

Derin Öğrenme ile FTIR Sinyallerinden Kolon Kanseri Riskinin Belirlenmesi

Suat TORAMAN¹, İbrahim TÜRKOĞLU²

¹Fırat Üniversitesi, Enformatik Bölümü, Elazığ, 23119

²Fırat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği, Elazığ, 23119
storaman@firat.edu.tr

(Geliş/Received: 23.03.2018; Kabul/Accepted: 03.09.2018)

Özet

Bu çalışmada, kolon kanseri hastaları ve sağlıklı kişiler, FTIR (Fourier Transform Infrared - Fourier Dönüşümü Kızılötesi) spektrogramlarından elde edilen özellikler yardımıyla sınıflandırılmıştır. Spektrogram resimlerinden özellik çıkarımı için derin öğrenme ağlarından Evrişimsel Sinir Ağları (ESA) kullanılmıştır. Kandan kanser belirleme çalışmalarında karşılaşılan en büyük zorluk hasta ve sağlıklı bireylerin FTIR sinyallerinin birbirine çok benzer olmasıdır. Önceki çalışmalarda, genellikle FTIR sinyalleri arasından bir ayırım bulabilmek için pik değerlerinden yararlanılmıştır. Bu çalışmada ise, bu zorluğun üstesinden gelmek için ESA'nın kullanıldığı yeni bir yaklaşım önerilmiştir. Önerilen yöntemde, kolon kanseri hastası ve sağlıklı kişilere ait plazmalardan elde edilen FTIR sinyalleri spektrogram resimlerine dönüştürülmüştür. AlexNet modeli kullanılarak spektrogram resimlerinden özellik çıkarımı gerçekleştirilmiştir. Elde edilen özellikler Destek Vektör Makinesi (DVM) ile sınıflandırılmıştır. Kan numunesinden kolon kanserinin sınıflandırılmasına yönelik olarak yapılan çalışmalar ile karşılaştırıldığında, önerilen yöntem ile yaklaşık %90 gibi daha iyi bir sınıflandırma sonucu elde edilmiştir. Sonuçlar, geliştirilen yöntemin kolon kanseri hastaları ve sağlıklı kişileri ayırt edebilmede kullanılabilecek faydalı bir yöntem olabileceğini göstermiştir.

Anahtar Kelimeler: FTIR, Spektrogram, Kolon Kanseri, Evrişimsel Sinir Ağları

Determination of Colon Cancer Risk from FTIR Signals by Deep Learning

Abstract

In this study, colon cancer patients and healthy persons were classified with the help of features obtained from FTIR spectrograms. Convolution Neural Networks (CNN) which one of the deep learning networks have been used in feature extraction of spectrogram images. The greatest challenge in cancer detection studies is that the FTIR signals of patients and healthy individuals are similar. In previous studies, peak values were generally used to distinguish FTIR signals. In this study, a new approach using the CNN has been proposed to overcome this difficulty. In the proposed method, FTIR signals obtained from plasma of colon cancer patients and healthy persons are converted into spectrogram images. Feature extraction from spectrogram images was performed using AlexNet model. The features obtained are classified by Support Vector Machine (SVM). Compared with studies on the classification of colon cancer from blood samples, a better classification result of about 90% was obtained with the proposed method. The results showed that the proposed method could be a useful method to distinguish colon cancer patients and healthy persons.

