



A new method for classifying colon cancer patients and healthy people from FTIR signals using wavelet transform and machine learning techniques

Suat Toraman^{1*} , İbrahim Türkoğlu²

¹Firat University, Department of Informatics, 23119, Elazığ, Turkey

²Firat University, Faculty of Technology, Department of Software Engineering, 23119, Elazığ, Turkey

Highlights:

- Examination of plasma IR signals of colon cancer patients and healthy persons
- Decomposition of FTIR signals into sub-bands by wavelet transform
- Classification of properties obtained from FTIR signals

Keywords:

- Fourier transform infrared signal
- Colon cancer
- Wavelet transform
- Feature extraction
- Classification

Article Info:

Research Article

Received: 13.05.2019

Accepted: 04.11.2019

DOI:

10.17341/gazimmfd.564803

Correspondence:

Author: Suat Toraman

e-mail:

storaman@firat.edu.tr

phone: +90 424 237 00 00

Graphical/Tabular Abstract




Figure A. Flow chart of proposed method

Purpose: The aim of the study is to investigate the possibility of classifying the liquid plasma IR spectra of colon cancer patients and healthy persons with machine learning techniques.

Theory and Methods:

Colon cancer is one of the major causes of mortality among adults in Turkey. According to data from the Turkish Statistical Institute, colon cancer is ranked as 4th among malignant tumor types resulting in death. One of the methods used in studies for the determination of cancer is FTIR spectroscopy. The major challenge in studies distinguishing between the FTIR signal of patients and that of healthy people is the lack of clear spectral difference in the FTIR signals. To overcome this challenge, plasma samples were measured as liquid, unlike studies in the literature. The signals were then decomposed and the statistical properties of each sub-band were subtracted. The extracted features were classified with three different classifiers. The FTIR signal was analyzed in three different intervals; 1300-1000 cm^{-1} , 1800-1300 cm^{-1} ve 1800-1000 cm^{-1} .

Results:

Colon cancer patients and healthy subjects were classified with an accuracy of 97.14% with SVM. The best classification results were obtained by examining the FTIR signal in one piece.

Conclusion:

Experimental results indicate that the proposed method may be useful in distinguishing between colon cancer patients and healthy individuals.



Dalgacık dönüşümü ve makine öğrenme teknikleri kullanılarak FTIR sinyallerinden kolon kanseri hastaları ve sağlıklı kişileri sınıflandırmak için yeni bir yöntem

Suat Toraman^{1*}, İbrahim Türkoğlu²

¹Fırat Üniversitesi, Enformatik Bölümü, 23119, Elazığ, Türkiye

²Fırat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, 23119, Elazığ, Türkiye

Ö N E Ç İ K A N L A R

- Kolon kanseri hastaları ve sağlıklı kişilerin plazma IR sinyallerinin incelenmesi
- FTIR sinyallerinin dalgacık dönüşümü ile alt bantlarına ayrıştırılması
- FTIR sinyallerinden elde edilen özelliklerin sınıflandırılması

Makale Bilgileri

Araştırma Makalesi
Geliş: 13.05.2019
Kabul: 04.11.2019

DOI:

10.17341/gazimmfd.564803

Anahtar Kelimeler:

Fourier dönüşümü kızılötesi sinyali, kolon kanseri, dalgacık dönüşümü, özellik çıkarımı, sınıflandırma

ÖZET

Fourier Dönüşümü Kızılötesi (FTIR) spektroskopisi, kimyasal değişimleri saptayabilme kabiliyetinden dolayı kan örneklerinden kanseri tespiti çalışmalarında kullanılmaktadır. Hastaların ve sağlıklı kişilerin FTIR sinyalini ayırt etmeye yönelik çalışmalarda en büyük zorluk, FTIR sinyallerinde açık bir spektral farkın olmamasıdır. Daha önceki çalışmalarda, bu zorluğun üstesinden gelmek için kan örneklerinin kurutulup, daha sonra FTIR ölçümü sonucu elde edilen sinyalindeki tepe (pik) değerleri veya tepe oranları kullanılmıştır. Önerilen yöntemde ise, literatürden farklı olarak, plazma örnekleri kurutulmadan sıvı halde ölçülmüş ve elde edilen FTIR sinyali bir bütün olarak incelenmiştir. Her bir FTIR sinyali, dalgacık dönüşümü kullanılarak alt bantlara ayrıştırılmıştır. Kolon kanseri hastaları ve sağlıklı kişiler, FTIR sinyalinin alt bantlardan çıkarılan özellikler kullanılarak sınıflandırılmıştır. Sınıflandırma işlemi için Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM) ve k-En Yakın Komşu (k-NN) algoritmaları kullanılmıştır. Kolon kanseri hastaları ve sağlıklı kişiler DVM ile %97,14 doğrulukla sınıflandırılmıştır. Deneysel sonuçlar, önerilen yöntemin, kolon kanseri hastalarını ve sağlıklı bireyleri ayırt etmede faydalı bir yöntem olabileceğini göstermektedir.

A new method for classifying colon cancer patients and healthy people from FTIR signals using wavelet transform and machine learning techniques

H I G H L I G H T S

- Examination of plasma IR signals of colon cancer patients and healthy persons
- Decomposition of FTIR signals into sub-bands by wavelet transform
- Classification of properties obtained from FTIR signals

Article Info

Research Article
Received: 13.05.2019
Accepted: 04.11.2019

DOI:

10.17341/gazimmfd.564803

Keywords:

Fourier transform infrared signal, colon cancer, wavelet transform, feature extraction, classification

ABSTRACT

Fourier Transform Infrared (FTIR) spectroscopy is used in studies to determine cancer from blood samples due to its ability to detect chemical changes. The major challenge in studies distinguishing between the FTIR signal of patients and that of healthy people is the lack of clear spectral difference in the FTIR signals. In previous studies, blood samples were dried to overcome this difficulty and peak values or ratios were used in the signal obtained by FTIR measurement. In the proposed method, unlike the literature, plasma samples were measured in liquid form and the resulting FTIR signal then examined as a whole. The FTIR signal was decomposed into sub-bands using wavelet transform. Colon cancer patients and healthy subjects were classified by using the features extracted from the sub-bands. Artificial Neural Networks (ANN), Support Vector Machines (SVM) and k-Nearest Neighbors (k-NN) were used for classification. Colon cancer patients and healthy subjects were classified with an accuracy of 97.14% with SVM. Experimental results indicate that the proposed method may be useful in distinguishing between colon cancer patients and healthy individuals.

