

## Dokunsal Sensör Sinyalleri ile Yüzey Dokularının Sınıflandırılması

### Surface Textures Classification with Tactile Sensor Signals

Cemil KILIÇ<sup>1</sup> , Ömer Faruk ALÇİN\*<sup>2</sup> , Muzaffer ASLAN<sup>3</sup> 

<sup>1</sup> Fen Bilimler Enstitüsü, Turgut Özal Üniversitesi, Malatya, Türkiye

<sup>2</sup>Yazılım Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

<sup>3</sup>Elektrik-Elektronik Mühendisliği Bölümü, Bingöl Üniversitesi, Bingöl, Türkiye

(cemilk1212@gmail.com, omer.alcin@inonu.edu.tr, muzfferaslan@bingol.edu.tr)

Received:Dec.04,2024

Accepted:Dec.14,2024

Published:Dec.25,2024

**Özetçe**— Dokunsal algılama, robotik ve protez teknolojilerinde çevresel etkileşimleri hassas bir şekilde yönetmek için kritik bir role sahiptirler. Bu alandaki önemli araştırma konularından biri yüzey tanımlamadır. Yüzeylerin doku özelliklerini anlamak amacıyla insan doku tanıma sistemleri yapay parmak yapıları kullanılarak modellenir. Bu modellemede, yüzeylere içsel ölçüm birimleri yerleştirilir ve bu birimler yüzeyde titreşim oluşturarak çeşitli elektriksel sinyaller toplar. Toplanan sinyaller, sinyal işleme ve örüntü tanıma teknikleri ile analiz edilip sınıflandırılır. Bu çalışmada, titreşimli dokunsal uyarıcı bir gömülü sistemden elde edilen 12 farklı dokuya ait sinyaller sınıflandırılması amaçlanmıştır. Deneysel çalışmalarda öznitelik çıkarımı için %50 oranında örtüşen kayan pencere yaklaşımı ile her bir pencerenin istatistiksel (ortalama, medyan) ve spektral (düzlük, merkez) değerler dizisi kullanılmıştır. Daha sonra bu öznitelikler dizisi doku sınıflandırılması için Destek Vektör Makinesi (DVM) ve k- En Yakın Komşu (k-EYK) sınıflandırıcılara girdi olarak uygulanmıştır. Deneysel sonuçlar DVM ve k-EYK sınıflandırıcı modellerinde sırasıyla %94,79 ve %95,83 sınıflandırma doğruluğu elde edilmiştir. Mevcut çalışmalar ile kıyaslandığında doğruluk açısından %4,69 daha yüksek performans elde edilmiştir.

**Anahtar Kelimeler** : Dokunsal sensör, Sinyal işleme, Doku sınıflandırma.

**Abstract**— Tactile sensing plays a critical role in robotics and prosthetic technologies for precisely managing environmental interactions. One of the significant research topics in this field is surface characterization. To understand the texture properties of surfaces, human tactile recognition systems are modeled using artificial finger structures. In this modeling process, intrinsic measurement units are embedded into surfaces, and these units generate vibrations on the surface to collect various electrical signals. The collected signals are analyzed and classified using signal processing and pattern recognition techniques.

In this study, the classification of signals from 12 different textures obtained from a vibrational tactile stimulator embedded system is targeted. For feature extraction in the experimental studies, a sliding window approach with 50% overlap was employed, using statistical (mean, median) and spectral (flatness, centroid) value sequences for each window. These feature sequences were then applied as input to Support Vector Machine (SVM) and k-Nearest Neighbor (k-NN) classifiers for texture classification. Experimental results demonstrated classification accuracies of 94.79% and 95.83% for the SVM and k-NN classifiers, respectively. Compared to existing studies, the proposed method achieved a 4.69% improvement in accuracy.

**Keywords** : Tactile sensor, Signal processing, Texture classification.

### 1. Giriş

Son yıllarda, bilim ve teknolojinin gelişmesine paralel olarak insan-bilgisayar etkileşimi, yapay zeka, giyilebilir cihazlar ve akıllı algılama teknolojilerinde önemli gelişmeler sağlandı. Bu gelişimler, günlük yaşantımızın her alanında köklü değişikliklere yol açtı. İnsan-bilgisayar etkileşimi, kullanıcı deneyimlerini daha da geliştiren ve yapay zeka destekleri ile kullanıcı arayüzlerini daha sezgisel hale getiren yenilikçi çözümler sunarak, teknolojinin herkes tarafından daha kolay ve verimli bir şekilde kullanılmasını sağladı. Özellikle giyilebilir cihazlar

teknolojilerindeki gelişmeler bireylerin sağlık ve yaşam kalitelerini sürekli olarak izlemelerini mümkün kıldı (Peng et al. 2021).

Bu gelişmeler; akıllı robot geri bildirim sistemlerine ve çeşitli dönüştürme mekanizmalarına dayanan dokunsal algılama sistemlerine olan ilginin de artırmasına öncülük etmektedir. Özellikle, akıllı robot teknolojileri, kullanıcılara gerçek zamanlı geri bildirim sağlayarak, etkileşimlerini daha doğal ve sezgisel hale getirmektedir. Bu sistemler, robotların insan hareketlerini ve tepkilerini anlamalarına ve buna uygun şekilde yanıt vermelerine olanak tanır, böylece daha uyumlu ve etkili bir insan-robot etkileşimi sağlanmaktadır. Dokunsal algılama sistemleri, fiziksel temas ve kuvvet geri bildirimleri kullanarak, kullanıcıların sanal ortamlarla etkileşimlerinde daha gerçekçi ve tatmin edici deneyimler yaşamalarını mümkün kılan rehabilitasyon ve tıp alanında da önemli sistemlerin gelişimini sağlayarak hastaların tedavi süreçlerini daha etkili kılmaktadır (Chi et al. 2018). Ayrıca, dokunsal algılama robotik ve protez araştırma alanlarında önemli katkılar sunmaktadır (Alves de Oliveira, Cretu, and Petriu 2017).

Dokunsal algılamada, kullanılan malzemenin doku, sertlik, pürüzlülük gibi özelliklerinin bilinmesi büyük önem taşır. Bu özellikler, robotların ve protezlerin objeleri doğru bir şekilde kavrayabilmesi ve etkileşimde bulunabilmesi için kritik veriler sağlar. İnsanda doku tanıma süreci, genellikle derinin yüzeye dokunması veya derinin yüzey üzerinde mikro titreşimler oluşturacak şekilde kaydırılması ile gerçekleştirilir. Bu süreç, insanın dokuları ve yüzeyleri anlamasında önemli bir rol oynar ve bu anlayış, robotik sistemler için daha gelişmiş dokunsal algılama teknolojilerinin tasarlanmasına önemli katkılar sağlamaktadır. İnsanın bu algılama yeteneği, robotlara benzer bir kapasite kazandırmak için kullanılan sensörler ve yapay cilt teknolojileri ile simüle edilerek, gerçek dünyadaki dokusal özelliklerin daha hassas bir şekilde algılanmasını mümkün kılmaktadır. (Kursun and Patooghy, 2020; Rocha Lima *et al.*, 2020). Tüm bu gelişmeler araştırmacıların, protez geliştirme ve gelişen robotik iş gücü talebindeki dokunsal algılamaya olan ilgiyi artırmaktadır. Son yıllarda yapılan bazı çalışmalar aşağıda verilmiştir.