Keywords: FTIR, Spectrogram, Colon Cancer, Convolution Neural Networks

1. Giriş

Türkiye’de kanser, ölüm nedenleri arasında ilk sıralarda yer almaktadır. Türkiye İstatistik Kurumu ölüm nedenleri 2017 verilerine göre Türkiye’de kadın ve erkeklerde görülen kanser türleri arasında kolorektal kanser türü dördüncü sırada yer almaktadır [1]. Kolon kanserinin belirlenmesine kolonoskopi, biyopsi, MR

(Manyetik Rezonans) vb. geleneksel yöntemler kullanılmaktadır. Bu yöntemlerden kolonoskopi ve biyopsi doğası gereği invazivdir. MR da ise hastalar belirli miktarda radyasyona maruz kalmaktadır [2, 3]. Bu nedenle, daha basit ve daha az invaziv yöntemlere ihtiyaç vardır. FTIR spektroskopisi, kanser belirleme çalışmalarında kullanılan yöntemlerden biridir. Örneğin, prostat

kanseri [4], mide kanseri [5] yemek borusu kanseri [6], meme kanseri [7], kolon kanseri [8–10] vb kanser türlerinde kullanılmaktadır. Ayrıca kan numuneleri ile de çeşitli hastalıkların ve kanser türlerinin belirlenmesinde FTIR işaretlerinin kullanıldığı çalışmalar

bulunmaktadır. Örneğin, lösemi [11, 12], Parkinson [13], mide kanseri [14], meme, mide, akciğer kanseri [3], akciğer kanseri [15] ve kolon kanseri [16, 17] vb. çalışmalar bulunmaktadır. Bu çalışmalar ile ilgili detaylı bilgi Tablo 1’de verilmiştir.

Tablo 1. Kan numunelerinden diğer kanser türleri üzerine yapılan çalışmalar

Yazarlar	Hastalık türü (hasta/normal sayısı)	Yöntemler	Sonuçlar
Erukhimovitch ve ark. [12] (2006)	Lösemi (10, 10)	Kümeleme Analizi	1056, 1270 ve 1592 cm ⁻¹ spektral piklerde belirgin azalma gözlemlendi.
Ahmed ve ark. [13] (2010)	Parkinson (61, 69)	Kümeleme Analizi, Pearson Korelasyon ve Ortalama Bağlantı Algoritması, YSA	Duyarlılık: %91.00 Özgüllük: %100.00 Doğruluk: %96.29
Ostrovsky ve ark. [3](2013)	Meme, Akciğer Mide, diğer (45, 41)	Temel Bileşen Analizi, Fisher Doğrusal Diskriminant Analizi	Duyarlılık: %93.33 Özgüllük: %87.80 Doğruluk: %90.70
Sheng et al. [11] (2013)	Lösemi (24, 19)	Eğri Uydurma	H2959 / H2931 ve RNA/DNA (A1115/A1028) oranları ayırt edici özellik olarak tanımlandı
Sheng ve ark. [14] (2013)	Mide kanseri (27, 19)	Eğri Uydurma	H2959 / H2931 oranı ayırt edici özellik olarak tanımlandı
Wang ve ark. [15] (2014)	Akciğer Kanseri (24, 22)	Eğri Uydurma	A1080 / A1170 oranı ayırt edici özellik olarak tanımlandı


Literatürde kan numunelerinden kanser belirleme çalışmalarında genellikle FTIR sinyallerin pik değerleri karşılaştırılarak bir kanserli/normal ayırımı yapılmaya çalışılmıştır. Ayrıca yapılan çalışmalarda kan numunelerinin kurutulması sonucu pik değerleri gözlemlenmekte ve bu değerler üstünden karşılaştırma yapılmaktadır. Bu çalışmada ise, plazma numuneleri sıvı olarak ölçülmüştür. Böylece mevcut çalışma ile sıvı plazma FTIR sinyalinden kolon kanseri ve sağlıklı kişiler arasında bir ayırım yapılabilir mi sorusuna cevap aranmıştır.