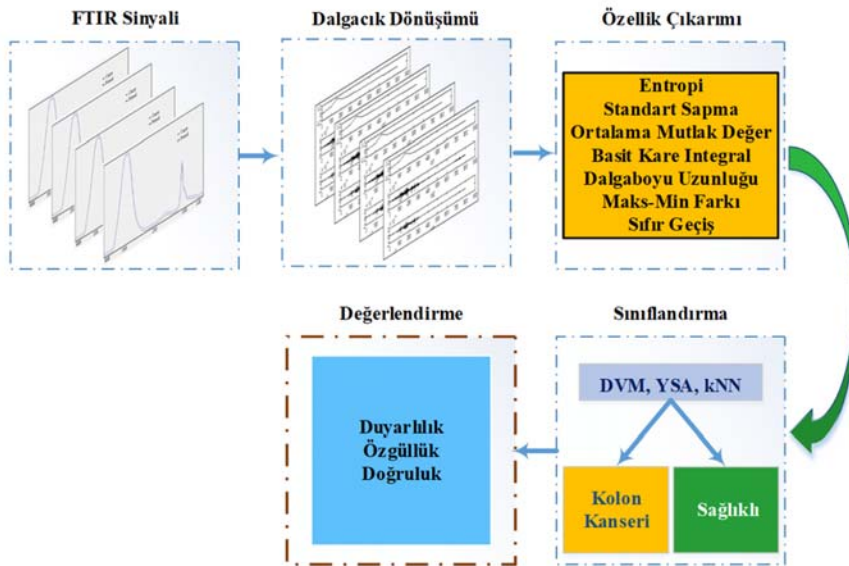
1. GİRİŞ (INTRODUCTION)

Kolon kanseri, Türkiye’de yetişkinler arasındaki en önemli ölüm nedenlerinden biridir. Türkiye İstatistik Kurumu'nun verilerine göre, kolon kanseri, ölümlerle sonuçlanan kötü huylu tümör tipleri arasında 4. sırada yer almaktadır [1]. Her yıl binlerce insan bu hastalık yüzünden hayatını kaybetmektedir. Kolon kanseri erken bir aşamada tespit edilebilirse, hastalar için hayatta kalma şansı büyük ölçüde artabilir. Kanser belirleme çalışmalarında kullanılan yöntemlerden biri Fourier Dönüşümü Kızılötesi (FTIR – Fourier Transform Infrared) spektroskopisidir. FTIR spektroskopisi, dokulardaki ve hücrelerdeki biyokimyasal değişiklikleri belirleme yeteneğine sahiptir. Bu özellik nedeniyle, FTIR spektroskopisi kanser araştırmalarında ve kanser belirleme çalışmalarında yaygın olarak kullanılmaktadır. Kan örnekleri kullanılarak yapılan çalışmalar aşağıda irdelenmiştir.

Erukhimovitch vd. [2] (2006) kan numunelerinden lösemi hastalığını belirlemeye yönelik bir çalışma gerçekleştirmiştir. Çalışmada 10 lösemi hastası ve 10 normal kişiye ait serum numuneleri kullanılmıştır. 1056, 1270 ve 1592 cm^{-1} spektral tepeleri incelenmiştir. Bu pik değerlerinde önemli değişiklikler gözlemlenmiştir. Tepe değerlerinin karşılaştırılması için kümeleme analizinden faydalanılmıştır. Ostrovsky vd. [3] (2013) FTIR spektroskopisi kullanılarak periferik kan plazmasının biyokimyasal analizine dayalı yeni bir yaklaşım önermiştir. Çalışmada 18 meme, 13 mide, 6 akciğer ve 8 karışık kanser (prostat, yumurtalık, bilinmeyen) türlerine ait kan numuneleri kullanılmıştır. Temel bileşen analizi (PCA - Principal Component Analysis) yöntemi ile özellik çıkarımı yapılmış ve daha sonra Fisher doğrusal ayırmacılık analizi (FLDA - Fisher Linear Discriminant Analysis) ile sınıflama işlemi gerçekleştirilmiştir. Sonuç olarak %93,33 duyarlılık,

%87,80 özgüllük ve %90,70 doğruluk değerleri elde edilmiştir. Sheng vd. [4] (2013) lösemiye serum numunelerini kullanarak belirlemeye çalışmıştır. Çalışmada 24 hasta 19 normal bireye ait numuneler kullanılmıştır. Çeşitli spektral tepeler incelenmiştir. H2959 / H2931 ve A1115/A1028 oranı ayırt edici özellik olarak tanımlanmıştır. Bu tanımlama işlemi için eğri uydurma yönteminden faydalanılmıştır. Sheng vd. [5] (2013) mide kanserini belirlemek için 27 hasta ve 19 normal bireyin serum numunelerini kullanmıştır. Serum numunelerine ait FTIR sinyallerinin tepe değerleri incelenmiştir. Tepe değerleri arasında H2959/H2931 oranı ayırt edici özellik olarak tanımlanmıştır. Wang vd. [6](2014) akciğer kanserini serum numunelerinden belirlemek için yaptıkları çalışmada 24 akciğer kanser hastası ve 22 sağlıklı bireyden kan numuneleri toplamıştır. Serum numunelerinin FTIR sinyalleri elde edilmiştir. Daha sonra eğri uydurma yöntemi yardımıyla A1080/A1170 oranı ayırt edici özellik olarak belirlenmiştir.

Günümüzde, kolon kanseri tanısında biyopsi, kolonoskopi, bilgisayarlı tomografi ve bazı tümör belirteçleri gibi yöntemler kullanılmaktadır. Kolonoskopi ve biyopsi, invaziv olan ve enfeksiyon riski taşıyan yöntemlerdir. Bilgisayarlı tomografi yönteminde ise hastalar radyasyona maruz kalmaktadır. Kanser tanısında kullanılan carcinoembryonic antijen (CEA) ve kanser antijeni (CA) (19-9) gibi bazı tümör belirteçlerinin duyarlılığı ve özgüllüğü ise düşüktür [3, 7]. Bu nedenle kanserin belirlenmesinde daha basit ve hastayı daha az rahatsız edici yöntemlerin geliştirilmesi önemlidir. Bu çalışmada, kandan kanser belirlenmesine yönelik yeni bir yöntem önerilmektedir. Önerilen yöntemin akış diyagramı Şekil 1’de gösterilmiştir. Kan örnekleri kullanılarak FTIR sinyalinden hastalık belirlenmesi için yapılan çalışmalarda gözlenen en büyük zorluk, hastaların FTIR sinyali ile sağlıklı kişilerin



Şekil 1. Çalışmanın akış diyagramı (Flowchart of the study)

FTIR sinyali arasında açık bir spektral fark bulunmamasıdır. Bu çalışmada, literatürdeki kandan kolon kanserinin belirlenmesi ile ilgili çalışmalarda rastlanmayan iki yöntem ile bu zorluğun üstesinden gelinmeye çalışılmıştır. İlk olarak, sinyalde küçük değişiklikleri bulabilme yeteneğinden dolayı FTIR sinyaline dalgacık dönüşümü uygulanmıştır [8]. İkincisi, Bölüm 2.3'te açıklanan istatistiksel özellikler ile FTIR sinyalinin alt bantlarından ayrı ayrı özellik çıkarımı gerçekleştirilmiştir. Ayrıca, literatürdeki çalışmaların aksine, plazma numunesi kurutulmadan sıvı halde ölçülmüştür. Diğer çalışmalarda, numunelerin kuruması için en az 30-60 dakika beklemek gerekmektedir. Bu işlem rutinde zaman alıcıdır. Ancak önerilen yöntemde böyle bir bekleme süresine ihtiyaç kalmamıştır. Sonuç olarak daha hızlı bir şekilde karar alma sürecinin sağlanması amaçlanmıştır. Özetle, önerilen yöntemin amacı, sıvı plazma IR spektrumlarından elde edilen özelliklerin, makine öğrenme teknikleri yardımıyla kolon kanseri hastaları ve sağlıklı kişileri sınıflandırabilme olasılığını belirleyebilmektir.