Sinapov ve diğ., yüzey dokularının tanımlamak için insansı robotlar tarafından dokunsal algı yöntemi kullanılmıştır. Üç eksenli ivmeölçer sensör takılı robotun tırnakları ile beş farklı keşif yaparak 20 farklı yüzey test edebiliyor. DVM ve K-En Yakın Komşu (k-EYK) makine öğrenme algoritmaları tarafından tanımlanıp sınıflandırılan ivmeölçer titreşimleri ile doğruluk oranı %80 olmuştur. Test yüzeyine uygulanan birden çok çizilme davranışı yüksek tanıma oranı sağlamaktadır (Sinapov et al. 2011).

Fishel ve Loeb, farklı normal kuvvet ve hız kombinasyonları kullanılarak her bir dokusal özellik için en etkili ölçüm yöntemleri tanımlanmıştır. Bu yöntemlerin doğruluğu, benzer doku çiftlerini ayırt etme konusunda oldukça yüksektir. Araştırmalar, %99.6 gibi olağanüstü yüksek bir doğruluk oranı elde ettiğini göstermiştir. Bu sonuç, insan dokunsal yeteneklerinin ötesinde bir performansı ifade eder ve dokusal farklılıkların belirlenmesinde ileri düzey bir hassasiyet sağlar. Çalışma ayrıca, 117 dokudan oluşan bir setin mutlak sınıflandırılmasında yapılan testlerde, genellikle az sayıda iyi seçilmiş keşif hareketinin yeterli olduğunu göstermiştir. Medyan değeri 5 olarak belirlenen bu hareket sayısı, %95.4'lük bir başarı oranı ile doğru dokusal sınıflandırma sağlamıştır. Bu sonuçlar, etkili doku algılamının ve sınıflandırmanın, minimum sayıda ama doğru seçilmiş hareketlerle gerçekleştirilebileceğini ortaya koymaktadır. Bu bulgular hem endüstriyel hem de akademik araştırmalarda dokunsal algılamının gelişmiş uygulamaları için değerli bilgiler sunmuştur (Fishel and Loeb 2012).

De Oliveira ve diğ., yüzeyi tanımak için kullanılan robotik parmağı dört motor ve en son motorda bulunan atalet ölçüm birimi (AÖB)'den oluşan bir sistem önerilmiştir. Yumuşak ve sert uçlarla parmaktan alınan veriler sinir ağında işlendikten sonra yedi farklı yüzeyin tespiti %97'lik bir doğrulukla gerçekleştirilmiştir (De Oliveira et al. 2015).

Oliveira ve diğ., çıkıntılı yüzeylerle temas halinde olan yeni bir biyolojik dokunsal prob tarafından alınan sinyalleri izleyerek yüzey karakterizasyonu sorununu değerlendirmektedirler. Bu amaçla, dokusal algılama hassasiyetini ve doğruluğunu artırmayı sağlayabilecek manyetik açılabilir hız ve yerleşim ünitesinin titreşimini destekler ve parmak ucuna uygulanan kuvvetlerin etkili bir şekilde derin basınç sensörü modülünden yararlanmışlardır. Modül, sensörlerin çeşitli yüzey türleri üzerindeki tepkilerini değerlendirmek amacıyla iki ayrı deneyde test edilmiştir. İlk deneyde, modülün içinde bulunan geleneksel sensörlerin, oluklu yüzeylerde belirli temel frekansta titreşimleri algılama yeteneği araştırılmıştır. Bu frekans aralığı 3.66 Hz ile 11.54 Hz arasında değişmekte olup, ölçümler sırasında elde edilen genel maksimum hata  $\pm 0.1$  Hz olarak belirlenmiştir. Bu bulgular, frekansların, modülün altında hareket ettirilen izgara desenleri üzerinde sabit bir oryantasyon, hız ve basınca bağlı olarak değiştiğini göstermektedir. Bu değişkenlerin, üç serbestlik dereceli robotik parmak kurulumunda sabit tutulmadığı için frekansların algılanmadığı ortaya konmuştur. İkinci deneyde ise, sensör modülünün robotik parmağın ucuna takıldığı durumlarda, yedi farklı kaba şekil üzerinde toplanan veriler detaylı bir şekilde analiz edilmiştir. Sonuçlar, farklı sensör türleri için elde edilen sınıflandırma doğruluklarının %85.1 ile %98.9 arasında değiştiğini ortaya koymuştur (Alves de Oliveira, Cretu, and Petriu 2017).

Kaboli ve Cheng, robotik sistemlerin dokunsal nesne tanımlarında nesnelere yüzey keşfinin süresinden bağımsız olarak sağlam dokunsal bilgi çıkarmasını sağlamak için bir dizi yeni dokunsal tanımlayıcı

