

Tekstil Proseslerinde Zamansal Model Tabanlı Toplu Anomali Tespiti

Temporal Pattern-Based Collective Anomaly Detection in Textile Processes

Devilliers Caleb Dube¹, Mustafa Çom², Mehmet Akar¹

¹Elektrik ve Elektronik Mühendisliği Bölümü
Boğaziçi Üniversitesi, İstanbul
devilliers.dube@boun.edu.tr
mehmet.akar@boun.edu.tr

²Eliar Elektronik San. A. Ş., İstanbul
mustafa.com@eliarge.com

Özetçe

Anomali tespiti, güç sistemleri ve iletişim ağları da dahil olmak üzere çeşitli sektörlerde dikkat çekmiştir. Bununla birlikte, tekstil proseslerine yeterince odaklanılmamıştır ve özellikle toplu anormalliklerle karşılaşan toplu prosesler üzerinde herhangi bir anormallik tespit araştırması yapılmamıştır. Bu bildiride, daha önce görülmemiş zamansal kalıpları anormallikler olarak tanımlamak için derin bir sinir ağı çerçevesi kullanılarak gözetimsiz anomali tespiti gerçekleştirilmiştir. Bu yaklaşım, F1-skoru kullanılarak simüle edilmiş ve gerçek zamanlı tekstil prosesleri sıcaklık verileri üzerinde değerlendirilmiştir. Modelin doğruluğunu incelemek için toplu işlemler için yeni bir değerlendirme metriği önerilmiştir. Tekstil verilerinden elde edilen sonuçlar, seçilen çerçevenin normal ve anormal zamansal kalıpları mükemmel bir şekilde ayırt edebildiğini göstermektedir. Ayrıca, önerilen değerlendirme metriğinin, dayanıklı bir model tasarlamak için en uygun parametre ayarlarını seçmeye yardımcı olduğu sonucuna varılmıştır.

Abstract

Anomaly detection has drawn attention from various sectors, including power systems and communication networks. However, there has not been enough focus on textile processes, and particularly, no anomaly detection research has been conducted on batch processes that encounter collective anomalies. In this paper, we perform unsupervised anomaly detection using a deep neural network framework to identify previously unseen temporal patterns as anomalies. This approach is evaluated on simulated and real-time textile processes temperature data using the F1-score. To further decide on the robustness of the model, we propose a novel evaluation metric for batch processes. The results from textile dyebath temperature data show that the chosen framework can perfectly discriminate between normal and abnormal temporal patterns. We also conclude that the proposed evaluation metric helps select optimal parameter settings to design a robust model.

1. Giriş

Dayanıklı ve etkili anormal durum tespit tekniklerine olan ihtiyaç, son yıllarda sistemlerin geniş ölçüde birbirine bağlanmasından ve endüstride Nesnelerin İnterneti (IoT) kullanımından kaynaklanan hassasiyet nedeniyle artmıştır [1]. Anomaliler günlük yaşamın bir parçasıdır, ancak endüstride yaşanan anomaliler insanlar ve çevre için ciddi bir tehlike oluşturabilmektedir. Bu nedenle, tam bir sistem arızası öncesinde anormalliklerin tanımlanması ve hafifletilmesi gerekmektedir. Bir anormal durum, veri noktası veya diğer verilerin dağılımından önemli ölçüde sapma gösteren veri noktası veya veri noktaları kümesidir. Anormal durum tespiti, bu tür standart veri dağılımından sapma gösteren veri noktalarını tanımlayan bir sınıflandırma sorunudur. Zaman serilerinde, anormal durumlar nokta, kolektif ve bağlamsal anormal durumlar olarak sınıflandırılabilir. Bu çalışmada, kolektif anormal durumlar üzerine odaklanılmış olup, istatistiksel aykırı değerlerin veya yeni zamansal desenlerin bir grubu olan bu anormal durumlar, bireysel olarak incelendiklerinde normal olarak sınıflandırılabilir [2].