Önceki çalışmalar incelendiğinde genellikle temel bileşen analizi (TBA), kümeleme analizi, doğrusal ayırım analizi (LDA), eğri uydurma gibi yöntemlerinden faydalanılarak pik değerleri arasında bir ayırımın olup olmadığı incelenmiştir [3, 13, 14]. Mevcut çalışmada ise, FTIR sinyalindeki belirli pik değerleri yerine sinyalin tamamı kullanılarak bir ayırım gerçekleştirilmiştir. Bu amaç için büyük ölçekli görüntü tanıma uygulamalarında yüksek doğruluğa sahip ESA’lar kullanılmıştır. ESA’ların milyonlarca resim ile eğitilmiş çeşitli mimarileri bulunmaktadır. Bu

mimarilerden biri de 2012 yılında yapılan ImageNet yarışmasını kazanan AlexNet’tir. AlexNet 1000 farklı sınıflandırma yapacak şekilde tasarlanmıştır. Fakat belirli bir göreve yönelik olarak bir ESA’yı eğitmek için oldukça büyük miktarda veriye ve bu veriyi işlemek için oldukça fazla zaman ve donanımsal özelliklere ihtiyaç vardır. Eğer büyük miktarda eğitim verisi yoksa bu durumda transfer öğrenme yaklaşımı kullanılabilir. Transfer öğrenme, belirli bir alana yönelik veriler ile eğitilmiş ESA’lar kullanılarak farklı bir alandaki veri kümesinden öznelik vektörü oluşturma yöntemidir [18]. Bu çalışmada içinde önceden eğitilmiş ESA modellerinden olan AlexNet mimarisi kullanılarak, FTIR spektrogramlarının sınıflandırıldığı ESA tabanlı bir yöntem önerilmiştir. Bu amaçla FTIR sinyalleri spektrogram görüntülerine dönüştürülmüştür. Daha sonra ESA’nın son katmanlarından özellik çıkarımı gerçekleştirilmiştir. AlexNet’in üst katmanlarının aktivasyonlarından elde edilen özelliklerin görüntü tanıma, sınıflama gibi görevleri için yeterli temsil gücüne sahip olduğu gösterilmiştir [19]. Mevcut çalışmada, tam bağlı katman

aktivasyonları kullanılarak (fc6 ve fc7) 4096 boyutlu özellik vektörü elde edilmiştir [19]. Elde edilen özellik vektörleri DVM sınıflandırıcıya giriş olarak verilerek sınıflandırma işlemi gerçekleştirilmiştir. Fakat böyle bir yaklaşımın uygunluğu, FTIR sinyallerinin sınıflandırılması için araştırılmamıştır. Özetle, bu çalışmanın

amacı, FTIR sinyallerinin spektrogram görüntüleri kullanılarak ESA yardımıyla elde edilen özelliklerin kolon kanseri hastaları ve sağlıklı kişileri ayırabilme olasılığını araştırmaktır. Şekil 1’de önerilen yöntemin çalışma prensibi gösterilmiştir.



Şekil 1. Çalışmanın akış diyagramı

2. Materyal ve Metot


2.1. Örnek hazırlama ve ftir ölçümü

Fırat Üniversitesi Genel Cerrahi Bölümü’ndeki 30 kolon kanseri hastası (yaş ort. 58.37 ± 14.35 23 Erkek, 7 Kadın) ve 40 sağlıklı kişiden (yaş ortalaması 52.18 ± 18.15 , Erkek (17), Kadın (23)) kan numuneleri alınmıştır. Kan numunelerinin, santrifüj işleminin ardından plazmaları ayrıştırılmış ve -20 C° ’de muhafaza edilmiştir. Plazma numunelerinin FTIR ölçümü Perkin-Elmer Spektrum 100 cihazı kullanılarak elde edilmiştir. $4000\text{-}450\text{ cm}^{-1}$ aralığında ölçülen numuneler, 32 tarama ve 4 cm^{-1} çözünürlük ile kaydedilmiştir. Çalışma için orta kızılötesi bant aralığı olan $4000\text{-}1000\text{ cm}^{-1}$ aralığı incelenmiştir. Bunun nedeni, genellikle kanser araştırmalarında önemli moleküllerin bu bant aralığında olmasıdır. Ayrıca, FTIR sinyalleri için temel bant düzeltme ve normalizasyon işlemleri gerçekleştirilmiştir. Bu çalışmada kullanılan veriler için, Fırat

Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu Başkanlığı’nın onayı alınmıştır [20].