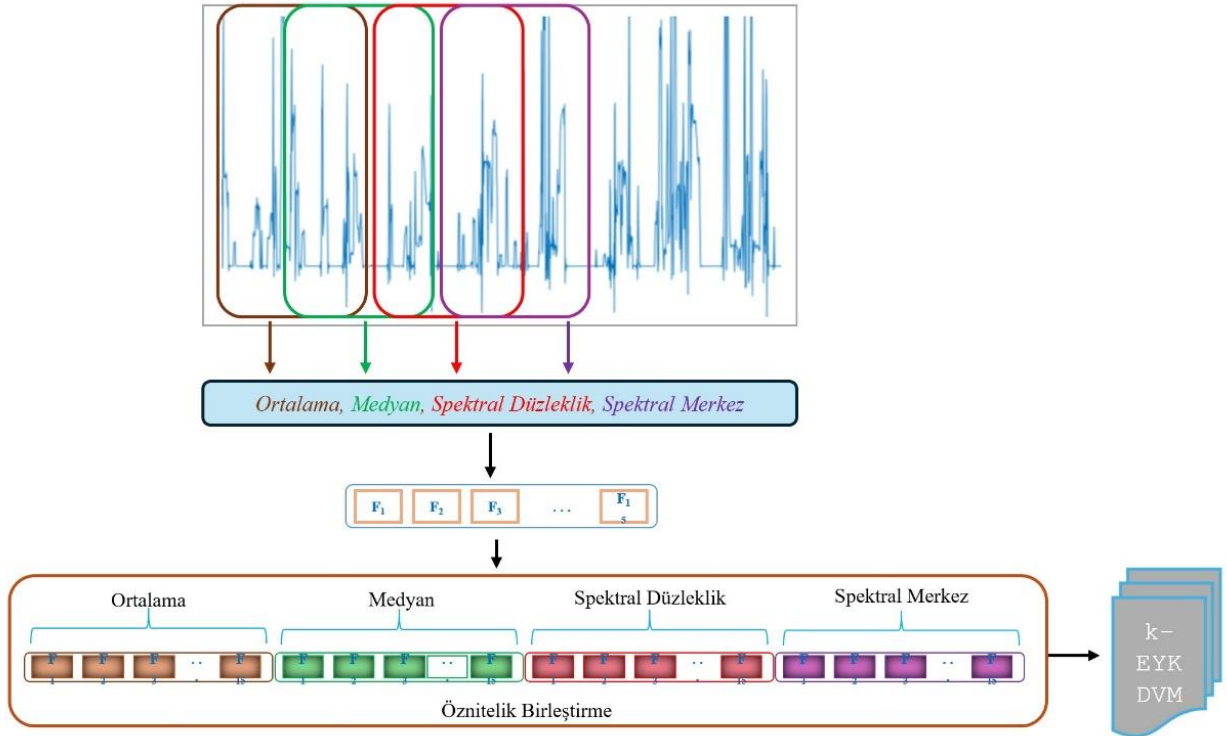
önermektedirler. Bu tanımlayıcılar, dinamik basınç sensörleri, ivmeölçerler, kapasitif sensörler ve empedans elektrot dizileri gibi farklı dokusal algılayıcıları içermektedir. Bu sensörler, dokusal tanımlayıcıların malzemeleri ve nesnelere algılama yeteneklerini test etmek için kullanılmıştır. Gölge El adı verilen bir dokusal tanımlayıcı, insan benzeri keşif hareketlerini gerçekleştirme yeteneği sayesinde, çeşitli dokusal özellikleri olan malzemeleri sınıflandırmada etkili olmuştur. Gölge El, 120 farklı malzemeyi dokusal özelliklerine göre %100 doğruluk oranıyla tanımlayabilmiştir. Ayrıca, 30 farklı el içi nesneyi de yüksek bir doğruluk oranıyla, yani %98 doğrulukla sınıflandırmıştır. Bu sonuçlar, Gölge El'in dokusal tanımlama görevlerinde son derece başarılı olduğunu ve dokusal algılama teknolojisinin ne kadar ileri bir düzeye ulaştığını göstermiştir (Kaboli and Cheng 2018).

Lima ve diğ., dokusal doku tanımda makine öğrenim yöntemlerinin performanslarını incelemişlerdir. Deneysel çalışmalarında, dokusal algılama özelliklerine sahip bir robot parmak ucu ve bir adım motoru kullanılmıştır. Deneyde kullanılan bu cihazlar, robot işletim sistem yazılımı yardımıyla merkezi bir kontrol sistemi ile yönetilmiştir. Elde edilen veriler, zamansal alanda analiz edilerek karar ağaçlar, rastgele orman ve destek vektör makine sınıflandırıcılara girdi olarak uygulanarak her bir sınıflandırıcının performansı değerlendirilmiştir. Karar ağaçları sınıflandırıcıda %95, rastgele orman sınıflandırıcıda %92 ve destek vektör makine sınıflandırıcıda %91 doğruluk performansına ulaşmışlar (Rocha Lima et al. 2020).

Lyu ve diğ., çok kanallı bir fiber Bragg ızgarası dokusal sensörü ve sıkıştırma uyarma (SE)-LSTM sınıflandırma derin öğrenme ağı kullanarak kavrayan nesnelere sınıflandıracak bir model önermektedirler. Ayrıca deney çalışmalarında, dokusal sinyali elde etmek için dalga boyu taramalı optik koherens tomografisinde yararlanarak, kavrama sürecine ilişkin veri dizisi için dokusal sensör sinyalini demodüle edilmiştir. Önerilen modele ait deneysel çalışmalarda %95,97 sınıflandırma doğruluğuna ulaştıkları görülmektedir (Lyu et al. 2022).

## 2. Materyal ve Yöntemler

Bu çalışmada, robotik ve protez çalışmalarının temelini oluşturan dokusal sensörlerden alınan yüzey dokularının k-EYK ve DVM gibi makine öğrenme yöntemleri sınıflandırılması yaklaşım sunulmaktadır. Genel çerçevesi Şekil 1'de verilen çalışma, iki aşamadan oluşmaktadır. İlk aşamada, dokusal sensörlerden alınan sinyaller %50 oranında örtüşen kayan pencere yaklaşımı ile pencerelere bölünür ve her pencerenin ortalama, standart sapma, spektral düzlük ve spektral merkez değerleri birleştirilerek zamansal özellikler oluşturulur. İkinci aşamada, bu zamansal özellikler birleştirilerek önerilen sınıflandırıcı modellerine uygulanarak sınıflandırılmaktadır.



Şekil 1. Önerilen modelin genel çerçevesi


## 2.1. Veri Seti

Lora-Rivera ve diğ., hazırlanan veri seti 12 farklı dokudan oluşmaktadır (Lora-Rivera, Oballe-Peinado, and Vidal-Verdú 2023). Veri seti oluşturulmasında hazırlanan düzenek için örneklem frekansı 485Hz olarak belirlenmiştir. Ayrıca düzenek 30m/s hızla hareket ettirilerek 200 kez tekrar edilmiştir. Toplamda veri setindeki 12 doku için (12x200) 2400 örnek veri alınmıştır. Ayrıca gerçek zamanlı her bir sinyal 16 bit uzunluğunda 2048 örneklili veri bir metin dosyasına kaydedilmiştir. Veri setindeki 12 yüzey dokusuna ait detaylar Tablo 1’de’de sunulmuştur.

**Tablo 1.** Veri seti doku bilgileri

Doku İsimleri	Kodu	Materyal	Modelleme
Doku 1	tex01	Filament-1 (Filaflex)	Chirp sinyali
Doku 2	tex02	Plastik-1	Kare Dalga (Uzaklığa bağlı)
Doku 3	tex03	Plastik-2	Kare Dalga (Uzaklığa bağlı)
Doku 4	tex04	Filament-2	Sinüzoidal sinyal
Doku 5	tex05	Filament-3	Sinüzoidal sinyal
Doku 6	tex06	Filament-4	Sinüzoidal sinyal
Doku 7	tex07	Metakrilat-1	Sinüs - Üçgen dalga sinyal
Doku 8	tex08	Metakrilat-2	Sinüs - Üçgen dalga sinyal
Doku 9	tex09	Metakrilat-1	Sinüs - Üçgen dalga sinyal
Doku 10	tex10	Kumaş-1	Belirgin örüntüye sahip olmayan sinyal
Doku 11	tex11	Kumaş-2	Belirgin örüntüye sahip olmayan sinyal
Doku 12	tex12	Kumaş-3	Belirgin örüntüye sahip olmayan sinyal

Tablo 1’ de görüleceği Doku 1, Doku 4, Doku 5 ve Doku 6 3-B yazıcılarda kullanılan Filament malzemelerdir. Doku 2 ve Doku 3 Poliaktik asit bileşiminden oluşan termoplastik polimer malzemedir. Doku 7, Doku 8 ve Doku 9 metakrilat asit içeriğinden oluşan reçine yapıya sahiptir. Geri kalan dokular ise üç farklı kumaş türleridir. Ayrıca Tablo 1’de veri seti materyallerin modellenmesinde kullanılan sinyal türleri görülmektedir. Veri setinin kullanılan malzemelerin dokusuna ilişkin görseller Şekil 2’de görülmektedir.