Farklı endüstrilerde, ekipman endüstriyel kontrol sistemleri (ICS'ler) ile gömülü hale getirilmiştir. Bu özelleşmiş elektronik kontrol sistemleri, endüstriyel süreçleri ve altyapı operasyonlarını izlemek için kullanılan sistemlerdir. ICS'lerin amacı, endüstriyel süreçlerin gerçek zamanlı izlenmesini ve kontrolünü sağlayarak düzgün ve güvenli bir işleyişi temin etmektir [3]. Bununla birlikte, ekipman arızası, insan ve yazılım hataları gibi faktörler anormal sistem davranışına neden olabilmektedir. İletişim ağlarında ve siber güvenlikte anormal durum tespiti adıyla anılan sızma tespiti, kötü amaçlı yazılım ve siber saldırılar nedeniyle önemli bir araştırma alanıdır. Sızma tespiti alanındaki araştırmalar, farklı veri setlerini kullanarak yapılan çeşitli tekniklerin bir derlemesinde görülebileceği gibi, bu alanlarda hızla büyümektedir [4].

Anormal durum tespiti araştırmasının yaygınlaşması, büyük veri kullanımını ve ardışık olarak daha iyi tekniklerin geliştirilmesini teşvik etmiştir. Endüstriyel süreçlerde, gerçek zamanlı olarak birçok yüksek boyutlu zaman serisi verisi üreten çeşitli sensörler kullanılmaktadır. Geleneksel makine öğrenimi teknikleri, otoregresif entegre hareketli ortalama gibi, çok sa-

yıda eğitim zamanı gerekmektedir ve büyük miktarda veriye tabi tutulduğunda aşırı uyuma sorunu yaşayabilmektedir. Bu çevreler istenen performansı vermeyebilmektedir veya gereken süre içinde anormallikleri tanımlayamayabilmektedir. Bu nedenle, zaman serilerinde uygulamalar için tercih edilmemektedir, çünkü anormal durum tespiti için dağıtılmadan önce uzun bir eğitim süresi gerekmektedir. En yakın komşu veya yoğunluk tabanlı algoritmalar zaman serisi verilerinin periyodik ve mevsimsellik bileşenlerini tanımlayamayabilmektedir [5]. Bu nedenle, derin öğrenme ve yapay sinir ağları tabanlı yaklaşımlar [6] mevcut en iyi teknikleri belirleyen domine edici yaklaşımlardır.

Anormal durum tespiti tekniklerinin kullanılabilirliği ve etkinliği, endüstride önemli bir adımdır. Bununla birlikte, birçok ticari olarak mevcut anormal durum tespit modellerinin, farklı makinelerden gelen geniş akış verileri üreten büyük şirketlerde kullanımı zor olabilmektedir. Her alanda, değerlendirme metrikleri ve hiperparametreler sürekli olarak değiştirilip ayarlanmalıdır ve büyük veri ile çalışırken bu talepkar bir görevdir. Bu durumdan kaçınmak için, bazı görevlerin otomatikleştirilmesi stratejisi olan otomatik makine öğrenimi benimsenebilmektedir [7].

Birçok zaman serisi anormal durum tespiti tekniği tahmin veya rekonstrüksiyona dayanmaktadır. DeepAnT, tahmin tabanlı bir model olup, tipik veri davranışını tahmin etmek için kullanılan dağılımı öğrenmek için etiketsiz verileri kullanılmaktadır. İki modülden oluşur: zaman serisi tahmincisi ve anormal durum tespit edici. Zaman serisi tahmincisi, önceki veri noktalarının belirli bir penceresini kullanarak bir sonraki zaman damgası için tahminler yapmak için evrişimli sinir ağları (CNN'ler) kullanılmaktadır. Anormal durum tespit edici modül, tahmin edilen değerlerin veri dağılımına uyup uymadığını belirlemek için beklenen değeri kullanmaktadır [8].

