

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**AKAN VERİDE ARTIMLI ÖĞRENME YAKLAŞIMLARI GELİŞTİRİLMESİ İLE VIDEO
VERİLERİNDE ANOMALİ TESPİTİ ÇALIŞMASI**

DOKTORA TEZİ

Bil. Yük. Müh. Özge AYDOĞDU

**HAZİRAN 2021
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**AKAN VERİDE ARTIMLI ÖĞRENME YAKLAŞIMLARI GELİŞTİRİLMESİ İLE VIDEO
VERİLERİNDE ANOMALİ TESPİTİ ÇALIŞMASI**

Özge AYDOĞDU

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 26 / 05 / 2021

Tezin Savunma Tarihi : 30 / 06 / 2021

Tez Danışmanı : Prof. Dr. Murat EKİNCİ

Trabzon 2021

ÖNSÖZ

Akan veri teknolojinin ilerlemesiyle birlikte birçok uygulama alanının ürettiği sırasız, sonsuz uzunlukta, sürekli üretilen bir veri türüdür ve analizi, işlenmesi ve öğrenmesi için özel yaklaşımlar gerektirmektedir. Bu tez çalışmasında akan veri için makine öğrenmesine dayalı akan verilerin kısıtlamalarını ve özelliklerini karşılayan yeni öğrenme yaklaşımları geliştirilmiş ve popüler akan veri setlerine uygulanmıştır. Geliştirilen akan veri yaklaşımlarından türetilen yaklaşımlar gerçek dünya problemi olan video anomali tespiti için literatürdeki çalışmalardan farklı olarak akan veri metodolojisi kullanılarak geliştirilmiş ve gerçek video setlerine uygulanarak problem irdelenmiştir.

Bu çalışmanın planlanmasında, araştırılmasında, yürütülmesinde ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren değerli tez danışmanım Prof. Dr. Murat EKİNCİ' ye sonsuz teşekkürlerimi sunarım. Tez sürecinde fikirlerinden yararlandığım ve tezin gelişmesinde bana ışık tutan değerli tez izleme komitesi hocalarım Doç. Dr. Güzin ULUTAŞ ve Dr. Öğr. Üyesi Mehmet ÖZTÜRK' e teşekkür ederim. Tez çalışmam süresince BİDEB 2228-B Yurt içi Doktora Burs Programı kapsamında beni maddi olarak destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)' a teşekkürlerimi bir borç bilirim. Bana doktora eğitimim ve özellikle akademisyenlik hayatım boyunca desteklerini esirgemeyen ve her zaman yanımda olan eşime ve aileme şükranlarımı sunarım.

Özge AYDOĞDU

Trabzon 2021

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “AKAN VERİDE ARTIMLI ÖĞRENME YAKLAŞIMLARI GELİŞTİRİLMESİ İle VIDEO VERİSİNDE ANOMALİ TESPİTİ ÇALIŞMASI” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Murat EKİNCİ’ nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 30/06/2021

Özge AYDOĞDU

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	X
SUMMARY	XI
ŞEKİLLER DİZİNİ.....	XII
TABLolar DİZİNİ.....	XIV
SEMBOLLER DİZİNİ	XVI
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Tezin Kapsamı.....	3
1.3. Akan Veri Kısıtlamaları	5
1.3.1. Tek Geçişlilik	5
1.3.2. Gerçek Zamanda Cevap Verme	5
1.3.3. Sınırlı Bellek	5
1.3.4. İçerik Farklılaşması	5
1.4. Akan Veri İşleme Genel Modeli	9
1.4.1. Zaman Pencereleeri.....	9
1.4.1.1. Dönüm Noktası Pencere Modeli	10
1.4.1.2. Kayan Pencere Modeli	10
1.4.1.3. Yaşlandırma Penceresi Modeli.....	11
1.4.1.4. Eğimli Zaman Penceresi Modeli	12
1.4.2. Hesaplama Yaklaşımları	12
1.4.2.1. İki Fazlı Öğrenme.....	13
1.4.2.2. Artımlı Öğrenme	13
1.4.3. Akan Veri Değerlendirme Teknikleri	14
1.5. Akan Veri Uygulamaları	14
1.5.1. Madencilik Sorgu Akışları	15
1.5.2. Ağ İzleme	15

1.5.3.	Sensor Ağları.....	15
1.5.4.	Sosyal Ağ Akışları	16
1.6.	Akan Veri Madenciliği Yazılım Araçları.....	16
1.6.1.	WEKA.....	16
1.6.2.	MOA.....	16
1.6.3.	RapidMiner.....	17
1.7.	Akan Veri Öğrenme Yaklaşımları ve Literatür Araştırması	17
1.7.1.	Akan Veri Kümeleme Yaklaşımları.....	17
1.7.2.	Akan Veri Sınıflandırma Yaklaşımları	18
1.7.3.	Akan Veri Öznitelik Çıkartma ve Boyut İndirgeme Yaklaşımları.....	19
1.7.3.1.	Kovaryans Matrisi Kullanan ATBA Yaklaşımları.....	20
1.7.3.2.	Kovaryans Matrisi Kullanmayan ATBA Yaklaşımları	22
1.7.3.3.	Çekirdek Tabanlı ATBA Yaklaşımları	23
1.7.3.4.	AKD Tabanlı Akan Veri Yaklaşımları.....	23
1.7.4.	AÖM ve Topluluk AÖM Tabanlı Akan Veri Yaklaşımları	24
1.8.	Video Verilerinde Anomali Tespiti.....	35
1.8.1.	Gözetleme Videolarında Anomali Tespiti Yaklaşımları.....	35
1.8.2.	Aktif Öğrenme.....	41
1.9.	Akan Veri ve Gözetleme Videosu Anomali Tespiti Veri Setleri	43
1.9.1.	Akan Veri Setleri.....	43
1.9.1.1.	Gerçek Veri Setleri.....	43
1.9.1.2.	Sentetik Veri Setleri	45
1.9.2.	Anomali Tespiti için Gözetleme Videosu Veri Setleri.....	46
2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME	48
2.1.	Ayrık Kosinüs Dönüşümü ve Sürü Zekasına Dayalı Akan Veri Özellik Çıkartımı Yaklaşımı.....	50
2.1.1.	İlklendirme Aşaması	52
2.1.1.1.	Öznitelik Normalizasyonu.....	53
2.1.1.2.	Ayrık Kosinüs Dönüşümü ile Frekans Uzayında Öznitelik Çıkartımı.....	53
2.1.1.3.	Öznitelik Seçme	54
2.1.1.3.1.	Deneysel Öznitelik Seçimi	55
2.1.1.3.2.	Otomatik Öznitelik Seçimi.....	56
2.1.1.3.2.1.	Parçacık Sürü Optimizasyonu ile öznitelik seçimi.....	56

2.1.1.3.2.2.	HPSO ile Öznitelik Seçimi.....	58
2.1.2.	Ardışıl Aşaması	59
2.1.2.1.	M1 Güncelleme Yaklaşımı	60
2.1.2.2.	M2 Güncelleme Yaklaşımı	60
2.1.2.3.	M3 Güncelleme Yaklaşımı	60
2.1.3.	Deneysel Sonuçlar	61
2.1.3.1.	AKD ile Özellik Çıkartma Yaklaşımının Performans Analizi.....	62
2.1.3.2.	Ayrık Kosinüs Dönüşümünün Katsayılarının Deneysel Seçiminin Analizi	64
2.1.3.3.	Sürü Zekasına Dayalı Otomatik Öznitelik Seçiminin Analizi.....	66
2.1.3.4.	Otomatik Öznitelik Seçiminin Zaman Maliyetinin İncelenmesi	67
2.2.	Aşırı Öğrenme Makineleri ve Temsili Öğrenmeye Dayalı Akan Veri Öğrenme Yaklaşımı.....	68
2.2.1.	İlklendirme Aşaması	70
2.2.1.1.	Aşırı Öğrenme Makineleri Tabanlı Otokodlayıcı	72
2.2.1.2.	Ağ Modelini Oluşturma	74
2.2.2.	Ardışıl Öğrenme Aşaması	76
2.2.3.	Topluluk Öğrenmesi ile Nihai Karar.....	77
2.2.4.	Deneysel Sonuçlar	77
2.2.4.1.	Sınıflandırma Performansı	78
2.2.4.2.	Topluluk Sınıflandırıcı Sayısının Analizi	79
2.2.4.3.	Ardışıl Yığınlardaki Veri Sayısının Performansa Etkisinin Analizi	81
2.3.	İçerik Farklılaşmasına Dayanıklı Danışmansız Özellik Temsiline Dayanan Çevrimiçi Ardışıl Aşırı Öğrenme Yaklaşımı.....	81
2.3.1.	İlklendirme Aşaması	83
2.3.2.	Ardışıl Öğrenme Aşaması	84
2.3.2.1.	İçerik Farklılaşması Algılanması	84
2.3.2.2.	İçerik Farklılaşması Algılanmadığı Durumda Ağ modelini Güncelleme	85
2.3.2.3.	İçerik Farklılaşması Algılandığı Durumda Yeni Konseptte Adapte Olma	86
2.3.4.	Deneysel Sonuçlar	87
2.3.4.1.	Sınıflandırma Performansı Analizi.....	88
2.3.4.2.	Gizli Katmandaki Nöron Sayısının Etkisi.....	90
2.3.4.3.	İçerik Farklılaşması Tespitindeki Eşik Değerin Etkisi.....	92
2.3.4.4.	Topluluk Sınıflandırıcı Sayısının Etkisi.....	94

2.3.4.5.	AÖM-OK Tabanlı Ağırlıkların İklendirilmesinin ve İçerik Farklılaşması Mekanizmasının Etkisinin Analizleri	95
2.4.	Gözetleme Videolarındaki Anomali Tespiti ve Anormal Olay Türü Tespiti için Akan Veri Tabanlı Yaklaşım	98
2.4.1.	Önişleme Aşaması.....	100
2.4.1.1.	Zamansal Segment Oluşturulması.....	101
2.4.1.2.	Segment Seviyesinde Zayıf Etiketleme.....	101
2.4.2.	Anomalinin Akan Veri Öğrenme Algoritması ile Tespiti.....	103
2.4.2.1.	DÖTÇA-AÖM ile Öğrenme.....	103
2.4.2.2.	Topluluk Öğrenmesi ile Nihai Kararın Verilmesi.....	104
2.4.3.	DeneySEL Sonuçlar.....	105
2.4.3.1.	Anomali Tespiti.....	106
2.4.3.1.1.	Sınıflandırma Performansı	106
2.4.3.1.2.	Zamansal Segment Boyutunun Performansa Etkisi	109
2.4.3.1.3.	Çalışma Zamanı Analizi.....	113
2.4.3.1.4.	Anomali Skoru Analizi.....	114
2.4.3.2.	Anormal Olay Türü Tespiti Performansı	115
2.5.	Ayrık Kosinüs Dönüşümü ve Sürü Zekasına Dayanan Akan Veri Tabanlı Video Anomali Tespiti ve Anormal Olay Türünün Algılanması Yaklaşımı.....	116
2.5.1.	Ön İşleme Aşaması.....	118
2.5.2.	Anomalinin Topluluk Sınıflandırıcısına Dayalı DÖTÇA-AÖM ile Tespiti ...	121
2.5.3.	DeneySEL Sonuçlar.....	121
2.5.3.1.	Anomali Tespiti Performansı	122
2.5.3.1.1.	Sınıflandırma Performansı	122
2.5.3.1.2.	AKD ve Zikzak Taramanın Etkisinin İncelenmesi	124
2.5.3.1.3.	HPSO ile Otomatik Öznitelik Seçiminin Analizi.....	126
2.5.3.2.	Anormal Olay Türü Tespiti Performansı	129
2.6.	Video Anomali Tespiti için Aktif Öğrenmeye Dayanan Akan Veri Tabanlı Yaklaşım.....	131
2.6.1.	Önişleme Aşaması.....	133
2.6.2.	Anomalinin Topluluk Sınıflandırıcısına Dayalı AÖDÖTÇA-AÖM ile Tespiti	134
2.6.3.	DeneySEL Sonuçlar.....	137

2.6.3.1.	Sınıflandırma Performansı	137
2.6.3.2.	Otomatik Öznitelik Seçiminin Etkisi	139
2.6.3.3.	Anomali Eşiğinin Etkisi	139
3.	SONUÇLAR	141
4.	ÖNERİLER VE TARTIŞMA	144
5.	KAYNAKLAR.....	146
ÖZGEÇMİŞ		



Doktora Tezi

ÖZET

AKAN VERİDE ARTIMLI ÖĞRENME YAKLAŞIMLARI GELİŞTİRİLMESİ ile VIDEO VERİSİNDE ANOMALİ TESPİTİ ÇALIŞMASI

Özge AYDOĞDU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Murat EKİNCİ
2021, 162 Sayfa

Tez çalışması kapsamında, son yılların popüler veri türü olan akan verilerin tüm karakteristik özelliklerini ve kısıtlamalarını göz önüne alan yeni artımlı öğrenme yaklaşımları önerilmektedir. Tezin literatüre ilk katkısı akan veriler için Ayrık Kosinüs Dönüşümü ve Sürü Zekasına dayalı otomatik öznitelik çıkartma ve seçme yaklaşımının sunulmasıdır. Bu yaklaşımdan elde edilen sonuçlar ışığında akan veriler için Çevrim içi Ardışıl – Aşırı Öğrenme Makinelerine ve Otokodlayıcılara dayalı bir öğrenme yaklaşımının geliştirilmesi tezin ikinci katkısıdır. Bir diğer katkısı, geliştirilen öğrenme yaklaşımının akan verilerin en büyük problemi olan içerik farklılaşmasına dayanıklı olacak şekilde geliştirilmesidir. Önerilen yaklaşımlar gerçek dünya problemlerinden biri olan gözetleme videosu anomali tespitiye uygulanarak ve bu alan için de yeni yaklaşımlar sunulmaktadır. Video anomali tespiti uygulamasında ise gerçekleştirilen yaklaşım zayıf etiketleme ve önerilen akan veri öğrenme yaklaşımına dayalı bir anomali tespiti ve anormal olay türünün akan veri metodolojisi ile çözülmesidir ve bu tezin dördüncü katkısını oluşturmaktadır. Tezin beşinci katkısı olarak önerilen yaklaşımın performans artışı açısından otomatik öznitelik çıkartma ve seçme yaklaşımı ile birleştirilerek sunulmasıdır. Son olarak video anomali tespiti için videoların etiket değerlerine minimum şekilde ihtiyaç duyan aktif öğrenmeye dayalı akan veri öğrenme yaklaşımı gerçekleştirilmiştir. Geliştirilen tüm yaklaşımlar gerçek, sentetik akan veri ve video veri setleri üzerinde literatürdeki popüler yaklaşımlar ile karşılaştırmalı olarak test edilmiş ve elde edilen yüksek başarı ile analizi umut verici sonuçlara ulaşılmıştır.