**Şekil 2.** Veri seti malzemelerinin dokusu

## 2.2. Özellik Çıkarım Yöntemleri

### 2.2.1. İstatiksel Yöntemler

Durağan ve durağan olmayan sinyal analizinde zaman, frekans bölgelerindeki sinyal özelliklerini anlamak ve analizi için istatiksel yöntemlerden yaygın olarak yararlanılmaktadır. Bu amaçla, dokunsal sinyallerden özellik çıkarımı için ortalama ve medyan özellikler kullanılmıştır. Bu iki istatiksel özellik, kabul edilebilir bir hassasiyet derecesiyle hemen hemen her veri dağılımını doğru bir şekilde karakterize edebilecek en önemli iki ölçümü oldukları için seçilmiştir.

Medyan ve ortalama özellikleri, özellikle medyan değeri veri setinin nasıl bir dağılıma sahip olduğuna ilişkin ölçümlerle birleştirildiğinde, verilerin doğası hakkında iyi bir gösterge sağlamaktadır (Siuly et al. 2019). Ortalama ve medyan değerleri sırasıyla Denklem 1 ve Denklem 2 verilmiştir.

$$\text{Ortalama} = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

$$\text{Medyan} = \begin{cases} x\left(\frac{N+1}{2}\right), & \text{N: tek ise} \\ \frac{x\left(\frac{N+1}{2}\right) + x\left(\frac{N}{2} + 1\right)}{2}, & \text{N: çift ise} \end{cases} \quad (2)$$

Denklem 1 ve 2'deki  $X$  veri setindeki her bir dokunsal sinyalini,  $N$  ise her bir dokunsal sinyaldeki örnek sayısını temsil etmektedir.

### 2.2.2. Spektral Yöntemler

Konuşma ve ses sinyali sınıflandırmasında yaygın olarak kullanılan spektral özellikler, son yıllarda dokunsal sinyaller gibi fizyolojik sinyal sınıflandırmasında da kullanılmaktadır (Hassan, Bashar, and Bhuiyan 2015). Spektral özellikler, sinyallerin genlik spektrumundan elde edilir ve bu özellikler sinyallerin tanımlanmasında ve ayırt edilmesinde önemli rol oynar. Ayrıca, sinyalin frekans bileşenlerinin özelliklerini özetleyerek, sinyalin genel yapısı hakkında bilgi verir (Hassan and Haque 2016). Sinyalin frekans içeriğinin çeşitli yönlerini analiz etmek için kullanılan ve sinyaller arasındaki farkları ayırt etmede önemli bilgiler sağlayan Spektral Merkez (SM) ve Spektral Düzlük (SD) dokunsal sinyallerin ayırt edici özelliklerin çıkarılmasını sağlamaktadır.

SM, spektrum üzerindeki kütle merkezini belirler ve bu sinyalin frekans bileşenlerinin dağılımının ortalama frekansını gösterir. Başka bir deyişle, SM, spektrumun frekans eksenindeki merkez noktasını temsil eder. Eğer SM'nin değeri yüksekse, bu durum sinyalin enerjisinin genellikle daha yüksek frekansta yoğunlaştığını gösterir. Yani, yüksek SM değeri, sinyalin daha yüksek frekans bileşenlerinin baskın olduğunu ve bu bileşenlerin sinyalin toplam enerjisinin büyük bir kısmını oluşturduğunu ifade eder (Kulkarni and Bairagi 2017).

SD, Zaman-Frekans Dağılımı (ZFD) içindeki enerji dağılımının ne kadar yoğun veya yayılmış olduğunu ölçen bir yaklaşımdır. Yüksek düzlük değeri, enerjinin ZFD'de eşit şekilde dağıldığını ve spektrumun düz bir yapıya sahip olduğunu gösterir. Buna karşın, düşük düzlük değeri, enerjinin ZFD içinde belirli bölgelere yoğunlaştığını ve spektrumda belirgin yoğunluk farklılıkları olduğunu belirtir (Boashash, Khan, and Ben-Jabeur 2015). Bu özellik, gürültü içeren bir sinyal bileşenlerinin zaman-frekans temsillerini, saf gürültünün zaman-frekans temsillerinden ayırt etmeyi sağlamaktadır. SD, bir sinyalin Fourier dönüşümünün genliklerinin geometrik ortalamaasının, aynı dönüşümün aritmetik ortalamaasına oranıdır. Bu oran, sinyalin frekans bileşenlerinin dağılımının ne kadar homojen olduğunu veya ne kadar düzensiz olduğunu belirlemede kullanılır (Boashash, Khan, and Ben-Jabeur 2015; Löfhede et al. 2010).

SM ve SD matematiksel bağıntıları sırasıyla Denklem 3, Denklem 4' de, görülmektedir.

$$SM = \frac{\sum_{n=0}^{N-1} n|Y(n)|}{\sum_{n=0}^{N-1} |Y(n)|} \quad (3)$$

$$SD = \frac{\prod_{n=0}^{N-1} |Y(n)|^{\frac{1}{N}}}{\frac{1}{N} \sum_{n=0}^{N-1} |Y(n)|} \quad (4)$$

Denklem 3 ve Denklem 4'teki  $N$  örnek sayısını,  $Y(n)$  ayrık fourier dönüşümünü temsil etmektedir.