Yapısal sağlık izlemede, yapısal anormalliklere ait önemli değişiklikleri etkili bir şekilde çıkarabilen algoritmalar geliştirmek kritik bir zorluktur. Ancak, özellikle sıcaklık dalgalanmaları gibi çevresel koşulların etkisi, veri yanlışlarına neden olabilmektedir. Bu nedenle, beklenmeyen sıcaklık dalgalanmalarını hesaba katan yapısal anormalliği belirlemek için teknikler geliştirmek esastır. Bu araştırma alanında, yapısal anormallik tespiti için Sıcaklık Tabanlı Hareketli Temel Bileşen Analizi yaklaşımı [9] sunulmaktadır.

Son zamanlarda, tekstil terbiye verilerinde anormal durum tespiti için yarı denetimli elastik şekil analizi çerçevesi önerilmiştir [10]. Kısmen etiketli veri gerektiren yarı denetimli bir yaklaşım kullanımı, hala büyük yüksek boyutlu çok değişkenli zaman serisi verileriyle çalışırken dikkate değer bir dezavantaj oluşturmaktadır. Bu, tekstil endüstrisinde anormal desenleri belirlemeye odaklanmış nadir çalışmalardan biridir. Ancak, toplu tekstil işlemleri için kolektif anormal durum tespiti alanında geniş çaplı araştırma henüz yapılmamıştır. Tekstil işlemleri, karmaşık, birbirine bağlı sistemlerden oluşur ve bu nedenle ekipman arızası ve aşırı ısınma gibi çeşitli anormalliklere karşı duyarlıdır, bu da işlem kesintilerine neden olabilir. Bu makalenin ana hedefleri şunlardır:

- Tekstil boyama prosesi sıcaklık verilerinden kolektif anormallikleri, özellikle salınımları, tanımlamak.
- Önerilen değerlendirme metriği kullanarak sağlam mo-

del parametre ayarlarını seçmek.

2. Yöntemler ve Veri Kümesi

2.1. Anomali Tespit Çerçevesi

Bu çalışmada, anormallikleri tespit etmek ve kök nedenin teşhisini sağlamak amacıyla tasarlanmış Çok-Ölçekli Evrişimsel Yinelgen Kodlayıcı-Çözücü (MSCRED) çerçevesini kullanılmaktadır [11]. MSCRED, önceden görülmemiş verilerin veya zamansal desenlerin kötü bir şekilde yeniden oluşturulduğu ve bu nedenle anormallik olarak işaretlendiği düşüncesini kullanan bir yeniden yapılandırma temelli bir yöntemdir. İlk olarak, MSCRED, çok değişkenli zaman serisi verileri içindeki korelasyonu kullanarak normal verilerin eğitim için korelasyon matrislerini, aynı zamanda imza matrisleri olarak adlandırılanları, oluşturmaktadır. Bu imza matrisleri daha sonra mekansal desen kodlaması için evrişimli bir kodlayıcıya beslenmektedir [12]. Ardından, verideki zamansal desenler, dikkat temelli Bir Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) kullanılarak yakalanmaktadır [13]. Bundan sonra, bir evrişimli çözücü kullanılarak korelasyon matrisleri yeniden oluşturulmaktadır. Son olarak, yeniden yapılandırılmış imza matrisleri orijinal olanlardan çıkarılarak artık matrisler elde edilmektedir.

Modeli veri setlerimizle uyumlu hale getirmek için bazı MSCRED parametre ayarları değiştirilmiştir. 1. Evrişimli kodlayıcıdan 4. evrişimli kodlayıcıya kadar olan bölgeler (conv1'den conv4'e kadar), sırasıyla $1 \times 1 \times 3$ boyutunda 32 filtre, $1 \times 1 \times 32$ boyutunda 64 filtre, $1 \times 1 \times 64$ boyutunda 128 filtre ve $1 \times 1 \times 128$ boyutunda 256 filtre kullanılmıştır. Ayrıca, tüm evrişimli kodlayıcı katmanlarında 1×1 boyutunda adımlar kullanılmıştır. ConvLSTM için bir adım uzunluğu olarak 2'yi seçilmiştir. Korelasyon matrislerini yeniden oluşturmak için, 1. çözücünden 4. çözücüyeye kadar olan bölgeler (deconv4'ten deconv1'e kadar), sırasıyla $1 \times 1 \times 256$ boyutunda 128 filtre, $1 \times 1 \times 128$ boyutunda 64 filtre, $1 \times 1 \times 64$ boyutunda 32 filtre ve $1 \times 1 \times 64$ boyutunda 3 filtre kullanılmıştır; her biri 1×1 boyutunda adım boyutuna sahiptir. Simülasyon veri seti için amaç noktasal anormallik skorlarını elde etmek olduğundan, daha kısa bir pencere boyutu olan $w = [10, 20, 30]$ seçtik. Ancak, tekstil veri seti için amaç toplu anormallik skorlarını elde etmektir; bu nedenle daha uzun bir pencere boyutu olan $w = [60, 90, 120]$ seçilmiştir.