2. MATERYAL VE METOTLAR (MATERIALS AND METHODS)

2.1. Numune Hazırlama ve FTIR Veri Analizi (Sample Preparation and FTIR data analysis)

Fırat Üniversitesi Genel Cerrahi Bölümü'nde kolon kanseri teşhisi konulan ve kolon kanseri tedavisi gören 30 hastadan ve 40 sağlıklı kişilerden kan örnekleri alınmıştır (Tablo 1). Kişilerden alınan 4 ml kan numunesi EDTA tüplerine konulmuştur. Numuneler 4 dk süreyle 4000 rpm'de santrifüj işlemine tabi tutulmuştur ve plazma numuneleri elde edilmiştir. Plazma örnekleri daha sonra yeni tüplere konulmuş ve -20°C sıcaklıktaki dolaplarda saklanmıştır. FTIR ölçümü için ZnSe (Zinc Selenide) attenuated total

reflection (ATR) aksesuarlı Perkin-Elmer Spectrum 100 FT-IR spektrometresi kullanılmıştır. Numuneler 32 taramada (yüksek sinyal-gürültü oranı için) ve 4000-450 cm^{-1} aralığında 4 cm^{-1} çözünürlükte ölçülmüştür (Şekil 2). Perkin Elmer spektrum yazılımıyla temel düzeltme yapıldıktan sonra, amid II ($\sim 1550 \text{cm}^{-1}$)'e göre veriler Eş. 1 ile normalize edilmiştir [3].

$$x_2 = 2(x[i] - \min(x))/x_1 \quad (1)$$

Burada, $\min(x)$, incelenen aralıktaki x spektrumunun en küçük değeridir. x_1 , amid II'nin değeridir ve x_2 , x 'in yeni değeridir. Ayrıca, bu çalışma Fırat Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu tarafından onaylanmıştır [9].

2.2. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)

Dalgacık dönüşümü (DD) zaman-frekans analiz yöntemleri arasında önemli bir yere sahiptir [10]. Bunun nedeni dalgacık dönüşümünün değişken boyutlu pencereler kullanmasıdır. Pencere ölçeği büyütüldüğünde, ana dalgacık genişler ve sinyalin düşük frekanslı bileşenleri elde edilir. Pencere ölçeği azaldığında, ana dalgacık daralır ve sinyalin yüksek frekanslı bileşenleri elde edilir [11]. Bu nedenle, sinyalin hem yüksek hem de düşük frekanslı bileşenleri verimli bir şekilde analiz edilebilir. (Eş. 2)

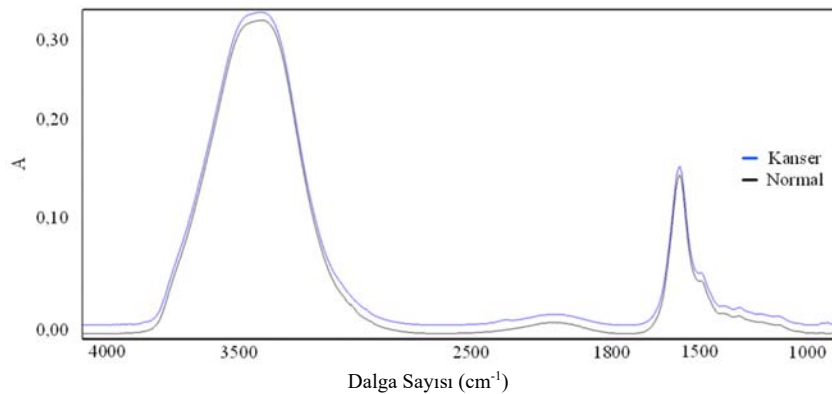
$$SDD(a, z) = \int_{-\infty}^{\infty} x(t)\psi_{a,z}^*(t)dt \quad (2)$$

Burada $x(t)$ sinyal ve ψ ana dalgacık fonksiyonudur. a ölçeği dalgacığın genişliğini gösterirken, z parametresi ise konumu verir [12]. Ana dalgacık Eş. 3'teki gibidir;

$$\psi_{a,z}(t) = a^{-1/2}\psi\left(\frac{t-z}{a}\right) \quad (3)$$

Tablo 1. Kanser hastası ve sağlıklı kişilerin istatistikleri (Statistics of cancer patients and healthy persons)

	Ortalama Yaş \pm Std	Cinsiyet		Kanser aşaması			
		Erkek	Kadın	I	II	III	IV
Kolon kanseri	58,37 \pm 14,35	23	7	4	11	10	5
Sağlıklı	52,18 \pm 18,15	17	23	-	-	-	-



Şekil 2. Kolon kanseri hastası ve sağlıklı kişinin plazmasına ait örnek bir IR spektrumu
(A sample IR spectra of colon cancer patient's plasma and healthy person's plasma)

Sürekli Dalgacık Dönüşümü (SDD) ölçek ($a = 2^i$) ve kaydırma parametreleri ($z = k \cdot 2^i$) kullanılarak ayrık forma dönüştürülür. Böylece, ayrık dalgacık dönüşümü Eş. 4'teki gibi elde edilir; [12]

$$W(i, k) = \sum_i \sum_k x(t) 2^{-i/2} \psi(2^{-i}t - k) \quad (4)$$

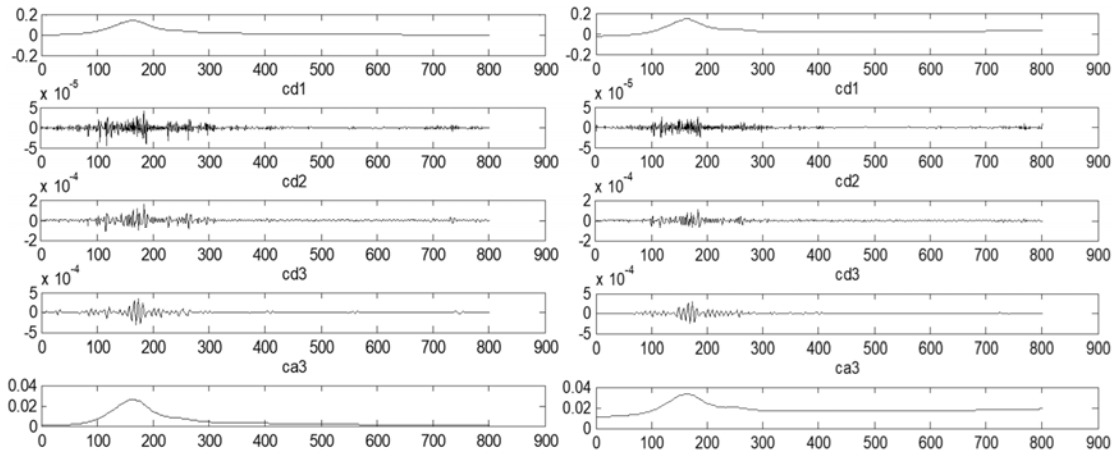
Ayrık dalgacık analizi ile birlikte, $x(n)$ sinyali, $g(n)$ alçak geçiren ve $h(n)$ yüksek geçiren filtreler ile yüksek ve düşük frekanslı bileşenlere ayrılmıştır. Sinyalin düşük frekanslı kısımlarına yaklaşık katsayıları (ca) ve yüksek frekanslı kısımlarına ise detay katsayıları (cd) denilmektedir. (Eş. 5)

$$\begin{aligned} cd(n) &= x(n) \cdot h(n) \\ ca(n) &= x(n) \cdot g(n) \end{aligned} \quad (5)$$

