



09
ŞUBAT
PAZARTESİ

GÖRÜŞ ÖTESİ
NON LINE OF SIGHT (NLOS)
ARAŞTIRMA VE ANALİZ ÇALIŞTAYI



**Açıklanabilir Yapay Zeka İle Görüş Ötesindeki
Nesne Türlerinin Tahmini**

Mücahit ÇALIŞAN

1. Giriş

2. Amaç

3. Materyal – Yöntem

3.1. Veri Seti ve Etiketleme

3.2. Çok Kanallı Sinyal İndirgeme

3.3. Ön İşleme

3.4. Özellik Çıkarımı: STFT Tabanlı Spektral Özet

3.5. Sınıflandırıcılar ve Çapraz Doğrulama

3.6. Performans Ölçütleri

3.7. Açıklanabilir Yapay Zeka (XAI)


4. Deneysel Sonuçlar

5. Açıklanabilirlik Sonuçları ve Tartışma

6. Sonuç

7. Kaynakça

İçindekiler



Açıklanabilir Yapay Zeka İle Görüş Ötesindeki Nesne Türlerinin Tahmini

1. Giriş

Görünmeyi Görmek: NLOS (Non-Line-of-Sight)
Hedef nesnelerin doğrudan görüş hattı olmaksızın tespit edilmesi problemidir.

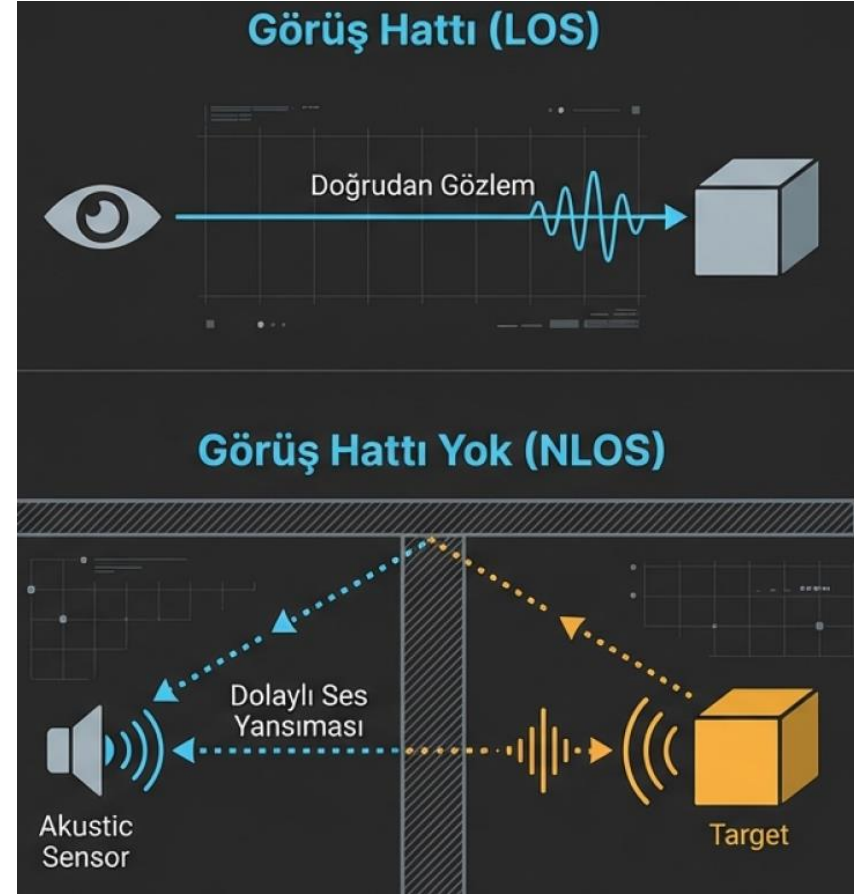
NLOS teknolojisinin temel prensibi (Ses Tabanlı)
Ses sinyalleri ve yansıtıcı yüzeyler aracılığıyla, doğrudan görünmeyen ortamlardaki nesnelere geri dönen akustik yansımalar analiz edilerek nesne türü tespiti gerçekleştirilir.

Uygulama Alanları

- Güvenlik (Tehdit tespiti)
- Arama-Kurtarma (Enkaz altı analizi)
- Endüstriyel izleme
- Robotik
- ...