2.2. Spektrogram görüntülerin oluşturulması

Fourier Dönüşümü, durağan sinyal içerisinde yer alan tüm frekans bileşenlerini tanımlayabilir. Ancak tüm sinyaller durağan değildir. Kısa Zamanlı Fourier Dönüşümü (KZFD), sinyalin aynı anda hem frekans hem de zaman bilgisi analizi verir [21]. KZFD, bir sinyalin Fourier dönüşümü fonksiyonunun, pencere fonksiyonu ile çarpılarak elde edilir. Bir sinyalin, zaman ve frekansın 2-D fonksiyonunun görüntülenmesi spektrogram olarak adlandırılır [22]. Bu çalışmada, spektrogram görüntüsü oluşturmak için FTIR sinyalinin $4000\text{-}1000\text{ cm}^{-1}$ bölgesi kullanılmıştır (Şekil 2). Spektrogramların elde edilmesi için 24 ms örtüşen 48 ms’lik Hamming penceresi kullanılmıştır. Ayrıca, dB güç skalasında güç spektral yoğunluğunu hesaplanmıştır.



Şekil 2. FTIR işaretinden elde edilen örnek bir spektrogram görüntüsü

2.3. Önceden eğitilmiş esa modeli ile özellik çıkarma ve sınıflandırma

Derin spektrum özelliklerini elde etmek için, spektrogram görüntüleri, önceden eğitilmiş ESA modeli olan AlexNet'e giriş olarak verilmiştir. AlexNet bir milyondan fazla resim kullanılarak eğitilmiş ve resimleri 1000 farklı kategoriye ayırabilen bir derin öğrenme modelidir [23]. AlexNet, 8 katmanlı bir yapıdan oluşmaktadır. Beş konvülyasyon katmanı (convolution layer) ve 3 tam bağlı katmandan (fully connected layer) oluşmaktadır. AlexNet modelinde, maksimum havuz katmanları (max-pooling layer), konvölüsyon katmanlarından sonra gelmektedir. Konvölüsyon katmanlarında farklı çekirdek boyutları kullanılmaktadır [23]. Derin öğrenme mimarisindeki derin katmanlar önceki katmanların düşük seviyeli özelliklerini kullanarak daha yüksek seviyeli özellikler sunar [24]. İlk katmanlar genel özellikleri içerirken derin katmanlar, veri setindeki belirli sınıfların belirli özelliklerini içerir. Bu çalışmada, özellik çıkarımı için fc6 ve fc7 katmanı kullanılmıştır. Her bir görüntü fc6 ve fc7 katmanlarında bulunan 4096 nöronlardan elde edilen 4096 boyutunda bir özellik vektörü ile temsil edilmektedir [25, 26].

Yapısal risk minimizasyonu prensibine dayalı bir makine öğrenme algoritması olan DVM, iki sınıflı veri kümelerinde, sınıfları ayırmak için en uygun hiper düzlemi bulmayı amaçlamaktadır. Sınıflandırma, bu belirlenen optimal hiper düzlem kullanılarak gerçekleştirilir [27, 28]. Bu çalışmada da, fc6 ve fc7 katmanından elde edilen 4096 özellik vektörleri ayrı ayrı Liblinear kütüphaneli DVM sınıflandırıcı kullanılarak sınıflandırılmıştır.

