

Fraktal Eğimden Arındırılmış Dalgalanma Analizi ile Yüzey Dokularının Sınıflandırılması

Surface Textures Classification with Fractal Detrended Fluctuation Analysis

Cemil KILIÇ¹ , Ömer Faruk ALÇİN^{*2} , Muzaffer ASLAN³ 

¹ Fen Bilimler Enstitüsü, Turgut Özal Üniversitesi, Malatya, Türkiye

²Yazılım Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

³Elektrik-Elektronik Mühendisliği Bölümü, Bingöl Üniversitesi, Bingöl, Türkiye

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

Received:Jan.31,2025

Accepted:Aug.22,2025

Published:Dec.01,2025

Özetçe— Dokunsal algılama, robotlara ve protezlere nesne tanıma, hassas manipülasyon, doğal etkileşim gibi yetenekler kazandırır. Dokunsal geri bildirim, fiziksel temas yoluyla bireylere dış çevreleri hakkında sürekli olarak hayati bilgiler sağlayarak önemli bir rol oynar. Bu nedenle, insan dostu biyomimetik elektronik ve esnek cihazlardaki hızlı gelişmeler, robotların özellikle tekstil gibi malzemeler için yerel geometri ve doku gibi malzeme özelliklerini ayırt etmelerini sağlar. Bu makale, dokunsal sinyalleri kullanarak yüzey dokularının sınıflandırılması için yenilikçi bir yöntem önerilmiştir. Önerilen yöntemde, öncelikle 3 eksenli ivmeölçer (X, Y, Z) dokunsal sinyalleri ve mikrofon sinyalleri, örtüşmeyen kayan pencere yaklaşımı ile veri çoğaltma işlemine tabi tutulmuştur. Durağan olmayan zaman serilerinin kuvvet yasasının uzun vadeli korelasyonlarını araştırmak için etkili bir yöntem olan Fraktal Eğimden Arındırılmış Dalgalanma Analizi (F-EADA) ile öznitelik çıkarımı yapılmıştır. Son aşamada, yaygın olarak tercih edilen makine öğrenme algoritması olan Destek Vektör Makinası (DVM) ile ivmeölçer ve mikrofon sinyallerinden elde edilen öznitelikler ayrı ayrı ve birleştirilerek dokuların sınıflandırılması gerçekleştirilmiştir. DeneySEL sonuçlar, pencere uzunluğu 1saniye olarak seçildiğinde F-EADA ile öznitelik çıkarımı ve SVM ile sınıflandırma yöntemlerini birleştirilmesinde, ivmeölçer verilerinde %82,91, mikrofon verilerinde %98,33 ve her iki sensöre ait verilerin birlikte kullanımında ise %99,16 oranında sınıflandırma doğruluğu elde edilmiştir. Mikrofon sinyallerinde, mevcut modellerden %12,08 ve ivmeölçer-mikrofon verilerinin birleştirilmesinde %0,56 daha yüksek sınıflandırma performans elde edilmiştir. Bu bulgular, fraktal-temelli özellik yaklaşımının, dokuya özgü mikro-dinamikleri yakalamada ve sınıflandırma genellemesini iyileştirmede yüksek etkinlik sunduğunu; gerçek zamanlı robotik dokunma, akıllı protez kontrolü ve kalite denetimi arayüzleri gibi uygulamalarda düşük maliyetli sensörlerle birlikte kullanılabilirliğinin, güvenilir ve verimli çözüm olanağı sağladığını ortaya koymaktadır.

Anahtar Kelimeler : Dokunsal sensör, F-EADA, Yüzey dokuları tanıma, DVM.

Abstract— Tactile perception endows robots and prosthetics with capabilities such as object recognition, precise manipulation, and natural interaction. Tactile feedback plays a vital role by continually providing individuals with critical information about their external environment through physical contact. Consequently, rapid advances in human-friendly biomimetic electronics and flexible devices enable robots to distinguish material properties—such as local geometry and texture—particularly in materials like textiles. This article proposes an innovative method for classifying surface textures using tactile signals. In the proposed method, three-axis accelerometer (X, Y, Z) tactile signals and microphone signals are first subjected to data augmentation via a non-overlapping sliding window approach. Feature extraction is performed using Fractal Detrended Fluctuation Analysis (F-DFA), an effective method for investigating the long-range correlations governed by power laws in non-stationary time series. In the final stage, features obtained from accelerometer and microphone signals are individually and collectively utilized for texture classification using the Support Vector Machine (SVM), a widely preferred machine learning algorithm. Experimental results demonstrate that when the window length is set to one second, the combination of feature extraction via F-DFA and classification via SVM achieves classification accuracies of

82.91% for accelerometer data, 98.33% for microphone data, and 99.16% when data from both sensors are combined. For microphone signals, classification performance surpasses current models by 12.08%, and for the combined accelerometer-microphone data, by 0.56%. These findings indicate that the fractal-based feature approach offers high efficacy in capturing texture-specific micro-dynamics and enhancing classification generalizability; its usability with low-cost sensors in applications such as real-time robotic touch, smart prosthetic control, and quality inspection interfaces provides a reliable and efficient solution.

Keywords : *Tactile sensor, FDFA, Surface textures recognition, SVM.*

1. Giriş

Dokunma duyusu, nesne yüzeyleriyle sürtünmeli titreşimler yoluyla başlayan dış çevre ile insan etkileşiminde önemli bir rol oynar. Çevredeki çeşitli uyaranlara yanıt olarak deri altı reseptörleri tarafından potansiyel sinyallerin üretilmesine dayanır. Bu sinyaller daha sonra beyin tarafından analiz edilir ve işlenir. Dokunma, insanların çevreleri hakkında bilgi toplamaları ve dünyayı anlamalarını ve şekillendirmeleri için önemli bir araç görevi görür (Prescott, Mitchinson, and Grant 2011; Zacharia et al. 2024).