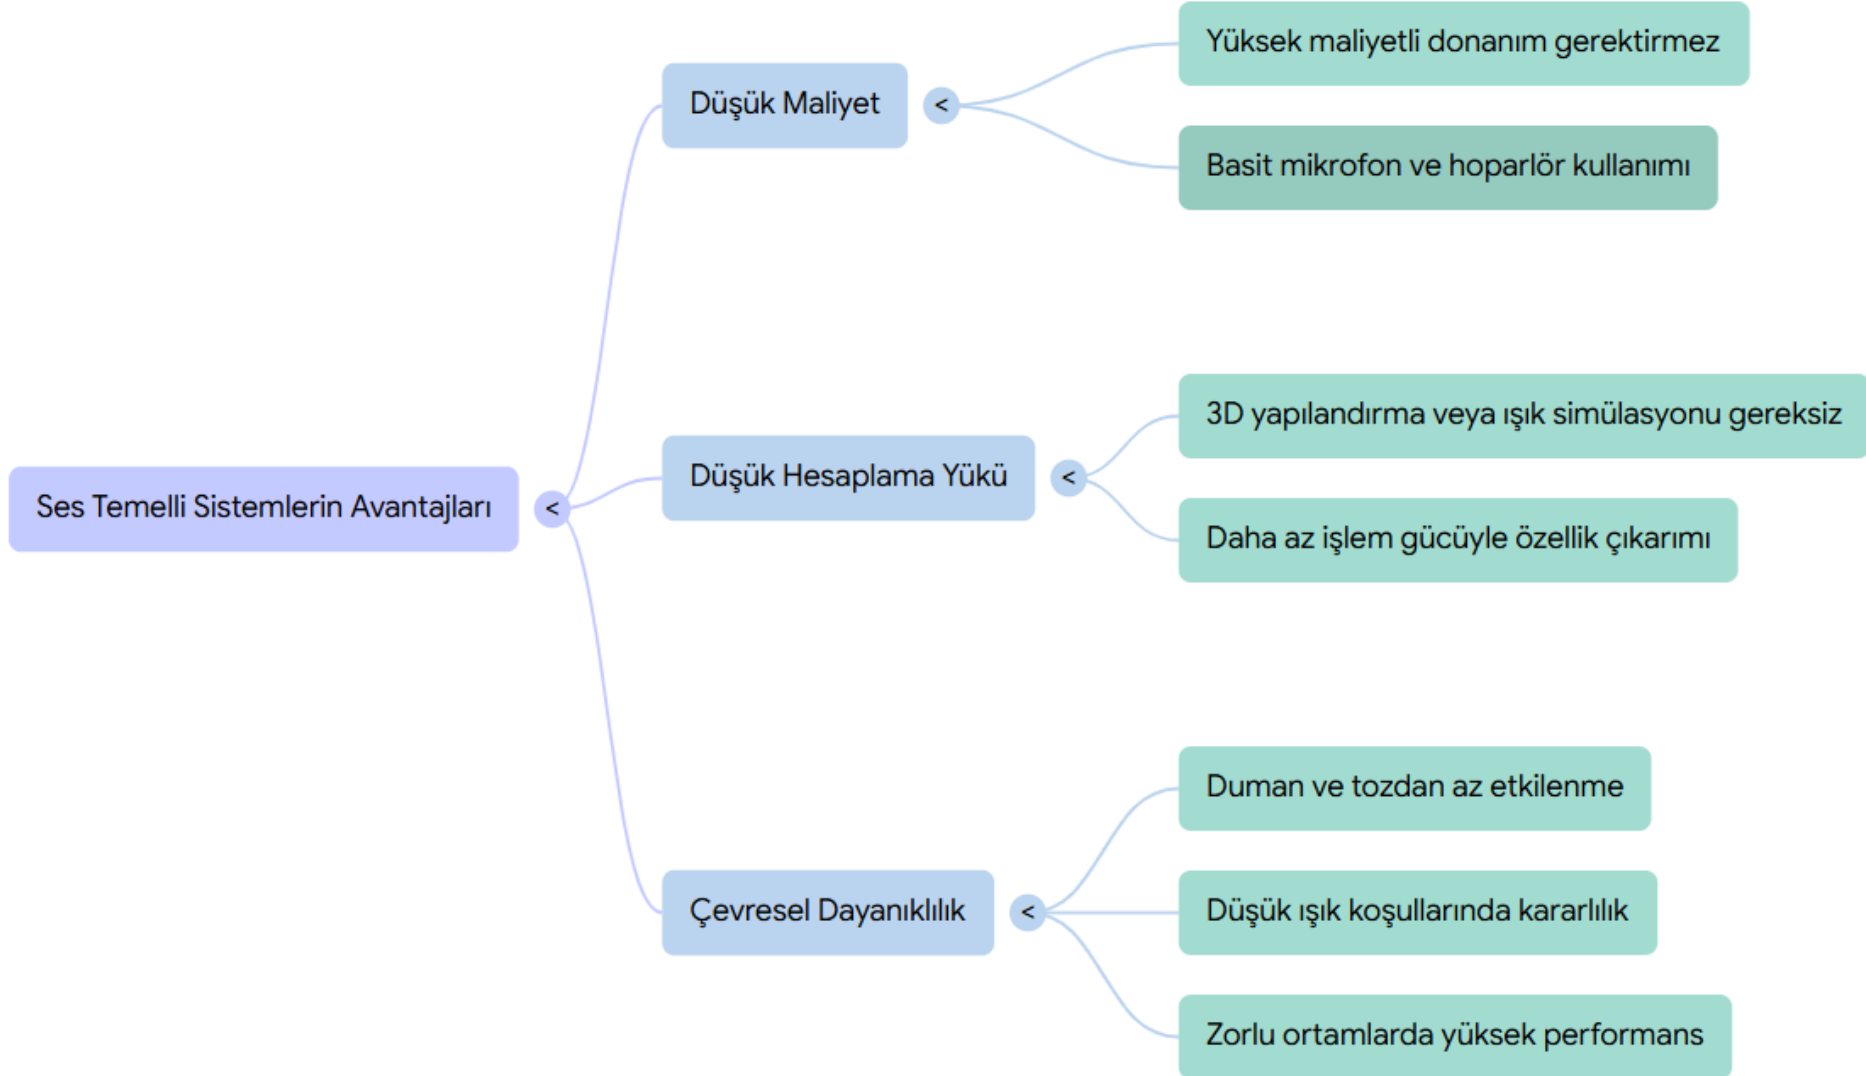
Neden Akustik?

Görsel verinin yetersiz kaldığı durumlarda, ses dalgalarının yüzeylerden yansımaları hedef hakkında ayırt edici ipuçları taşır.