2.3. Özellik Çıkarımı (Feature Extraction)

Özellik çıkarma, örüntü tanıma ve sınıflandırmadaki en önemli adımlardan biridir. Bu çalışmada, durağan olmayan FTIR sinyallerinden özellik çıkarımı yapılmıştır. Sinyali analiz ederken zaman-frekans bilgisinin kaybolmaması önemlidir. Bu sebeple, FTIR sinyalini analiz etmek için DD kullanılmıştır. FTIR sinyalini alt bantlara ayırmak için çeşitli dalgacık türleri (*daubechies* (db), *coiflet* ($coif$) ve *symlets*) kullanılmıştır. Ayrıştırma seviyesi, sinyallerin analizi için üç olarak belirlenmiştir. Dalgacık türleri ve ayrıştırma seviyeleri karşılaştırmalı olarak yapılan denemeler sonucu en uygun sonucu verecek şekilde belirlenmiştir. FTIR sinyallerinin yaklaşık katsayıları ($ca3$) ve detay katsayıları ($cd1$ - $cd3$), Şekil 3'te gösterilmektedir. Alt bantlara ayrıştırılan her sinyalin aşağıdaki özellikleri ayrı ayrı hesaplanmıştır [13-15]. Her sinyal, bir yaklaşık ve üç detay katsayısı olmak üzere toplam dört alt banttan oluşmaktadır.

Daha sonra, her alt bandın yedi farklı özelliği hesaplanmıştır. Böylece, her bir alt bandın boyutu azaltılmış ve her bir sinyal daha az özellik ile temsil edilmiştir. $a3$ 'ün sıfır geçiş değeri hesaplanmamıştır. Çünkü $a3$ yaklaşık katsayısı sıfır geçiş değerine sahip değildir.



Şekil 3. Kolon kanseri hastası (sol) ve sağlıklı bireye (sağ) ait örnek bir sinyalin yaklaşık ve detay katsayıları
(A sample wavelet approximate and detail coefficients of colon cancer patient (left) and healthy person (right))

- 1) Her bir alt bandın entropisi.
- 2) Her alt bandın standart sapması.
- 3) Her alt bandın ortalama mutlak değeri.
- 4) Her alt bandın basit kare integrali.
- 5) Her bir alt bandın dalga boyu.
- 6) Her bir alt bandın en büyük ve en küçük değer farkı.
- 7) Her bir alt bandın sıfır geçiş sayısı.

Her bir sinyal 27 özellik kümesi ile temsil edilmiştir (Şekil 4). Hesaplanan özellikler Tablo 2'te verilmiştir. (Eş. 6-Eş. 12) Burada, x_i FTIR sinyalinin dalga sayısını, N ise sinyalin uzunluğunu temsil eder. p_i , p 'nin olasılık fonksiyonunu temsil eder [48]. $\max(x)$ ve $\min(x)$, sinyalin belirtilen aralığında en büyük ve en küçük değerleridir. Ayrıca, her özellik vektörü, en büyük değerine bölünerek normalize edilmiştir.

2.4. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları, insan beyninin biyolojik yapısından ilham alan matematiksel bir modeldir. YSA, nöron adı verilen birimlerden oluşturulmuştur [16, 17]. Yapay sinir ağları, örüntü tanıma, zaman serisi tahmini ve sinyal işlemede başarıyla kullanılmıştır [18]. En yaygın kullanılan yapay sinir ağı modellerinden biri çok katmanlı algılayıcıdır (ÇKA) [16]. Bu çalışmada, verileri sınıflandırmak için bir ÇKA sinir ağı modeli kullanılmıştır. En uygun gizli katman ve nöron sayısı deneysel karşılaştırmalar sonucu belirlenmiştir. Kullanılan katmanlar ve parametreler şunlardır. Katman sayısı 4'tür (1 giriş katmanı, 2 gizli katman ve 1 çıkış katmanı). Gizli katmanlardaki nöron sayısı sırasıyla 20 ve 10 olarak belirlenmiştir. Başlangıç ağırlıkları rastgele seçilmiştir. Aktivasyon fonksiyonu Logaritmik sigmoid'dir. Öğrenme oranı 0,005'tir.

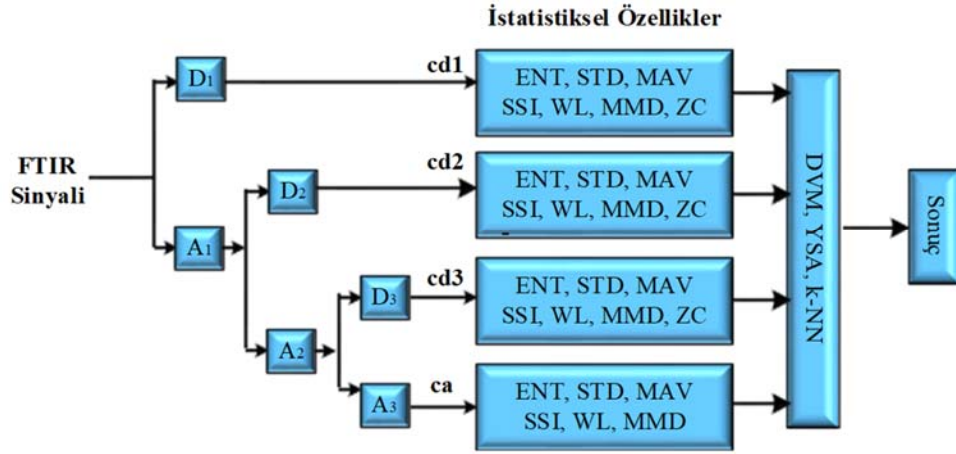
2.5. Destek Vektör Makineleri (Support Vector Machines)

Destek vektör makineleri, yapısal risk azaltma ilkesine dayalı olarak geliştirilen bir makine öğrenme algoritmasıdır. DVM iki sınıflı veya daha fazla sınıfa sahip veri kümelerinin sınıflandırılması için kullanılır (örneğin sağlıklı ve hasta

Tablo 2. FTIR sinyallerinden elde edilen özellikler (Features extracted from the FTIR signals)