İlk olarak, tekstil boyama prosesi sıcaklık veri seti, referans sıcaklıkları olmayan kontrolsüz bölgeleri ve diğer farklı türdeki anormallikler çıkarılarak temizlenmektedir. Algoritma zamansal desenleri öğrendiği için, veri setinin tümünde referans sıcaklığı değeri bu çalışmada 50°C olarak ayarlandı ve boyama prosesi sıcaklığı, referans ile sıcaklık arasındaki fark değişmeden kalacak şekilde kaydırılmıştır. Bunun amacı, modelin bir partiden diğerine referansın değişimini bir zamansal desen olarak öğrenmesini engellemektir. Eğitim verisinde anormallikleri çıkardık, böylece model yalnızca normal desenleri öğrenmektedir. İki zaman serisi olduğundan, her bir veri noktası 2×2 korelasyon matrisi ile temsil edilmektedir ve RGB imza matrisi olarak MSCRED çerçevesine beslenmektedir. Korelasyon matrislerinin yeniden yapılandırma hatalarının toplamı, noktasal anormallik tespitinde anormallik skorları olarak kullanılmaktadır. Her parti için imza matrislerinin kötü bir şekilde ye-

niden oluşturulan girdilerinin ortalama sayısı, toplu anormallik tespiti için anormallik skorları olarak kullanılmaktadır.

2.2. Veri Kümesi

Öncelikle, referans ve simüle edilen sinyal olmak üzere 2 zaman serisi içeren sentetik bir veri kümesi oluşturulmuştur. Tekstil boyama prosesi sıcaklık veri kümesi de aynı şekilde 2 zaman serisi içermektedir. Bu veri setlerinin ayrıntılı bilgileri Tablo 1’de sunulmuştur.

Tablo 1: Veri kümesinin açıklamaları

Veri Seti	Simüle Edilen	Tekstil
Uzunluk	7000	50245
Eğitim Seti	0 - 5000	0 - 35000
Doğrulama Seti	5000 - 5500	35000 - 40018
Test Seti	5500 - 7000	40018 - 50245

2.2.1. Simüle Edilen Veri Kümesi

Sentetik bir veri oluşturmak için öncelikle, ilk olarak, aşağıdaki şekilde gösterilen bir sinüzoidal dalga fonksiyonundan 100 veri noktası üretilmektedir (1):

$$f_1(t) = \sin\left(\frac{2\pi t}{T}\right) + r(t), 0 \leq t < 100 \quad (1)$$

burada t zaman damgasını, T dönemi (100) ve $r(t)$ referansı temsil etmektedir.

Sonrasında, $100 \leq t < 200$ aralığında $r(t) + 1$ ile $r(t) - 1$ arasında eşit aralıklı 100 veri noktası üretilmiştir. Ardından, bu veri noktalarını sinüzoidal dalga ile birleştirerek normal noktaların veya bilinen zamansal desenlerin 1 periyodunu oluşturulmuştur. Birleştirmeden sonra, simüle edilen sinyal bir sinüzoidal dalga ile bir üçgen dalga takip eden bir yapıya sahiptir. Bu veri noktaları toplamda 33 periyot boyunca tekrarlandı ve 6600 normal nokta elde edilmiştir.