Anahtar Kelimeler: Akan veri, Artımlı öğrenme, İçerik farklılaşması, Ayrık kosinüs dönüşümü, Sürü zekâsı, Aşırı öğrenme makineleri, otokodlayıcı, Aktif öğrenme, Video anomali tespiti.

PhD. Thesis

SUMMARY

THE WORK OF THE INCREMENTAL LEARNING APPROACHES DEVELOPMENT IN DATA STREAM WITH ANOMALY DETECTION IN VIDEO DATA

Özge AYDOĞDU

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Murat EKİNCİ
2021, 162 Pages

In the thesis study, novel incremental learning approaches which take into account all characteristics and limitation of the data stream are proposed. The first contribution to the literature is the presentation of automatic feature extraction and selection approach based on Discrete Cosine Transform and Swarm Intelligence for data stream. The second contribution is to develop a data stream learning approach based on Online Sequential-Extreme Learning Machines and Autoencoders for data stream in light of the obtained results of the first approach. Another contribution of the thesis is the improvement of the developed learning approach to be robust to the concept drift problem of the data stream. The proposed approaches are applied to the surveillance video detection application area, one of the real-world data stream problems. In the video anomaly detection application, anomaly detection process is performed with developed data stream learning approach and a weak-labelling technique, and this is the fourth contribution of the thesis. Moreover, this approach have ability to determine the abnormal event type. As the fifth contribution of the thesis to the literature, the developed video anomaly detection approach is combined with the automatic feature extraction and selection approach to increase the video anomaly detection performance. Finally, a novel data stream learning approach based on active learning, which requires minimum video label values for video anomaly detection, has been implemented. All the developed approaches are tested on real, synthetic data stream and video data sets in comparison with popular approaches in the literature, and the analysis has achieved promising results with high success.

Key Words: Data stream, Incremental learning, Concept drift, Discrete Cosine Transform, Swarm intelligence, Extreme learning machine, Autoencoder, Active learning, Video anomaly detection.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. Tez kapsamının genel yapısı	4
Şekil 2. (a) Orijinal veri üzerinden (b) sanal farklılaşma (c) gerçek farklılaşma gösterimi ..	7
Şekil 3. İçerik farklılaşmasındaki (a) ani (b) kademeli (c) artımlı ve (d) tekrarlı farklılaşması örüntüleri.....	8
Şekil 4. Akan veri işlenmesindeki genel süreç modeli	9
Şekil 5. Dönüm noktası zaman penceresi modeli.....	10
Şekil 6. Kayan pencere modeli	11
Şekil 7. Yaşlandırma penceresi modeli	11
Şekil 8. Eğimli zaman penceresi modeli	12
Şekil 9. İki fazlı öğrenme yaklaşımının genel modeli	13
Şekil 10. Artımlı öğrenme genel modeli	14
Şekil 11. Temel AÖM yapısı.....	25
Şekil 12. Topluluk öğrenmesi genel modeli.....	30
Şekil 13. AKD ve sürü zekasına dayalı yaklaşımın genel modeli.....	51
Şekil 14. Deneysel öznitelik seçimi gösterimi.....	55
Şekil 15. M1 güncelleme yaklaşımı. (a) $(i + 1)$. veriler mevcut akan veri örneğidir ve ilk model S veriden oluşmaktadır. (b) Mevcut yeni örnek, ilk modelin sonuna eklenir. (c) İlk modelin ilk örneği modelden çıkarılır. (d) Mevcut örnek güncellenmiş başlangıç modeli.....	60
Şekil 16. M3 güncelleme yaklaşımı. (a) $(S + 1)$. veriler mevcut akan veri örneğidir ve ilk model S veriden oluşmaktadır. (b) Mevcut yeni örnek, ilk modelin sonuna eklenir ve son örnek modelden çıkarılmaz (c) Yeni örnek geldiğinde verinin en sonuna tekrar eklenir (d) Yeni örnek modelin güncellenmiş hali.....	61
Şekil 17. Önerilen yöntemde AKD katsayılarının deneysel olarak ilk yarısının ve son yarısının seçilmesinin (a) ElecNormNews, (b) PokerHand, (c) ForestCovType ve (d) DS1 veri setlerine göre performans analizi	65
Şekil 18. Önerilen yöntemde otomatik ve deneysel öznitelik seçiminin (a) ElecNormNews, (b) PokerHand veri setlerine göre performans kıyaslaması	66
Şekil 19. ÇA-AÖM ve AÖM-OK' dan oluşan akan veri öğrenme yaklaşımının akış şeması	69
Şekil 20. Yaklaşımındaki topluluk öğrenmesinin genel yapısı	70
Şekil 21. ÇA-AÖM ve AÖM-OK ile kurulan ilklendirme aşamasının gösterimi	71
Şekil 22. AÖM-OK ağ modeli.....	72

Şekil 23. Ardışıl yığınlardaki veri sayısının yaklaşımın performansına (a) Pendigits (b) ElecNormNews (c) EEG Eye (d) ForestCovType ve (e) Hyperplane veri setleri üzerinde etkisinin analizi	80
Şekil 24. DÖTÇA-AÖM yaklaşımının akış şeması	83
Şekil 25. Eşik Değerin DO üzerindeki etkisinin (a) ForestCovType (b) KddCup99 (c) ElecNormNews (d) Pendigits (e) Hyperplane (f) LED (g) Agrawal (h) RandomTree (i) Shuttle (j) EEG Eye	92
Şekil 26. Sunulan yaklaşımın genel akış şeması	100
Şekil 27. Önışleme aşamasının gösterimi	101
Şekil 28. Segment seviyesinde etiketlemenin (a) anormal ve (b) normal olay için gösterimi	102
Şekil 29. DÖTÇA-AÖM' nin anomali tespiti için genel modeli.....	104
Şekil 30. DÖTÇA-AÖM' nin anomali tespiti için güncellenmiş akış şeması.....	104
Şekil 31. Anormal olay türü tespiti için geliştirilen ağ modeli.....	105
Şekil 32. n boyutunun, önerilen yaklaşımın üç veri seti üzerindeki TPR ve FPR sonuçları üzerindeki etkisi. (a) UCF-Crimes TPR ve FPR sonuçları (b) Ped1 ve Ped2' de TPR sonuçları (c) Ped1 ve Ped2' de FPR sonuçları.....	109
Şekil 33. Eşik değerin. (a) UCF-Crimes (b) Ped1 ve (c) Ped2 veri setlerinin üzerindeki etkisi	112
Şekil 34. (a) UCF-Crimes (b) Ped1 (c) Ped2 için anomali skoru görselleştirilmesi. Hesaplanan anomali skoru mavi olarak gösterilirken ve temel gerçek kırmızı alan olarak verilmiştir. 0 normal bölgeyi, 1 anormal bölgeyi temsil etmektedir. Çerçeveler üzerindeki anormal olaylar ve gecikmeler kırmızı daire ile vurgulanmıştır.	115
Şekil 35. AKD ve HPSO' ya dayalı akan veri tabanlı video anomali tespiti ve anormal olay türünün belirlenmesi yaklaşımının genel modeli.	117
Şekil 36. AKD ve HPSO süreçlerini içeren öznitelik çıkartma aşamasının genel modeli	118
Şekil 37. 6*6' lık örnek görüntünün zikzak tarama ile vektör elde edilme işlemi	119
Şekil 38. Farklı özellik sayıları için HPSO' nun 3 veri setinde davranışı	127
Şekil 39. Aktif öğrenmeye dayalı anomali tespit yaklaşımının genel modeli	132
Şekil 40. Önışleme aşamasının genel modeli	133
Şekil 41. AÖDÖTÇA-AÖM' nin genel modeli	134
Şekil 42. AÖDÖTÇA-AÖM' nin ağ modeli	134
Şekil 43. Anomali eşik değerinin (a) UCSD Ped1 (b) UCSD Ped2 ve (c) UCF- Crimes veri setlerinin üzerindeki etkisi.....	140

TABLolar DİZİNİ

Sayfa No

Tablo 1. Gerçek ve sentetik akan veri setleri.....	46
Tablo 2. AKD ve sürü zekasına dayalı öznitelik çıkartma yaklaşımında kullanılan veri setleri	62
Tablo 3. Geleneksel TBA [62] ve önerilen yaklaşımın karşılaştırılması	63
Tablo 4. ATBA-Li [67], GKATBA [73] ve önerilen yaklaşımın karşılaştırılması	63
Tablo 5. YAÇTBA [76] ve önerilen yaklaşımın karşılaştırılması.....	63
Tablo 6. Literatürdeki çalışmaların önerilen HPSO-AKD ile kıyaslaması	67
Tablo 7. HSO-AKD ve PSO-AKD' nin GKATBA ile öğrenme zamanı karşılaştırılması..	67
Tablo 8. HPSO-AKD ve PSO-AKD' nin ATBA-Ozawa ve ATBA-Li algoritmaları ile öğrenme zamanı karşılaştırılması.....	68
Tablo 9. AÖM-OK dayanan ÇA-AÖM yaklaşımının orijinal ÇA-AÖM ile YSVS ve DO üzerinden karşılaştırılması.....	78
Tablo 10. AÖM-OK dayanan ÇA-AÖM yaklaşımının topluluk öğrenmesi performansı ...	79
Tablo 11. DÖTÇA-AÖM ve ÇA-AÖM' nin DO ve YSVS sonuçları	88
Tablo 12. DÖTÇA-AÖM ve IDS-ELM ve DELM ile karşılaştırılması.....	89
Tablo 13. Nöron sayısının performansa etkisi analizinin DÖTÇA-AÖM ve ÇA-AÖM sonuçları.....	91
Tablo 14. Topluluk DÖTÇA-AÖM' nin sınıflandırma performansı ve karşılaştırılması	95
Tablo 15. AÖM-OK' ya dayalı ağırlık hesaplama stratejisinin etkisinin ortalama ve standart	96
Tablo 16. İçerik farklılaşması mekanizmasının etkisinin DO ve YSVS üzerinden incelenmesi ((+) İçerik farklılaşması mekanizması var, (-) içerik farklılaşması mekanizması yok).....	97
Tablo 17. UCF-Crimes veri seti için EAA [%] sonuçları	107
Tablo 18. UCSD veri seti için EAA [%] ve EHO sonuçları.....	108
Tablo 19. Segment boyutunun Ped1 ve Ped2 üzerinde etkisinin analizi.....	110
Tablo 20. Segment boyutunun UCF-Crimes üzerinde etkisinin analizi.....	111
Tablo 21. Üç veri seti için farklı yığın boyutlarındaki veri sayısı.....	111
Tablo 22. Önerilen yaklaşımın tüm süreçlerinin üç veri seti için ms. cinsinden çalışma zamanının analizi	113
Tablo 23. Anormal olay türünü belirleme performansının literatürdeki çalışmalar ile karşılaştırılması.....	116
Tablo 24. UCSD veri seti için anomali tespit doğruluk değerlerinin diğer yaklaşımlarla karşılaştırılması.....	122