Özellikler	Matematiksel tanımı
Log Entropy (ENT)	$\sum_i \log(p_i^2) \quad (6)$
Standart Sapma (Standard deviation -STD)	$\sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (7)$
Ortalama mutlak değer (Mean absolute value - MAV)	$\frac{1}{N} \sum_{i=1}^N x_i \quad (8)$
Basit kare Integral (Simple square integral - SSI)	$\sum_{i=1}^N x_i ^2 \quad (9)$
Dalga boyu uzunluğu (Waveform length - WL)	$\sum_{i=1}^{N-1} x_{i+1} - x_i \quad (10)$
En büyük ve en küçük değer farkı (Max-min difference -MMD)	$\max(x_i) - \min(x_i) \quad (11)$
Sıfır geçiş (Zero Crossing - ZC)	$\sum_{i=1}^{N-1} [isrt(x_i \times x_{i+1}) \cap x_i - x_{i+1} \geq eşik] \quad (12)$

$$isrt(x) = \begin{cases} 1, & \text{if } x \geq eşik \\ 0, & \text{değilse} \end{cases}$$

**Şekil 4.** FTIR sinyalinin alt bantlara ayrıştırılması ve alt bantlardan elde edilen 27 özelliğin sınıflandırılması (Separating FTIR signal into sub-bands and classifying the 27 features obtained from the sub-bands)

gibi). DVM, iki sınıfı birbirinden ayıracak en uygun hiper düzlemi bulmayı amaçlamaktadır. Sınıflandırma işlemi bu belirlenen en uygun hiper düzlem kullanılarak gerçekleştirilir [19, 20]. İki sınıflı bir sınıflandırma probleminde, eğitim verileri $\{x_i, y_i\}, i = 1, 2, 3, \dots, n, x_i \in R^d$ d -boyutlu uzayda ve sınıf etiketleri $y_i \in \{-1, +1\}$ olsun. DVM, iki sınıfın eğitim verileri arasında belirgin bir hiper düzlem bulmaya çalışır [21-23]. Bu durumda, en uygun hiper düzlem ile ilişkili eşitsizlikler şunlardır; (Eş. 13)

$$\begin{aligned} w \cdot x_i + b &\geq +1, y = +1 \\ w \cdot x_i + b &\leq -1, y = -1 \end{aligned} \quad (13)$$

Bu hiper düzlemleri oluşturan noktalara destek vektörleri denir ve bu düzlemler $w \cdot x_i + b = \pm 1$ olarak ifade edilir. Optimal hiper düzlem için $\|W\|$ en az olacak şekilde belirlenmelidir. Bu ise, aşağıdaki sınırlı optimizasyon problemini çözerek sağlanabilir [24, 25]. (Eş. 14, Eş. 15)

$$\arg \min \frac{1}{2} \|w\|^2 \quad (14)$$

$$y_i(w \cdot x_i + b) \geq 1 \quad i = 1 \dots n \quad (15)$$

Bu problem aşağıdaki Lagrange çarpanı metodu ile çözülebilir. (Eş. 16)

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i(w \cdot x_i + b) - 1] \quad (16)$$

Burada α , Lagrange çarpanı ve x_i , destek vektörleridir. Sonuç olarak, doğrusal olarak ayrılabilen iki sınıflı bir kümeleme problemi için karar fonksiyonu şöyledir; [24, 25] (Eş. 17)

$$f(x) = \text{sign}(\sum_{i=1}^n y_i \alpha_i (x \cdot x_i) + b) \quad (17)$$

Bu çalışmada, çekirdek fonksiyonlarından radial basis function (RBF), Polinom ve Lineer kullanılmıştır.

2.6. k En Yakın Komşu Algoritması (k-Nearest Neighbors Algorithm)

k-En yakın komşu algoritması (k-NN) sınıflandırma için kullanılan parametrik olmayan bir yöntemdir. k, yeni girdinin (x) karşılaştırıldığı komşu sayısını temsil eder. k-en yakın komşu kuralına göre, x girişi en yakın k adet küme elemanları arasından en sık temsil edilen gruba atanır. Böylece, yeni girdi en yakın sınıfa dahil edilmiş olur [26].

2.7. Sınıflandırma ve Performans Parametreleri (Parameters for Classification and Performance)

Veriler sınıflandırma performanslarının daha nesnel olarak değerlendirilmesi için, çapraz doğrulama yöntemi kullanılarak DVM, YSA ve k-NN ile sınıflandırılmıştır. Veri kümesi on parçaya ayrılmıştır. Veri setinin dokuz parçası eğitim için kullanılırken, geri kalan bir parçası test için kullanılmıştır. Bu işlem her parça için ayrı ayrı tekrarlanmış ve tüm parçalar hem eğitim hem de test verisi olacak şekilde kullanılmıştır. Tüm parçaların doğruluk değerleri hesaplandıktan sonra ortalaması alınmış ve ortalama doğruluk bulunmuştur. Tüm veriler MATLAB ortamında işlenmiştir.

Sınıflandırıcının performansını değerlendirmek için aşağıdaki üç gösterge kullanılmıştır; duyarlılık, özgüllük ve doğruluk. Bu üç gösterge, karışıklık matrisi kullanılarak hesaplanmıştır. Karışıklık matrisindeki dört değer şu şekilde tanımlanmıştır: Gerçek pozitif (TP), uygun şekilde tanımlanmış hastaların sayısı, yanlış negatif (FN) yanlış tanımlanmış hasta sayısı, gerçek negatif (TN), uygun şekilde tanımlanmış sağlıklı kişilerin sayısı ve yanlış pozitif (FP), yanlış tanımlanmış sağlıklı kişilerin sayısıdır. Duyarlılık, özgüllük ve doğruluk göstergeleri Eş. 18- Eş. 20'deki gibi tanımlanmıştır:

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \times 100 \quad (18)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \times 100 \quad (19)$$

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \times 100 \quad (20)$$

3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Kolon kanseri hastalarının ve sağlıklı kişilerin FTIR sinyalleri 1800-1000 cm^{-1} aralığında analiz edilmiştir. FTIR sinyalinin bu aralıkta incelenmesinin nedeni, kanser tespitinde kullanılan önemli moleküllerin bu aralıkta olmasındandır [3]. Kan örnekleri üzerinde yapılan önceki çalışmalarda, numuneler kurutulmuş ve bazı tepeler ortaya çıkmıştır [3, 5, 6]. Bu tepe değerleri kullanılarak kanser ve normal ayrımı yapılmıştır. Bununla birlikte, bu çalışmada, plazma örneklerinin kurumasına gerek kalmadan kan örneklerinin FTIR ölçümleri alınmış ve önceki çalışmaların aksine, FTIR sinyalleri DD ile alt bantlara ayrılmıştır. Db2-20, coif2-5 ve sym2-20 dalgacık tiplerinin tümü alt bant ayrıştırma işlemleri için ayrı ayrı incelenmiştir. FTIR sinyalinden özellik çıkarımı için üç aralık kullanılmıştır. Bunlar 1800-1000 cm^{-1} , 1800-1300 cm^{-1} ve 1300-1000 cm^{-1} 'dir. Buradaki amaç sinyaldeki değişimin belirli bir aralıkta yoğunlaşmış yoğunlaşmadığını belirleyebilmek içindir. Üç ayrı sınıflandırıcı ile gerçekleştirilen sınıflandırmaya ait sonuçlar Tablo 3 ve Tablo 4'te gösterilmektedir.