Son olarak, yeni bir zamansal desen olan kare dalga, (2)’de gösterildiği gibi, 1 periyot boyunca simüle edilmiştir:

$$f_2(t) = \begin{cases} 1 + r(t), & 0 \leq t < 25 \\ -1 + r(t), & 25 \leq t < 50 \end{cases} \quad (2)$$

Kare dalga toplamda 8 periyot boyunca tekrarlandı ve 400 noktadan oluşan yeni bir zamansal desen elde edilmiştir. Bu desen 6600 normal noktasıyla birleştirilerek toplamda 7000 noktadan oluşan bir veri seti oluşturulmuştur. Referans değeri veri kümesi boyunca 50 olarak sabitlenmiştir; bu nedenle, simüle edilen sinyal 49 ile 51 arasında değişen bir yapıya sahip şekilde tasarlanmaktadır.

2.2.2. Tekstil Boyama Prosesi Sıcaklık Veri Kümesi

Bu çalışmada kullandığımız tekstil veri kümesi, referans ve gerçek zamanlı boyama prosesi sıcaklıklarını içermektedir. Tekstil işlemleri, 130°C ’ye kadar çıkabilen farklı sıcaklık seviyelerinde parti halinde gerçekleşmektedir. Boyama işlemi ilerledikçe, boyama prosesi sıcaklığının referansı takip etmesi beklenmektedir. Bu nedenle, normal işlem çalışması referansı yaklaşılan desenlerden veya düşük takip hatasına sahip olan desenlerden oluşmalıdır. Sönümlenmiş bir salınımla davranan sıcaklık parti halinde normal olarak kabul edilmektedir. Aynı şekilde,

referansın hafifçe üzerine yakınsayan boyama prosesi sıcaklığı da normal bir desen olarak kabul edilmektedir. Öte yandan, parti sıcaklığı sönümsüz veya azalmayan salınımlı bir davranış sergiliyorsa, bu anormallik olarak kabul edilmektedir. Veri kümemiz, bilinen bir konuma yerleştirilmiş bir anormallik içeren bir tane anormallığı içermektedir.

3. Deneyle

Bu bölümde, uygulanan tekniğin performansı hem simüle edilen hem de tekstil veri kümesinde değerlendirilmiştir. Simüle edilen veri kümesi için değerlendirme olarak F1-skorunu kullanılmış bulunmaktadır, bu skor *precision* ve *recall* hesaplanmaktadır:

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

burada TP , FP ve FN sırasıyla doğru pozitif, yanlış pozitif ve yanlış negatif sayılarıdır. Tüm deneyler boyunca F1-skorunu en üst seviyeye çıkaran anormallik eşik değerlerini deneysel olarak seçilmektedir.

Tekstil veri seti için yeni bir değerlendirme metriği önerdik ve bu metriği kullanarak değerlendirme yapılmaktadır. Ayrıca, bölüm 2.1’de açıklanan parametrelere sahip olan MSCRED modelinin performansını, dikkat mekanizmasını kullanmayan bir MSCRED varyantı olan $CNN_{ConvLSTM}^{ED}$ modeli ile karşılaştırılmaktadır.

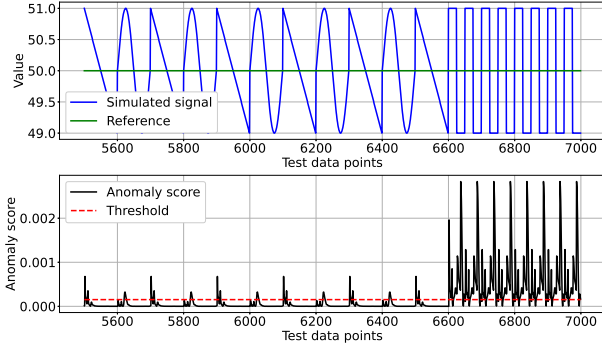
3.1. Simüle Edilen Veri ile Sonuçlar

En yaygın kullanılan metrikleri kullanarak anormallik tespiti sonuçlarını sağlanmaktadır. Ayrıca, kolektif anormallik tespitinde F1-skorunun kullanımını ve sınırlamalarını analiz edilmiştir.