Tablo 25. UCF-Crimes veri seti için anomali tespit doğruluk değerlerinin diğer yaklaşımlarla karşılaştırılması	123
Tablo 26. Veri setleri için ardışıl yığın ve segment boyutunun 5 olduğu durumdaki AKD-Zikzak-HPSO ile Satır senaryolarının anomali tespit performansı.....	123
Tablo 27. UCSD Ped1 veri seti için 1, 3 ve 5 yığın değerlerindeki EAA, YSVS ve EHO sonuçları	124
Tablo 28. UCSD Ped1 veri seti için 1, 3 ve 5 yığın değerlerindeki EAA, YSVS ve EHO sonuçları	125
Tablo 29. UCF-Crimes veri seti için 5 ardışıl yığını için farklı segment boyutlarındaki EAA, YSVS ve EHO sonuçları.....	125
Tablo 30. Veri setleri için AKD-Zikzak-HPSO ile AKD-Satır-HPSO' nun karşılaştırılması	126
Tablo 31. Tablo 30' da ki sonuçları veren öznitelik sayısı.....	126
Tablo 32. AKD-Zikzak-HPSO için segment boyunun 5 ve 10 olduğu durumlarda elde edilen bazı metriklerin sonuçları.....	128
Tablo 33. Ped1 veri seti için segment boyutu 5 ve 10 olduğu durumdaki karmaşıklık matrisi	128
Tablo 34. Ped2 veri seti için segment boyutu 5 ve 10 olduğu durumdaki karmaşıklık matrisi	128
Tablo 35. UCF-Crimes veri seti için segment boyutu 5 ve 10 olduğu durumdaki karmaşıklık matrisi.....	128
Tablo 36. Anormal olay türü tespiti performansı incelenmesi	129
Tablo 37. AKD-Zikzak-HPSO' daki seçilen öznitelik sayıları	129
Tablo 38. Sunulan yaklaşımın $n = 5$ olduğu duruma ait bazı metriklerin sonuçları	130
Tablo 39. 7 topluluk sınıflandırıcıdan oluşan sunulan yaklaşımın $n=5$ olduğu duruma ait karmaşıklık matrisi.....	130
Tablo 40. 1 topluluk sınıflandırıcıdan oluşan sunulan yaklaşımın $n=5$ olduğu duruma ait karmaşıklık matrisi.....	130
Tablo 41. UCF-Crimes veri seti için HPSO ile AKD' ye dayalı TAÖDÖTÇA-AÖM anomali tespit yaklaşımının EAA metriğinin diğer yaklaşımlarla karşılaştırılması	137
Tablo 42. UCSD veri seti için HPSO ile AKD' ye dayalı TAÖDÖTÇA-AÖM anomali tespit yaklaşımının EAA, YSVS ve EHO metriklerinin diğer yaklaşımlarla karşılaştırılması	137
Tablo 43. Ped1, Ped2 ve UCF-Crimes için HPSO ile otomatik öznitelik seçimi sonucu elde edilen anomali ve tüm çerçeveler için sonuçlar	138
Tablo 44. Sırasıyla Ped1, Ped2 ve UCF-Crimes için HPSO ile otomatik öznitelik seçimi sonucu elde edilen karmaşıklık matrisi	139
Tablo 45. Veri setlerinin HPSO varken ve HPSO yokken elde edilen sonuçları.....	139

SEMBOLLER DİZİNİ

AÇTBA	: Artımlı Çekirdek Temel Bileşen Analizi
AEKK	: Artımlı En Küçük Kareler
AKD	: Ayrık Kosinüs Dönüşümü
AKD-Satır	: AKD uygulandıktan sonra satır taramasına göre vektör oluşturulması
AKD-Satır-HPSO	: AKD uygulandıktan sonra satır taramasına göre oluşturulan vektörün HPSO ile otomatik özellik seçimi ile indirgenmesi
AKD-Zikzak	: AKD uygulandıktan sonra zikzak taramasına göre vektör oluşturulması
AKD-Zikzak-HPSO	: AKD uygulandıktan sonra zikzak taramasına göre oluşturulan vektörün HPSO ile otomatik özellik seçimi ile indirgenmesi
AÖTDÖTÇA-AÖM	: Aktif Öğrenmeye Dayalı Topluluk tabanlı Danışmansız Öznitelik Temsili Çevrim İçi- Aşırı Öğrenme Makineleri
AÖ	: Aktif Öğrenme
AÖM	: Aşırı Öğrenme Makineleri
AÖM-OK	: Aşırı Öğrenme Makineleri Otokodlayıcı
ATBA	: Artımlı Temel Bileşen Analizi
ÇA- AÖM	: Çevrim içi Aşırı Öğrenme Makineleri
ÇTBA	: Çekirdek Temel Bileşen Analizi
ÇÖÖ	: Çok Örnekli Öğrenme
DAVS	: Doğru Sınıflandırılan Veri Sayısı
DÖTÇA-AÖM	: Danışmansız Öznitelik Temsili Çevrim İçi- Aşırı Öğrenme Makineleri
EAA	: Eğri Altında Kalan Alan
EHO	: Eşit Hata Oranı
EKK	: En Küçük Kareler
FD	: Fourier Dönüşümü
FPR	: Yanlış Pozitif Oranı
GKATBA	: Gerçek Kovaryanssız Artımlı Temel Bileşen Analizi

GA	: Gerçek Anormal Olaylar
GN	: Gerçek Normal Olaylar
HPSO	: Hızlandırılmış Parçacık Sürü Optimizasyonu
HPSO-AKD	: Hızlandırılmış Parçacık Sürü Optimizasyonu ile Ayrık Kosinüs Dönüşümünün Uygulanması
KEYK	: K En Yakın Komşuluk
MOA	: Massive Online Analysis
M1-İY	: M1 tekniği ile ilk yarıdaki katsayıların seçilmesi
M1-SY	: M1 tekniği ile son yarıdaki katsayıların seçilmesi
PSO	: Parçacık Sürü Optimizasyonu
PSO-AKD	: Parçacık Sürü Optimizasyonu ile Ayrık Kosinüs Dönüşümünün Uygulanması
SS	: Sınıflandırıcı Sayısı
SZ	: Sürü Zekâsı
Std	: Standart Sapma
TA	: Tahmin Edilen Anormal Olaylar
TBA	: Temel Bileşen Analizi
TÇA-AÖM	: Topluluk Tabanlı Çevrim İçi Aşırı Öğrenme Makineleri
TDÖTÇA-AÖM	: Topluluk tabanlı Danışmansız Öznitelik Temsili Çevrim İçi- Aşırı Öğrenme Makineleri
TKİBA	: Tek Katmanlı İleri Beslemeli Ağ
TN	: Tahmin Edilen Normal Olaylar
TPR	: Doğru Pozitif Oranı
YSVS	: Yanlış Sınıflandırılan Veri Sayısı
1-B	: 1 Boyut

1. GENEL BİLGİLER

1.1. Giriş

Veri madenciliği ve büyük veri analizi, geniş veri setlerinden özgün ve efektif bilgi çıkaran, makine öğrenmesi tekniklerini kullanarak akıllı karar destek sistemlerinin tasarlanmasında anahtar bileşen olarak görev yapan bir süreçtir [1]. Geleneksel veri madenciliği çalışmaları büyük ölçüde yerleşmiş, statik veriye odaklanmaktadır. Fakat teknolojinin gelişmesiyle birlikte birçok uygulama büyük hızda ve büyük miktarda veri üretmektedir. Üretilen bu veriler, gerçek dünya uygulamalarının çoğunda akan veri olarak isimlendirilen ve devasa boyutlara ulaşabilen anlık sürekli verilerdir. Akan veri madenciliği ve işlenmesi bu verilerden anlamlı bilgiler üretmek ve bu bilgileri kullanmak için geliştirilen süreçlerdir.

Akan verilerin ortaya çıkmasıyla birlikte teknolojik gelişmeler artış göstermektedir ve bu durum verinin saklanması için kullanılan veri tabanları ve veri yapıları türlerinde, veri haberleşmesinde ve verilerin işlenme şeklinde değişiklikler ve gelişmeler gerçekleşmesine neden olmuştur. Günümüzde birçok organizasyon daha önce olmadığı kadar yüksek hızda ve büyük miktarda veri üretmektedir. Bu nedenle verilerin saklanma süreci oldukça zorlaşmaktadır. Mesela, Google günlük olarak 3,5 milyar arama ile uğraşmaktadır. NASA uyduları 4 TB görüntü üretmektedir ve Walmart 20 milyardan çok hesap hareketi kaydetmektedir. Akan verilerin günlük olarak üretildiği düşünülürse, akıllara sonsuz miktarda, sürekli, hızlı ve zamanla gelişen akan verilerin kısıtlı bir zamanda nasıl modelleneceği sorusu gelmektedir [2]. Bu soruya cevap verebilmek için öncelikle akan verilerin özelliklerini incelemek gerekmektedir. Ağ trafiği, web tıklama akışları, video izleme ve sensor ağları gibi birçok uygulama alanından elde edildiği bilinen bu veriler, geleneksel verilerden birçok yönden farklılık içermektedir [3].

Akan veri, potansiyel olarak sınırsız, zaman içinde gelen veri öğelerinin sıralı bir dizisi olarak tanımlanabilmektedir. Her veri öğesinin gelişi arasındaki zaman aralıkları değişebilmektedir. Bu veri öğeleri, ilişkisel veri tabanı demetleri gibi basit öznitelik-değer çiftleri veya grafikler gibi daha karmaşık yapılar olabilmektedir. Akan veri ile geleneksel statik veri kümeleri arasındaki temel farklar şunlardır [4, 5, 6]:

1. Akan veri öğeleri zaman içinde ardışıl olarak oluşmaktadır.

2. Veri ögelerinin geldiği sıra üzerinde herhangi bir kontrol yoktur ve işleme sistemi her an tepki vermeye hazır olmalıdır.
3. Verilerin boyutu çok büyüktür ve muhtemelen sonsuz uzunluktadır. Bu nedenle akan veri içindeki tüm verileri bellekte saklamak imkansızdır.
4. Bir anda sadece bir akan verinin ögesinin işlenmesi mümkündür; öge işlendikten sonra saklanamaz ve atılmaktadır. Sadece gerekli bir durum olduğunda depolanabilirler veya verilerin toplu istatistikleri ya da özetleri hesaplanabilmektedir.
5. Veri ögelerinin geliş hızı oldukça hızlıdır.
6. Akan veriler içerik olarak değişime müsaittir. Yani veri kaynağındaki dağılım anında değişebilmektedir.
7. Veri etiketleme çok maliyetli, hatta bazı durumlarda imkânsız olabilmektedir ve hemen gerçekleşmeyebilir.

Bu özelliklere sahip bir akan veri seti ana bellekte tutulamayacak kadar çok büyüktür ve alternatif olarak ikincil bellek elemanları kullanılmaktadır. Çünkü geleneksel yöntemlerin bu setlere rastgele erişimi oldukça maliyetli bir işlemdir. Bu özellikleri göz önüne alındığında akan verileri işlemek için özel yöntemlere ihtiyaç duyulduğu görülmektedir. Bu yöntemler, akan veri örneği ya da yığını olduğu gibi veriyi işleyerek bir sonuç üretebilmelidir. Ayrıca akan verideki değişimleri algılayıp hızlı bir şekilde uyum sağlayabilmelidir [7].

Akan veri madenciliğinin ve akan veri işlemenin amacı örnek sayısının lineer olarak artmasına göre model oluşturma işlemi oluşturmaktır. Bunun dışında veri sürekli geldiği için, önceden oluşturulan model yeni gelen veriye ait bilgi ile birleştirilmelidir. Ayrıca zamanı geçmiş eski veriler elemine edilmelidir. Basit bir şekilde modeli sadece yeni gelen veri ile yeniden eğitip güncellemek, eskimiş verileri atmadan işlemler yapmak akan verileri işlemek için yeterli ve efektif olmamaktadır. Bu yüzden her örnek geldiğinde modeli artımlı bir şekilde güncellemek gerekmektedir.

Akan veri madenciliği sürekli olarak gelen akan verilerden gizli örüntüleri çıkarmayı hedeflemektedir. Verinin durağan olduğu ve birçok kez tekrar tekrar okunduğu geleneksel veri madenciliğinin aksine, akan veri madenciliği algoritmaları sınırlı bellek, tek geçişlilik, gerçek zamanlı işlem yapma ve içerik farklılaşması gibi birçok zorluk ve kısıtlamaya cevap vermek zorundadır [2].

1.2. Tezin Kapsamı


Akan verinin yaygınlaşması ve uygulanma alanlarının gün geçtikçe gelişmesi dolayısıyla bu tez kapsamında akan verinin tüm karakteristiklerini ve kısıtlamalarını göz önüne alarak yüksek başarıya sahip bir öğrenme yaklaşımı geliştirilmesi ve analiz edilmesi hedeflenmiştir. Bu nedenle akan veri setleri üzerinde çeşitli yaklaşımlar önerilmiştir. Bunun dışında önerilen yaklaşımlar akan veri gerçek dünya problemlerinden biri olan anomali tespitine uygulanmış ve sonuçlar elde edilmiştir. Anomali tespiti için tez kapsamında seçilen ve uygulanan alan gözetleme videolarındaki anormal olayların belirlenmesidir. Tüm bunların ışığında tez çalışması iki ana başlığa ayrıldığını söylemek doğru bir ifade olacaktır. Bunlardan ilki akan veri öğrenme yaklaşımları geliştirilmesidir. Diğer ise akan ver gerçek dünya problemi olan gözetleme videolarındaki anomali tespiti için geliştirilen yaklaşımların uygulanmasıdır.