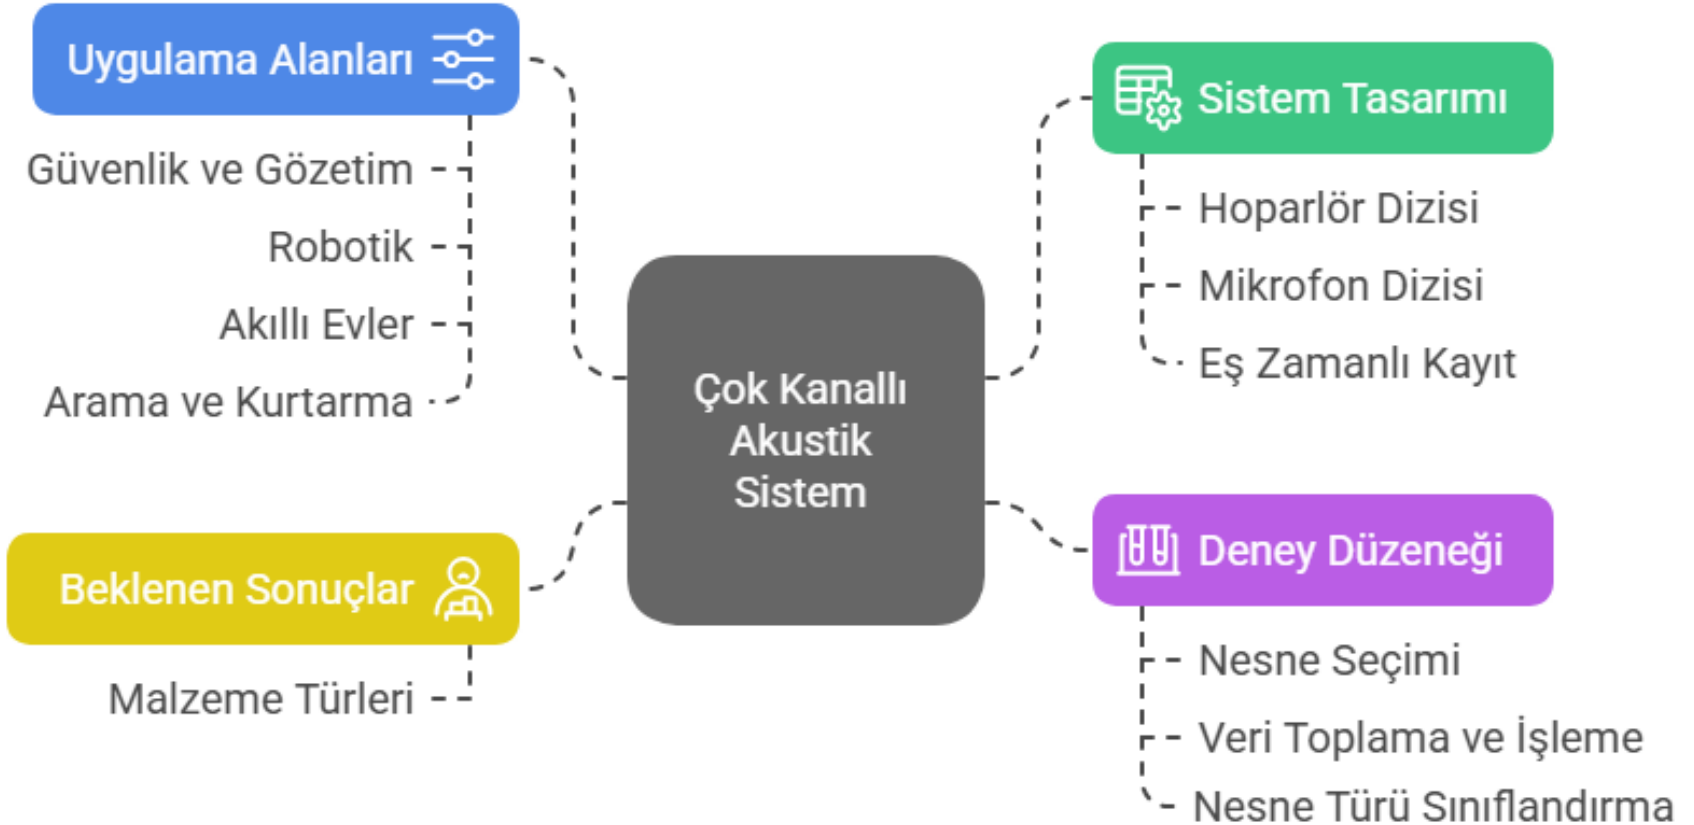


2. Amaç

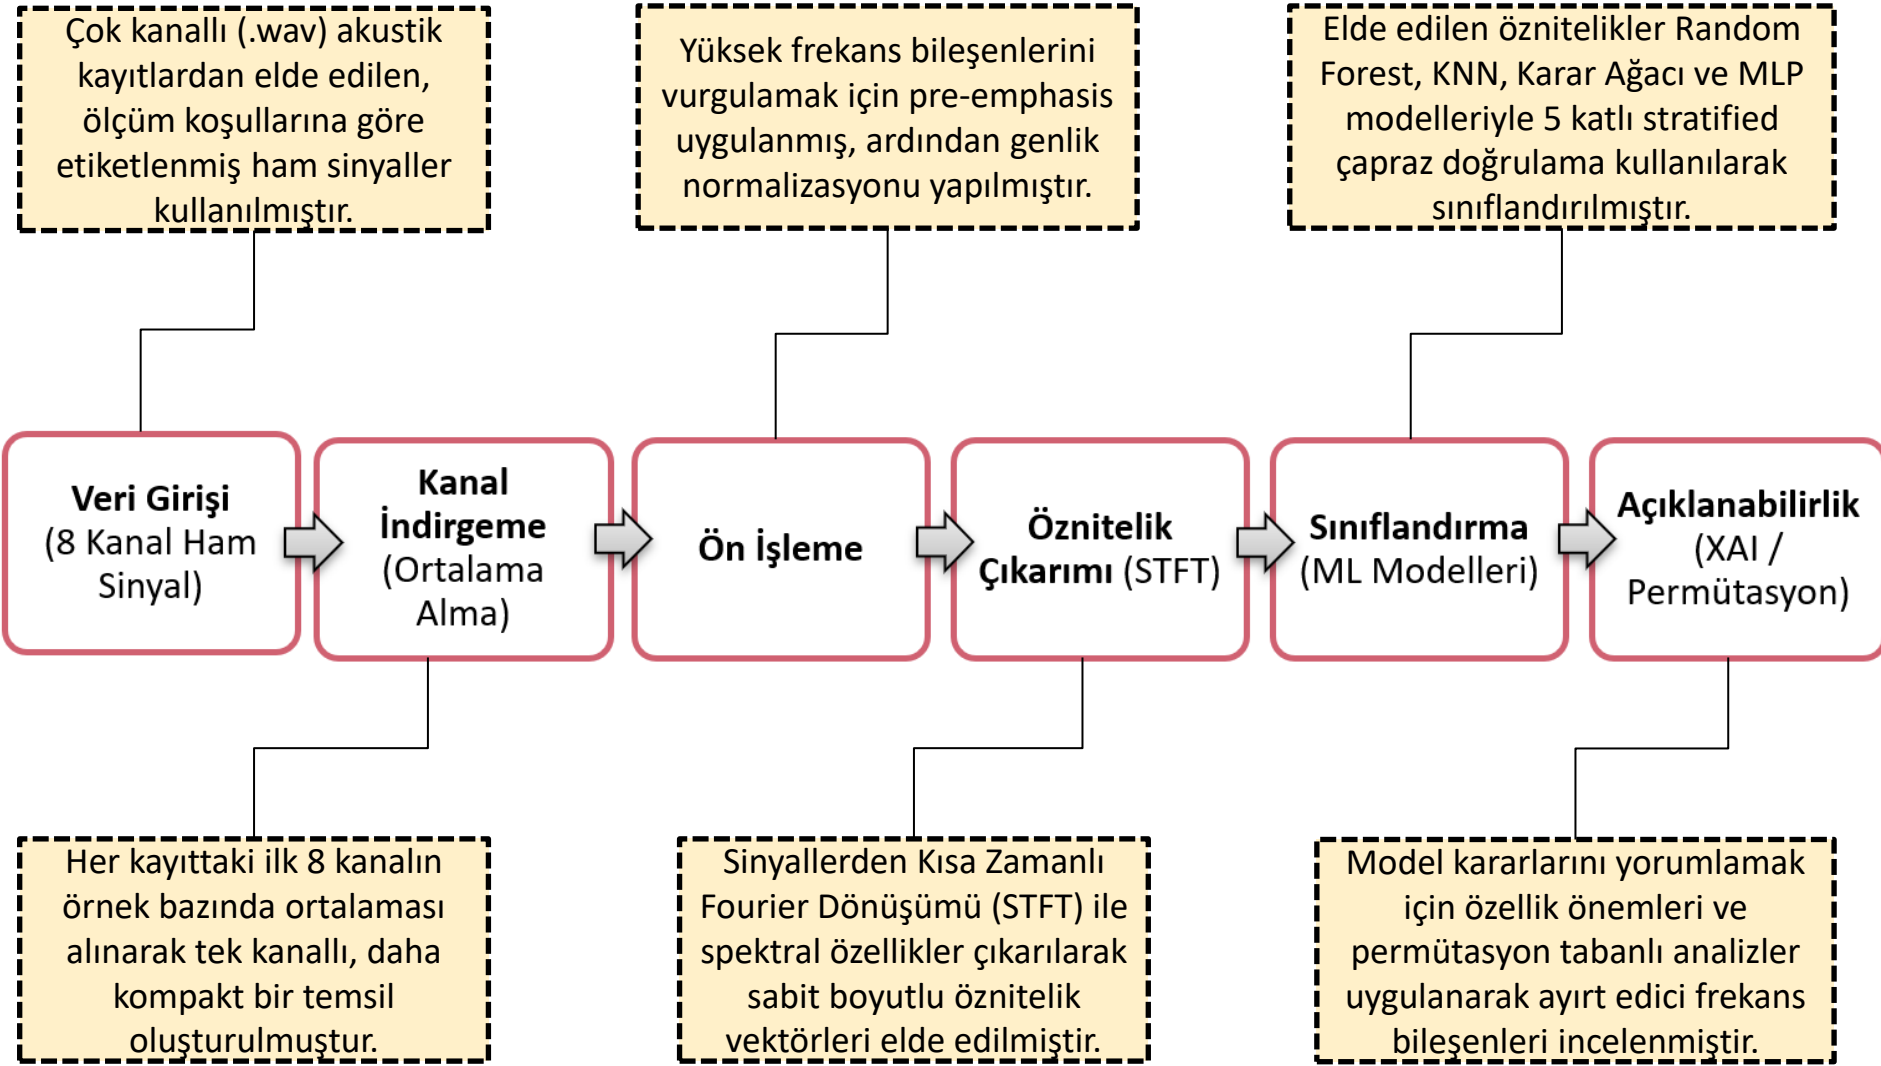
Düşük maliyetli, çok kanallı bir akustik sistem ile NLOS ortamda bulunan nesnelerin türünü yüksek doğrulukla tespit edebildiğini göstermektedir. Akustik sinyallerin görüş ötesi nesne tanıma uygulamalarında etkin biçimde kullanılabileceğini ortaya koymaktadır.