Tablo 2: Noktasal anormali tespiti sonuçları % olarak

Yöntem	Precision	Recall	F1
$CNN_{ConvLSTM}^{ED}$	75.47	50.00	60.15
MSCRED	81.67	85.75	83.66


Şekiller 1 ve 2, sırasıyla MSCRED ve $CNN_{ConvLSTM}^{ED}$ kullanılarak elde edilen noktasal anormallik skorlarını göstermektedir. MSCRED’in daha az yanlış pozitif ve yanlış negatif sonuçlar verdiği görülmektedir. Tablo 2’de gösterilen anormallik tespiti F1-skorları, MSCRED’in üstün performansının bir kanıtını daha sunmaktadır. Bu durum, modelin en önemli veri özelliklerini seçmesine ve daha az önemsiz olanları görmezden gelmesine izin veren dikkat mekanizmasına atfedilebilmektedir. Bu sonuçlar noktasal anormallik skorlarından elde edildiğinden, toplu işlemlerde bazı anormal veri noktalarının normal olarak tespit edilebileceği unutulmamalıdır. Bu nedenle, toplu anormallik skorları Şekil 3’te gösterildiği gibi elde edilmelidir. Veriyi toplu işlemler olarak değerlendirerek, model bilinen ve yeni zamansal desenler arasındaki farkı 1 F1-skoruyla ayırt edilmektedir. Ancak, bu şekilde toplu anormallikleri değerlendirmek, en iyi ve en sağlam modeli belirleme konusunda bir ikilem



Şekil 1: Simüle verinin test alt kümesi ve MSCRED kullanılarak noktasal anormallik tespiti.



Şekil 2: $CNN_{ConvLSTM}^{ED}$ kullanılarak noktasal anormallik tespiti.



Şekil 3: MSCRED kullanılarak kolektif anormallik tespiti.

bırakmaktadır. Bu nedenle, bu konuda ayrıntılı olarak açıklanan yeni bir değerlendirme metriği önerilmektedir.

3.2. Tekstil Sıcaklık Verileri ile Sonuçlar

Modelin sağlamlığını daha fazla değerlendirmek için anormallik eşiği düzenlemesi (ATR) metrik öneriyoruz. ATR , anormallik oluşturmadan eşiği değiştirme özgürlüğünü ölçer ve aşağıdaki gibi hesaplanmaktadır:


$$ATR = \frac{A1_{min} - A0_{max}}{A1_{min}} \times 100\% \quad (6)$$

burada $A1_{min}$, doğru pozitif partilerin en küçük anormallik skoru ve $A0_{max}$, normal partilerin en büyük anormallik skordur. Bu metriği önerme nedenimiz, farklı veri setilerindeki normal desenlerin önemli bir derecede benzerlik göstermesi, ancak tamamen aynı olmamasıdır. Bu nedenle model, bu desenleri daha önce bu makalede sunulan tanımlara uygun olarak normal olarak sınıflandırmaya devam etmelidir.


Bu çalışmada, modelin anormal partileri normal partilerden mükemmel bir şekilde ayırt etmesi gerekmektedir. Bu nedenle F1-skorunu kullanırken, modelin mükemmel bir değere sahip olması gerekmektedir. Bu bölümde kullanılan tüm modeller, partilerin hassasiyetini 1, hatırlatmayı 1 ve dolayısıyla F1-skorunu 1 olarak vermektedir. Daha sonra $A1_{min}$ ve ATR

Tablo 3: Kolektif anormallik tespiti sonuçları


Framework	θ	ATR	$A1_{min} \times ATR$
$CNN_{ConvLSTM}^{ED}$	5×10^{-6}	66.12%	0.54
MSCRED	5×10^{-5}	100%	0.17
MSCRED	5×10^{-6}	90.58%	0.67
MSCRED	5×10^{-7}	14.15%	0.55




Şekil 4: $\theta = 5 \times 10^{-5}$ değeriyle MSCRED kullanılarak kolektif anormallik tespiti.



Şekil 5: $\theta = 5 \times 10^{-6}$ değeri kullanılarak MSCRED ile yapılan kolektif anormallik tespiti.