Son dönemlerdeki teknolojik ve bilimsel gelişmelere bağlı olarak akıllı algılama teknolojileri ve insan-bilgisayar etkileşiminde de önemli gelişmeler sağladı. Bu gelişmeler, özellikle sağlık ve robotik uygulamalarında köklü değişikliklere yol açtı. İnsan-bilgisayar etkileşimi ve yapay zeka destekleri ile kullanıcı arayüzlerini geliştiren ve daha yenilikçi çözümler sunarak, teknolojinin herkes tarafından daha etkili bir şekilde kullanılmasını sağladı (Y. Peng et al. 2021).

Bu gelişmeler; sağlık ve akıllı robotik uygulamalarında doku algılama sistemlerine olan ilginin de artmasına önemli katkılar sağlamaktadır. Doku sensörleri temassız veya temaslı olmak üzere iki grupta ele alınırlar. Temassız sensörler, farklı malzemelerin özelliklerini algılamak için şekiller, renkler ve görünüm gibi veriler sağladığı için görmeye dayanır (Hu, Bo, and Ren 2011). Genellikle görüntü sensörlerine dayanan temassız sensörler mükemmel çözünürlük sunmalarına rağmen düzensiz aydınlatma, gölgeler veya karanlık ortamlar gibi çevresel faktörlerle bağlı olmaları nedeni ile daha az tercih edilmektedirler (Dallaire et al. 2014). Bununla birlikte dokunsal (temaslı) sensörler, yüzey bilgisini ileten mekanik titreşimler üretmek için doğrudan malzeme ile etkileşime girmektedirler. Bu titreşimler, malzemenin dokusu hakkında önemli veriler sağlayarak doku tanıma ve analiz için kullanılabilirler (Strese et al. 2017).

Dokunsal sensörler akıllı robot teknolojilerinin, kullanıcılarla etkileşimlerini daha doğal ve sezgisel hale getirebilmek için gerçek zamanlı geri bildirim sağlamaktadır. Bu teknolojiler sayesinde robotlar, insan hareketlerini ve tepkilerini analiz ederek uygun yanıtlar verebilmekte, böylece insan-robot etkileşiminde daha uyumlu ve etkili bir deneyim sunulmaktadır (Ma, Li, and Chen 2024). Sağlık sistemlerinde ise dokunsal temas ve buna bağlı kuvvet geri bildirimleri yardımıyla, kullanıcıların sanal ortamlarla daha gerçekçi ve tatmin edici bir etkileşim kurmalarının yanı sıra dokunulan malzemelerinin tanınmasını da kolaylaştırmaktadır. Bu sayede, hastaların tedavi süreçlerini daha verimli hale getiren yenilikçi çözümler geliştirilebilmektedir (Chi et al. 2018; Zacharia et al. 2024). Ayrıca, dokunsal algılama teknolojisi, özellikle protez araştırmalarında da dikkate değer katkılar sağlamaktadır (Alves de Oliveira, Cretu, and Petriu 2017).

Dokunsal sensörlerin yaygın olarak kullanıldığı akıllı robot ve protez uygulama sistemlerinde, nesnelerin doğru bir biçimde kavranabilmesi o nesnenin yapılmış olduğu malzemenin sertlik, doku ve pürüzlülük gibi özelliklerin doğru tanınması aşamaları oldukça önemlidir. Bu sistemlerin başarımı, tıpkı insandaki doku tanıma süreci gibi mikro titreşimlere bağlıdır (Kursun and Patooghy, 2020; Rocha Lima et al., 2020). Bundan dolayı araştırmacılar, etkili mikro titreşimlerin alınabilmesini sağlayacak daha gelişmiş dokunsal algılama teknolojilerinin tasarlanmasına, protez geliştirme ve dokunsal robotik çalışmalarına yönelmektedirler. Son yıllarda araştırmacıların bu alanda yaptığı bazı çalışmalar aşağıda verilmiştir.

Oliveira ve diğ., dokunsal algılama hassasiyetini ve doğruluğunu artıracak şekilde manyetik açılma hız ve parmak ucuna uygulanan kuvvetlerin etkilerinden etkili bir biçimde yararlanmayı sağlayan derin basınç sensörü modülünü kullanmışlardır. Bu modül, sensörlerin farklı yüzey türlerindeki tepkilerini değerlendirmek amacıyla iki ayrı deney gerçekleştirmişlerdir. İlk deneyde, modüldeki geleneksel sensörlerin, oluklu yüzeylerde 3,66Hz ile 11,54Hz frekans aralığında titreşimleri algılama kabiliyeti incelenmiştir. Ayrıca, modüldeki frekans değişiminin modül altındaki ızgara desenlerinin sabit bir hız, yön ve basınçla hareket ettirilmesine bağlı olduğu görülmüştür. İkinci deneyde ise, sensör modülünün robotik parmak ucuna yerleştirilen dokunsal sensörün, yedi farklı kaba yüzeyinden toplanan veriler ayrıntılı şekilde analiz edilmiştir. Analiz sonuçları, bu yüzeylerin sınıflandırma doğruluklarının %85.1 ile %98.9 arasında değişim gösterdiğini ortaya koymuştur. Ancak, bu doğruluk performansının geleneksel sensörlerin frekansına bağlı olduğu ve bu frekansın ise geliştirilen modüldeki üç serbestlik derecesine sahip robotik bir parmak düzeninin sabit tutulmamasına bağlı olduğu belirtilmektedir. (Alves de Oliveira, Cretu, and Petriu 2017).