Tez kapsamında ilk ana başlık olan akan veri öğrenme yaklaşımlarının geliştirilmesi iki alt başlığa ayrılmaktadır. Önce akan veriler için öznitelik çıkartma ve boyut indirgeme yaklaşımını geliştirilmiştir. Bunun için Ayrık Kosinüs Dönüşümü (AKD) ve Hızlandırılmış Parçacık Sürü Optimizasyonuna dayalı otomatik bir öznitelik çıkartma boyut indirgeme yaklaşımı sunulmuştur. Diğer alt başlık ise Aşırı Öğrenme Makineleri (AÖM) tabanlı akan veri artımlı topluluk öğrenmesi yaklaşımını geliştirilmesidir. Bu başlık altında iki yaklaşım önerilmiştir. Biri Çevrim içi Artımlı Aşırı Öğrenme Makineleri (ÇA-AÖM) ve Aşırı Öğrenme Makineleri Otokodlayıcı (AÖM-OK)' ya dayalı bir yaklaşım geliştirilmesidir. Bu yaklaşım akan verinin en önemli sorunu olan içerik farklılaşmasına yeteri kadar dayanıklı olmadığı için Danışmansız Öznitelik Temsiline dayanan Çevrim içi Aşırı Öğrenme Makineleri Tabanlı (DÖTÇA-AÖM) bir öğrenme yaklaşımı önerilmiştir. Her iki yaklaşım danışmanlı topluluk öğrenmesi yaklaşımlarıdır. Bu yaklaşımların performansları literatürde yer alan popüler gerçek ve sentetik akan veri setleri üzerinde ölçülmüştür.

Diğer ana başlık olarak gerçek dünya problemi olan gözetleme videolarındaki anormal olay tespiti ve olay türünün belirlenmesi üç alt başlıktan oluşmaktadır. Bu başlıklardan ilk ikisi akan veri için geliştirilen yaklaşımların anomali tespiti problemine uyarlanmasıdır. DÖTÇA-AÖM ve zayıf etiketlemeye dayalı yaklaşım ile video anomali tespiti ve anormal olay türünün belirlenmesine literatürdeki diğer yaklaşımların aksine akan veri tabanlı bir çözüm üretilerek sunulmuştur. İkinci olarak sunulan yaklaşım akan veri için önerilen öznitelik çıkartma ve boyut indirgeme yaklaşımı ve zayıf etiketlemeye dayalı teknik içeren

DÖTÇA-AÖM tabanlı yaklaşımın birleştirilmesidir. Burada otomatik olarak ne yüksek sonucu elde eden ve hata oranını düşüren öznelik seti ile öğrenme işleminin ve anomali tespitinin gerçekleşmesi hedeflenmiştir. Son olarak ise danışmanlı bir yaklaşımlardan uzaklaşılarak video anomali problemine özgün olan bir aktif öğrenme tabanlı bir yaklaşım önerilmiştir. Burada DÖTÇA-AÖM yaklaşımı aktif öğrenme stratejisine dönüştürülmüş ve yaklaşım geliştirilmiştir. Bu yaklaşımla en az seviyede etiket değerine ihtiyaç duyulması amaçlanmıştır. Anomali tespiti ve anormal olay türünün belirlenmesi yaklaşımları literatürde yer alan gerçek gözetleme video görüntüleri kullanılarak performans değerlendirmesi gerçekleştirilmiştir. Tez kapsamının genel yapısını oluşturan şema Şekil 1’ de verilmektedir.

Şekil 1’de verilen yaklaşımlar için tezin genel bilgiler bölümünde konu tanıtımı, literatür taraması özet halinde anlatılmaktadır. Yapılan Çalışmalar, Bulgular ve İrdeleme bölümünde ise tez kapsamın geliştirilen yaklaşımlar anlatılarak ve performans ölçümü için yapılan deneysel sonuçlar analiz edilip yorumlanarak literatür kıyaslamalarıyla birlikte verilmektedir. Sonuçlar kısmında çalışmadaki yaklaşımlar ve katkıları özetlenmektedir. Çalışmanın son kısmı olan Öneriler kısmında ise gelecekte yapılabilecek çalışmalara ışık tutabilecek öneriler sunulmaktadır.



Şekil 1. Tez kapsamının genel yapısı

1.3. Akan Veri Kısıtlamaları

1.3.1. Tek Geçişlilik

Birçok kez ve tekrarlı olarak verilerin okunabildiği geleneksel veri madenciliğinin aksine, akan veri uygulamalarında her örnek en çok bir kez değerlendirilmektedir ve geriye dönüş olmamaktadır [8, 9, 10]. Ana belleğin yetersiz olması ve giriş/çıkış işlemlerinin zaman açısından pahalı olması anlık cevap alınması gereken akan verilerin tek geçişli olarak yani sadece bir kez işlenmesini zorunlu kılmaktadır. Fakat algoritmaların türüne göre kısa dönemlik tamponlama yapıları da kullanılabilmektedir.

1.3.2. Gerçek Zamanda Cevap Verme

Market stok tahmini, video görüntülerdeki anomali durumunun yakalanması gibi birçok akan veri uygulaması gerçek zamanda yani anında (çevrimiçi) cevap istemektedir. Akan veri uygulamalarında işlem zamanı ve karar verme süreci oldukça hızlı olmalıdır [9, 11, 12].

1.3.3. Sınırlı Bellek

Akan veri yapısında gelen ya da oluşan veri sayısı devasa büyüklüktedir ya da potansiyel olarak sonsuz olduğu düşünülmektedir. Verilerin olabildiğince küçük bir özet bilgisi hesaplanıp saklanabilmeli ve geri kalanı atılmalıdır. Bu nedenle yaklaşık cevaplar akan veri uygulamalarında kabul edilebilmektedir [9, 10, 11].

1.3.4. İçerik Farklılaşması


Verilere ait keşfedilen örüntülerin ya da dağılımlarının zamanla değişmesi, kaynağın farklı dağılıma sahip veriler üretmesi içerik farklılaşmasıdır [8, 9, 11, 12]. Geleneksel uygulamalar sadece tek bir içerikle çalışmaktadır. Yani örnekler sabit olasılık dağılımına sahip bir kaynak tarafından üretilmektedir ve akan veri örnekleri sabit bir olasılık dağılımına sahiptir. Bu durum eğitim ile test veri setinin aynı tür dağılımda olması avantajını sağlamaktadır. Fakat akan verilerde ise içerik dinamiktir ve birden çok içeriğe sahip

olabilmektedir. Veriler zaman içinde gelişebilmekte ve değişebilmektedir. Bu durumda, hedef kavramlar (örnek sınıfları) ve / veya öznitelik dağılımları değişmektedir. Diğer bir deyişle, akan verinin üretildiği kavram, minimum kararlılık süresinden sonra değişime uğramaktadır [13]. Algoritmaların içeriğin değişmesine dayanıklı olması ve değişen içeriğe göre modeli güncellemesi gerekmektedir. Çünkü içerik farklılaşması, geçmiş eğitim örneklerinden öğrenilen modellerinin doğruluğunu bozmaktadır. İçerik farklılaşmasından etkilenen tipik gerçek yaşam akan veri uygulamaları şunları içerebilir [14]:

- Saldırganların güvenlik sistemlerini aşmanın yeni yollarını aradıkları bilgisayar veya telekomünikasyon sistemleri
- Trafik modellerinin zaman içinde değişebileceği trafik izleme
- İklim değişiklikleri ve doğal anormalliklerin tahmini etkileyebileceği hava durumu tahminleri,
- Kişisel çıkarları takip eden sistem, kullanıcıların tercihlerini değiştirebilecekleri kişisel bir reklam
- Uygulanan ilaçlara veya hastaların doğal direncine yanıt olarak hastalığın ilerlemesinin etkilenebileceği ve değiştirilebileceği tıbbi karar yardımı.

İçerik farklılaşmasına ait gerçek hayattaki diğer örnekler arasında spam elektronik-posta kategorizasyonu, nesne konumlandırma, endüstriyel izleme sistemleri, finansal dolandırıcılık tespiti ve robotik de verilebilmektedir.

t anındaki her bir noktada bütün örnekler ortak olasılık dağılımı $P^t(x, y)$ olan bir kaynak tarafından üretilmektedir. Eğer bütün örnekler aynı dağılımla üretilmişse, verilerin içeriği sabit veya durağan olmaktadır. Eğer t anı içindeki iki ayrı nokta olan t ve $t + \Delta$ için $P^t(x, y) \neq P^{t+\Delta}(x, y)$ olacak bir x varsa, o zaman bir içerik farklılaşması mevcuttur denilmektedir. Bu ortak olasılık dağılım fonksiyonu olan $P^t(x, y)$ 'nin farklı bileşenleri içerik farklılaşması meydana geldiğinde değişebilmektedir. Özellikle $P(y)$ sınıflarının önceki olasılıkları ve sınıf koşullu olasılıkları olan $P(x|y)$ 'den biri ya da her ikisi de değişebilmektedir. Tüm bunların sonuç olarak, $P(y|x)$ sınıflarının son olasılıkları da değişebilir ya da değişmeyebilir. Bu değişikliklerin nedenine ve etkisine bağlı olarak iki tür içerik farklılaşması, ayırt edilmektedir. Bunlar Şekil 2' de de gösterilen gerçek farklılaşma ve sanal farklılaşmadır.




Şekil 2. (a) Orijinal veri üzerinden (b) sanal farklılaşma (c) gerçek farklılaşma gösterimi

Gerçek farklılaşma, $P(y|x)$ 'deki bir değişiklik olarak tanımlanmaktadır. Bu tür değişikliklerin $P(x)$ 'de herhangi bir değişiklik olsun veya olmasın meydana gelebilmektedir. Bu nedenle, gerçek sınıf etiketlerini bilmeden veri dağılımından görülebilir veya görünmeyebilirler. Bazı yöntemler, yalnızca giriş öznitelik değerlerini kullanarak içerik farklılaşmalarını saptamaya çalıştığından, böyle bir ayırım çok önemlidir. Gerçek farklılaşma aynı zamanda bir içerik farklılaşması ve koşullu değişim olarak da adlandırılır [15].

Sanal farklılaşma, karar sınırlarını etkilemeyen özellik değeri $P(x)$ veya sınıf dağılım $P(y)$ 'de bir değişiklik olarak tanımlanmaktadır. Sanal farklılaşmalar geçici farklılaşmalar, örnekleme farklılaşmaları veya özellik değişiklikleri olarak da adlandırılmıştır [16]. Literatürde gelişen veri öğrenme yaklaşımlarının çoğunluğu gerçek farklılaşma üzerine yoğunlaşmaktadır. Fakat her ne kadar gerçek sınıf sınırlarını değiştirmese bile, sanal farklılaşma öğrenilen sınıf sınırlarının yetersiz kalmasına neden olabilmektedir. Bu nedenle, gerçek farklılaşmayı ele alan tekniklerin, belirli bir sanal farklılaşma türleri için hala işe yarayabileceği söylenebilmektedir. Sonraki olasılıklar değiştirmese, var olan modeli yeniden inşa etmeye gerek olmamaktadır. Çünkü karar sınırları sanal farklılaşma türünde hala aynı kalmaktadır. Fakat sanal farklılaşması tespit etmek önem yaklaşımların doğru sonuç üretmesi açısından önem taşımaktadır. Çünkü sınıflandırıcının karar sınırlarını etkilemese bile, gerçek farklılaşma olarak algılanıp yanlış yorumlanması sınıflandırıcının yeniden eğitilmesi hakkında yanlış karar doğurabilmektedir.


Literatürde, içerik farklılaşmasının neden ve sonuçlar farklılıklarına göre ayrılmasının yanı sıra, kalıcılıkları, öngörülebilirlikleri, ciddiyetleri ve sıklıkları ile karakterize edildikleri dört farklı örüntü olarak da kategorize edilmektedir [17]. Bunlar Şekil 3’ te görüldüğü gibi ani, kademeli, artımlı ve tekrarlı (recurrent) içerik farklılaşmalarıdır [18]. Bunlardan en popülerleri ve yoğun olarak araştırılanları ani ve kademeli içerik farklılaşmalarıdır [19]. Ani farklılaşma, t anındaki kaynak dağılımının $t + 1$ anında ani bir şekilde farklı dağılımla yer değiştirmesi sonucu ortaya çıkmaktadır. Kademeli farklılaşma ise aniye göre radikal değişiklik olmadan yavaş ve kademeli olarak dağılımın değişmesidir. Bu tür içerik farklılaşmasında ilk dağılımdan P^j örnekleme olasılığının azaldığı, bir sonraki P^{j+1} dağılımından örnek alma olasılığının arttığı geçiş aşamasını ifade etmektedir. Yani iki model aynı anda bir arada bulunabilmektedir [20]. Bu farklılaşma akan veri daha uzun bir süre gözlemlenince değişim fark edilebilmektedir. Artımlı içerik farklılaşması, bir dizi küçük, şiddetli olmayan değişikliklerden oluşmaktadır. Artımlı bir içerik farklılaşmasında, geçiş sırasında bir dizi farklı veri dağılımları ortaya çıkmaktadır. Her değişiklik küçük olduğu için, her küçük değişiklik aniden meydana gelse bile, farklılaşma ancak uzun bir süre sonra fark edilebilmektedir. Tekrarlı içerik farklılaşmasında ise, daha önce aktif olan bir içerik, bir süre sonra yeniden ortaya çıkmaktadır. Bunların dışında, akan verilerde hatalar (nadir olaylar / aykırı değerler) ve gürültü içerebilir, ancak bunlar içerik farklılaşması olarak değerlendirilmez ve akan veri öğrenme yaklaşımları bunlara karşı sağlam olmalıdır.