Şekil 6: $\theta = 5 \times 10^{-7}$ değeri kullanılarak MSCRED ile yapılan kolektif anormallik tespiti.



Şekil 7: $\theta = 5 \times 10^{-6}$ değeri kullanılarak $CNN_{ConvLSTM}^{ED}$ ile yapılan kolektif anormallik tespiti.

değerlerini kullanarak en iyi model parametrelerini seçiyoruz. Optimal anormallik skorları ve optimal ATR elde etmeyi amaçlanmaktadır. Çalışmamızda $A1_{min} \times ATR = A1_{min} - A0_{max}$ ifadesini en büyük hale getiren bir model seçilmektedir. Farklı ATR değerleri, yeniden yapılandırma hatalarının hata eşiğini (θ) değiştirerek elde edilebilmektedir:

6. Kaynakça

$$\mathcal{L}_i = \left\| \mathcal{X}_i - \hat{\mathcal{X}}_i \right\|^2, i = 1, 2, \dots, m \quad (7)$$

burada m , test veri noktalarının sayısıdır, \mathcal{X}_i ve $\hat{\mathcal{X}}_i$ sırasıyla orijinal ve yeniden yapılandırılmış korelasyon matrisleridir. Noktasal anormallik skoru, \mathcal{L}_i içindeki girdilerin θ değerinden büyük olan sayısıdır.

Çalışmamız için ideal bir model, $ATR = 100\%$, $A1_{min} = 4$, ve $A1_{min} \times ATR = 4$ özelliklerine sahip olacaktır. Şekiller 4 ile 7, bölüm 2.1’de açıklanan parametrelere sahip MSCRED ve $CNN_{ConvLSTM}^{ED}$ modellerinin farklı θ değerlerindeki toplu anormallik skorlarını göstermektedir. Tablo 3, önerilen metrik kullanılarak yapılan toplu anormallik tespiti sonuçlarını ve en iyi modeli seçmek için kullanılan karar kriterlerini göstermektedir.

Şekil 4’deki modelin θ değeri deneylerimizdeki en yüksektir. Bu sonuçlar, yüksek θ değerinin mükemmel bir ATR ’ye karşılık geldiğini göstermektedir; ancak osilasyon anomalisi partisinde düşük bir anormallik skoru istenmeyen bir durumdur. Diğer taraftan, Şekil 6’da gösterilen en düşük θ değerini kullanmak, normal partiler için anormallik skorlarını büyük ölçüde artırırken, aynı zamanda normal partiler için de geçerlidir. Bu, anormallik eşliğini değiştirme özgürlüğünün düşük olmasıyla sonuçlanır, bu da modelin farklı bir veri setine tabi tutulduğunda ayırt edici yeteneğini düşürebilmektedir. Optimal model, $\theta = 5 \times 10^{-6}$ değeri ile elde edilmektedir ve Şekil 5’ten görüleceği gibi model, hedeflenen anormallığe göre nispeten yüksek anormallik skorları sağlarken normal partilerin anormallik skorlarını 0’a yakın tutmaktadır. Ayrıca, MSCRED’in performansı, optimal θ değeri kullanılarak $CNN_{ConvLSTM}^{ED}$ ile karşılaştırılmıştır. Sonuçlar, MSCRED’in daha iyi performans gösterdiğini ve bu durumun dikkat mekanizmasının zamansal desenleri öğrenmedeki önemini daha da kanıtladığını göstermektedir.

Bu deneyleri, Intel(R) Core(TM) i7-7700 CPU @ 3.60GHz işlemciye ve NVIDIA GeForce GTX 1050 grafik kartına sahip bir bilgisayarda PyTorch kullanarak gerçekleştirilmiştir.