Cao ve diğ., dokunsal tanıma yaklaşımlarında sadece dokunsal veriler ile doku tanımanın yeterli olmayacağını bu nedenle, dokunsal eğitim örnekleri gerektirmeden, görsel ve anlamsal bilgilerini kullanarak malzemelere ilk kez dokunulduğunda tanımak için bir dokunsal Sıfır Atış Öğrenme (SAÖ) yöntemini önermektedirler. Bu amaçla SAÖ yöntem performansını arttırmak için, görme yoluyla dokunsal ipuçları sağlayan görsel modalite ve üst düzey özellikler veren anlamsal nitelikler bir araya getirilmiştir. Deneysel çalışmaları ile önerilen modelin, daha önce dokunulmamış malzemeleri sınıflandırmada %83,06'lık tanıma doğruluğu elde etmişlerdir (Cao et al. 2024).

Lima ve arkadaşları, dokunsal sensörler ile doku tanıma çeşitli makine öğrenimi yöntemlerinin performanslarını karşılaştırmışlar. Araştırmacılar, deneysel kurulum sistemlerinde dokunsal algılama özelliklerine sahip robot parmak ucu ve bir adım motorundan faydalanmışlardır. Bu sistemden toplanan verilerin, zamansal analizleri yapıldıktan sonra rastgele orman, karar ağaçları ve DVM sınıflandırıcılara girdi olarak uygulanmıştır. Deneysel çalışmalarında, DVM, karar ağaçları ve rastgele orman sınıflandırıcılarda sırasıyla %91, %92 ve %95 doğruluk oranı elde etmişlerdir (Rocha Lima et al. 2020).

Kong ve diğ., dokunsal sensörlere dayalı iyonik robotların dokuların sınıflandırılması için sinyal-gürültü oranı 48 dB, en düşük algılama sınırı 1 Pascal (Pa) olan piramidal bir mikro yapıyı sahip gradyan konformal iyonik jel kaplamasıyla birleştiren esnek bir sensör verilerinin girdi olarak kullanan Basınç-Kayma Çift Dalı Evrişimli Sinir Ağı (PSNet) mimarisi önermişlerdir. Farklı yüzeyler üzerinde yapılan dokunsal deneylerde %97,16'lık bir tanıma başarımı sağlamışlar. Bu sonuçlar ile çalışmanın biyonomik robotlar, akıllı protezler ve hassas insan-bilgisayar etkileşiminde büyük potansiyeli sahip olduğu belirtilmektedir (Kong et al. 2024).

Zacharia ve diğ., tek bir düzenekte eş zamanlı malzeme ve doku algılamayı gerçekleştiren, serbest duran tek elektrotlu triboelektrik nanogeneratör prensibini kullanan esnek bir triboelektrik dokunsal sensör önermektedirler. Yapay bir parmak ile tek bir temas-kaydırma-ayırma hareketinde hem temas-ayırma hem de yüzey kayma modlarının avantajlarını birleştiren dokunsal algılama malzeme bilgisi ve kayma hareketinden doku verileri elde edilmiştir. Daha sonra bu veriler 1B bir 1D evrişimli yapay sinir ağına uygulanarak malzemelerin ve dokuların eş zamanlı sınıflandırılması yapılmıştır. Deneysel sonuçlar, tüm farklı yüzeylerde ortalama %98,4'lük bir tanıma doğruluğu sağlanmıştır (Zacharia et al. 2024).

Qin ve diğ., çeşitli dokuları ayırt edebilen polivinil florür tabanlı parmak izinden esinlenen bir dokunsal sensörün tasarımını odaklanmaktadır. Çeşitli dokulardan sensörden yardımıyla alınan sinyaller makine öğrenimi yöntemleriyle sınıflandırılmaktadır. Geliştirilen sensörün performansı, farklı malzeme dokularını tanımaya ve Braille karakterlerini tanımaya yönelik iki deney yapılmıştır. Her iki deneyde sırasıyla %97,4 ve %96,5 doğruluk oranına ulaşılmıştır (Qin et al. 2024).

Kılıç ve diğ., titreşimli dokunsal uyarıcı kullanan bir gömülü sistem aracılığıyla 12 farklı dokuya ait sinyallerin sınıflandırılmasını hedeflemiştir. Deneylerde, örtüşmeli kayan pencere yaklaşımı ile spektral ve istatistiksel özellikler birleştirilerek k-En Yakın Komşu (k-NN) ve DVM sınıflandırıcılarına girdi olarak verilmiştir. Çalışmalarında, her iki sınıflandırıcı modelinde sırasıyla %95,83 ve %94,79 sınıflandırma doğruluğuna ulaşılmıştır (Kılıç, Alçin, and Aslan 2024).


Shao ve diğ., dokunsal sinyallere dayalı yüzey dokusu sınıflandırması için deneysel mod ayrıştırmasına (EMD) ve entropi ile öznelilik çıkarımına dayalı yeni bir yöntem önerilmiştir. Önerilen yöntem için, öncelikle her kanalın (X, Y, Z ve S) dokunsal sinyalleri, deneysel mod ayrıştırmasına (EMD) dayanarak ayrıştırılır. Ardından, içsel mod fonksiyonları (IMF) elde edilir. İkinci olarak, birden fazla IMF'ye dayanarak, her IMF için örnek entropisi hesaplanır. Bu nedenle, çoklu-IMF örnek entropisi (MISE) özellikleri oluşturulmuştur. Nihai aşamada, farklı dokuları tanımak için elde edilen öznelilikler çeşitli makine öğrenimi algoritmalarına uygulanmaktadır. Sonuçlar, önerilen MISE özelliklerine sahip DVM sınıflandırma yönteminin en yüksek sınıflandırma doğruluğunu elde ettiğini göstermektedir (Shao et al. 2021).