Şekil 3. İçerik farklılaşmasındaki (a) ani (b) kademeli (c) artımlı ve (d) tekrarlı farklılaşma örüntüleri

1.4. Akan Veri İşleme Genel Modeli

Akan veri uygulamalarının genel yapısı Şekil 4'teki gibi gösterilebilmektedir. Akan veri geldiğinde, tampon yapısı en yeni verileri saklamak için kullanılmaktadır. Akan veri işleme motoru verinin özet bilgisini oluşturmak için tampondaki veriyi okur. Özet bilgi zaman pencereci ve / veya hesaplama yaklaşımları kullanılarak elde edilebilmektedir. Kullanıcı isteği ya da belli bir zaman geçmesi gibi uygun kriter oluştuğunda akan veri işleme motoru özet bilgileri işleyerek çıkış değerlerini oluşturur. Genel modelde yer alan geleneksel yaklaşımlar birçok akan veri algoritmasının türetilmesi ya da bu yapıya adapte edilmesi için kullanılmaktadır. Akan veri doğrulama teknikleriyle de algoritmaların performans ölçümü yapılmaktadır [2]. Akan veri işleme sürecindeki en önemli yere sahip aşamalar olan zaman penceresi ve hesaplama yaklaşımları alt başlıklarda detaylı olarak açıklanacaktır.



Şekil 4. Akan veri işlenmesindeki genel süreç modeli

1.4.1. Zaman Pencereci


Akan veriler potansiyel olarak sonsuzdur. Bu nedenle akan veri örneklerinin tümünün incelenmesi imkansızdır. Sadece bir anda ilgili bir kısmını işlemek mümkündür. Buradaki ilgili kısım, veri nesnelerinin bir zaman penceresi olarak tanımlanmaktadır. Zaman penceresi eşitlik (1)' deki şekilde ifade edilmektedir.

$$W[i, j] = (x_i, x_i + 1, \dots, x_j), i < j \quad (1)$$

Akan veriler işlemek için farklı zaman penceresi türleri kullanılmaktadır. Bunlar: dönüm noktası penceresi, kayan pencere, yaşlandırma penceresi ve eğimli zaman penceresidir.

1.4.1.1. Dönüm Noktası Pencere Modeli

Dönüm noktası pencere modeli, başlangıç anı olan $t = 1$ anından şimdiki zaman anına t_c 'ye kadar tüm akan veri ile ilgilenmektedir ve $W[1, t_c]$ ile ifade edilmektedir [2]. Bu modelinde penceredeki tüm işlemler eşit derecede önemlidir. Geçmiş ve şimdiki veriler arasında bir fark bulunmamaktadır. Ancak, akan veri sürekli geliştikçe, eski veri nesneleriyle oluşturulan model yeni gelenlerle tutarsız hale gelebilmektedir. Dönüm noktası pencere modeli Şekil 5' teki gibidir.




Şekil 5. Dönüm noktası zaman penceresi modeli

1.4.1.2. Kayan Pencere Modeli

Kayan pencere modeli $W[t_c - w + 1, t_c]$, sadece en son olan w tane veri ile ilgilenmektedir. Bu verilerden önce gelen veriler elemine edilmektedir [2]. Bu modelde işlemlerin sonucu w penceresinin boyutuna bağlı olmaktadır. Eğer w çok büyükse ve içerik farklılaşması mevcutsa, pencere muhtemelen güncel olmayan verileri de içereceğinden öğrenme modelinin başarısı azalacaktır. Diğer durumda w küçükse, pencerede yetersiz sayıda veri durumu olabilmektedir. Öğrenme modelinde aşırı öğrenme sorunu oluşacaktır ve ayrıca büyük varyans değerlerinden mustarip olacaktır. Kayan pencere modeli kullanan


çalışmalarda pencere boyutu, ya kullanıcı tarafından sabit bir değer olarak ya da deneysel olarak seçilen bir değer olarak belirtilmektedir. Bunun dışında, pencere boyutunun modelin doğruluğuna göre değiştiği esnek kayan pencere yapıları için öneriler de bulunmaktadır. Bu modellerde, doğruluk yüksek olduğunda pencere genişlemekte ve doğruluk düşük olduğunda ise pencere küçülmektedir. Kayan pencere modeli Şekil 6’ da gösterilmektedir.



Şekil 6. Kayan pencere modeli

1.4.1.3. Yaşlandırma Penceresi Modeli

Şekil 7’ de gösterilen yaşlandırma pencere modelinde, her veri nesnesine varış zamanına göre farklı bir ağırlık atanmaktadır. Böylece yeni veriler eskilere göre daha yüksek ağırlık almaktadır [2].



Şekil 7. Yaşlandırma penceresi modeli


Yaşlandırma penceresi ile, eski ve güncel olmayan işlemlerin öğrenme modeli sonuçları üzerindeki etkisini azaltılmaktadır. Bu modelde genellikle eşitlik (2)’deki azalan

bir üstel fonksiyon kullanılmaktadır. Bu fonksiyonda t , bir veri nesnesinin mevcut zaman ile varış zamanı arasındaki zaman farkına eşit olan yaşıdır. Yaşlandırma penceresinin, gerçek uygulamalarda $[0.99, 1]$ aralığında ayarlanan uygun bir yaşlandırma parametresi λ seçmesi gerekmektedir.

$$f(\Delta t) = \lambda^{\Delta t}, (0 < \lambda < 1) \quad (2)$$

1.4.1.4. Eğimli Zaman Penceresi Modeli

Eğimli zaman penceresi [2], yaşlandırma penceresi ile kayan pencere modelleri arasında kalan bir modeldir. Verilerin güncelliğine göre farklı seviyelerde verilere ayrıntılı işlemler yapmaktadır. Geçmişten gelen uzun vadeli verilere kaba ölçekte ele alırken, yeni ve güncel verilere daha ince ölçekte ele almaktadır. Eğimli zaman penceresi, yaklaşık olarak tüm veri kümesini depolar ve depolama gereksinimleri ile doğruluk arasında hoş bir denge sağlar. Ancak model uzun süre çalıştıktan sonra kararsız hale gelebilmektedir. Bu modelin gösterimi Şekil 8’de verilmektedir.




Şekil 8. Eğimli zaman penceresi modeli

1.4.2. Hesaplama Yaklaşımları

Akan veri işlemede önemli bir yeri olan hesaplama yaklaşımları artımlı öğrenme ve iki-fazlı öğrenme olmak üzere ikiye ayrılmaktadır.

1.4.2.1. İki Fazlı Öğrenme


Çevrim içi-Çevrim dışı öğrenme olarak da bilinmektedir ve yaygın bir tekniktir. Temel mantık, işlemleri iki faza ayırmaktır. İlk faz çevrim içi fazdır ve bellekte tutulan veri özeti gerçek zamanlı olarak güncellenmektedir. İkinci faz olan çevrim dışı fazda, kullanıcı istek yaparsa ya da belli bir zaman geçmişse saklanan veri özeti üzerinde işlem yapılmaktadır. Bu yaklaşımda yüksek hızda işlem yapılabilir. Fakat sonuç gelene kadar kullanıcının beklemesi problemi vardır [21, 22]. Bu öğrenme türüne ait genel model Şekil 9’ da ki gibidir.



Şekil 9. İki fazlı öğrenme yaklaşımının genel modeli

1.4.2.2. Artımlı Öğrenme

Bu öğrenme yaklaşımında oluşturulan model her yeni gelen veri ile oluşan değişikliklere uyum sağlamak için artımlı bir şekilde gelişmektedir. Yani bu yaklaşımlarda, model her yeni gelen akan veri örneği ile eğitilmektedir. Bu nedenle artımlı öğrenme yaklaşımları akan verilerin ihtiyaçlarını sağlayabilmek açısından çok elverişlidir. Artımlı öğrenmede tek geçişli olarak tabir edilen her verinin teker teker ele alınması tekniği kullanıldığı gibi pencere yaklaşımlarına dayalı veri kullanımı yer alabilmektedir. Anlık sonuç vermesi açısından artımlı öğrenme büyük bir avantaja sahiptir. Artımlı öğrenme ile gerçekleştirilen çalışmalar dinamik bir yapı kazanmaktadır. Fakat bazı durumlarda fazla hesaplama kaynağı gerektirebilmektedir [23, 24]. Birçok geleneksel makine öğrenimi algoritmaları doğaları gereği artımlı öğrenmeyi desteklemektedir. Ancak akan veriler için kullanılabilmesi için akan veri kısıtlamalarını ve karakteristiklerini göz önüne alarak geliştirilmeleri gerekmektedir. Akan verilerde artımlı öğrenme için kullanılan en yaygın teknik önce-test-sonra eğitimidir. Artımlı öğrenmeye ait genel süreç Şekil 10’ da gösterilmektedir.



Şekil 10. Artımlı öğrenme genel modeli

1.4.3. Akan Veri Değerlendirme Teknikleri

Sınırlı miktarda veriye sahip geleneksel veri madenciliğinde, doğrulama süreci veri kullanımını en üst düzeye çıkarmaya odaklanmaktadır. Fakat geleneksel yaklaşımlar için kullanılan yöntemler akan verilerin karakteristik özelliklerinden dolayı bu verilere uygulanamamaktadır. Bunun için farklı teknikler ortaya atılmıştır. Akan veri ortamında doğrulama teknikleri, veriler potansiyel olarak sonsuz olduğundan modeli çeşitli aşamalarda değerlendirmeye odaklanmaktadır.

Hold-out ve prequential, akan veriler için kullanılan iki popüler tekniktir [2]. Hold-out yönteminde, veri örnekleri yığınlar halinde toplanmaktadır. Her veri yığını önce bir test örneği olarak kullanılır ve ardından modeli güncellemek için kullanılmaktadır. Modelin verinin en son değişikliklerine uyum sağlamasına izin verdiği için içerik farklılaşması olan senaryolarda hold-out yöntemi tercih edilmektedir.

Prequential (veya Aralıklı Önce-Test-Sonra-Eğitim), akan veriler için başka bir değerlendirme tekniğidir. Her veri örneği, modeli artımlı olarak güncellemeden önce modeli test etmek için kullanılmaktadır. Önceden tanımlanmış bir yığın boyutuna ihtiyaç duymama avantajına sahiptir.

1.5. Akan Veri Uygulamaları

Teknolojinin ilerlemesi ile geliştirilen birçok uygulama alanı sürekli olarak muazzam büyüklükteki akan veri türünde veriler üretmektedir. Bu nedenle akan veri uygulama alanı oldukça geniş bir alana sahiptir. Bunlar ağ oluşturma, finans, borsa, eğitim, telekomünikasyon, sağlık hizmetleri, hava durumu tahmini ve daha pek çoğu gibi uygulamalardan veya endüstri alanlarıdır. Bu alanları kapsayan genel uygulama alanları alt başlıklarda verilmektedir.

1.5.1. Madencilik Sorgu Akışları

Bilgi almak için web ‘de arama yapmak, günlük yaşantının önemli bir etkinliği haline gelmiştir. Google, Bing ve Yahoo gibi mevcut arama motorları günlük olarak milyonlarca sorgu ile karşı karşıyadır. Kullanıcılara daha iyi arama sonuçları sağlamak için sorgu akışlarının madenciliği, kullanıcıların arama sonuçlarına hızlı göz atmasını kolaylaştırmak için web arama sonuçlarını kümelemek ya da alternatif sorgular önererek kullanıcıların aramasını hassaslaştırmak gibi çok fazla araştırmaya konu olmaktadır [25, 26].

1.5.2. Ağ İzleme

İnternet, IP paketleri göndererek birbirine bağlanan ve birbiriyle iletişim kuran birçok yönlendirici içermektedir. Bu tür ağları yönetmek için, gerçek zamanlı olarak kullanım modellerini ve olağandışı etkinlikleri keşfetmek için trafik verilerinin analiz edilmesi gerekmektedir. Trafik verileri, kaynak ve hedef IP adreslerini içeren paket günlükleri gibi birçok düzeyde günlük dosyaları biçiminde kaydedilmektedir. Ağ izlemeye ve yönetimine en iyi örnek, büyük bir İnternet servis sağlayıcı ağındaki kötü niyetli saldırıları tespit etmek ve önlemektir. Servis Hizmeti reddi (DOS atakları), uzak makineden yetkisiz erişim (R2L), yerel süper kullanıcı ayrıcalıklarına yetkisiz erişim (U2R) gibi farklı saldırı türlerini gerçek zamanlı olarak sınıflandırmak, gözetlemek ve diğer araştırma saldırıları için bir akan veri öğrenme modeli gerekmektedir [19].