3. Materyal – Yöntem (Genel Çerçeve)



3. Materyal – Yöntem



3. Materyal – Yöntem

Nesne Senaryoları ve kullanılan malzemeler.
Bu senaryolarda ortamda canlı bulunmamaktadır.
Sadece statik nesnelere yer almaktadır. Nesnelere
ortama tekli ve ikili kombinasyonlar şeklinde
bırakılmıştır.



Senaryo 1

Beyaz Eşya & PVC



Senaryo 2

Ahşap & PVC



Senaryo 3

Tuğla & Ahşap



Senaryo 4

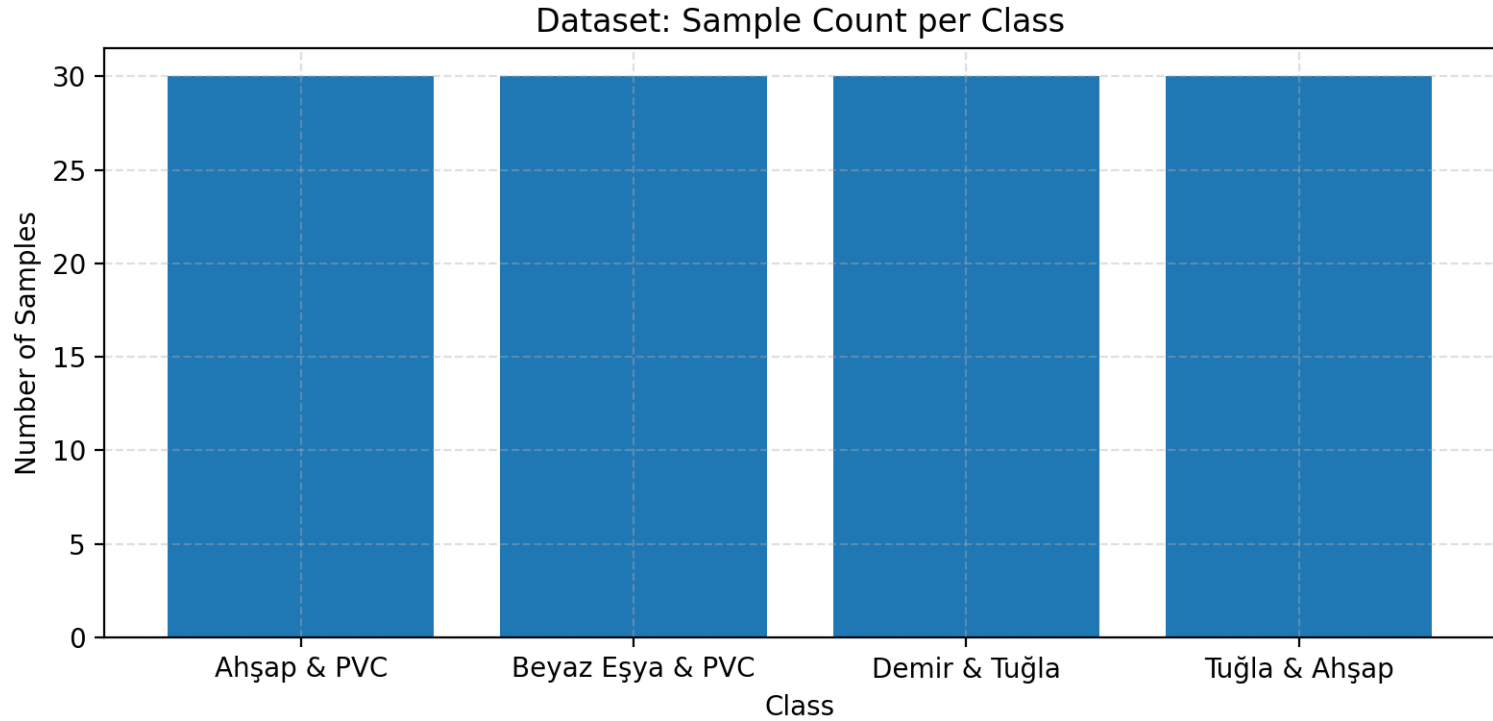
Demir & Tuğla



3. Materyal – Yöntem


Veri Seti

Veri seti .wav formatında çok kanallı akustik kayıtlardan oluşmaktadır. Dosya isimleri belirli bir şemaya sahiptir ve bu şema üzerinden ölçüm koşulları (yansıtıcı yüzey, senaryo, tarama yöntemi vb.) ayrıştırılmaktadır.




3. Materyal – Yöntem

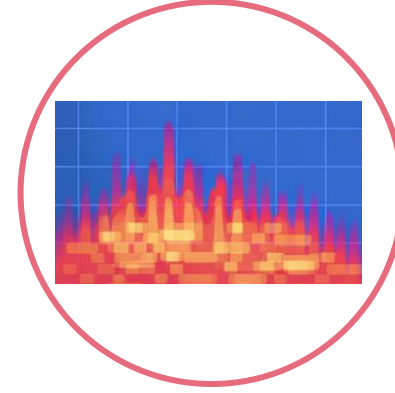
Çok Kanallı Sinyal İndirgeme



Her .wav kaydından ilk 8 kanal kullanılmıştır.