## 2.3. Sınıflandırma Yöntemleri

### 2.3.1. k-En Yakın Komşu

k-En Yakın Komşu (k-EYK) denetimli öğrenme algoritmaları arasında bulunan ve parametrik model kullanmayan bir makine öğrenme tekniğidir. Bu algoritma, veri setinde yer alan her bir örneği sınıflandırırken, veri noktalarının etrafındaki komşularını temel alır ve belirli bir mesafe ölçütüne göre yakınlıklarını değerlendirir. Parametrik olmayan doğası, k-EYK'nin herhangi bir önceden belirlenmiş model veya dağılım varsayımına ihtiyaç duymadan doğrudan veri noktalarının birbirleriyle ilişkilerini kullanarak sınıflama yapmasına olanak tanır. Bu özellik, k-EYK'yi veri setinin doğrudan özelliklerine dayalı olarak sınıflandırma yapmak için esnek ve etkili bir yöntem haline getirir (Aslan and Nur Zurel 2022; Gupta et al. 2023). Başka bir ifadeyle, k-EYK algoritması, üzerinde çalıştığı verilerle ilgili önceden belirlenmiş bir varsayımda bulunmaz veya modelleme yapmaz. Bu algoritmanın temel prensibi, benzer özelliklere sahip veri noktalarının birbirine yakın konumlandığı varsayımına dayanmaktadır. Yani, k-EYK, verilerin sınıflandırılmasında, birbirine yakın olan verilerin genellikle benzer sınıf etiketlerine sahip olduğunu kabul eder ve bu yakınlık bilgilerini kullanarak yeni verileri sınıflandırır (Aslan and Nur Zurel 2022). Bu algoritmanın matematiksel temeli oldukça basittir. Ancak, k-EYK algoritmasını etkili bir şekilde kullanabilmesi üç ana bileşene bağlıdır. Bunların ilki, k değerinin belirlenmesidir. K değeri, algoritmanın değerlendireceği en yakın komşu sayısını ifade eder. İkinci olarak, mesafe ölçümleri kullanılarak veri noktaları arasındaki uzaklıklar hesaplanır. Yaygın olarak kullanılan mesafe ölçütleri arasında Öklid mesafe ve Manhattan mesafesi bulunmaktadır. Son olarak, k-EYK algoritması, çoğunluk oylaması yöntemine dayanır. Burada belirli bir veri noktasının sınıfını belirlemek için en yakın komşuların sınıf etiketlerinin çoğunluğu dikkate alınır (Gupta et al. 2023).

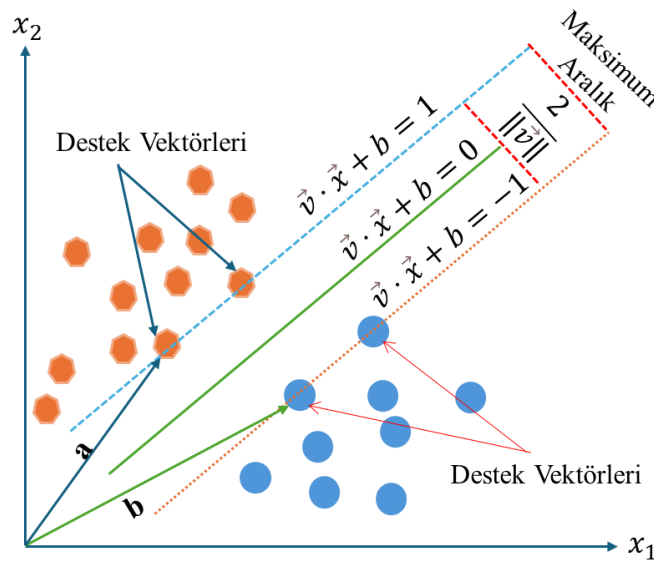
### 2.3.2. Destek Vektör Makinesi

DVM, doğrusal ve doğrusal olmayan verileri sınıflandırmak için yaygın olarak kullanılan basit ve son derece etkili bir yöntem olan istatistiksel öğrenme teorisine dayanan denetimli bir öğrenme algoritmasıdır (Vapnik 1999). DVM doğrusal sınıflandırıcının temel amacı, iki sınıf verisini ayırabilecek en uygun hiper düzlemi bulmaktır.  $y_n \in \{-1, 1\}$  ve  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$  sınıf etiketlerine sahip bir veri kümesi düşünün.  $x_n \in \mathbb{R}$ , n veri kümesindeki öge sayısını temsil eder. Dolayısıyla verileri ayırmak için çok fazla ayırım çizgisi çizilebilmesi, verileri iki sınıfa ayırma isteğinin bir sonucu olarak değerlendirilmektedir.

Bu verilerin sınıflandırılmasında optimal ayırım çizgisini tespit etmek her zaman kolay olmayabilir. DVM Şekil 3'te görüldüğü gibi iki sınıflı verileri sınıflandırırken birbirine en yakın sınıf noktalar arasındaki mesafeyi maksimize eden bir hiper düzlem bulmaktadır.

Şekil 3' de görülen vektör  $a'$  nın, hiper düzlemin normali (ağırlık vektörü)  $v$  olarak adlandırılabilir. Bu durumda,  $v$  ağırlık vektörü Şekil 3.' teki gibi hesaplanabilir. Buna göre, en iyi hiper düzlemi belirlemek için kullanılacak karar fonksiyonları Denklem 5'teki gibi yazılabilir. Böylece iki sınıflı verimizi ayırmak daha etkili bir şekilde gerçekleştirilebilir.

$$\begin{aligned} v \cdot x_i + b &\geq 1, & \text{her } y &= +1 \\ v \cdot x_i + b &\leq -1, & \text{her } y &= -1 \end{aligned} \quad (5)$$



Şekil 3. En iyi hiper düzlem ve marj gösterimi



Denklem 5' deki  $b$  sapma (a ve b vektörleri arasındaki açı) değerini temsil etmektedir. Sınıf etiketleri göz önünde bulundurularak Denklem 5 düzenlendiğinde ve kısıtlamalar ile Denklem 6 gibi yazılabilir.

$$y_i \cdot (v^T \cdot x_i + b) \geq 1 \quad (6)$$

Ayrıca DVM'deki hiper düzlemler arasındaki mesafenin maksimum olabilmesi ancak  $\|v\|$  değerinin en küçük değer alması ile sağlanabilecektir (Vapnik 1999).

#### 2.4. Değerlendirme Ölçütleri

Sınıflandırıcı modellerinin performansının değerlendirilmesinde genellikle doğruluk, duyarlılık, özgüllük, keskinlik ve F1 skor gibi değerlendirme ölçütleri kullanılmaktadır. Bu ölçütlere gerçek sınıflar ile sınıflandırıcı modelinin sınıf tahminleri arasındaki ilişkiye bağlıdır. Bu ilişkiyi tanımlayan yapı, karmaşıklık matrisi olarak tanımlanmakta ve Şekil 4'te bu karmaşıklık matrisi görülmektedir.