1.5.3. Sensor Ağları

Bir sensor ağı, bir ortamı iş birliği içinde izleyen uzamsal olarak dağıtılmış otonom sensorlerden oluşur. Bu sensorler, sıcaklık, ses, titreşim, basınç, nem ve ışık gibi ortamlarla ilgili fiziksel değerleri algılayabilir; verilerini ağ üzerinden iş birliği içinde bir merkeze aktarabilmektedirler. Sensor ağları, trafik izleme, akıllı evler, habitat izleme ve sağlık hizmetleri gibi birçok gerçek yaşam uygulamasında yer almaktadır [19]. Örneğin, modern hastaneler, sağlık hizmeti kalitesini ve personel verimliliğini artırmak için bir hasta izleme sistemi ile donatılmıştır. Kritik hastalara bağlı birçok vücut sensörü, sıcaklık, elektrokardiyogram, nabız oksimetresi ve kan basıncı gibi büyük fizyolojik veriler üretebilmektedir. Sensor cihazları yalnızca güncellenmiş verileri depoladığından ve insan

gözleri bu sinyal inceliklerini tespit edemediğinden, sistem sağlık hizmeti akan verilerini gerçek zamanlı olarak analiz etmeli ve önemli olayları tanımlamak için klinik kurallar gibi tıp uzmanları için anlamlı bilgiler çıkarmalıdır.

1.5.4. Sosyal Ağ Akışları

Çevrim içi sosyal ağlar gün geçtikçe daha popüler hale gelmektedir. Mesela Facebook, Twitter ve LinkedIn gibi sosyal ağların milyonlarca aktif kullanıcısı bulunmaktadır. Bu tür ağlar metin, multimedya, bağlantı ve etkileşim gibi muazzam miktarda çevrim içi akan verileri oluşturmaktadır. Literatürde sosyal ağ madenciliği üzerine çok fazla araştırma bulunmaktadır. Örneğin, sosyal ağlardaki toplulukları tespit etmek ve gelişimlerini izlemek için akan veri kümeleme yöntemleri kullanılmaktadır. Toplulukların bir sosyal ağda nasıl ortaya çıktığını, genişlediğini, küçüldüğünü ve geliştiğini açıklayabilirler [27, 28]. Dahası, akan veri sınıflandırma algoritması farklı kullanıcı türlerini sınıflandırmaya, tartışma konularını kategorilere ayırmaya [29] veya olay algılamaya [30] yardımcı olmaktadır.

1.6. Akan Veri Madenciliği Yazılım Araçları

Akan veri madenciliği araştırması için bazı yararlı, açık kaynaklı yazılımlar bulunmaktadır. Bunların en popüler olanları WEKA, Massive Online Analysis (MOA) ve RapidMiner' dır.

1.6.1. WEKA

Akademik ortamda en çok bilinen ve kullanılan veri madenciliği yazılımıdır. WEKA, veri ön işleme, sınıflandırma, regresyon, kümeleme, ilişkilendirme kuralları ve görselleştirme gibi bir dizi öğrenme algoritması içermektedir.

1.6.2. MOA

Akan veri öğrenimi için tasarlanmış WEKA' ya dayanan bir yazılımdır. Akan veri geliştirmek için Çok Hızlı Karar Ağaçları [31], Topluluk Öğrenmesi [32] gibi birçok çevrim

İçerik öğrenme algoritması içermektedir. Bunların dışında MOA ile çeşitli koşullarda yapay akan veri setleri üretilmektedir. MOA ile üretilip, literatürde sıklıkla kullanılan veri setleri Sea, Stagger ve Hyperplane akan veri setleri örnek verilebilmektedir.

1.6.3. RapidMiner

Veri madenciliği için başka bir açık kaynaklı yazılımdır. RapidMiner, WEKA'daki tüm algoritmaları ve diğer gelişmiş algoritmaları içerdiği için WEKA'dan daha güçlüdür. Dahası, bir madencilik sürecini bir dizi operatör olarak tanımlayabildiği ve daha fazla görselleştirme aracı sağladığı için daha sezgiseldir.

1.7. Akan Veri Öğrenme Yaklaşımları ve Literatür Araştırması

Akan veri öğrenme yaklaşımları geleneksel verilerde de olduğu gibi genel olarak kümeleme ve sınıflandırma, öznitelik çıkartma gibi kategorilere ayrılmaktadır. Bu kategoriler alt başlıklarda kısaca açıklanmaktadır.

1.7.1. Akan Veri Kümeleme Yaklaşımları

Kümeleme ya da veri bölümlenmesi, nesneleri küme adı verilen farklı setler halinde gruplama işlemidir. Amaç benzer nesneleri aynı küme içine, farklıları ise diğer kümelere gruplamaktır. Kümeleme geleneksel veriler üzerinde çok çalışılmış bir problemdir ve bu konu ile alakalı olarak birçok çalışma ortaya konulmaktadır. Akan veri kümeleme işlemi ise geleneksel kümeleme yaklaşımına göre daha zor bir işlemdir. Bu işlemde akan verilerin karakteristik özelliklerini ve kısıtlamalarını göz önüne bulundurmak gerekmektedir. Çünkü akan veri zamanla değişebilen içeriğe sahiptir ve çok hızlı bir şekilde değişebilmektedir. Ayrıca akan verileri anında ve sadece bir kez işlemek gerekmektedir. Bu verileri sonradan işlemek için depolama imkânı yoktur ve tüm veriye ulaşmak imkânsızdır. Bu nedenle geleneksel yöntemleri akan veri kümelemek için kullanmak mümkün olmamaktadır. Literatürdeki akan veri kümeleme yaklaşımlarının büyük bir çoğunluğu, geleneksel algoritmaların sınırlı bellek, tek seferde işleme, gerçek zamanlı işleme ve içerik farklılaşması gibi akan veri kısıtlamalarını karşılayacak şekilde genişletilmiş versiyonlarıdır. Aynı geleneksel kümeleme yöntemlerinde olduğu gibi akan veri kümeleme yöntemleri

bölümlemeli kümeleme [32, 33, 34, 35, 36], hiyerarşik kümeleme [13, 37, 38, 39, 40], yoğunluk tabanlı kümeleme [41, 42, 43, 44, 45, 46], ızgara tabanlı kümeleme [47, 48, 49, 50] ve model tabanlı kümeleme [23, 51] olmak üzere beşe ayrılmaktadır [2]. Kullanılan yöntemlerin büyük bir çoğunluğu var olan çalışmaların akan veri yapısına uyarlanmasıyla elde edilmiştir [2].

Akan verilerinin kümelenmesi için birçok kümeleme metodu önerilmesine rağmen, bu yöntemlerin bir kısmı akan veri kısıtlamalarına çözüm üretememektedir. Bunlardan en önemlisi içerik farklılaşması sorunudur. İçerik farklılaşması için algoritma içerik farklılaşmasına adapte olabilmelidir. Yani yaklaşımın yeni içerikle güncellenip, eski içeriği atması gerekir. Ayrıca algoritma farklı türlerdeki içerik farklılaşması algılamalı ve adapte olabilmelidir. Mesela küme yenileme ya da değiştirmeye beraber kayan pencere genişletilmeli ya da yenilenen kümenin geçmiş bilgileri elde edilmelidir. Bir başka örnek olarak algoritma en eski kümeyi değil de en az bilgiye sahip kümeyi kaldırmalıdır.

1.7.2. Akan Veri Sınıflandırma Yaklaşımları

Akan veri sınıflandırması, tek sınıflandırıcı ile sınıflandırma ve topluluk öğrenmesine dayalı sınıflandırma olmak üzere iki yöntemle yapılmaktadır. Tek sınıflandırıcı ile sınıflandırma yöntemi hızlıdır ve aynı zamanda hesaplama için daha az bellek almaktadır. Fakat bilinmeyen modeller veya bilinmeyen örnekler arttıkça performansı düşme eğilimi göstermektedir. Bunun aksine, bir topluluk öğrenmesine dayalı yöntem daha fazla zaman ve bellek gerektirir; ancak bilinmeyen modellerin varlığında iyi performans göstermektedir. Topluluk öğrenmesi yönteminde üretilen çıktı, farklı sınıflandırıcıların tahminidir. Akan veriler için araştırmacıların çoğu kolay uygulama, her türlü veriyi işleme yeteneği ve en önemlisi yüksek performansı nedeniyle bir topluluk öğrenmesine dayanan yöntem kullanmaktadır [52, 53, 54]. Torbalama (bagging) ve güçlendirme (boosting), topluluk öğrenmesi yöntem türleridir. Literatürde araştırmaların çoğu, yığın tabanlı [52, 55, 56] ve pencere tabanlı yaklaşımları [57, 58] öğrenme için kullandıkları akan veri sınıflandırması için topluluk yöntemini denemişlerdir. Bu yaklaşımlar, değerlendirme sürecinde önemli bir rol oynar. Akan veri madenciliği alanındaki temel sorun, içerik farklılaşması tespiti ve bu farklılaşmaya göre işlem yapılmasıdır. İçerik farklılaşması, zaman içinde veri değişimi kavramıdır. Araştırmacıların çoğu içerik farklılaşması problemlerini farklı yöntemlerin yardımıyla çözmeye çalışmaktadır [59].

Akan veri sınıflandırma yaklaşımlar içerik farklılaşması sorununa çözüm üretecek yaklaşımlar olmalıdır. Çünkü günümüzde muazzam miktarda veri gerçek hayattaki uygulamalardan üretilmektedir ve üretilen verilerden bilgi çıkarmak önemlidir. Ancak üretilen veriler her zaman sabitlenmez; zamanla değişir, yani akan verilerde içerik farklılaşması meydana gelmektedir. İçerik farklılaşması varlığında, öğrenme algoritmasının performansı her zaman azalır ve bu da yanlış bilgi temsiline neden olur. Bu nedenle, akan veri sınıflandırması alanında içerik farklılaşmasının ele alınması önemlidir. Diğer bir sorun, çeken nadir sınıf veya dengesiz sınıf veya çarpık sınıftır. Arka sınıf probleminde, çoğunluk sınıfı doğruluğu her zaman azınlık sınıfı doğruluğunu alt etmektedir ve bu da yanlış sonuç elde edilmesine neden olmaktadır. Bu sorun, akan veri sınıflandırma sürecini etkilemektedir. Ayrıca yaklaşımlar her veriyi tek bir seferde işlemeli, bir daha bu verilere geri dönüş olmamalıdır.

1.7.3. Akan Veri Öznitelik Çıkartma ve Boyut İndirgeme Yaklaşımları

Özellik çıkartma veri madenciliği ve makine öğrenmesi uygulamalarının önemli işlem aşamalarından birisidir ve veriyi yüksek boyutlu uzaydan düşük boyutlu uzaya iz düşürerek yararlı özellikleri çıkartmayı amaçlamaktadır. Özellik çıkartma yüksek ölçekli akan veri sınıflandırma uygulamalarında doğru sonuçlar elde etmeyi yardım etmektedir. Ancak, geleneksel özellik çıkarma teknikleri, akan verinin gereksinimlerini karşılayamamaktadır. Bu nedenle, artımlı özellik çıkarma teknikleri, akan verilerin özellik çıkarımını kolaylaştırmak için tasarlanmıştır [60] ve akan veriler için geleneksel yöntemlerin sorunlarını çözmeyi amaçlarlar. Her ne kadar artımlı özellik çıkarma teknikleri çeşitli sorunlara cevap verebilse de bazı teknikler zaman karmaşıklığı ve hesaplama maliyetleri açısından yüksek boyutlu akan veriler için uygun olamamaktadır.

Danışmansız yaklaşımların büyük çoğunluğu akan verilere kolaylıkla uygulanabilmektedir. Fakat, bunların büyük çoğunluğu büyük ölçekli veriler için öz uzayı belirlerken veri bağımlılığı ve yüksek hesaplama maliyeti gibi sorunlara sahiptir. Dahası, gelen her veriyi anında işlemek için uzun bir süre gerektirmektedir. Bu sorunlar, artımlı özellik çıkarma algoritmalarını akan verileri işlemede karmaşık hale getirmektedir. Bu zorluk, AKD [61] gibi alternatif denetimsiz yaklaşımların kullanılmasına neden olmaktadır.