1800-1300 cm^{-1} aralığında en iyi sınıflandırma sonucu k-NN ile %91,42'dir. 1300-1000 cm^{-1} aralığında en iyi sonuç DVM ile %85,71'dir. Dalgacık dönüşümü sonucu elde edilen özellikler 1800-1300 cm^{-1} aralığında daha belirgindir. Tablo 3 incelendiğinde 1800-1300 cm^{-1} aralığında, 1300-1000 cm^{-1} aralığına göre daha iyi bir sınıflandırma sonucuna ulaşılmıştır. Bu durum, 1800-1300 cm^{-1} aralığında sinyalin daha ayırt edici özellikler içerdiğini göstermektedir. Ayrıca, en yüksek doğruluk değerlerine coif3, db10 ve db12 dalgacık türlerinde ulaşılmıştır. Bu durum ise, işaretin bu dalgacık türlerine daha fazla benzer olduğu göstermektedir [27]. Tablo 4'e bakıldığında ise, FTIR sinyalinin tek parça olarak incelenmesi sonucu, doğruluk değerlerinin daha yüksek çıktığı görülmektedir. Özellik çıkarımı esansında sinyalin tek parça olarak değerlendirilmesi çıkarılan özelliklerin etkinliğinin artmasını sağlamıştır. Elde edilen sonuçlar Tablo 3 ile karşılaştırıldığında, sinyali parçalara bölerek yapılan bir

Tablo 3. 1800-1300 cm^{-1} ve 1300-1000 cm^{-1} aralığında en iyi sınıflandırma sonuçları. Kısaltmalar; Duy: Duyarlılık, Özg: Özgüllük, Doğ: Doğruluk

(Best classification results in 1800-1300 cm^{-1} and 1300-1000 cm^{-1} ranges. Duy: Sensitivity, Özg: Specificity, Doğ: Accuracy)

Aralık	Sınıflandırıcı	Dalgacık Türü	Duy(%)	Özg(%)	Doğ(%)
1800-1300 cm^{-1}	DVM	db14	88,88	86,04	87,14
	YSA	db14	82,75	85,36	84,28
	k-NN	coif3	92,85	90,47	91,42
1300-1000 cm^{-1}	DVM	db10	85,71	85,71	85,71
	YSA	coif2	82,75	85,36	84,28
	k-NN	db10	78,78	89,19	84,28

özellik çıkarma işleminin, sinyalin bir bütün olarak incelenmesine göre daha az etkili olduğunu göstermiştir. Tablo 4'teki sınıflandırma sonuçlarına göre en yüksek doğruluğa DVM'nin RBF çekirdek fonksiyonu ile ulaşılmıştır. DVM parametrelerinden C ise $[10^{-3}, \dots, 10^{+3}]$ aralığında incelenmiştir. En yüksek doğruluk $C=1000$ ile elde edilmiştir. K-NN sınıflandırıcı için k parametresi ise $[1, \dots, 20]$ aralığında incelenmiştir. Tablo 3 ve 4'te verilen k-NN sonuçları $k=1$ değeri için en yüksek sonuçları vermiştir.

Tablo 4. 1800-1000 cm^{-1} aralığında en iyi sınıflandırma sonuçları (Best classification results in 1800-1000 cm^{-1} range)

Sınıflandırıcı	Dalgacık türü	Duy (%)	Özg (%)	Doğ (%)
DVM	db12	96,67	97,50	97,14
YSA	db14	93,33	95,00	94,29
k-NN	coif3	90,00	92,50	91,42

Kandan hastalık veya kanser belirlenmesine yönelik çalışmalar genellikle, kan örneklerinin kurutulmasından sonra elde edilen tepe değerleri kullanılarak yapılmıştır. Örneğin, Wang vd. [6] ve Sheng vd. [5] FTIR sinyalinin tepe oranlarını hesaplamış ve bu oranları kullanarak hasta ve sağlıklı ayrımını gerçekleştirmiştir. Ahmed vd. [28], değişken bölgelerdeki Parkinson Hastalığı ile normal arasındaki sınıflandırma kabiliyetini belirlemek için YSA'ya giriş parametresi olarak 10 tepe değeri, yaş, eğitim ve cinsiyet parametrelerini vermiştir. Ostrovsky vd. [3], önceki çalışmaların aksine, sadece belirli biyo belirteçleri kullanmak yerine, plazmadaki biyokimyasal bilgiden de yararlanmışlardır. Bu nedenle, PCA ve FLDA ile belirli bir spektral aralıktan özellik çıkarma ve sınıflandırma gerçekleştirmiştir. Böylece, tüm spektrumdaki bilgilerden yararlanılmış ve aynı zamanda, boyut küçültme yoluyla verinin daha küçük bir şekilde temsil edilmesini sağlamıştır.

Önceki çalışmalar incelendiğinde görüldüğü gibi, kan örneklerinin kuruması için belirli bir süre beklenmektedir. Önerilen çalışmada ise, plazma numuneleri kurutulmadan

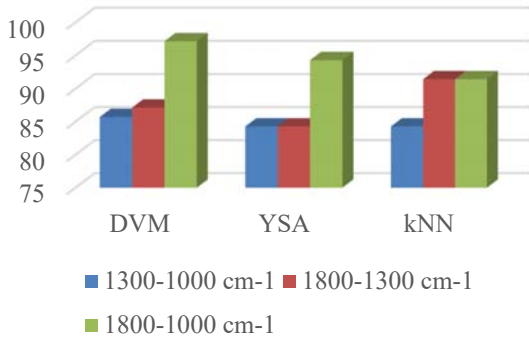
FTIR sinyalleri elde edilmiş ve kanser/normal ayrımı doğrudan bu sinyaller üzerinden yapılmıştır. Bu nedenle, mühendislik temelli bir yaklaşımla sinyal bir bütün olarak incelenmiştir ve ardından bilgi tüm sinyalden çıkarılmıştır. Literatürdeki çalışmalardan farklı olarak sadece belirli tepe değerleri incelenerek bir sınıflandırma işlemi gerçekleştirilmemiştir. Böylece sinyaldeki bütün dalga boyu değerlerinin sınıflandırma üzerindeki etkisi korunmuştur.