Necip ve Cretu, doku tanıma için ivmeölçer ve ses verisi biçimindeki dokunsal verilerin sınıflandırılması için makine öğrenim algoritmalarını kullanmaktadır. Her bir ivmeölçer ve ses verilerinin ortalama, standart sapma, mutlak medyan, sinyalin gücünü karakterize eden enerji ve her bir duyu modaliteyle ilişkili algısal özelliklerini yansıtan sinyallerden çıkarılan fourier özelliklerinin birleştirilmesinden oluşan yeni bir özellik veri seti oluşturulmuştur. Sınıflandırma performansını arttırmak için yeni veri setinden temel bileşen analiziyle en iyi özellikler belirlenmiştir. Özellik sayısı, sınıflandırma performansı ve hesaplama süresi arasındaki en iyi uzlaşmayı belirlemek amacıyla çeşitli makine öğrenimi modelleri karşılaştırılmıştır. (Necip and Cretu 2023).

Literatür detaylarında da görüldüğü gibi son dönemlerde dokunsal algılamada önemli çalışmalar yapılmış olmakla birlikte bu alanda hala önemli eksiklikler bulunmaktadır. Bu çalışmada, mevcut çalışmalardan farklı olarak, %50 oranında örtüşen kayan pencere yaklaşımı ile istatistiksel (ortalama, medyan) ile spektral düzleklik ve spektral merkez özellikleri elde edilerek veri kümesine ait özelliklerin sayısı artırılarak veri çoğullama yapılarak F-EADA yaklaşımı ile elde edilen öznelilikler dizisinin k-EYK ve DVM gibi popüler makine öğrenme yaklaşım ile sınıflandırılması gerçekleştirilmektedir.

2. Materyal ve Yöntemler

Bu çalışmada, protez ve akıllı robotik uygulamalarında yaygın olarak kullanılan dokunsal sensörlerden alınan yüzey doku verileri ile ve bu dokulara ait ses verilerinin DVM ile sınıflandırılması yaklaşım sunulmaktadır. Genel çerçevesi Şekil 1'de verilen çalışma, iki aşamadan oluşmaktadır. İlk aşamada, dokunsal sensörlerden alınan sinyaller ve mikrofon sinyalleri belirli bir genişlikteki kayan pencere yaklaşımı ile pencerelere bölünmektedir. Böylelikle her dokuya ait sinyaller çoğullandıktan sonra fraktal yaklaşım ile öznelik çıkartım yapılmaktadır. Nihai aşamada sınıflandırma için fraktal özellikler DVM sınıflandırıcıya girdi olarak uygulanmaktadır.



Şekil 1. Önerilen modelin genel çerçevesi

2.1. Veri Seti

Dokunsal yüzey veri seti için 3 boyutlu ivmeölçer (NXP, MMA-7660) sensörü ve bir kapasitif mikrofondan (CUI, CMA-4544PF-W) oluşan bir sistem ile hazırlanmıştır (Kursun and Patooghy 2020a). Sistem, dokunsal titreşim uyarıcı ve dokunsal sensörlerden alınan verileri kaydeden iki gömülü sistemi içermektedir. Uyarıcı sistemi, kontrol ünitesi, motor sürücü modülü ve tambur modülü olmak üzere üç bölümden oluşmaktadır. Kontrol ünitesi, tamburu kontrol etmek için deney özelliklerini okumakta ve okunan özelliklerle tambur kontrol edilmektedir. Motor sürücü modülü, tamburu kontrol eden step motoru veriler doğrultusunda kontrollü sağlanmaktadır. Malzemelerin psikofiziksel boyutlarının pürüzlülük, yumuşaklık, sıcaklık ve sürtünme gibi özellikler (Okamoto, Nagano, and Ho 2016) dikkate alınarak çalışmada malzemelerin yüzeylerine dokunan yapay parmağın tek bir temas noktası olmakla birlikte buna bağlı sensörler bulunmaktadır. Yapay parmağın, uyarıcı üzerinde bulunan dokulu malzemeye teması ile bağlı sensörler ait titreşimli sinyalleri gerçek zamanlı kaydı yapılmıştır. Veri setine ait materyalleri yüzey doku örnekleri Şekil 2'de görülmektedir.



Şekil 2. Veri seti materyal dokuları

2.2. Özellik Çıkarım Yöntemi

2.2.1. Kayan Pencere Yaklaşımı

Kayan pencere yaklaşımı, basitliği ve sezgiselliği nedeniyle zamansal dizileri kaydetmek ve yeni özelliklerin belirlenmesi için yaygın kullanılan bir yöntemdir (BenYahmed et al. 2015). Kayan pencere yaklaşımı, özellikle zaman serilerinin ön işleme aşamasında verileri bir zaman çerçevesine göre yeniden yapılandırmaktadır (Vafaeipour et al. 2014). Belirlenen pencere genişliğine bağlı olarak soldan-sağa veya belirli zamandan istenen zamana kadar pencerenin zaman serisi sinyali üzerinden kaydırılarak her bir pencereden istenen veriler alınmaktadır. Bu işlemlerde pencere boyutu, sabit ya da dinamik olarak belirlenebilir. Ayrıca pencerelerin belirli oranlarda örtüşmesi veya örtüşme olmadan pencere hareket ettirilebilmektedir.