Kanal sayısı 8'in altında olan kayıtlar veri tutarlılığı için dışlanmıştır.




Seçilen kanalların örnek bazında ortalaması alınarak tek kanallı sinyal elde edilmiştir.


Bu yaklaşım, kanallar arası genel enerji ve spektral eğilimleri korurken boyutu azaltarak sınıflandırıcıların eğitimini kolaylaştırır.

Örnek Ses Sinyalleri (Ahşap nesne)


Orjinal Sinyal Enerjisi Zaman Grafiği






Sinyal 1: Tam Sinyal - Sınıf: Ahşap



İkincil Yansıma



Örnek Ses Sinyalleri (Demir nesne)



3. Materyal – Yöntem

Ön İşleme

Sinyalin yüksek frekans bileşenlerini vurgulamak amacıyla pre-emphasis uygulanmıştır.

Ardından sinyal genliği normalize edilerek ölçek farkları giderilmiştir.

Normalizasyon, sinyalin maksimum mutlak genlik değerine bölünmesi ile gerçekleştirilmiştir.

Bu aşamadaki amacımız;

- Spektral detayları belirginleştirmek.
- Özellik çıkarımı ve sınıflandırma için daha dengeli bir sinyal temsili elde etmektir.


3. Materyal – Yöntem

Özellik Çıkarımı

Özellik çıkarımı için Kısa Zamanlı Fourier Dönüşümü (STFT) kullanılmıştır. Her sinyal, sabit pencere ve kayma parametreleriyle zaman–frekans uzayına taşınmıştır.

Adım1 - STFT Uygulama
Sinyal zaman–frekans uzayına taşınır

Adım3 - Log-Spektral Ölçek
 $S(f, t) = \log(1 + |X(f, t)|)$




Adım2 – Parametreler
Pencere uzunluğu: $n_fft = 1024$
Kayma miktarı: $hop_length = 256$

Adım4 - Zamansal Özet
Sabit boyutlu özellik vektörü
 $\phi(f) = \frac{1}{T} \sum_{t=1}^T S(f, t)$

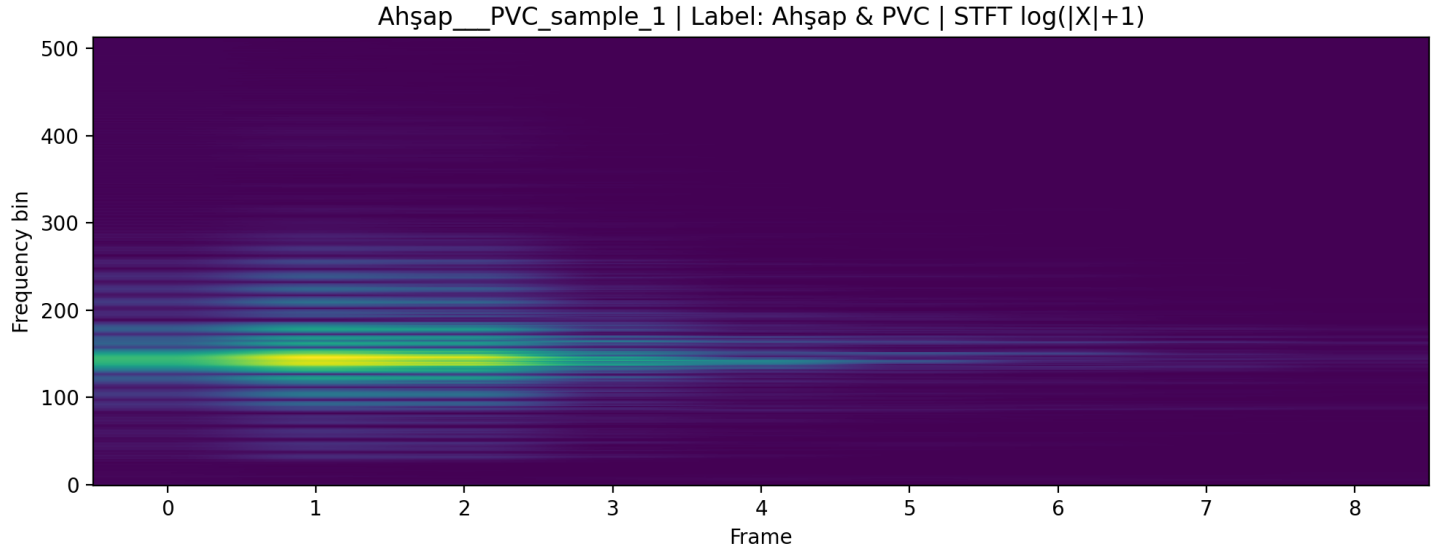
3. Materyal – Yöntem

Özellik Çıkarımı

Ön işlenmiş
sinyal (STFT
girdisi)



Log-ölçekli
STFT çıktısı



3. Materyal – Yöntem

Sınıflandırıcılar ve Çapraz Doğrulama

STFT tabanlı özellikler, dört farklı sınıflandırıcı ile 5 katlı stratified çapraz doğrulama kullanılarak eğitilmiş ve karşılaştırılmıştır.

1

Random Forest

Birden fazla karar ağacının birleşimiyle çalışan bu model, karmaşık ve doğrusal olmayan örüntüleri başarıyla yakalayabilmektedir.

2

k-En Yakın Komşu (kNN)

Örnekler arası uzaklığa dayalı çalışan kNN, benzer sinyal örneklerinin aynı sınıfa atanmasını sağlar.

3


Karar Ağacı (Decision Tree)

Öznitelik uzayını ardışık karar kurallarıyla bölen bu model, sınıflandırma sürecini açık ve yorumlanabilir hale getirir.

4

Çok Katmanlı Algılayıcı (MLP)

Gizli katmanlı yapısı sayesinde karmaşık örüntüleri öğrenebilen MLP, doğrusal olmayan sınırlarda yüksek performans sunar.



3. Materyal – Yöntem

Performans Ölçütleri

Her model için performans 5 katlı stratified çapraz doğrulama sonucunda aşağıdaki ölçütler üzerinden değerlendirilmiştir:

- Doğruluk (Accuracy)
- Precision
- Recall
- F1 Skoru

Makro ortalama kullanımı ile tüm sınıfların performansa eşit katkı sağlaması hedeflenmiştir.

3. Materyal – Yöntem

Açıklanabilir Yapay Zeka (XAI)

Model kararlarının yorumlanabilmesi amacıyla iki tamamlayıcı açıklanabilirlik yaklaşımı kullanılmıştır.



Ağaç Tabanlı Özellik Önemi

Random Forest ve Karar Ağacı için yerleşik feature_importances_ kullanılarak frekans bazlı önem grafikleri üretilmiştir.

Amaç: Modelin karar verirken hangi frekans bileşenlerine daha fazla ağırlık verdiğini ortaya koymak.