Kandan kolon kanseri belirlenmesi ile ilgili çalışmalar Tablo 5'da gösterilmektedir. Barlev vd. [7], bir saatlik kuruma süresi geçtikten sonra plazma ve periferik kan mononükleer hücrelerinin (PBMC) FTIR ölçümlerini yapmış ve 1800-700 cm^{-1} spektral bölgesini incelemiştir. Özellikler, PCA yöntemi ile plazma (11 özellik) ve PBMC'den (13 özellik) çıkarılmıştır. Daha sonra hastalar ve sağlıklı kişiler arasında ayırım yapmak için diskriminant analizi gerçekleştirilmiştir. Sonuç olarak kolon kanseri hastaları ve sağlıklı bireyler %81,5 duyarlılık ve %71,4 özgüllük ile sınıflandırılmıştır. Toraman vd. [29], ham FTIR sinyalinden istatistiksel özellikleri çıkarmıştır. FTIR sinyalinden altı farklı istatistiksel özellik elde edilmiş ve incelenmiştir. %88,72 doğruluğa ulaşmıştır. Ayrıca, [30] çalışmasının FTIR sinyalinde çeşitli istatistiksel özellikler çıkarılmış ve bu özellikler DVM ve YSA kullanılarak sınıflandırılmıştır. Mevcut çalışmada ise, [30] çalışmasının aksine, FTIR sinyali dalgacık dönüşümü kullanılarak alt bantlarına ayrıştırılmış ve yedi farklı istatistiksel özellik çıkarılmıştır. Böylece, sinyalin alt bantları da incelenmiştir. Daha sonra üç farklı sınıflandırıcı ile elde edilen özellikler sınıflandırılmıştır. [31] çalışmasında FTIR sinyalleri derin öğrenme yöntemi kullanılarak özellik çıkarımı gerçekleştirilmiştir. Özellik çıkarımı için öncelikle FTIR sinyalleri spektrogram görüntüsüne dönüştürülmüştür. Önceden eğitilmiş derin öğrenme modellerinden AlexNet ile spektrogram görüntülerinden özellikler çıkarılmıştır. Yapılan çalışma ile %89,44'lük doğruluk değerine ulaşılmıştır. Sonuç olarak, mevcut çalışma ile önceki çalışmalardan daha yüksek doğruluk değerleri elde edilmiştir. Kandan kolon kanserinin

Tablo 5. Kan örnekleri kullanarak kolon kanseri ile ilgili çalışmaların karşılaştırılması (Comparison of studies on colon cancer using blood samples)

Yazarlar	Tür	Hasta ve sağlıklı sayısı	Kullanılan özellikler ve algoritmalar	Sonuçlar (%)
Barlev vd. [7]	Kolorektal kanser	34+10, 18	PCA, FLDA, Quadratic Discrimination Analysis	AUC: 0,77 Duy: 81,50 Özg: 71,40
Toraman vd. [29]	Kolon kanseri	30, 40	İstatistiksel Özellik çıkarımı, YSA, DVM	Duy: 83,33 Özg: 92,50 Doğ: 88,72
Toraman vd. [31]	Kolon kanseri	30, 40	Evrişimsel Sinir Ağları, Spektrogram, DVM	Duy: 88,75 Özg: 90,00 Doğ: 89,44
Toraman vd. [30]	Kolon kanseri	30, 40	İstatistiksel Özellik çıkarımı, YSA, DVM	Duy: 93,33 Özg: 97,50 Doğ: 95,71
Önerilen yöntem	Kolon kanseri	30, 40	DD, İstatistiksel Özellik çıkarımı, k-NN, YSA, DVM	Duy: 96,67 Özg: 97,50 Doğ: 97,14

belirlenmesine yönelik yapılan çalışmalar Tablo 5'da karşılaştırmalı olarak verilmiştir. FTIR sinyalinin dört alt-bant grubuna ayrılmasından kaynaklanan ek özellik bilgilerinin varlığı, sınıflandırma performansını arttırmıştır. 1800-1000 cm^{-1} aralığında en iyi performans gösteren sınıflandırma, DVM ile yapılmıştır. DVM parametrelerinin esnekliği nedeniyle, FTIR sinyalinden çıkarılan özellikleri diğer sınıflandırıcılardan daha iyi bir şekilde ayırt edebilmiştir. Elde edilen en iyi doğruluk sonuçları Şekil 5'te gösterilmiştir.



Şekil 5. DVM, YSA ve k-NN'nin sınıflandırma doğrulukları (Classification accuracy of SVM, ANN and k-NN)

4. SİMGELER (SYMBOLS)

x	: spektrumun en küçük değeri
x_2	: x 'in yeni değeri
x_1	: amid II'nin değeri
a	: ölçek parametresi
z	: konum parametresi
ψ	: ana dalgacık fonksiyonu
t	: zaman
$x(n)$: sinyal
$g(n)$: alçak geçiren filtre
$h(n)$: yüksek geçiren filtre
ca	: yaklaşık katsayısı
cd	: detay katsayısı
p_i	: olasılık fonksiyonu
x_i	: eğitim veri kümesi
y_i	: etiket
R^d	: d boyutlu uzay
w	: ağırlıklar
b	: bias
L	: Lagrange fonksiyonu
α	: Lagrange çarpanı
$f(x)$: karar fonksiyonu
k	: komşu veri sayısı

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, kolon kanserinin FTIR sinyallerinden belirlenmesi için basit ve hızlı bir yöntem önerilmiştir. Sinyallerin alt bantları, FTIR sinyallerinin benzerliğinden kaynaklanan zorlukların üstesinden gelmek için kullanılmıştır. Sinyalden elde edilen özelliklerle hızlı bir

sınıflandırma işlemi gerçekleştirilmiştir. Tedavide erken teşhisin önemi göz önüne alındığında, hızlı ve etkili karar alma yöntemlerinin önemi daha iyi anlaşılmaktadır. Bu çalışmada, literatürdeki çalışmalardan farklı olarak plazma numunesi sıvı halde ölçülmüştür. Sıvı ölçüm ile daha hızlı bir karar verme süresine ulaşılmıştır. FTIR ölçümü yapılırken, suyun plazma üzerindeki etkisi göz ardı edilmiştir. Bu nedenle, gelecekteki çalışmalarda araştırmacılar, suyun etkisinin daha iyi anlaşılabilmesi için, suyu numunelerden uzaklaştırıldıktan sonra FTIR ölçümünü gerçekleştirmeyi planlamaktadır. Ayrıca bu çalışmada kimyasal bağlar kullanılarak gerçekleştirilen sınıflandırma çalışmalarının aksine, mühendislik tabanlı bir yaklaşım ile kolon kanseri ve sağlıklı kişilerin FTIR sinyalleri arasında çeşitli istatistiksel özellikler ile bir ayırımı yapılabileceği noktasına odaklanılmıştır. Ayrıca, mevcut ön çalışmanın sonuçlarının geçerliliğini ve güvenilirliğini değerlendirmek için örneklem hacminin artırıldığı daha fazla çalışmaya ihtiyaç vardır. Bu çalışmada elde edilen sonuçların farklı kanser türlerini belirlemeye yönelik araştırmalar için farklı bir bakış açısı sunacağına umuyoruz.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Kan örneklerinin toplanmasındaki katkılarından dolayı Fırat Tıp Merkezi Genel Cerrahi Anabilim Dalı'ndan, Doç. Dr. Mustafa Girgin'e ve plazma numunelerinin elde edilmesindeki katkılarından dolayı Fırat Üniversitesi Tıp Fakültesi Tıbbi Biyokimya Anabilim Dalı'ndan Prof. Dr. Bilal Üstündağ'a teşekkür ediyoruz. Ayrıca, bu araştırma çalışmasının yürütülmesinde işbirliği ve yardımlarından dolayı Fırat Üniversitesi Hastanesi Merkez Laboratuvarı ve Bingöl Üniversitesi Merkez Laboratuvarı Uygulama ve Araştırma Merkezi'ne de teşekkür ediyoruz.