2.2.2. İstatistiksel Fraktal Eğimden Arındırılmış Dalgallılık Analizi

F-EADA metodolojisi DNA dizilimlerini analiz etmek için Peng ve arkadaşları tarafından önerilmiştir. İstatistiksel ölçekleme teoremi tabanlı bir yöntem olan F-EADA metodolojisi yerel eğilimlerin ortadan kaldırılmasında genellikle sabit-sabit bir polinom düzenine bağlı olduğu durağan olmayan zaman serilerinin kuvvet yasasının uzun vadeli korelasyonlarını araştırmak için tercih edilen etkili bir yöntemdir. Örneğin biyomedikal, fiziksel, sosyal ve finansal alanlarda kullanılmaktadır. N örneklili zaman serisinin F-EADA metodolojisiyle profil fonksiyonunu hesaplamak amacıyla Denklem (1) kullanılabilir (Castiglioni and Faini 2019; C.-K. Peng et al. 1994).

$$y(k) = \sum_{i=1}^k (x(i) - \bar{x}) \quad (1)$$

$x(n)$ sinyalinin, aritmetik ortalaması $\bar{x}$ olarak verilmiştir. Daha sonra profil sinyali m uzunluğundaki parçalara bölünerek uydurulan $y_m(k)$ eğrisi en küçük karelere metoduyla oluşturulur. L. Dereceli Polimal eğilimi temsil eden eğri uydurulmuştur. Eğri uydurma işleminden sonra hesaplanabilen Dalgalanma fonksiyonu Denklem (2)'de belirtilmiştir.

$$F(m) = \sqrt{\frac{1}{N} \sum_{k=1}^N (y(k) - y_m(k))^2} \quad (2)$$

Ölçekleme üsteli a olarak tanımlanan ölçekleme teoreminde Dalgalanma fonksiyonu ile ilişkili parametrenin hesaplanması Denklem (3)'te yer almaktadır.

$$F(m) = m^a \quad (3)$$

$\text{Log}(F(m)) - \text{log}(m)$ grafiğinin eğimi zaman serisinin bağımlılığı hakkında bilgi verir. Temel F-EADA tanımı daha açık bir şekilde sunulabilir. F-EADA denklem (4) ile tanımlanabilir.

$$F_q(m) = \sqrt[q]{\frac{1}{N} \sum_{k=1}^N (y(k) - y_m(k))^q} \quad (4)$$

F-EADA'nın derecesi q ile gösterilir. Sıfır olmayan q değeri için geçerli olan Denklem (5)' in tanımlanmasında L Hospital kuralı kullanılabilir. Ölçeklendirme üssü ve F-EADA Denklem (6)' daki gibi birbiriyle ilişkilidir (Qian, Gu, and Zhou 2011).

$$F_0(m) = \exp\left(\frac{1}{N} \sum_{k=1}^N \ln(y(k) - y_m(k))\right) \quad (5)$$

$$F_q(m) = m^{h(q)} \quad (6)$$

Bu çalışmada, 1.ve 2. dereceden eğimden arındırılmış polinom F-EADA1 ve F-EADA2 katsayıları öznelilik olarak kabul kullanılmaktadır.

2.3. Sınıflandırma Yöntemi

2.3.1. Destek Vektör Makinesi

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. Bu algoritma, hem doğrusal hem de doğrusal olmayan veri setlerinin sınıflandırılmasında üstün performans göstermektedir, (Vapnik 1999). DVM algoritmasının ana hedefi, iki farklı sınıfa ait veri noktalarını optimum şekilde ayırabilen hiper düzlemi tespit etmeye dayanmaktadır. Matematiksel olarak tanımlamak gerekirse, $y_n \in \{-1,1\}$ sınıf etiketlerine sahip $= \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ veri kümesini ele alalım. Burada $x_n \in \mathbb{R}$ olmak üzere, n veri kümesindeki toplam örnek sayısını göstermektedir. Bu bağlamda, veri noktalarını iki ayrı sınıfa ayırabilecek çok sayıda farklı ayırma düzlem oluşturulabilmesi mümkündür. Bununla birlikte bu verilerin sınıflandırılmasındaki en iyi ayırım düzleminin tespit zorlu bir süreçtir. Ağırlık w ve önyargı b , ile temsil edildiği DVM sınıflandırma fonksiyonu Denklem 7'deki gibi tanımlanabilir.

$$f(x_n) = w^T x_n + b \quad (7)$$

Denklem 7' deki parametrelerin Denklem 8'deki optimizasyon problemi çözülerek türetilir (Liu et al. 2024).

$$\min_{w,b} \|w\|^2 + C \sum_{n=1}^m \xi_n, \quad y_n (w^T x_n + b) \geq 1 - \xi_n, \quad \xi_n \geq 0 \quad (8)$$


Burada C düzenleme parametresi, ξ_n hatalı sınıflandırmaların nasıl yönetileceği konusunda esneklik sağlamak ve farklı özelliklere sahip veri kümelerini barındırmak için tanımlanmış gevşek değişkenini temsil etmektedir.

Pratik uygulamalarda, DVM çekirdek fonksiyonlarını kullanabilir, bu da karmaşık desenleri daha etkili bir şekilde modelleme yeteneğini genişletir. Bu esneklik, dönüştürülmüş özellik alanlarında koordinatların açık bir şekilde hesaplanmasını gerektirmeden DVM'nin başarımını artırır. Yaygın olarak kullanılan çekirdek fonksiyonları Doğrusal, Polinom, Radyal Baz Fonksiyonu (RBF) ve Sigmoid şeklindedir. Her çekirdek fonksiyonu, daha yüksek boyutlu uzaydaki iki vektörün nokta çarpımına karşılık gelir ve karmaşık senaryolarda sınıflandırmayı kolaylaştırır (Vapnik 1999).

3. Bulgular

Bu bölümde, önerilen yönteme ait deneysel çalışmalar, Intel Xeon Silver 3.3 GHz işlemci, 64 GB Ram ve NVIDIA P2200 Quadro GPU kartına sahip iş istasyonuna kurulu MATLAB (R2023b) ile gerçekleştirilmiştir.