Permütasyon Önem Analizi

Modelden bağımsız olarak test seti üzerinde özelliklerin rastgele permütasyonu sonrası F1 skorundaki düşüş ölçülmüştür. Bu yöntem tüm modeller için ortak bir açıklanabilirlik sunar.


Amaç: Özelliklerin model performansına gerçek katkısını değerlendirmek.

Çalışmada, her fold'da en çok karıştırılan sınıf çifti tespit edilmiş ve bu iki sınıfın ayrımında öne çıkan frekans özellikleri “pair-diff” grafikleri ile raporlanmıştır.

4. Deneysel Sonuçlar

Modellerin 5 katlı çapraz doğrulama sonucunda elde edilen ortalama performans değerleri şekilde sunulmuştur.

Classifier Performance Comparison (5-fold mean)



4. Deneysel Sonular

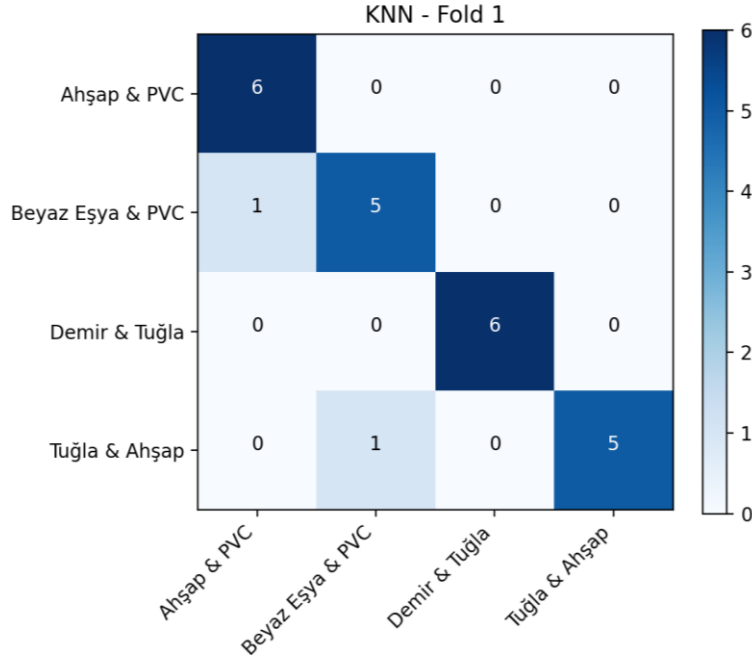
Modellerin 5 katlı apraz doėrulama sonucunda elde edilen ortalama performans deėerleri Őekilde sunulmuŐtur.

Model	Accuracy	Precision	Recall	F1
Random Forest	1.00	1.00	1.00	1.00
kNN (k=5)	0.858	0.869	0.858	0.853
Decision Tree	0.958	0.969	0.958	0.959
MLP	1.00	1.00	1.00	1.00

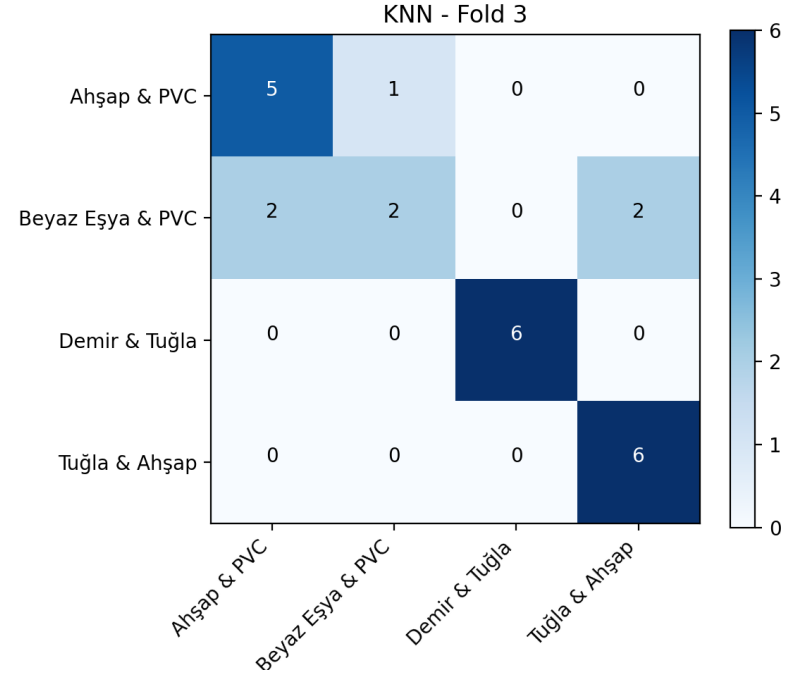
Random Forest ve MLP modelleri, tm ltlerde mkemmel performans gstererek alıŐmada en baŐarılı sınıflandırıcılar olmuŐtur.

4. Deneysel Sonuçlar

Hata analizi kapsamında, çalışmada kullanılan tüm sınıflandırıcıların her fold'da ait karmaşıklık matrisleri incelenmiştir. Bu analiz ile modelin hangi sınıflar arasında daha fazla karışıklık yaşadığını ortaya koymayı amaçlanmaktadır.



Beyaz Eşya & PVC → Ahşap & PVC
1 örnek hatalı sınıflandırma gözlenmiştir.



Beyaz Eşya & PVC → Ahşap & PVC ve
Beyaz Eşya & PVC → Tuğla & Ahşap
2'şer örnek hatalı sınıflandırma gözlenmiştir.

