorot iklendirme farklı katmanlardaki varyansı sabit tutar ve daha çok \tanh aktivasyon fonksiyonu içeren ağlarda kullanılır. Erken durma da regülarizasyonu sağlar ve sonsuza kadar eğitim olmasını engeller. Gradyanlar, Adam iyileyicisi kullanılarak güncellenmiştir [20]. LSTMler ile sınıflandırma problemlerinde çapraz entropi kullanılmaktadır. Bu sayede aşağıda verilen hata fonksiyonunun LSTM eğitimiyle zamanla azalması beklenmektedir. Burada M sınıf sayısı, $y_t \in \{0,1\} \in \mathcal{R}^M$ ve $z_t \in \mathcal{R}^M$ olasılık vektörü olarak ifade edilir. Çapraz entropi sınıflandırma problemlerinde çokça kullanılan bir hata fonksiyonudur. İleriye doğru yayılım ağlarında eğitim hızını ve performansını artırdığı belirtilmiştir [21]. Ayrıca çapraz entropinin ortalama kare hatası (MSE)'na göre daha iyi sonuç verdiği de [22]'da gösterilmiştir. Kullanılan hata fonksiyonu aşağıda gösterilmiştir.

$$L = \sum_{t=1}^M y_t \log(z_t) \quad (6)$$


TABLO I: LSTM Ağına Parametreleri

Parametre	Değer
MiniBatch Büyüklüğü	80
L2 Regularizasyon Parametresi	1e-4
Öğrenme Katsayısı	1e-2
Saklı Katman Sayısı	1
İyileştirici	Adam
Kayıp Fonksiyonu	Çapraz Entropi
Erken Durma (Geçerleme Kaybı)	5 epok

IX. SONUÇLAR VE TARTIŞMA

Bu çalışmada hem MATLAB 2020a hem de Python 3.6 ile Tensorflow tabanlı Keras kütüphanesi kullanılmış, yapay

sinir ağıları bu yolla oluşturulmuştur. Eğitim sırasında NVIDIA TITAN Xp grafik işlemci birimi (GPU) da kullanılmıştır. İlk bölümde bu 3 farklı öznitelikle LSTM üzerinden eğitim yapılmış, test ve geçerleme kayıplarının zamana bağlı değişimi Şekil 5’de verilmiştir. Burada erken durma özelliği gözlemlenebilmektedir. Geçerlilik kaybı azalmamaya başladıktan 5 iterasyon sonra eğitim durdurulmuştur.



Şekil 4: Kayıp vs İterasyon

Bunun dışında yukarıda açıklanan CNN-LSTM sinir ağıyla ve sadece temel olan 2 öznitelik kullanarak (pozitif ve negatif frekans zarfı) LSTM eğitimi ile de sonuçlar elde edilmiş ve elde edilen test doğruluklarındaki standart sapmaların azalması için 5 farklı deney yapılmış ve ortalama alınmıştır. Bu sonuçlar Tablo II’de verilmiştir. Bu sonuçlar incelendiğinde yeni eklenen öznitelik ile tüm değerlendirme kriterlerinde üstün performans gösterdiği görülmektedir. Burada en çok dikkate alınması gereken değerlendirme kriteri F1 skorudur. Bazı modellerde hassasiyet yüksek çıkarken bazı modellerde duyarlılık yüksek çıkmaktadır. F1 skoru tanımı gereği hem hassasiyet hem de duyarlılığı hesaba katmaktadır o yüzden daha anlamlı bir değerlendirme kriteridir.

TABLO II: Önerilen Metotun diğer metotlarla farklı değerlendirme kriterleriyle kıyaslaması

	Test Doğruluğu(%)	Hassasiyet	Duyarlılık	F1 skoru
Yeni Öznitelik vektörüyle LSTM	96	0.95	0.94	0.96
CNN-LSTM	87	0.87	0.86	0.86
Temel Öznitelik vektörüyle LSTM	78	0.75	0.77	0.76

BİLGİLENDİRME

Bu araştırmada yazarlardan Oytun GÜNEŞ’e sağlanan finansal destek için Türkiye Bilimsel ve Teknolojik Araştırma Kurumuna (TUBİTAK) teşekkür ederiz. Bunun yanı sıra bu araştırmada kullanılan Quadro P6000 ekran kartının başışı için NVIDIA Corporation’a da teşekkür ederiz.