Bu çalışmada önerilen doku sınıflandırması, 12 yüzey dokusu için hazırlanmış ve 12 kayıttan oluşan veri seti ile test edilmiştir. Her bir kayıt 3 eksenli ivme ve bir mikrofon kaydından oluşmaktadır. İvme sensörleri 200Hz ile örneklenirken, mikrofon ses sinyali 8kHz ile kaydedilmiştir (Kursun and Patooghy 2020a). Sensör kayıtları 20 saniye için kaydedilerek ivme sensörleri 4000 örnekten mikrofon kaydı ise 160000 örnekten oluşmaktadır. Şekil 3'te Kumaş-1 dokusuna ait üç eksenli ivmeölçer ve mikrofon sinyalleri görülmektedir.



Şekil 3. Kumaş-1 dokusuna ait ivmeölçer ve mikrofon sinyalleri

Deneysel çalışmaların ilk aşamasında, veri setindeki sinyal sayılarının yetersiz olması nedeni ile öncelikle verideki her bir sinyalden %50 oranında örtüşen kayan pencere yaklaşımı ile istatistiksel (ortalama, medyan) ile spektral düzleklik ve spektral merkez özellikleri elde edilerek veri kümesine ait özelliklerin sayıları arttırılmıştır. Normalde her bir pencereden bir özellik yerine ortalama, medyan, spektral düzleklik ve spektral merkez olmak üzere 4 özellik elde edilmiştir. Böylece sinyalin N kez pencereleyerek $4 \times N$ adet özellik elde edilmiştir. Bu işlem aşamasında pencere uzunlukları ampirik yolla belirlenmiştir.

Örneğin bir dokuya ait 20s süre ile kaydı yapılan X-ekseni ivmeölçer sinyali 1×4000 örnek içermektedir. Bu sinyal örtüşmeyen ve pencere uzunluğu 0,2 saniye seçildiğinde bu ivmeölçer sinyalinden 1×40 örnek oluşan 100 adet sinyal elde edilmektedir. Veri setine ait 12 ayrı ivmeölçer sinyalinden toplamda 1×40 örnek oluşan 1200 sinyalden oluşan veri seti elde edilmektedir. Aynı şekilde 1×160000 örnek içeren mikrofon sinyalinden aynı pencere uzunluğu ile 1×1600 örnek uzunluğunda 100 adet ayrı sinyal elde edilmektedir. Kullanılan pencere genişliklerine ve elde edilen sinyal sayıları Tablo 1’de verilmiştir.

Tablo 1. Pencere genişlikleri ve elde edilen sinyal sayıları

Pencere uzunluğu (saniye)	Sinyal sayısı	Sinyal Uzunluğu X, Y, Z	
		X, Y, Z	Mikrofon
0,2	1200	40	1600
0,4	600	80	3200
0,5	480	100	4000
0,8	300	160	6400
1,0	240	200	8000

İkinci aşmada, çoğullanan her bir sinyalden ampirik yaklaşımla -5 ve 5 aralığında 0,1’ lik artış ile en yüksek başarımlı dikkate alınarak kullanılan kaba arama algoritması ile F-EADA fraktal parametresi belirlenmiştir. Birinci ve ikinci derece polinom katsayıları birleştirilerek bir ivmeölçer sinyali ile F-EADA için 42 öznitelik elde edilmiştir. Böylece 3-eksenli (X, Y, Z) ivmeölçer için öznitelik vektörü 1×126 ve mikrofon sinyali için 1×252 boyutunda öznitelik vektörü elde edilmiştir. İvme sensörü ile mikrofon beraber değerlendirildiğinde 1×378 öznitelik vektörü elde edilmiştir. Her bir pencere genişliği için elde edilen öznitelik matrisleri Tablo 2’de detaylandırılmıştır. Ayrıca pencere uzunluğunun 1 saniye olarak belirlenmesi durumunda, F-EADA yaklaşımının hesaplama verimliliği ve gerçek zamanlı uygulamalara uyumluluğu açısından dikkat çekici sonuçlar verdiği gözlemlenmiştir; nitekim, bu yapılandırma altında öznitelik çıkarımı mikrofon sinyalleri için yaklaşık 2,38

saniyede, ivme sinyalleri için 2,61 saniyede ve her iki sinyalin birlikte kullanıldığı çoklu senaryoda 3,07 saniyelik toplam işlem süresiyle tamamlanabilmektedir.

Tablo 2. Pencere genişliklerine göre öznelite matrisi boyutları

Pencere uzunluğu (saniye)	Öznelite Matris Boyutu		
	İvme Ölçer	Mikrofon	İvme Ölçer + Mikrofon
0,2	1200×126	1200×252	1200×378
0,4	600×252	600×294	600×546
0,5	480×252	480×294	480×546
0,8	300×378	300×336	300×714
1,0	240×378	240×336	240×714

Nihai aşamada, F-EADA öznelite DVM sınıflandırıcısına girdi olarak uygulanmıştır. DVM’de doğrusal çekirdek tercih edilmiş olup, çekirdek ölçeği ve C düzeltme parametresi $[2^{-5}$ ve $2^{15}]$ aralıkları taranarak en yüksek başarıyı sağlayan değer empirik yolla belirlenmiştir. Ayrıca deneysel çalışmalarda daha güvenilir ve kararlı sonuçlar elde etmek için 10 katlı çapraz doğrulama kullanılmış ve 10 katlı çapraz doğrulamanın ortalama değerleri sınıflandırma sonucu olarak alınmıştır. Sınıflandırma doğruluk performansı Tablo 3’te gösterilmiştir.