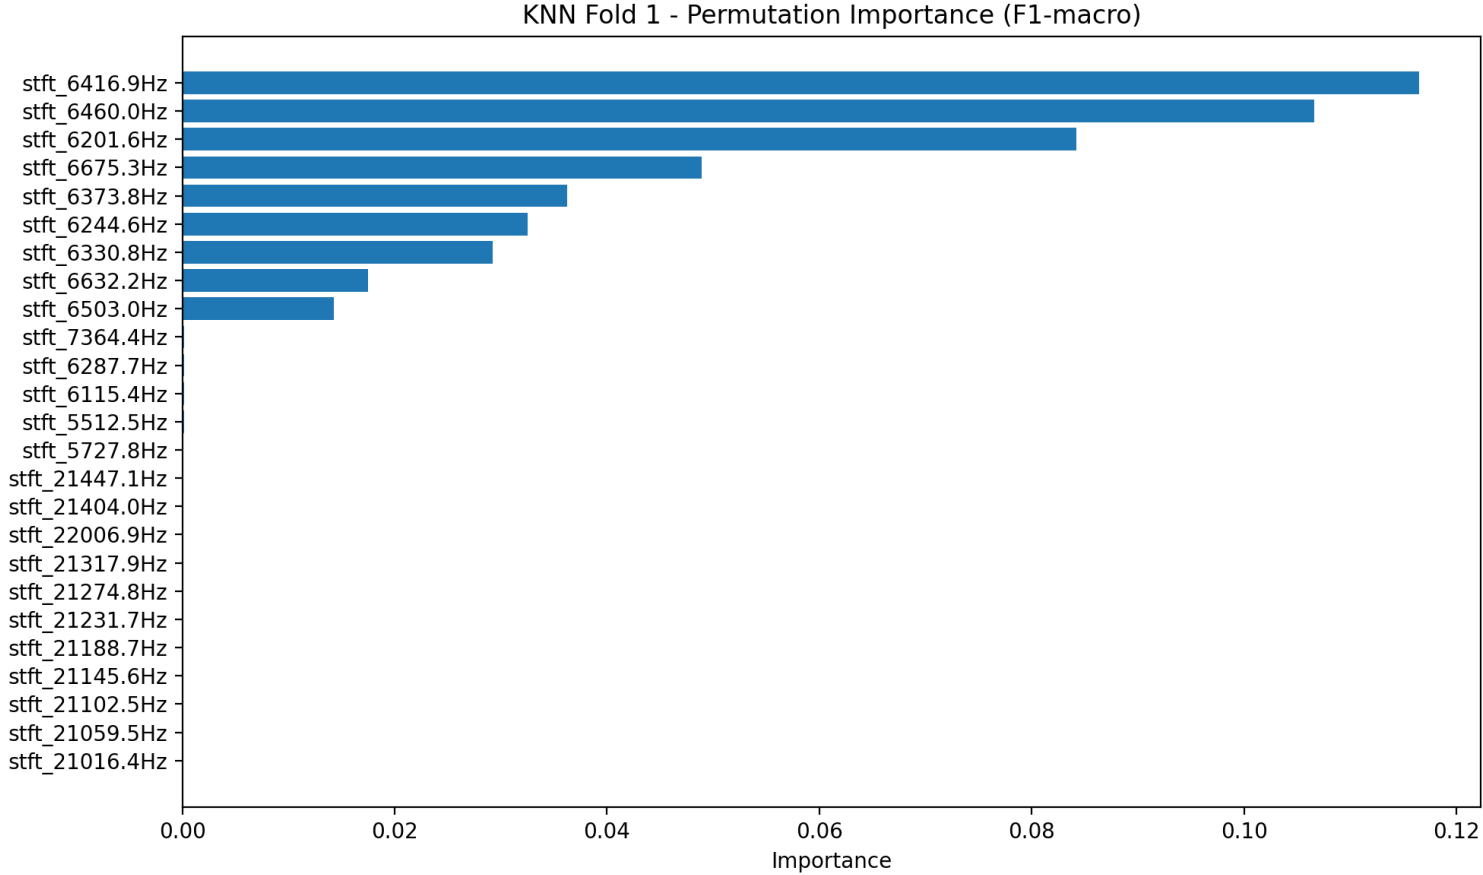
5. Açıklanabilirlik Sonuçları ve Tartışma

Permütasyon önem analizi ve ağaç tabanlı önem skorları, sınıflandırma kararlarının belirli frekans bantlarında yoğunlaştığını göstermektedir. STFT özniteliklerinin Hz cinsinden etiketlenmesi, modelin hangi frekans bölgelerinden ayırt edici bilgi çektiğinin doğrudan gözlemlenebilmesine olanak sağlamıştır.

Elde edilen bulgular, NLOS yansımaların, nesne–yüzey etkileşiminden kaynaklanan malzemeye özgü spektral izler taşıdığını göstermektedir.

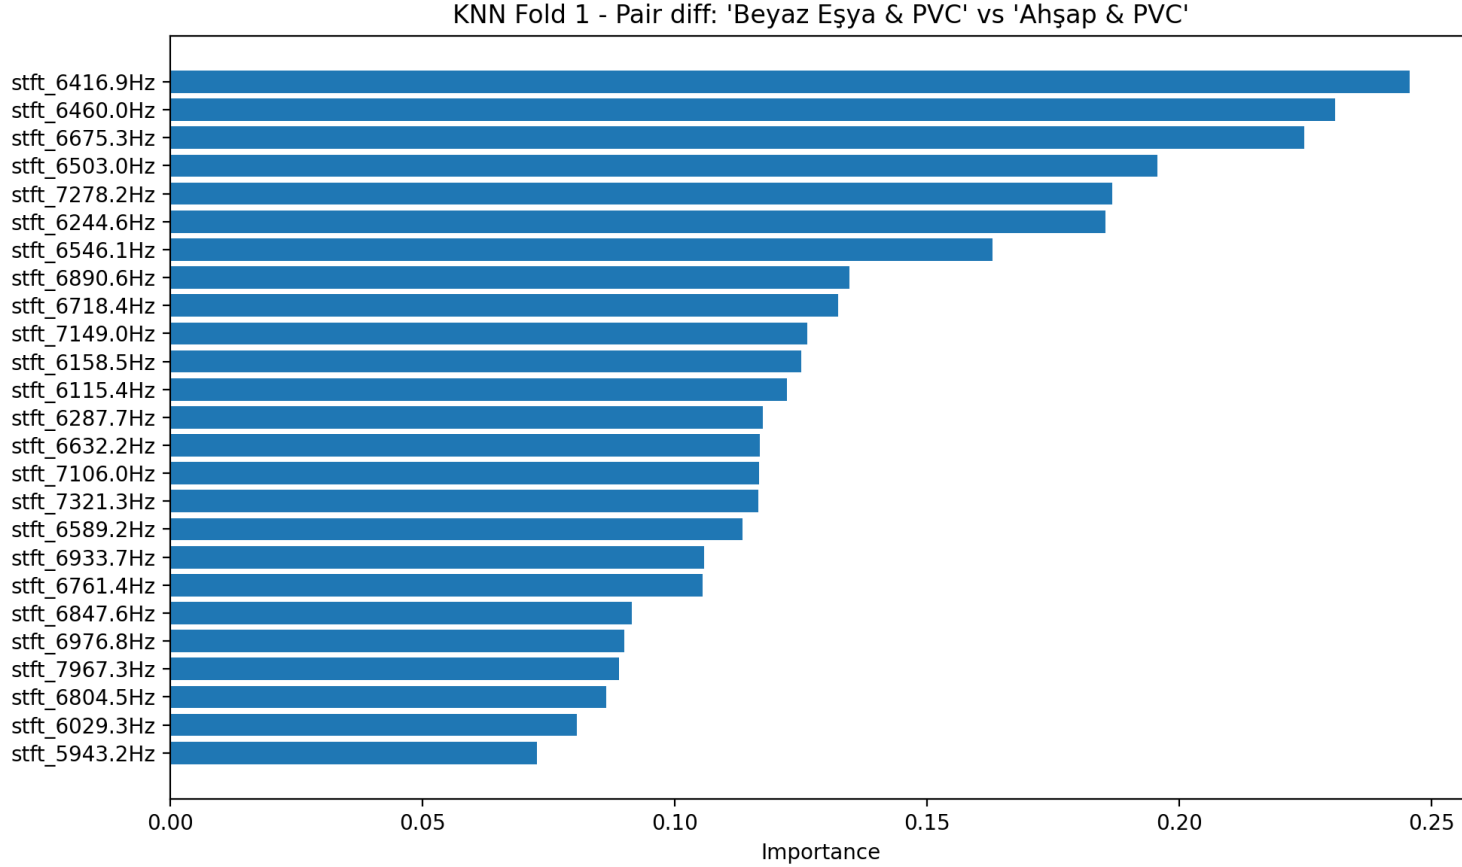
En çok karışan sınıf çiftlerine ait pair-diff analizleri, sınıflar arasındaki karışmanın çoğunlukla benzer malzeme türleri ve benzer yansıma karakteristikleri gibi fiziksel nedenlerden kaynaklandığına işaret etmektedir.