		Tahmin Sınıflar	
		Pozitif	Negatif
Gerçek Sınıflar	Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)

Şekil 4. Karmaşıklık matrisi

Şekil 4'teki TP; gerçekte pozitif, sınıflandırıcı tahmini de pozitiftir. FP; gerçek sınıfı negatif, sınıflandırıcı tahmini negatiftir. FN; gerçek sınıfı pozitif, sınıflandırıcı tahmini pozitiftir. TN; gerçek sınıf negatif, sınıflandırıcı tahmini negatiftir. Buna göre her bir performans değerlendirme ölçüt bağıntısı Denklem 7- Denklem 11 arasında görülmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (7)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (8)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (9)$$

$$\text{Keskinlik} = \frac{TP}{TP+FP} \quad (10)$$

$$\text{F1-Skor} = 2 \times \frac{\text{Duyarlılık} \times \text{Keskinlik}}{\text{Duyarlılık} + \text{Keskinlik}} \quad (11)$$

### 3. Bulgular

Doku sinyallerinin sınıflandırılmasında, öznelik çıkarım yaklaşımları ile özelliklerin hesaplanması, bu özelliklerin bazı makine öğrenim modelleri ile sınıflandırılmasında MATLAB (R2023b) ortamında gerçekleştirilmiştir. Deneysel çalışmalarda, Intel Xeon Silver 3.3 GHz işlemci, NVIDIA P2200 Quadro GPU kartı ve 64 GB özelliklere sahip iş istasyonu kullanılmıştır.

Bölüm 2.1'de sunulduğu gibi veri setimiz 2400 doku sinyalinden oluşmaktadır. Ayrıca her bir doku sinyal  $1 \times 2048$  boyutundadır. Deneysel çalışmanın ilk aşamasında, pencere uzunluğu ve örtüşme oranı ampirik olarak belirlenen ve her bir sinyal için pencere uzunluğu 256 örnek ve %50 oranında örtüşün 15 pencereye bölünmüştür. Daha sonra 256 örnekle 15 pencerenin her birinden ortalama, standart sapma, spektral düzlük ve spektral merkez değerleri hesaplanmıştır. Böylece veri setimizdeki  $1 \times 2048$  boyutundaki bir sinyalden her bir öznelik çıkarım yöntemi ile 15'er öznelik dizisi oluşturuldu. Her bir öznelik çıkarımından elde edilen bu öznelikler dizisi

birleştirilerek 1×60 boyutunda öznitelik dizisi elde edildi. Bu yaklaşım ile veri setindeki 2400 sinyalden 2400×60 boyutunda öznitelik matrisi elde edilir.

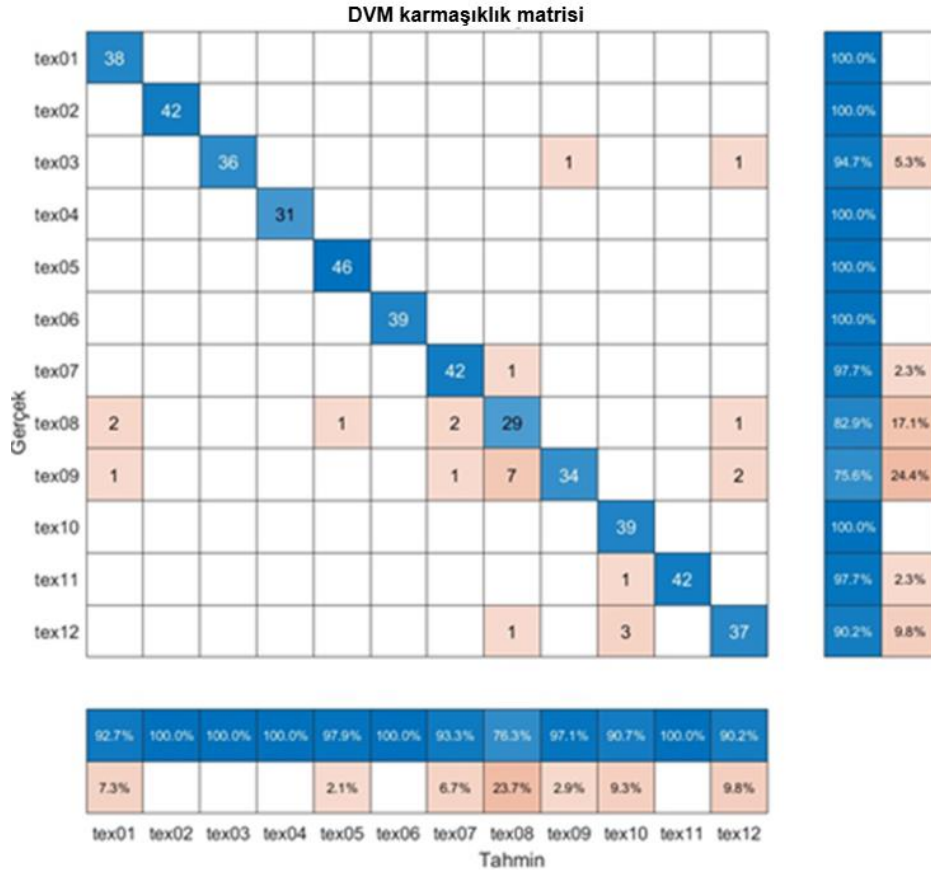
En son aşamada, dokunsal yapılara ait sinyallerden elde edilen 2400×60 boyutlu öznitelikler matris sınıflandırılması amacıyla k-EYK ve DVM makine öğrenim sınıflandırıcı modellerine uygulandı. DVM ve k-EYK sınıflandırıcı modellerinin değerlendirme ölçütlerine göre sınıflandırma performansları Tablo 2’de görülmektedir.

**Tablo 2.** DVM ve k-EYK sınıflandırıcı modellerinin sınıflandırma performansları

Sınıflandırıcı Modeli	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Skor
DVM	94,79	94,89	99,52	94,85	0,94
k-EYK	95,83	95,84	99,62	95,93	0,95

Tablo 2’deki sonuçlardan görüldüğü üzere DVM sınıflandırıcıda %94,79 doğruluk, %94,89 duyarlılık, %99,52 özgüllük, %94,85 oranında başarımlar elde edilmiştir. Aynı şekilde k-EYK sınıflandırıcı doğruluk, duyarlılık, özgüllük, keskinlik ve F1-Skor değerlendirme ölçütlerinde sırasıyla %95,83, %95,84, %99,62, %95,93 ve 0,95 oranlarında başarımlar sağlanmıştır. Her iki sınıflandırıcı modeli karşılaştırıldığında tüm performans değerlendirme ölçütlerinde k-EYK sınıflandırıcının daha yüksek sonuçlara ulaştığı görülebilmektedir.