KAYNAKLAR (REFERENCES)

1. Türkiye İstatistik Kurumu, Ölüm Nedeni İstatistikleri. <http://www.tuik.gov.tr/PdfGetir.do?id=27620>, Erişim tarihi:09.01.2019.
2. Erukhimovitch, V., Talyshinsky, M., Souprun, Y., Huleihel, M., FTIR spectroscopy examination of leukemia patients plasma. *Vib Spectrosc.* 40 (1), 40-46, 2006.
3. Ostrovsky, E., Zelig, U., Guskova, I., Ariad, S., Mordechai, S., Nisky, I., Kapilushnik, J., Detection of cancer using advanced computerized analysis of infrared spectra of peripheral blood. *IEEE Trans Biomed Eng.* 60 (2), 343-353, 2013.
4. Sheng, D., Liu, X., Li, W., Wang, Y., Chen, X., Wang, X., Distinction of leukemia patients' and healthy persons' serum using FTIR spectroscopy. *Spectrochim Acta - Part A Mol Biomol Spectrosc.* 101, 228-232, 2013.
5. Sheng, D., Wu, Y., Wang, X., Huang, D., Chen, X., Liu, X., Comparison of serum from gastric cancer patients and from healthy persons using FTIR spectroscopy. *Spectrochim Acta - Part A Mol Biomol Spectrosc.* 116, 365-369, 2013.

6. Wang, X., Shen, X., Sheng, D., Chen, X., Liu, X., FTIR spectroscopic comparison of serum from lung cancer patients and healthy persons. *Spectrochim Acta - Part A Mol Biomol Spectrosc.* 122, 193-197, 2014.
7. Barlev, E., Zelig, U., Bar, O., Segev, C., Mordechai, S., Kapelushnik, J., Nathan, I., Flomen, F., Kashtan, H., Dickman, R., Madhala-Givon, O., Wasserberg, N., A novel method for screening colorectal cancer by infrared spectroscopy of peripheral blood mononuclear cells and plasma. *J Gastroenterol.* 56-78, 2015.
8. Cheng, CG., Tian, YM., Jin, WY., A study on the early detection of colon cancer using the methods of wavelet feature extraction and SVM classifications of FTIR. *Spectroscopy.* 22 (5), 397-404, 2008.
9. Toraman, S., Kızılötesi Spektroskopisi Kullanılarak Kan Örneklerinden Kolon Kanserine Yönelik Özellik Çıkarımı. Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2016.
10. Akansu, AN., Serdijn, WA., Selesnick, IW., Emerging applications of wavelets: A review. *Phys Commun.* 3 (2), 1-18, 2010.
11. Aydın, F., Aslan, Z., Diagnosis of neuro degenerative diseases using machine learning methods and wavelet transform. *Journal of the Faculty of Engineering and Architecture of Gazi University.* 32 (3), 749-766, 2017.
12. Haşiloğlu, A., Rotation-Invariant Texture Analysis and Classification by Artificial Neural Networks and Wavelet Transform. *Turkish J Eng Environ Sci.* 25 (5), 405-413, 2001.
13. Phinyomark, A., Hirunviriyaya, S., Limsakul, C., Phukpattaranont, P., Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation. *Electrical Engineering/Electronics Computer Telecommunications and Information Technology (ECTI-CON), 2010 International Conference on.* Chiang Mai, Thailand, 856-860, 19-21 May, 2010.
14. Phinyomark, A., Limsakul, C., Phukpattaranont, P., A Novel Feature Extraction for Robust EMG Pattern Recognition. *J Comput.* 1 (1), 71-80, 2009.
15. Vigneshwari, C., Vimala, V., Vignesh, SV., Sumithra, G., Analysis of Finger Movements Using EEG Signal. *Int J Emerg Technol Adv Eng.* 3 (1), 583-588, 2013.
16. Ghahdarjani, AM., Hormozi, F., Asl, AH., Convective heat transfer and pressure drop study on nanofluids in double-walled reactor by developing an optimal multilayer perceptron artificial neural network. *Int Commun Heat Mass Transf.* 84, 11-19, 2017.
17. Atanassov, K., Sotirov, S., Index matrix interpretation of the Multilayer perceptron. 2013 IEEE International Symposium on Innovations in Intelligent Systems and Applications, IEEE INISTA 2013. Albena, Bulgaria, 1-3, 19-21 June, 2013.
18. Subasi, A., Ercelebi, E., Classification of EEG signals using neural network and logistic regression. *Comput Methods Programs Biomed.* 78, 87-99, 2005.
19. Khazae, A., Ebrahimzadeh, A., Classification of electrocardiogram signals with support vector machines and genetic algorithms using power spectral features. *Biomed Signal Process Control.* 5 (4), 252-263, 2010.
20. Kharat, PA., Dudul, S V., Daubechies Wavelet Neural Network Classifier for the Diagnosis of Epilepsy. *WSEAS Trans Biol Biomed.* 9 (4), 103-113, 2012.
21. Ayhan, S., Erdoğan, Ş., Kernel Function Selection for the Solution of Classification Problems via Support Vector Machines. *Eskişehir Osmangazi Univ J Econ Adm Sci.* 9 (1), 175-198, 2014.
22. Akbari, A., Arjmandi, MK., Employing linear prediction residual signal of wavelet sub-bands in automatic detection of laryngeal pathology. *Biomed Signal Process Control.* 18, 293-302, 2015.
23. Yücesoy, E., V. Nabiye, V., Determination of a speaker's age and gender with an SVM classifier based on GMM supervectors. *Journal of the Faculty of Engineering and Architecture of Gazi University.* 31 (3), 501-509, 2016.
24. Osuna, E., Freund, R., Girosi, F., Support Vector Machines : Training and Applications. Massachusetts Inst Technol. 9217041 (1602), 1997.
25. Kavzoğlu, T., Çölkesen, İ., Investigation of the Effects of Kernel Functions in Satellite Image Classification Using Support Vector Machines. *Harit Derg.* 144, 73-82, 2010.
26. Duda, RO., Hart, PE., Stork, DG., Pattern Classification, Second Edition, Wiley-Interscience publication, 2000
27. Ngui, WK., Leong, MS., Hee, LM., Abdelrhman, AM., Wavelet Analysis: Mother Wavelet Selection Methods. *Appl Mech Mater.* 393, 953-958, 2013.
28. 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.* 53 (2), 181-188, 2010.
29. Toraman, S., Türkoğlu, İ., A New Automatic Recognition Method for Determine Colon Cancer from FTIR Sign Patterns. *Kilis, Turkey, 2354-2361, 19-20 March, 2016.*
30. Toraman, S., Girgin, M., Üstündağ, B., Türkoğlu, İ., Classification of the Likelihood of Colon Cancer With Machine Learning Techniques Using FTIR Signals Obtained From Plasma. *Turkish J Electrical Engineering Comput Sciences.* doi: 10.3906/elk-1801-259.
31. Toraman, S., Türkoğlu, İ., Derin Öğrenme ile FTIR Sinyallerinden Kolon Kanseri Riskinin Belirlenmesi. *Fırat Üniversitesi Mühendislik Bilim Derg.* 30 (3), 115-120, 2018.