KAYNAKLAR

- [1] V. C. Chen, F. Li, S. . Ho, and H. Wechsler, “Micro-doppler effect in radar: phenomenon, model, and simulation study,” *IEEE Transactions on Aerospace and Electronic Systems*, vol. 42, no. 1, pp. 2–21, 2006.
- [2] A. Bartsch, F. Fitzek, and R. Raschhofer, “Pedestrian recognition using automotive radar sensors,” *Advances in Radio Science*, vol. 10, no. B. 2, pp. 45–55, 2012.
- [3] L. Du, L. Li, B. Wang, and J. Xiao, “Micro-doppler feature extraction based on time-frequency spectrogram for ground moving targets classification with low-resolution radar,” *IEEE Sensors Journal*, vol. 16, no. 10, pp. 3756–3763, 2016.
- [4] O. H. Y. Lam, R. Kulke, M. Hagelen, and G. Möllenbeck, “Classification of moving targets using micro-doppler radar,” in *2016 17th International Radar Symposium (IRS)*. IEEE, 2016, pp. 1–6.
- [5] S. Björklund, T. Johansson, and H. Petersson, “Target classification in perimeter protection with a micro-doppler radar,” in *2016 17th International Radar Symposium (IRS)*. IEEE, 2016, pp. 1–5.
- [6] Z. Zhang, R. Zhang, W. Sheng, Y. Han, and X. Ma, “Feature extraction and classification of human motions with lfmcw radar,” in *2016 IEEE International Workshop on Electromagnetics: Applications and Student Innovation Competition (iWEM)*. IEEE, 2016, pp. 1–3.
- [7] C. Clemente, L. Pallotta, A. De Maio, J. J. Soraghan, and A. Farina, “A novel algorithm for radar classification based on doppler characteristics exploiting orthogonal pseudo-zernike polynomials,” *IEEE Transactions on Aerospace and Electronic Systems*, vol. 51, no. 1, pp. 417–430, 2015.
- [8] S. Heuel and H. Rohling, “Two-stage pedestrian classification in automotive radar systems,” in *2011 12th International Radar Symposium (IRS)*. IEEE, 2011, pp. 477–484.
- [9] H. Rohling, “Pedestrian classification in automotive radar systems,” in *2012 13th international radar symposium*. IEEE, 2012, pp. 39–44.
- [10] R. Pérez, F. Schubert, R. Raschhofer, and E. Biebl, “Single-frame vulnerable road users classification with a 77 ghz fmcw radar sensor and a convolutional neural network,” in *2018 19th International Radar Symposium (IRS)*. IEEE, 2018, pp. 1–10.
- [11] Z. Zeng, M. G. Amin, and T. Shan, “Arm motion classification using time-series analysis of the spectrogram frequency envelopes,” *Remote Sensing*, vol. 12, no. 3, pp. 1–7, 2020.
- [12] A. Graves and N. Jaitly, “Towards end-to-end speech recognition with recurrent neural networks,” in *International conference on machine learning*. PMLR, 2014, pp. 1764–1772.
- [13] I. Sutskever, O. Vinyals, and Q. V. Le, “Sequence to sequence learning with neural networks,” *arXiv preprint arXiv:1409.3215*, 2014.
- [14] T. Mikolov, M. Karafiát, L. Burget, J. Černocký, and S. Khudanpur, “Recurrent neural network based language model,” in *Eleventh annual conference of the international speech communication association*, 2010, pp. 1045–1048.
- [15] N. Bölücü and B. Can, “Sarcasm target identification with lstm networks,” in *2020 28th Signal Processing and Communications Applications Conference (SIU)*, 2020, pp. 1–4.
- [16] H. Sak, A. W. Senior, and F. Beaufays, “Long short-term memory recurrent neural network architectures for large scale acoustic modeling,” 2014.
- [17] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [18] J. Donahue, L. Anne Hendricks, S. Guadarrama, M. Rohrbach, S. Venugopalan, K. Saenko, and T. Darrell, “Long-term recurrent convolutional networks for visual recognition and description,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 2625–2634.
- [19] A. Angelov, A. Robertson, R. Murray-Smith, and F. Fioranelli, “Practical classification of different moving targets using automotive radar and deep neural networks,” *IET Radar, Sonar and Navigation*, vol. 12, no. 10, pp. 1082–1089, 2018.
- [20] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–15, 2015.
- [21] G. P. Zhang, “Neural networks for classification: a survey,” *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 30, no. 4, pp. 451–462, 2000.
- [22] P. Golik, P. Doetsch, and H. Ney, “Cross-entropy vs. squared error training: a theoretical and experimental comparison,” in *Interspeech*, vol. 13, 2013, pp. 1756–1760.