Tablo 3. Pencere genişliklerine göre sınıflandırma doğruluk performansı

Pencere uzunluğu (saniye)	Doğruluk (%)		
	İvme Ölçer	Mikrofon	İvme Ölçer + Mikrofon
0,2	68,75	94,75	96,50
0,4	76,50	97,00	97,50
0,5	80,00	97,91	98,95
0,8	81,33	98,00	99,00
1,0	82,91	98,33	99,16

Tablo 3’teki deneysel sonuçlar incelendiğinde, pencere uzunluğu 200ms (0,2s) seçildiğinde ivmeölçer verilerinde %68,75, mikrofon verilerinde %97,75 ve her iki verinin birlikte kullanımında %96,50 doğruluk başarıyı elde edilmiştir. Pencere uzunluğu 500ms olarak seçildiğinde ivmeölçer, mikrofon ve her ikisinin birlikte kullanılması durumunda sırasıyla %80, %97,91 ve 98,95 doğruluk oranlarına ulaşılmıştır. En yüksek başarıyı ise pencere uzunluğunun 1s olarak seçildiğinde ivmeölçerde %82,91, mikrofon verisinde %98,33 ve her iki sensöre ait veriler birlikte kullanıldığında ise %99,16 doğruluk oranına ulaşılmıştır. Deneysel sonuçlar, pencere uzunluğu arttıkça sınıflandırma başarıyı bütün durumlarda arttı ve her iki sensör birlikte kullanıldığında en yüksek doğruluğun elde edildiği görülmektedir.

Tablo 4. Önerilen yöntemin diğer yöntemler ile karşılaştırılması

Çalışma	İvme Ölçer	Mikrofon	İvme + Mikrofon
	Doğruluk (%)	Doğruluk (%)	Doğruluk (%)
Kursun and Patooghy 2020a	97,69	86,25	98,60
Shao et al. 2021	96,77	98,20	99,60
Önerilen Yöntem	82,91	98,33	99,16

Önerilen yüzey dokusu sınıflandırma yönteminin daha detaylı performans değerlendirmesi için aynı veri setini kullanan diğer mevcut yöntemler ile karşılaştırma sonuçları Tablo 4'te verilmiştir.

Tablo 4'deki Kursun ve Patooghy tarafından yapılan çalışmada, ivmeölçer verilerinde %97,69, mikron verilerinde %86,25 ve iki sensör verilerinin birlikte kullanımında %98,60 doğru oranına ulaşılmıştır. Aynı şekilde Shao ve diğ., tarafından yapılan çalışmada ivmeölçer, mikron ve her iki sensör verisinin birlikte kullanımında sırasıyla %96,77, %98,20 ve %99,60 doğruluk oranlarına ulaşılmıştır. Önerilen yöntem ivmeölçer sinyalleri baz alındığında diğer yöntemlerin gerisinde kalırken mikrofona sinyalinde diğer yöntemlerden sırasıyla %12,08 ve %0,13 daha yüksek doğruluk oranı elde edilmiştir. İvme sensörü ve mikrofona öznelikleri birleştirildiğinde Shao ve diğ., tarafından yapılan çalışmanın %0,44 oranında gerisinde kalırken çalışmanın gerisinde kalırken Kursun and Patooghy tarafından yapılan çalışmadan %0,56 daha üstün başarı göstermektedir.

4. Sonuç

Bu çalışmada, farklı yüzey dokularının sınıflandırılması için ivmeölçer sensörü ve mikrofona sinyallerini içeren F-EADA ve DVM algoritmalarının kullanımına dayalı bir yöntem önerilmiştir. Çalışmada önerilen yöntem, 12 farklı yüzey dokusuna ait 12 ivmeölçer ve bu yüzey dokularına ait mikrofona sinyallerini içeren veri seti ile test edilmiştir. Deneyisel çalışmalarda veri sayısı, örtüşmeyen ve kayan pencere yaklaşım ile artırıldı. Ardından en yüksek doğruluk değeri dikkate alınarak kullanılan kaba arama algoritması F-EADA fraktal parametresi ile ivmeölçer ve mikrofona verilerinden ayrı ayrı öznelik çıkarımı yapıldı. Deneyisel çalışmaların nihai aşamasında elde edilen öznelikler bağımsız ve birleştirilerek DVM'na girdi olarak uygulandı.

Deneyisel sonuçlar, veri çoğaltmada pencere genişliği arttıkça yüzey dokularının sınıflandırma performansında önemli bir iyileşme sağlandı. Pencere uzunluğu bir saniye seçildiğinde ivmeölçer, mikrofona ve her iki sensör verisinin birlikte kullanımında sırasıyla %82,91, %98,33 ve %99,16 doğruluk oranlarına ulaşılarak en yüksek performans elde edildi.

Önerilen yöntemin performansı, mevcut çalışma performansları ile karşılaştırıldığında mikrofona sinyallerinin sınıflandırılmasında %12,08 ve %0,13 daha yüksek doğruluk oranı sağlandı. İvme ölçer ve mikrofona verilerine ait özneliklerin birleştirilmesinde ise %0,56 daha üstün sınıflandırma doğruluğu sağlandı. Deneyisel sonuçlar önerilen yöntemin yüzey dokularının sınıflandırılmasında tercih edilebilirliğini göstermektedir.