5. Açıklanabilirlik Sonuçları ve Tartışma



- F1-macro grafiği bize şunu veriyor: Eğer bu frekans özelliğini bozarsam (karıştırırsam) modelin başarısı ne kadar düşüyor?
- Grafikte uzun bar'lar çok önemli frekansları verir.
- Bu model karar verirken özellikle 6–7 kHz bandına çok güvenmektedir.

5. Açıklanabilirlik Sonuçları ve Tartışma



- Bu grafik iki sınıfın neden karıştığını anlamamızı sağlar.
- Pair-diff sadece iki sınıfı alıyor ve her frekans için ortalama spektral farkı hesaplıyor.
- Böylece bu iki sınıfı ayıran frekanslar hangileridir bulunabilir.

6. Sonuç

1. Çok kanallı akustik ölçümlerden elde edilen STFT tabanlı özet spektral özellikler kullanılarak, NLOS koşullarda farklı nesne senaryolarının sınıflandırılması gerçekleştirilmiştir.
2. Değerlendirme 5 katlı çapraz doğrulama yaklaşımıyla yapılmış ve bu sayede tüm sınıflar için dengeli bir performans analizi sağlanmıştır.
3. Bulgular STFT tabanlı frekans özetlerinin, NLOS ortamda nesne–yüzey etkileşimlerinden kaynaklanan ayırt edici bilgiyi etkili biçimde temsil edebildiğini göstermektedir.
4. Gerçekleştirilen açıklanabilirlik (XAI) analizleri, model kararlarının özellikle belirli orta–yüksek frekans bantlarında (yaklaşık 6–7 kHz) yoğunlaştığını ortaya koymuştur.
5. Hata analizi ve pair-diff incelemeleri, sınıflar arası karışmanın çoğunlukla benzer malzeme türleri ve benzer yansıma karakteristikleri nedeniyle, belirli spektral bölgelerde oluştuğunu göstermiştir.

STFT tabanlı özellikler ve XAI destekli analizler, NLOS koşullarda nesne sınıflandırmasının hem yüksek doğrulukla hem de fiziksel olarak yorumlanabilir biçimde yapılabileceğini göstermiştir.

6. Kaynaklar

- [1] Lindell, D. B., Wetzstein, G., & Koltun, V. (2019). Acoustic non-line-of-sight imaging. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 6780-6789).
- [2] Boger-Lombard, J., Slobodkin, Y., & Katz, O. (2023). Towards passive non-line-of-sight acoustic localization around corners using uncontrolled random noise sources. *Scientific Reports*, 13(1), 4952.
- [3] Velten, A., Willwacher, T., Gupta, O., Veeraraghavan, A., Bawendi, M. G., & Raskar, R. (2012). Recovering three-dimensional shape around a corner using ultrafast time-of-flight imaging. *Nature communications*, 3(1), 745.
- [4] O’Toole, M., Lindell, D. B., & Wetzstein, G. (2018). Confocal non-line-of-sight imaging based on the light-cone transform. *Nature*, 555(7696), 338-341.
- [5] Olgun, N., & Çalişan, M. (2024, September). Location Detection of an Object Non Line of Sight with Audio Signal. In *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-4). IEEE.
- [6] Zhu, D., & Cai, W. (2022). Fast non-line-of-sight imaging with two-step deep remapping. *ACS Photonics*, 9(6), 2046-2055.
- [7] Shen, S., Wang, Z., Liu, P., Pan, Z., Li, R., Gao, T., ... & Yu, J. (2021). Non-line-of-sight imaging via neural transient fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(7), 2257-2268.
- [8] Bianco, M. J., Gerstoft, P., Traer, J., Ozanich, E., Roch, M. A., Gannot, S., & Deledalle, C. A. (2019). Machine learning in acoustics: Theory and applications. *The Journal of the Acoustical Society of America*, 146(5), 3590-3628.
- [9] Shin, U. H., Jang, S., & Kim, K. (2023, August). Acoustic NLOS Imaging with Cross Modal Knowledge Distillation. In *IJCAI* (pp. 1405-1413).
- [10] Schulz, Y., Mattar, A. K., Hehn, T. M., & Kooij, J. F. (2021). Hearing what you cannot see: Acoustic vehicle detection around corners. *IEEE Robotics and Automation Letters*, 6(2), 2587-2594.
- [11] Heide, F., O’Toole, M., Zang, K., Lindell, D. B., Diamond, S., & Wetzstein, G. (2019). Non-line-of-sight imaging with partial occluders and surface normals. *ACM Transactions on Graphics (ToG)*, 38(3), 1-10.
- [12] J. Boger-Lombard and O. Katz, “Passive acoustic Non-Line-of-Sight localization around corners,” *Scientific Reports*, vol. 13, 2023.
- [13] Boger-Lombard, J., Slobodkin, Y., & Katz, O. (2023). Towards passive non-line-of-sight acoustic localization around corners using uncontrolled random noise sources. *Scientific Reports*, 13(1), 4952.
- [14] Naser, F., et al. (2019). Infrastructure-free NLoS Obstacle Detection for Autonomous Cars. *IEEE International Conference on Intelligent Robots and Systems (IROS)*, 250–257.
- [15] Ayotte, S., et al. (2011). Semiconductor Laser White Noise Suppression by Optical Filtering.
- [16] Jain, R., Kumar, S., & Singh, M. (2021). Echo Feature Based Object Detection Using Deep Convolutional Neural Networks in NLOS Environment. *Sensors*, 21(11), 3728. <https://doi.org/10.3390/s21113728>
- [17] Yue, L., Wang, Z., Li, X., & Guo, X. (2021). Deep Learning Based Detection of Hidden Targets in Low Signal-to-Noise Acoustic Environments. *Applied Acoustics*, 180, 108110. <https://doi.org/10.1016/j.apacoust.2021.108110>
- [18] Jung, Y. (2018). Multiple predicting K-fold cross-validation for model selection. *Journal of Nonparametric Statistics*, 30(1), 197–215. <https://doi.org/10.1080/10485252.2017.1414095>



Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 123E386 numaralı Tübitak-1001 projesi kapsamında desteklenmiştir.