3. Deneysel Sonuçlar

Çalışma için Intel Core i5-4200 CPU ve 8 GB bellek kullanan bir bilgisayar kullanılmıştır. Çalışmadaki işlemler MATLAB kullanılarak gerçekleştirilmiştir. Spektrogram görüntülerini oluşturmak için, daha önce AlexNet kullanımı için uygun bir spektrogram renk haritası olduğu gösterilen viridis renk haritası kullanılmıştır [29]. Spektrogram görüntülerinin başlangıç boyutu 875×656 'dır. AlexNet ile uyumluluk için, tüm spektrogram resimleri 227×227 olarak yeniden boyutlandırılmıştır. Daha sonra AlexNet modelinin fc6 ve fc7 aktivasyonlarını kullanarak spektrogram görüntülerinden derin spektrum özellikleri çıkarılmıştır. Her model 4096 boyutlu bir özellik vektörü üretmektedir. Üretilen özellik vektörü homojen haritalama özelliğine sahip Liblinear kütüphaneli DVM sınıflandırılmıştır. Bu sınıflandırıcı türünün kullanılmasının sebebi, küçük miktarlardaki eğitim verisi için daha etkili bir sınıflandırma gerçekleştirebilmesidir [30, 31]. Ayrıca DVM parametrelerinden biri olan C ise $[10^{-4}, \dots, 10^3]$ aralığında incelenmiştir.

Gerçekleştirilen çalışmada fc6 ve fc7 katmanlarından elde edilen derin özellik vektörleri için ayrı ayrı sınıflandırma işlemi gerçekleştirilmiştir. Fc7 katmanından elde edilen özellik vektörleri ile daha başarılı bir sınıflandırma sonucu elde edilmiştir. Tablo 2'de görüldüğü gibi fc7 ile %89.44 oranında sınıflama doğruluğu elde edilmiştir. Derin özellik vektörlerinin DVM'ye giriş vektörü olarak verilmesinden önce 4 katlı çapraz doğrulama yöntemi uygulanmıştır. Ayrıca 4 katlı çapraz doğrulama yöntemi rastgele seçilen test verileri ile 10 kez uygulanmıştır. Tablo 2'deki sonuçlar 10 denemenin sonunda elde edilen ortalama değerleri göstermektedir.

Kolon kanserinin kan numunelerinden belirlenmesine yönelik literatürde rastlanılan çalışmanın sonuçları Tablo2'de karşılaştırmalı olarak verilmiştir. Barlev ve ark. yaptığı çalışmada TBA ve diskriminant analiz yöntemleri kullanılarak bir ayırım yapılmaya çalışılmıştır. Mevcut çalışmada ise, ESA yardımıyla elde edilen özelliklerin sınıflandırılması sonucu daha iyi bir duyarlılık, özgüllük ve doğruluğa ulaşılmıştır.

Tablo 2. Kan örnekleri kullanılarak kolon kanserine yönelik yapılan çalışmaların karşılaştırılması

Yazarlar	Hastalık türü (hasta/normal sayısı)	Yöntemler	Sonuçlar	
Barlev ve ark. [2] (2015)	Kolorektal kanseri (34+10, 18)	TBA, Fisher Doğrusal Ayrım Analizi, Kuadratik Diskriminant Analizi	Eğri altındaki alan (AUC) : 0.77 Duyarlılık: 81.50% Özgüllük: 71.40%	
Önerilen yöntem	Kolon kanseri (30, 40)	ESA, Özellik Çıkarımı, DVM	Fc6 (Ortalama + Standart Sapma)	Fc7 (Ortalama + Standart Sapma)
			Doğ: %86.66 ± 5.972	%89.44 ± 4.864
			Duy: %85 ± 7.905	%88,75 ± 3.952
			Özg: %88 ± 6.324	%90 ± 6.667