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.
- BenYahmed, Yahya, Azuraliza Abu Bakar, Abdul RazakHamdan, Almahdi Ahmed, and Sharifah Mastura Syed Abdullah. 2015. "Adaptive Sliding Window Algorithm for Weather Data Segmentation." *Journal of Theoretical and Applied Information Technology* 80(2): 322–33.
- Cao, Guanqun, Jiaqi Jiang, Danushka Bollegala, Min Li, and Shan Luo. 2024. "Multimodal Zero-Shot Learning for Tactile Texture Recognition." *Robotics and Autonomous Systems* 176: 104688. doi:10.1016/j.robot.2024.104688.
- Castiglioni, Paolo, and Andrea Faini. 2019. "A Fast DFA Algorithm for Multifractal Multiscale Analysis of Physiological Time Series." *Frontiers in Physiology* 10. doi:10.3389/fphys.2019.00115.
- 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.
- Dallaire, Patrick, Philippe Giguère, Daniel Émond, and Brahim Chaib-draa. 2014. "Autonomous Tactile Perception: A Combined Improved Sensing and Bayesian Nonparametric Approach." *Robotics and Autonomous Systems* 62(4): 422–35. doi:10.1016/j.robot.2013.11.011.
- Hu, Diane, Liefeng Bo, and Xiaofeng Ren. 2011. "Toward Robust Material Recognition for Everyday Objects." In *Proceedings of the British Machine Vision Conference 2011*, British Machine Vision Association, 48.1–48.11. doi:10.5244/C.25.48.
- Kılıç, Cemil, Ömer Faruk Alçın, and Muzaffer Aslan. 2024. "Dokunsal Sensör Sinyalleri İle Yüzey Dokularının Sınıflandırılması." *Computer Science*. doi:10.53070/bbd.1596239.
- Kong, Yongkang, Guanyin Cheng, Mengqin Zhang, Yongting Zhao, Wujun Meng, Xin Tian, Bihao Sun, Fuping Yang, and Dapeng Wei. 2024. "Highly Efficient Recognition of Similar Objects Based on Ionic Robotic Tactile Sensors." *Science Bulletin* 69(13): 2089–98. doi:10.1016/j.scib.2024.04.060.

- Kursun, Olcay, and Ahmad Patooghy. 2020a. "An Embedded System for Collection and Real-Time Classification of a Tactile Dataset." *IEEE Access* 8: 97462–73. doi:10.1109/ACCESS.2020.2996576.
- Kursun, Olcay, and Ahmad Patooghy. 2020b. "Journal of Computer Science." *IEEE Access* 8: 97462–73. doi:10.1109/ACCESS.2020.2996576.
- Liu, Qi, Ming Ling, Yanxiang Zhu, Yibo Rui, and Rui Wang. 2024. "Preventing Short Violations in Clock Routing with an SVM Classifier before Powerplanning and Placement." *Microelectronics Journal* 153. doi:10.1016/j.mejo.2024.106429.
- Ma, Feihong, Yuliang Li, and Meng Chen. 2024. "Tactile Texture Recognition of Multi-Modal Bionic Finger Based on Multi-Modal CBAM-CNN Interpretable Method." *Displays* 83: 102732. doi:10.1016/j.displa.2024.102732.
- Necip, Mustapha, and Ana Maria Cretu. 2023. "Texture Classification Based on Sound and Vibro-Tactile Data †." In *Engineering Proceedings*, Basel Switzerland: MDPI, 5. doi:10.3390/ecsa-10-16082.
- Okamoto, Shogo, Hikaru Nagano, and Hsin Ni Ho. 2016. "Psychophysical Dimensions of Material Perception and Methods to Specify Textural Space." In *Pervasive Haptics: Science, Design, and Application*, , 3–20. doi:10.1007/978-4-431-55772-2_1.
- Peng, C.-K., S. V. Buldyrev, S. Havlin, M. Simons, H. E. Stanley, and A. L. Goldberger. 1994. "Mosaic Organization of DNA Nucleotides." *Physical Review E* 49(2): 1685–89. doi:10.1103/PhysRevE.49.1685.
- 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.
- Prescott, Tony, Ben Mitchinson, and Robyn Grant. 2011. "Vibrissal Behavior and Function." *Scholarpedia* 6(10): 6642. doi:10.4249/scholarpedia.6642.
- Qian, Xi-Yuan, Gao-Feng Gu, and Wei-Xing Zhou. 2011. "Modified Detrended Fluctuation Analysis Based on Empirical Mode Decomposition for the Characterization of Anti-Persistent Processes." *Physica A: Statistical Mechanics and its Applications* 390(23–24): 4388–95. doi:10.1016/j.physa.2011.07.008.
- Qin, Liguang, Luxin Hao, Xiaodong Huang, Rui Zhang, Shan Lu, Zheng Wang, Jianbo Liu, et al. 2024. "Fingerprint-Inspired Biomimetic Tactile Sensors for the Surface Texture Recognition." *Sensors and Actuators A: Physical* 371: 115275. doi:10.1016/j.sna.2024.115275.
- 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/SENSOR47087.2021.9639755.
- 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.
- Shao, Shiliang, Ting Wang, Yun Su, Chen Yao, Chunhe Song, and Zhaojie Ju. 2021. "Multi-IMF Sample Entropy Features with Machine Learning for Surface Texture Recognition Based on Robot Tactile Perception." *International Journal of Humanoid Robotics* 18(02): 2150005. doi:10.1142/S0219843621500055.
- Strese, Matti, Clemens Schuwerk, Albert Iepure, and Eckehard Steinbach. 2017. "Multimodal Feature-Based Surface Material Classification." *IEEE Transactions on Haptics* 10(2): 226–39. doi:10.1109/TOH.2016.2625787.
- Vafaeipour, Majid, Omid Rahbari, Marc A. Rosen, Farivar Fazelpour, and Pooyandeh Ansarirad. 2014. "Application of Sliding Window Technique for Prediction of Wind Velocity Time Series." *International Journal of Energy and Environmental Engineering* 5(2–3): 1–7. doi:10.1007/s40095-014-0105-5.
- Vapnik, Vladimir N. 1999. "An Overview of Statistical Learning Theory." *IEEE Transactions on Neural Networks* 10(5): 988–99. doi:10.1109/72.788640.
- Zacharia, V., A. Bardakas, A. Anastasopoulos, M.A. Moustaka, E. Hourdakis, and C. Tsamis. 2024. "Design of a Flexible Tactile Sensor for Material and Texture Identification Utilizing Both Contact-Separation and Surface Sliding Modes for Real-Life Touch Simulation." *Nano Energy* 127: 109702. doi:10.1016/j.nanoen.2024.109702.