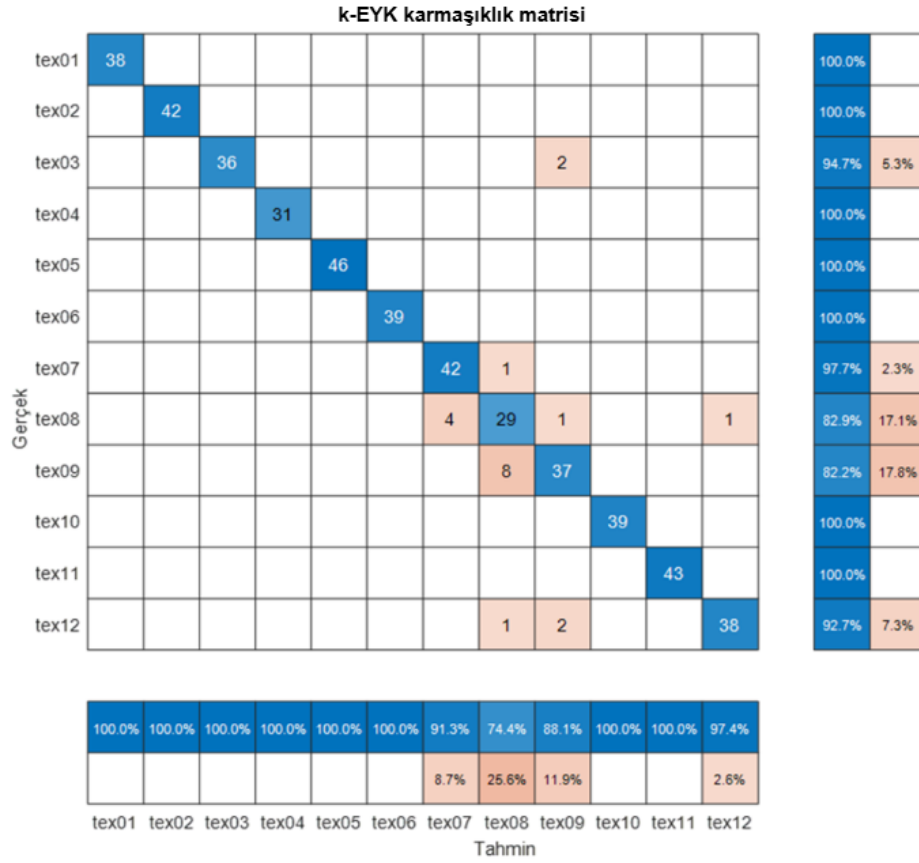
Veri setindeki her bir dokunun daha detaylı performans analizi için DVM, k-EYK sınıflandırıcı modellerin performans değerlendirmeleri için karmaşıklık matrisleri kullanılmıştır. Şekil 5’te DVM, Şekil 6’da k-EYK modellerinin karmaşıklık matrisleri verilmiştir.



**Şekil 5.** DVM sınıflandırıcı modeline ait karmaşıklık matrisi

Şekil 5’te DVM karmaşıklık matrisinde tex02, tex03, tex04, tex05, tex06 ve tex11 dokularının tamamı doğru bir şekilde sınıflandırıldığı görülebilmektedir. Bununla birlikte gerçekte tex03 olan birer doku örnekleri hatalı olarak tex09 ve tex12 olarak sınıflandırılmıştır. Gerçekte tex08 doku örneklerinin ikisi tex01, biri tex05, ikisi tex06 ve biri tex12 olarak hatalı sınıflandırılmıştır. Benzer şekilde gerçekte tex09 doku örneklerinden biri tex01, biri tex07, 7 adeti tex08 ve ikisi tex12 olarak hatalı sınıflandırıldığı görülmektedir.





**Şekil 6.** k-EYK sınıflandırıcı modeline ait karmaşıklık matrisi

Şekil 6'daki k-EYK sınıflandırıcı modeline ait karmaşık matrisinde görüldüğü üzere gerçekte tex03 olan iki gözlem tex09 olarak hatalı sınıflandırılmıştır. Benzer şekilde gerçekte tex07 olması gereken bir doku tex08, gerçekte tex08 olan 4 doku örneği tex07 ve birer adet doku sırasıyla tex09 ve tex12 olarak hatalı sınıflandırılmıştır. Ayrıca gerçekte tex12 olan bir doku tex08 ve iki doku tex09 olarak hatalı sınıflandırılmıştır. Bununla birlikte Bununla birlikte karmaşıklık matrisinde tex01, tex02, tex03, tex04, tex05, tex05, tex10 ve tex11 dokularının tamamı doğru bir şekilde sınıflandırıldığı görülmektedir

Önerilen yöntemin, aynı veri setini kullanan mevcut çalışmalar performans karşılaştırmaları Tablo 3'te verilmiştir. Tablo 3'te görüldüğü üzere olasılıksal ve spektral özniteliklerin birleştirilerek k-EYK sınıflandırıcıda (önerilen model) %95,83 doğruluk oranına ulaşıldığı görülmektedir. Lora-Rivera ve diğ., tarama algoritması ve hızlı fourier dönüşümü (FFT) öznitelik çıkarım yöntemlerinin sınıflandırma doğruluk oranları sırasıyla %89,17 ve %91,14 olarak elde edilmiştir. Önerilen yöntem, mevcut çalışmalardan en iyi yöntem başarımından %4,69 oranında daha yüksek doğruluk puanına sahiptir. Bu oran önerilen yöntemin başarısını göstermektedir.

**Tablo 3.** Mevcut yöntemler ile performans karşılaştırması

Model	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Skor
k-EYK (Önerilen)	95,83	95,84	99,62	95,93	0,95
Tarama Algoritması (Lora-Rivera ve diğ.)	89,17	-	-	-	-
FFT (Lora-Rivera ve diğ.)	91,14	-	-	-	-

#### 4. Sonuç

Bu çalışmada, robotik ve protez mekanizmalarında kritik bir öneme sahip olan yüzey dokularının tespit edilmesi için etkili ve yenilikçi bir yöntem önerilmiştir. Önerilen yöntemde, 12 farklı materyale ait dokunsal sinyallerden oluşan veri seti test edilmiştir. Deneysel çalışmalarda öznitelik çıkarım için örtüşen pencere yapısı kullanılmış ve pencere genişliği 256 örnek olan ve %50 oranında örtüşme ile her sinyalden her bir öznitelik çıkarım

yaklaşımı ile 15 öznitelik elde edilmiştir. Her sinyale ait ortalama, medyan, spektral merkez ve spektral düzlük değer dizisi birleştirilerek toplamda 1x60 öznitelik verisi elde edilmiştir. Daha sonra bu öznitelikler doku sınıflandırması için DVM ve k-EYK sınıflandırıcılara girdi olarak uygulandı. DVM ve k-EYK sınıflandırıcılarda sırasıyla %94.79 ve %95.83 sınıflandırma doğruluğu elde edilmiştir. Mevcut çalışmalar ile kıyaslandığında doğruluk açısından yaklaşık %4.69 daha yüksek performans elde edilmiştir.

Sonuç olarak, bu çalışmada önerilen yenilikçi yöntem, yüzey dokularının tespiti konusunda yüksek doğruluk oranları ile dikkat çekmiş ve mevcut yaklaşımlara göre belirgin bir üstünlük göstermiştir. Bu bulgular, robotik ve protez teknolojilerinde yüzey dokularının daha hassas bir şekilde tespit edilmesine katkı sağlayacak potansiyeli işaret etmektedir.