4. Sonuç ve Öneriler

Bu yazıda kolon kanseri hastaları ve sağlıklı bireylere ait FTIR sinyallerinin sınıflandırması için yeni bir yöntem önerilmiştir. Önerilen yöntem, FTIR sinyallerinin spektrogram görüntüsünün elde edilmesi, spektrogram görüntülerinden derin özelliklerinin çıkarılması ve çıkarılan bu özelliklerin sınıflandırılması aşamalarını içermektedir. FTIR sinyallerinden hastalık tespitine yönelik çalışmalarda sadece belirli pik değerleri üzerinden bir değerlendirme yapılmaktadır. Fakat bu çalışmada, derin öğrenme yaklaşımının genel prensibi olan sinyalin tamamından ESA yapısı ile özellik çıkarımı gerçekleştirilmiştir. Ayrıca transfer öğrenme yaklaşımının FTIR sinyallerine ilk defa uygulanmasının nasıl sonuçlar verdiği test edilmiştir. Ayrıca mevcut çalışmada numuneler sıvı olarak ölçülmüştür. Plazmadaki suyun kolon kanseri hastalarını ve sağlıklı kişileri ayırabilmedeki etkisinin daha iyi anlaşılabilmesi için numunelerin kurutulduğu çalışmaların kandan kanser belirleme çalışmalarında büyük katkı sağlayacağı düşünülmektedir. Sonuç olarak, yapılan çalışma ile FTIR sinyallerin spektrogram görüntülerinin oluşturulması ve bunların önceden eğitilmiş ESA'lar kullanılarak sınıflandırılmasının kanser belirleme çalışmalarına farklı bir bakış açısı getireceğini umuyoruz.

5. Teşekkür

Kan numunelerinin alınmasında Genel Cerrahi Uzmanı Doç. Dr. Mustafa Girgin'e, numunelerin ayrıştırılmasında Biyokimya

Uzmanı Prof. Dr. Bilal Üstündağ'a yardımlarından dolayı ve numunelerin FTIR analizdeki alt yapı desteğinden dolayı Bingöl Üniversitesi Merkezi Laboratuvar Uygulama ve Araştırma Merkezi'ne teşekkür ederiz.

6. Kaynaklar

1. Türkiye İstatistik Kurumu, Ölüm Nedeni İstatistikleri, Sayı:27620, 2018
2. Barlev E, Zelig U, Bar O, et al A novel method for screening colorectal cancer by infrared spectroscopy of peripheral blood mononuclear cells and plasma. J Gastroenterol
3. Ostrovsky E, Zelig U, Gusakova I, et al (2012) Detection of Cancer Using Advanced Computerized Analysis of Infrared Spectra of Peripheral Blood. IEEE Trans Biomed Eng 60:1–1
4. Baker MJ, Gazi E, Brown MD, et al (2008) FTIR-based spectroscopic analysis in the identification of clinically aggressive prostate cancer. Br J Cancer 99:1859–1866
5. Fujioka N, Morimoto Y, Arai T, Kikuchi M Discrimination between normal and malignant human gastric tissues by Fourier transform infrared spectroscopy. Cancer Detect Prev. doi: 10.1016/j.cdp.2003.11.004
6. Maziak DE, Do MT, Shamji FM, et al Fourier-transform infrared spectroscopic study of characteristic molecular structure in cancer cells of esophagus: An exploratory study. Cancer Detect Prev. doi: 10.1016/j.cdp.2007.03.003
7. Fabian H, Thi NAN, Eiden M, et al (2006) Diagnosing benign and malignant lesions in breast tissue sections by using IR-microspectroscopy. Biochim Biophys Acta 1758:874–882
8. Cheng CG, Tian YM, Jin WY (2008) A study on the early detection of colon cancer using the methods of wavelet feature extraction and SVM classifications of FTIR. Spectroscopy 22:397–404