Literatürde en popüler artımlı öznitelik çıkartma algoritmalarının temeli Temel Bileşen Analizi' ne (TBA) dayandığı görülmektedir. TBA [62] geleneksel veriler için boyut

indirgeme ve öznitelik çıkartma algoritması olarak kullanılmak için geliştirilmiştir. TBA'nın birçok artımlı versiyonu, artımlı öğrenme biçiminde TBA (ATBA) icra edilmesi için geliştirilmiştir ve halen daha bu alanda çalışmalar devam etmektedir. Literatürde ATBA algoritmaları iki kategoriye ayrılmaktadır [63]: İlk kategoride yer alan algoritmalar her yeni gelen veri örneği için öz vektör ve öz değerlerin yeniden hesaplanmasına dayanmaktadır. Bu kategorideki ATBA yaklaşımlarının çeşitlenmesinin en önemli nedeni kovaryans matrisin artımlı olarak farklı şekillerde temsil edilmesi ve hesaplanmasıdır. Artımlı öğrenmenin ana karakteristik özelliklerinden dolayı, kovaryans matris her yeni veri ile güncellenmek zorundadır. Ancak, veri ölçeği ve öznitelik sayısı arttıkça, hesaplama maliyeti de buna bağlı olarak artmaktadır. Bundan dolayı kovaryans matrisinin güncellenmesi ve yeni öz uzayın hesaplanması her yeni veri için zorlaşmaktadır. Ayrıca, bu algoritmaların önceden tahmin edilemeyen bir yaklaşıklık hatası problemi de bulunmaktadır.

1.7.3.1. Kovaryans Matrisi Kullanan ATBA Yaklaşımları

Bu kategorideki tüm ATBA algoritmaları ve uygulamaları, her akan veri için öz uzayı yeniden belirleme veya güncelleme gereksinimi duymaları nedeniyle yüksek hesaplama maliyeti ve zaman karmaşıklığından mustarıptır. ATBA algoritmaları, veri bağımlılığı, yüksek hesaplama maliyeti ve zaman karmaşıklığı nedeniyle anında yanıt gerektiren akan verileri işlemek için uygun olmamaktadır. Bu kategoriye ait ATBA yaklaşımları ve ATBA uygulamaları bu başlık altında aşağıdaki gibi özetlenmektedir.

Hall vd. [64] artımlı özellik çıkarmak amacıyla ilk ATBA algoritması önermiştir. Bu algoritma, kovaryans matrisi kalan tahmin yöntemini kullanarak her veri için kovaryans matrisini güncellemektedir. Yazarlar daha sonra çalışmalarını yalnızca bir veri kullanmak yerine yığın yapısı kullanarak geliştirmişlerdir [65]. Bu çalışma yığın yapısını kullanarak öz uzayı bölmeye ve birleştirmeye dayanmaktadır.

Liu vd. [66] video çekim sınırını tespit etmek için öz uzayın artımlı güncellenmesine dayanan bir yaklaşım geliştirmişlerdir. Bu yaklaşım yeni bir video karesi oluşur oluşmaz histogram temsilini hesaplamaktadır. Daha sonra yeni karelerin özellikleri ve belirlenen öz uzay kullanılarak çekim sınırını tespit edilmektedir. Bu yaklaşımda en son işlem olarak öz uzay TBA tabanlı artımlı bir algoritma ile güncellenmektedir.

Li vd. [67] TBA tabanlı artımlı ve sağlam bir alt uzay öğrenme algoritması geliştirmiştir. Bu algoritma öz değerleri ve öz vektörleri hesaplamak için iki adım

içermektedir. İlk olarak, algoritma ilk gözlem verileriyle ilk temel bileşenleri hesaplar. Daha sonra, yeni gözlem verileri oluştuğunda önceki öz vektörler ve öz değerler kullanılarak ana yeni bileşenler elde edilir. Algoritmanın uygulanması kolay olmasına rağmen, diğer ATBA algoritmalarında da olduğu gibi zaman karmaşıklığı, hesaplama ve derleme maliyetinden mustarip olmaktadır.

Ozawa vd. [68], birikim oranına dayalı genişletilmiş bir ATBA algoritması önermişlerdir. Öz uzay, öz eksenlerin dönüşü ve ATBA algoritmalarında yer alan boyutsal artış kullanılarak güncellenir. Çalışmada literatürdeki boyutsal artış yaklaşımını kullanan algoritmaların boyutsal artışı kalan vektörünün normu önceden belirlenen bir eşik değerden daha büyük olduğunda elde ettiği raporlanmıştır. Bu raporlamaya göre eğer bu eşik değer çok küçükse, tekrar edilmesine gerek duyulmayan fazlalık öz uzay elde edilir. Bu durum da algoritmanın hesaplama verimliliğinde ve performansında düşüşe neden olmaktadır. Bu nedenle, en iyi eşik değerini belirlemenin bu algoritmalar için bir zorluk teşkil ettiği vurgulanmıştır. En iyi eşik değerini belirleme ihtiyacı nedeniyle, önerdikleri çalışma olan genişletilmiş ATBA ile birikim oranını kullanılarak bu sorunun elemine edilmeye çalışılmıştır. Daha sonra Ozawa vd. [69] bu çalışmaya yığın yapısı ekleyip yığın ATBA olarak adlandırarak geliştirmişlerdir. Yığın ATBA, ATBA'dan farklı olarak tek geçişli veri modeli yerine yığın modeli kullanmaktadır. Öz uzay, her bir seferde mevcut yığın için aşamalı olarak güncellenmektedir.

Zhao vd. [61], Tekil Değer Ayrışımı Güncelleme tabanlı ATBA (TDAG-ATBA) adı verilen artımlı bir öğrenme ve özellik çıkarma algoritması geliştirmiştir. Algoritma TDA güncelleme algoritması kullanmaktadır. TDA güncelleme algoritması sayesinde öz uzayın sıfırdan hesaplanmasına gerek duyulmamaktadır.

Rosas-Arias vd. [70] video dizilerindeki araçları saymak için bir çevrim içi öğrenme yaklaşımı önermiştir. Bu yaklaşım, bir TDA algoritması kullanan ATBA yöntemine dayanmaktadır. Başka bir çalışmada Fujiwara vd. [71] ise, çok boyutlu akan verileri görselleştirmek için ATBA'ya dayalı artımlı bir boyut azaltma algoritması sunmuştur. Sunulan yaklaşım, diğer yaklaşımda olduğu gibi öz uzayı hesaplamak için TDA kullanmaktadır.

Wei vd. [72], çalışmalarında geliştirdikleri iki yaklaşımın birinde TDA ile kovaryans matrisin güncellendiği ATBA yaklaşımını akan veri temel bileşen ayrıştırması ve özellik çıkartması için önermişlerdir. Fakat bu yaklaşımın zaman ve hesaplama karmaşıklığı oldukça yüksektir.

1.7.3.2. Kovaryans Matrisi Kullanmayan ATBA Yaklaşımları

Bu kategorideki ATBA algoritmaları, kovaryans matrisini kullanmadan öz uzayı hesaplamaya dayanmaktadır. Öz vektörler, yüksek mertebeden temel bileşenler kullanılarak tek tek hesaplanır. Bu nedenle, kaç öz vektörün hesaplanması gerektiğini önceden bilmek gerekmektedir. Buna ek olarak, bu kategorideki algoritmalarda da veri bağımlılığı sorunu bulunmaktadır. Her ne kadar örneklerin ve özniteliklerin sayısındaki artış, algoritmanın zaman karmaşıklığını doğrusal olarak etkilemese de bu kategorideki yaklaşımlarda kümülatif hata yayılmaktadır ve temel bileşenlerin artımlı hesaplanması nedeniyle son öz vektörler doğru bir şekilde tahmin edilememektedir. Bu kategoriye giren algoritmalar ve uygulamaları aşağıdaki gibi özetlenmiştir.

Weng vd. [73] bu kategorinin temel yaklaşımlarından biri olan Gerçek Kovaryanssız ATBA (GKATBA) önermiştir. GKATBA, TBA tabanlı bir algoritma değildir ve kovaryans matris içermemektedir. Bu nedenle her yeni veri için kovaryans matris yeniden yapılandırılmasına gerek duyulmamaktadır. Yaklaşım öz uzayı kovaryans matris kullanımı olmadan aşamalı bir yaklaşımla belirler. Mevcut hesaplanan temel bileşen, GKATBA’ da ki bir sonraki düşük dereceli temel bileşenin temelini oluşturmaktadır. Algoritmada en baskın temel bileşen önce hesaplanır ve ardından ikincisi baskın bileşen birincisi kullanılarak elde edilir. Yani her bileşen kendinden sonra gelen düşük dereceli bileşeni üretmek için kullanılmaktadır. GKATBA, yapı olarak akan veriye için uygun bir algoritmadır ve bu yaklaşım kullanılarak akan veri için öznitelik çıkarma algoritmaları geliştirilmiştir [3, 72].

Wei vd. [72], çalışmalarında geliştirdikleri diğer yaklaşımda GKATBA fikrine dayanan akan veri için birleşik verilerinin kovaryans kullanılmadan artımlı kovaryans ayrıştırmasını önermişlerdir.

Zeng vd. [3] akan veriler için GKATBA ile temel ve baskın bileşenleri çıkartılmasına dayana iki aşamalı artımlı en küçük kareler (AEKK) bir boyut indirgeme ve öznitelik çıkartma küçültme algoritması önermiştir. Bu yaklaşımda ilk temel bileşen EKK ile elde edilirken diğer düşük dereceli temel bileşenler kovaryans matris kullanılmadan GKATBA ile elde edilmektedir.

1.7.3.3. Çekirdek Tabanlı ATBA Yaklaşımları

TBA ve ATBA algoritmaları doğrusal dönüşümlerdir ve özellikleri doğrusal uzayda çıkarmaktadır. Ancak, doğrusal dönüşüm her durumda ihtiyaçları karşılayamamaktadır. Bu tür durumlarda çekirdek yapısı ile daha doğru sonuçlar elde edilebilmektedir. Literatürde akan veri özellik çıkarmak için artımlı Çekirdek-TBA (AÇTBA) tabanlı artımlı algoritmalar yer almaktadır. AÇTBA algoritmaları, ATBA ile aynı sorunlardan mustarıptır. Dahası, akan veri için en iyi çekirdek türünü seçmek ÇTBA' da bir zorluk olarak yer almaktadır. Akan veri için kullanılan AÇTBA yaklaşımları aşağıdaki gibi özetlenmiştir.

Tokumoto vd. [74] doğrusal uzayda elde edilen temel bileşenlerin akan veriler öznitelik çıkartmasında her zaman yeterli olmayacağı düşüncesiyle AÇTBA yaklaşımı önermiştir. Bu yaklaşım verileri yığın olarak ele alarak kovaryans matris güncellemesi yapmaktadır. Her yığın için kovaryans matris güncellenerek öz uzay ve temel bileşenler elde edilmektedir.

Ghashami vd. [75] akan verideki küçük ve temel ögeleri ile işlem yapılan AÇTBA algoritması geliştirmişlerdir. Bu yaklaşım öz uzay hesabı ve kovaryans matris güncellenmesi için TDA yöntemini kullanmaktadır.

Joseph vd. [76] akan veri özellik çıkartma amaçlı yığın yapısını kullanan AÇTBA algoritması önermişlerdir. Bu yaklaşım birikim oranını kullanan ATBA algoritmalarındaki gibi her veri yığını için kovaryans matrisin güncellenmesine ve öz uzayın yeniden hesaplanmasına dayanmaktadır.

1.7.3.4. AKD Tabanlı Akan Veri Yaklaşımları

Literatürde, AKD' ye dayalı sınırlı akan veri çalışmaları bulunmaktadır. Mevcut AKD tabanlı çalışmalar, akan veri kümeleme, içerik farklılaşması probleminin analizi ve akan veri sorgu analizi [77] hakkındadır. AKD tabanlı akan veri özellik çıkartma ve boyut indirgeme çalışması yer almamaktadır. Literatürde akan veri için AKD kullanan yaklaşımlar aşağıdaki gibi özetlenmiştir.

Yu vd. [78] akan verilere ızgara yoğunluğuna dayalı bir kümeleme işlemi yaklaşımı önermiştir. Bu yaklaşımda AKD ile akan verilere sıkıştırma işlemi gerçekleştirilmektedir ve sonrasında kümeleme işlemi yapılmaktadır.

Hayat vd. [79] akan veri içerik farklılaşması algılanması için kümelemeye dayanan bir yaklaşım önermiştir. Bu yöntemde AKD yeni sınıfları ve içerik farklılaşmasını tespit etmek için gerekli olan üretken modelleri oluşturmak için kullanılmaktadır.


Jiang vd. [80] AKD' ye dayalı olarak akan veri eşdeğer sorgu boyutunu tahmin etmek için AKD tabanlı bir yaklaşım önermiştir. Çalışmada AKD veri dağılımlarının kısa ve doğru temsillerini sağlamak için kullanılmaktadır.

1.7.4. AÖM ve Topluluk AÖM Tabanlı Akan Veri Yaklaşımları

Bu bölümde, AÖM modeli ve akan veri için kullanılan ÇA-AÖM modeli anlatılarak, ÇA-AÖM tabanlı topluluk öğrenmesine dayanan akan veri sınıflandırması için ilgili çalışmaların kısa bir incelemesi verilmektedir. Akan verinin içerik farklılaşması problemini inceleyen ilgili çalışmalar da ayrıca tartışılmıştır.