4. Sonuçlar

Bu çalışmada, tekstil süreçlerinde kolektif anormallik tespiti üzerine yapılan bir çalışma sunulmuştur. Bu alan, bu araştırma alanında henüz çok fazla ilgi görmemiştir. Ayrıca, toplu olarak veri toplanan verilerde kolektif anormallikler için yeni bir değerlendirme metriği önerilmiştir. Çeşitli parametre ayarları kullanılarak 2 farklı derin öğrenme yapısıyla deneylerimizi gerçekleştirilmiştir. Benzer F1-skorları elde edildiğinde en dayanıklı modeli seçmede önerilen değerlendirme metriğinin faydalı olduğuna sonuçlanmaktadır. Bundan sonraki çalışmamız, arızalı programlama mantık denetleyicileri ve sensörler nedeniyle gürültülü veriler gibi çeşitli anormallikleri içeren geniş bir dizi tekstil veri setinde derin öğrenme çerçeveleri tasarlamayı ve değerlendirmeyi içerecektir. Ayrıca, optimal model seçimi için farklı karar kriterlerini tasarlama ve inceleme konusunda çalışmalar yapılacaktır.

5. Teşekkürler

Tekstil boyama prosesi verilerini ve gerekli alan uzmanlığını sağladığı için Eliar Elektronik San. A.Ş.’ye teşekkür ederiz.

- [1] K. Wójcicki, M. Biegańska, B. Paliwoda, and J. Górna, “Internet of Things in Industry: Research Profiling, Application, Challenges and Opportunities—A Review,” *Energies*, vol. 15, no. 5, p. 1806, Feb. 2022.
- [2] M. Thill, W. Konen, H. Wang, and T. Bäck, “Temporal convolutional autoencoder for unsupervised anomaly detection in time series,” *Applied Soft Computing*, vol. 112, p. 107751, Nov. 2021.
- [3] M. R. Asghar, Q. Hu, and S. Zeadally, “Cybersecurity in industrial control systems: Issues, technologies, and challenges,” *Computer Networks*, vol. 165, p. 106946, Dec. 2019.
- [4] A. Khraisat, I. Gondal, P. Vamplew, and J. Kamruzzaman, “Survey of intrusion detection systems: techniques, datasets and challenges,” *Cybersecur*, vol. 2, no. 1, p. 20, Dec. 2019.
- [5] A. B. Nassif, M. A. Talib, Q. Nasir and F. M. Dakalbab, “Machine Learning for Anomaly Detection: A Systematic Review,” in *IEEE Access*, vol. 9, pp. 78658-78700, 2021.
- [6] D. Wagner, T. Michels, F. C. F. Schulz, A. Nair, M. Rudolph, and M. Kloft, “TimeSeAD: Benchmarking Deep Multivariate Time-Series Anomaly Detection,” *Transactions on Machine Learning Research*, 2023.
- [7] M. Bahri, F. Salutari, A. Putina, and M. Sozio, “AutoML: state of the art with a focus on anomaly detection, challenges, and research directions,” *Int J Data Sci Anal*, vol. 14, no. 2, pp. 113–126, Aug. 2022.
- [8] M. Munir, S. A. Siddiqui, A. Dengel and S. Ahmed, “DeepAnT: A Deep Learning Approach for Unsupervised Anomaly Detection in Time Series,” in *IEEE Access*, vol. 7, pp. 1991-2005, 2019.
- [9] Y. Zhu, Y.-Q. Ni, H. Jin, D. Inaudi, and I. Laory, “A temperature-driven MPCA method for structural anomaly detection,” *Engineering Structures*, vol. 190, pp. 447–458, Jul. 2019.
- [10] F. F. Ferro, M. Rampazzo and A. Beghi, “Elastic Shape Analysis for Anomaly Detection in Textile Finishing Time-Series Data,” 2022 IEEE Conference on Control Technology and Applications (CCTA), Trieste, Italy, 2022, pp. 82-88.
- [11] C. Zhang et al., “A Deep Neural Network for Unsupervised Anomaly Detection and Diagnosis in Multivariate Time Series Data,” *AAAI*, vol. 33, no. 01, pp. 1409–1416, Jul. 2019.
- [12] J. Long, E. Shelhamer, and T. Darrell, “Fully convolutional networks for semantic segmentation,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 3431–3440.
- [13] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W. Woo, “Convolutional LSTM network: A machine learning approach for precipitation nowcasting,” *Advances in neural information processing systems*, vol. 28, 2015.