9. Cheng C, Xiong W, Tian Y (2009) Classification of rat FTIR colon cancer data using wavelets and BPNN. *Chinese J Chem* 27:911–914
10. Zwielly A, Mordechai S, Sinielnikov I, et al (2010) Advanced statistical techniques applied to comprehensive FTIR spectra on human colonic tissues. *Med Phys* 37:1047–55
11. Sheng D, Liu X, Li W, et al (2013) Distinction of leukemia patients' and healthy persons' serum using FTIR spectroscopy. *Spectrochim Acta - Part A Mol Biomol Spectrosc* 101:228–232
12. Erukhimovitch V, Talyshinsky M, Souprun Y, Huleihel M (2006) FTIR spectroscopy examination of leukemia patients plasma. *Vib Spectrosc* 40:40–46
13. Ahmed SSSJ, Santosh W, Kumar S, Thanka Christlet TH Neural network algorithm for the early detection of Parkinson's disease from blood plasma by FTIR micro-spectroscopy. *Vib Spectrosc*. doi: 10.1016/j.vibspec.2010.01.019
14. Sheng D, Wu Y, Wang X, et al (2013) Comparison of serum from gastric cancer patients and from healthy persons using FTIR spectroscopy. *Spectrochim Acta - Part A Mol Biomol Spectrosc* 116:365–369
15. Wang X, Shen X, Sheng D, et al (2014) FTIR spectroscopic comparison of serum from lung cancer patients and healthy persons. *Spectrochim Acta - Part A Mol Biomol Spectrosc* 122:193–197
16. Barlev E, Zelig U, Bar O, et al (2015) A novel method for screening colorectal cancer by infrared spectroscopy of peripheral blood mononuclear cells and plasma. *J Gastroenterol* 56–78
17. Toraman S, Türkoğlu İ (2016) FTIR İşaret Örüntülerinden Kolon Kanserinin Belirlenmesine Yönelik Yeni Bir Otomatik Tanıma Yöntemi. *Int Conf Nat Sci Eng* 2354–2361
18. Kaya A, Keçeli AS, Can AB Akciğer nodül özelliklerinin tahmininde çeşitli sınıflama stratejilerinin incelenmesi. *Gazi Üniversitesi Mimar Mühendislik Fakültesi Derg* (2018), <https://doi.org/10.17341/gazimmfd416530>
19. Cummins N, Amiriparian S, Hagerer G, et al (2017) An Image-based Deep Spectrum Feature Representation for the Recognition of Emotional Speech. *Proc 2017 ACM Multimed Conf - MM '17* 478–484
20. Toraman S (2016) Kızılötesi Spektroskopisi Kullanılarak Kan Örneklerinden Kolon Kanserine Yönelik Özellik Çıkarımı. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi
21. Taşaner MM (2009) Çoklu Silindirik Hedeflerin Sınıflandırılması. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi
22. Mustafa M, Taib MN, Murat ZH, et al (2011) Classification of EEG spectrogram image with ANN approach for brainwave balancing application. *Int J Simul Syst Sci Technol* 12:29–36
23. Krizhevsky A, Sutskever I, Hinton GE (2012) ImageNet Classification with Deep Convolutional Neural Networks. *Adv Neural Inf Process Syst* 1–9
24. MATLAB and Computer Vision System Toolbox, The MathWorks, Inc., Natick, Massachusetts, United States.
25. Zhou Y, Nejati H, Do T-T, et al (2016) Image-based Vehicle Analysis using Deep Neural Network: A Systematic Study
26. Şengür A, Akılotu BN, Tuncer SA, et al (2018) Optic Disc Determination in Retinal Images with Deep Features. In: 26th Signal Processing and Communications Applications Conference (SIU). pp 4–7
27. Khazae A, Ebrahimzadeh A Classification of electrocardiogram signals with support vector machines and genetic algorithms using power spectral features. *Biomed Signal Process Control*. doi: 10.1016/j.bspc.2010.07.006
28. Kharat PA, Dudul S V. (2012) Daubechies wavelet neural network classifier for the diagnosis of epilepsy. *WSEAS Trans Biol Biomed* 9:103–113
29. Amiriparian S, Gerczuk M, Ottl S, et al (2017) Snore Sound Classification Using Image-based Deep Spectrum Features Chair of Complex & Intelligent Systems , Universit . 3512–3516
30. Vedaldi A, Zisserman A (2010) Efficient Additive Kernels via Explicit Feature Maps. *Proc {CVPR}* 34:480–492
31. Fan R-E, Chang K-W, Hsieh C-J, et al (2008) LIBLINEAR: A Library for Large Linear Classification. *J Mach Learn Res* 9:1871–1874.