Gelecek çalışmalarda, sınıflandırma performansını arttırmak için dokusal sensör sinyallerinin frekans analizi yapılarak frekans bileşenlerinin öznitelik hesaplama yaklaşımları ve evrimsel sinir ağları gibi mimarilere odaklanılabilir. Ayrıca gerçek zamanlı sistemlerde daha az hesaplama karmaşıklığı için öznitelik seçim algoritmaları üzerine çalışmalar sürdürülebilir.

## Kaynaklar

- Alves de Oliveira, Thiago, Ana-Maria Cretu, and Emil Petriu. 2017. "Multimodal Bio-Inspired Tactile Sensing Module for Surface Characterization." *Sensors* 17(6): 1187. doi:10.3390/s17061187.
- Aslan, Muzaffer, and Ebra Nur Zurel. 2022. "An Efficient Hybrid Model for Appliances Classification Based on Time Series Features." *Energy and Buildings* 266: 112087. doi:10.1016/j.enbuild.2022.112087.
- Boashash, Boualem, Nabeel Ali Khan, and Taoufik Ben-Jabeur. 2015. "Time-Frequency Features for Pattern Recognition Using High-Resolution TFDs: A Tutorial Review." *Digital Signal Processing* 40: 1–30. doi:10.1016/j.dsp.2014.12.015.
- Chi, Cheng, Xuguang Sun, Ning Xue, Tong Li, and Chang Liu. 2018. "Recent Progress in Technologies for Tactile Sensors." *Sensors* 18(4): 948. doi:10.3390/s18040948.
- Fishel, Jeremy A., and Gerald E. Loeb. 2012. "Bayesian Exploration for Intelligent Identification of Textures." *Frontiers in Neurorobotics* 6. doi:10.3389/fnbot.2012.00004.
- Gupta, Ashutosh Kumar, Sunny Chakroborty, Swarup Kumar Ghosh, and Subhas Ganguly. 2023. "A Machine Learning Model for Multi-Class Classification of Quenched and Partitioned Steel Microstructure Type by the k-Nearest Neighbor Algorithm." *Computational Materials Science* 228: 112321. doi:10.1016/j.commatsci.2023.112321.
- Hassan, Ahnaf Rashik, Syed Khairul Bashar, and Mohammed Imamul Hassan Bhuiyan. 2015. "On the Classification of Sleep States by Means of Statistical and Spectral Features from Single Channel Electroencephalogram." In *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, IEEE, 2238–43. doi:10.1109/ICACCI.2015.7275950.
- Hassan, Ahnaf Rashik, and Md. Aynal Haque. 2016. "Computer-Aided Obstructive Sleep Apnea Screening from Single-Lead Electrocardiogram Using Statistical and Spectral Features and Bootstrap Aggregating." *Biocybernetics and Biomedical Engineering* 36(1): 256–66. doi:10.1016/j.bbe.2015.11.003.
- Kaboli, Mohsen, and Gordon Cheng. 2018. "Robust Tactile Descriptors for Discriminating Objects From Textural Properties via Artificial Robotic Skin." *IEEE Transactions on Robotics* 34(4): 985–1003. doi:10.1109/TRO.2018.2830364.
- Kulkarni, N. N., and V. K. Bairagi. 2017. "Extracting Salient Features for EEG-Based Diagnosis of Alzheimer's Disease Using Support Vector Machine Classifier." *IETE Journal of Research* 63(1): 11–22. doi:10.1080/03772063.2016.1241164.
- Kursun, Olcay, and Ahmad Patooghy. 2020. "Journal of Computer Science." *IEEE Access* 8: 97462–73. doi:10.1109/ACCESS.2020.2996576.
- Löfhede, Johan, Magnus Thordstein, Nils Löfgren, Anders Flisberg, Manuel Rosa-Zurera, Ingemar Kjellmer, and Kaj Lindecrantz. 2010. "Automatic Classification of Background EEG Activity in Healthy and Sick Neonates." *Journal of Neural Engineering* 7(1): 016007. doi:10.1088/1741-2560/7/1/016007.
- Lora-Rivera, Raúl, Óscar Oballe-Peinado, and Fernando Vidal-Verdú. 2023. "Texture Detection With Feature Extraction on Embedded FPGA." *IEEE Sensors Journal* 23(11): 12093–104. doi:10.1109/JSEN.2023.3268794.

- Lyu, Chengang, Bo Yang, Jiachen Tian, Jie Jin, Chunfeng Ge, and Jiachen Yang. 2022. "Three-Fingers FBG Tactile Sensing System Based on Squeeze-and-Excitation LSTM for Object Classification." *IEEE Transactions on Instrumentation and Measurement* 71: 1–11. doi:10.1109/TIM.2022.3181290.
- De Oliveira, Thiago Eustaquio Alves, Ana Maria Cretu, Vinicius Prado Da Fonseca, and Emil M. Petriu. 2015. "Touch Sensing for Humanoid Robots." *IEEE Instrumentation and Measurement Magazine* 18(5): 13–19. doi:10.1109/MIM.2015.7271221.
- Peng, Yiyao, Ning Yang, Qian Xu, Yang Dai, and Zhiqiang Wang. 2021. "Recent Advances in Flexible Tactile Sensors for Intelligent Systems." *Sensors* 21(16): 5392. doi:10.3390/s21165392.
- Rocha Lima, Bruno Monteiro, Thiago Eustaquio Alves de Oliveira, and Vinicius Prado da Fonseca. 2021. "Classification of Textures Using a Tactile-Enabled Finger in Dynamic Exploration Tasks." In *2021 IEEE Sensors*, IEEE, 1–4. doi:10.1109/SENSORS47087.2021.9639755.
- Rocha Lima, Bruno Monteiro, Vinicius Prado da Fonseca, Thiago Eustaquio Alves de Oliveira, Qi Zhu, and Emil M. Petriu. 2020. "Dynamic Tactile Exploration for Texture Classification Using a Miniaturized Multi-Modal Tactile Sensor and Machine Learning." *SYSCON 2020 - 14th Annual IEEE International Systems Conference, Proceedings*. doi:10.1109/SysCon47679.2020.9275871.
- Sinapov, J, V Sukhoy, R Sahai, and A Stoytchev. 2011. "Vibrotactile Recognition and Categorization of Surfaces by a Humanoid Robot." *IEEE Transactions on Robotics* 27(3): 488–97. doi:10.1109/TRO.2011.2127130.
- Siuly, Siuly, Omer F. Alcin, Varun Bajaj, Abdulkadir Sengur, and Yanchun Zhang. 2019. "Exploring Hermite Transformation in Brain Signal Analysis for the Detection of Epileptic Seizure." *IET Science, Measurement & Technology* 13(1): 35–41. doi:10.1049/iet-smt.2018.5358.
- Vapnik, Vladimir N. 1999. "An Overview of Statistical Learning Theory." *IEEE Transactions on Neural Networks* 10(5): 988–99. doi:10.1109/72.788640.