AÖM, Huang ve arkadaşları tarafından 2006 yılında ortaya atılan efektif bir makine öğrenmesi algoritmasıdır [81]. AÖM tek bir gizli katmana sahip olan ileri beslemeli bir yapay sinir ağıdır (TKİBA). Bu nedenle AÖM' nin çalışma prensibi belirli bir dereceye kadar yapay sinir ağlarının çalışma prensipleri ile aynıdır. Ancak yapay sinir ağlarından en büyük farkı, AÖM' nin giriş katmanı ile gizli katmanı arasındaki ağırlıklar (α) ile bias (b) değerleri rastgele bir şekilde atanmaktadır ve bu değerler eğitimin ileriki aşamasında güncellenmemektedir. Buna karşın gizli katman ile çıkış katmanı arasındaki ağırlıklar (β) ise tek bir seferde doğrusal bir model yardımıyla analitik ve hızlı bir şekilde belirlenmektedir. Yani AÖM özyineleme olmadan analitik bir şekilde ağ yapısının öğrenildiği bir yaklaşımdır.

Temel AÖM modeli Şekil 11' de görüldüğü gibidir ve geleneksel beslemeli yapay sinir ağları ile farkı özyineleme olmadan tek seferde öğrenilebilmesidir. Huang ve arkadaşları bu durumu yani önerdikleri AÖM modelindeki ağırlıkları analitik bir şekilde tek seferde hesaplayıp, bu yöntem ile elde edilecek çözümün eşsiz olduğunu kanıtlamaktadırlar. AÖM' nin çıktı ağırlıkları genelleştirilmiş ters işlem yoluyla analitik olarak belirlenmektedir. Bu işlem, iki temel teoreme bağlı olarak gerçekleşmektedir [81, 82]. Temel olarak AÖM' nin eğitiminin hızlı olması, çok iyi bir genelleştirme performansı sağlaması birçok alanda kullanılmasına neden olmaktadır [81]. Ayrıca yapay sinir ağ bazlı bir model olduğundan, yapay sinir ağlarının kullanılabileceği her alanda aşırı öğrenme makineleri modelinin de kullanılması mümkündür.



Şekil 11. Temel AÖM yapısı

N keyfi rasgele örnekler $(\mathbf{x}_i, \mathbf{t}_i)$ için, $(\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}])$, L gizli düğümleri olan ve $g(\mathbf{x})$ lineer olmayan sonsuz bir aktivasyon fonksiyonu olan standart bir AÖM' nin çıkışı herhangi bir aralıkta ayırt edilebilir matematiksel olarak aşağıdaki gibi modellenmiştir.

$$\sum_{i=1}^L \beta_i g(\mathbf{a}_i, b_i, \mathbf{x}_j) = o_j, \quad j = 1, 2, \dots, N \quad (3)$$

Burada $\mathbf{a}_i$, giriş katmanını gizli katmanla birleştiren ağırlık, β_i gizli katmanı çıkış katmanı ile birleştiren ağırlık ve b_i i . gizli nöronun biasıdır. AÖM' nin mantığı dayandığı iki temel teoremin koşulları sağlandığında, giriş olarak aldığı N örneği sıfır hatayla yakınsatabilmesine dayanmaktadır. Böylece (3) eşitliği (4) şeklinde yazılabilmektedir.

$$\sum_{i=1}^L \beta_i g(\mathbf{a}_i, b_i, \mathbf{x}_j) = \mathbf{t}_j, \quad j = 1, 2, \dots, N \quad (4)$$

(4) eşitliği daha açık şekilde (5)'teki gibi yazılabilmektedir.

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (5)$$

Öyle ki;

$$\mathbf{H} = \begin{pmatrix} \mathbf{g}(a_1, b_1, \mathbf{x}_1) & \cdots & \mathbf{g}(a_L, b_L, \mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ \mathbf{g}(a_1, b_1, \mathbf{x}_N) & \cdots & \mathbf{g}(a_L, b_L, \mathbf{x}_N) \end{pmatrix} \quad (6)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^T \\ \vdots \\ \boldsymbol{\beta}_L^T \end{bmatrix} \quad \text{ve} \quad \mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix} \quad (7)$$

Bir dizi analitik işlem ve optimizasyon probleminin Lagrangian çarpıcıları ile çözülmesi sonrası $\boldsymbol{\beta}$ gizli katman ağırlıkları (8) ve (10) eşitlikleri ile, çıktı değerleri (9) ve (11) eşitlikleri ile elde edilmektedir. Eğer $N > L$ ise (8) ve (9) eşitlikleri, değilse (9) ve (10) eşitlikleri kullanılmaktadır.

Eğer $N > L$ ise;

$$\boldsymbol{\beta} = \mathbf{H}^\dagger \mathbf{T} = \left(\frac{I}{c} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{T} \quad (8)$$

$$f(\mathbf{x}) = h(\mathbf{x}) \boldsymbol{\beta} = h(\mathbf{x}) \left(\frac{I}{c} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{T} \quad (9)$$

Eğer $N < L$ ise;

$$\boldsymbol{\beta} = \mathbf{H}^T \left(\frac{I}{c} + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{T} \quad (10)$$

$$f(\mathbf{x}) = h(\mathbf{x}) \boldsymbol{\beta} = h(\mathbf{x}) \mathbf{H}^T \left(\frac{I}{c} + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{T} \quad (11)$$

AÖM algoritması aşağıdaki Algoritma 1'deki gibi özetlenebilmektedir.

Algoritma 1 AÖM

Girdi: Eğitim seti $\mathbf{X} = \{(\mathbf{x}_i, t_i) | i = 1, 2, \dots, N\}$, aktivasyon fonksiyonu $g(\mathbf{x})$, gizli katmandaki, nöron sayısı L

Çıkış: Çıktı katmanı ağırlıkları $\boldsymbol{\beta}$, $f(\mathbf{x})$

1: Giriş katmanı ile gizli katman arasındaki ağırlıkları $\mathbf{a}_i$ ve gizli katman biası $\mathbf{b}_i$, rastgele olarak ata. $i = 1, 2, \dots, L$

2: Gizli katman çıkış matrisi $\mathbf{H}$ eşitlik (6)'da ki gibi hesapla.

3: Çıkış ağırlıkları β 'yı ve çıkış değerlerini $N > L$ ise eşitlik (8) ve (9)' da ki gibi, değilse eşitlik (10) ve (11)' deki gibi hesapla.

4: β ve $f(x)$ ' i geri döndür.

AÖM' nin basit yapısı, kısa eğitim zamanı gerektirmesi ve çok iyi genelleştirme kabiliyeti, akan veri için öğrenme yaklaşımlarının gereksinimleri fazlasıyla karşılamaktadır. Bu nedenden dolayı özellikle akan veri sınıflandırma süreci için AÖM yaklaşımı oldukça uygundur ve literatürde AÖM' ye dayalı birçok çalışma mevcuttur [83, 84, 85]. Ancak AÖM' nin temel yapısı artımlı öğrenme yaklaşımına uymamaktadır. Bunu gidermek amaçlı Çevrim içi Ardışıl Aşırı Öğrenme Makineleri (ÇA-AÖM) adı verilen bir artımlı öğrenmenin gerçekleştiği bir AÖM yapısı önerilmiştir [86] ve bu alandaki çalışmalar ÇA-AÖM yapısına dayanmaktadır.

ÇA-AÖM' de öğrenme verilerin birer birer ya da yığın şeklinde kullanılmasıyla gerçekleşmektedir [86]. Gizli katman parametreleri yani giriş katmanı ağırlıkları ve bias değerleri yine AÖM' de olduğu gibi rastgele olarak seçilmektedir. Fakat yine AÖM' de olduğu gibi gizli katman ağırlıkları analitik olarak hesaplanıp, her ardışık gelen veri ya da veri yığını ile güncellenmektedir. ÇA-AÖM iki aşamadan oluşmaktadır. İlk aşama iklendirme aşamasıdır ve belli sayıda veri kullanarak ilk TKİBA modeli oluşturulmaktadır. Başka bir deyişle, ilk TKİBA modeli temel AÖM' nin ana fikri kullanılarak inşa edilmektedir. Diğer aşama ise ardışıl öğrenme aşamasıdır ve bu aşamada TKİBA model ardışıl olarak gelen her yeni veri ya da yığın ile artımlı olarak güncellenmektedir. Ağ modelinde güncellenen parametre gizli katman ile çıkış katmanı ağırlıkları olan β ' dır.

$X_0 = \{(x_i, t_i)_{i=1}^{N_0}\}$ N_0 tane örnek içeren ($N_0 > L$) ilk yığın olsun. $H_0^T H_0$ matris çarpımı K_0 adı verilen bir değişkene atansın. Bu durumda gizli katman ile çıkış katmanı arasındaki ağırlıklar ilk veri yığını için β eşitlik (12)' deki gibi yazılabilmektedir.

$$\beta^{(0)} = K_0^{-1} H_0^T T_0 \quad (12)$$

Öyle ki;

$$H_0 = \begin{pmatrix} g(a_1, b_1, x_1) & \cdots & g(a_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ g(a_1, b_1, x_{N_0}) & \cdots & g(a_L, b_L, x_{N_0}) \end{pmatrix} \text{ ve } T_0 = \begin{bmatrix} t_1^T \\ \vdots \\ t_{N_0}^T \end{bmatrix} \quad (13)$$

$\mathbf{X}_{k+1} = (\mathbf{x}_i, t_i)_{i=(\sum_{j=0}^k N_j)+1}^{\sum_{j=0}^{k+1} N_j}$ $k + 1$ ' inci gelen yığın olsun. Bu durumda gizli katman ile çıkış katmanı arasındaki ağırlıklar $\boldsymbol{\beta}$ ve $\mathbf{K}_{k+1}$ sırasıyla eşitlik (15) ve (14) gibi hesaplanmaktadır.

$$\mathbf{K}_{k+1} = \mathbf{K}_k + \mathbf{H}_{k+1}^T \mathbf{H}_{k+1} \quad (14)$$

$$\boldsymbol{\beta}^{(k+1)} = \boldsymbol{\beta}^{(k)} + \mathbf{K}_{k+1}^{-1} \mathbf{H}_{k+1}^T (\mathbf{T}_{k+1} - \mathbf{H}_{k+1} \boldsymbol{\beta}^{(k)}) \quad (15)$$

Öyle ki;

$$\mathbf{H}_{k+1} = \begin{pmatrix} g(\mathbf{a}_1, \mathbf{b}_1, \mathbf{x}_{(\sum_{j=0}^k N_j)+1}) & \cdots & g(\mathbf{a}_L, \mathbf{b}_L, \mathbf{x}_{(\sum_{j=0}^k N_j)+1}) \\ \vdots & \ddots & \vdots \\ g(\mathbf{a}_1, \mathbf{b}_1, \mathbf{x}_{(\sum_{j=0}^{k+1} N_j)}) & \cdots & g(\mathbf{a}_L, \mathbf{b}_L, \mathbf{x}_{(\sum_{j=0}^{k+1} N_j)}) \end{pmatrix} \text{ ve} \quad (16)$$

$$\mathbf{T}_{k+1} = \begin{bmatrix} \mathbf{t}_{(\sum_{j=0}^k N_j)+1}^T \\ \vdots \\ \mathbf{t}_{(\sum_{j=0}^{k+1} N_j)+1}^T \end{bmatrix}$$

Eşitlik (15)' te $\mathbf{K}_{k+1}$ matrisinin tersinin alınması gerekmektedir ve bu durum çok fazla hesaplama neden olmaktadır. Bu nedenle Woodbury denklemi kullanılarak $\mathbf{K}_{k+1}$ ' in tersi eşitlik (17)' deki gibi hesaplanabilmektedir.

$$\mathbf{K}_{k+1}^{-1} = \mathbf{K}_k^{-1} - \mathbf{K}_k^{-1} \mathbf{H}_{k+1}^T (\mathbf{I} + \mathbf{H}_{k+1} \mathbf{K}_k^{-1} \mathbf{H}_{k+1}^T)^{-1} \mathbf{H}_{k+1} \mathbf{K}_k^{-1} \quad (17)$$

ÇA-AÖM algoritması aşağıdaki Algoritma 2'deki gibidir.

Algoritma 2: ÇA-AÖM

Girdi: Eğitim seti $\mathbf{X} = \{(\mathbf{x}_i, t_i) | i = 1, 2, \dots, N\}$, aktivasyon fonksiyonu $g(\mathbf{x})$, gizli katmandaki, nöron sayısı L i ilk yığındaki veri sayısı N_0 , ardışıl yığınlardaki veri sayısı N_k

Çıkış: Çıktı katmanını ağırlıkları $\boldsymbol{\beta}, f(\mathbf{x})$

1: İlkendirme Aşaması: İlk TKİBA modelini N_0 ilk yığını için inşa et.

- a) Giriş katmanı ile gizli katman arasındaki ağırlıkları $\mathbf{a}_i$ ve gizli katman biası $\mathbf{b}_i$ rastgele olarak ata. $i = 1, 2, \dots, L$
- b) Gizli katman çıkış matrisi H_0 eşitlik (13)' deki gibi hesapla.
- c) K_0 ve gizli katman ile çıkış katmanı arasındaki ağırlık matrisi $\beta^{(0)}$ ' ı eşitlik (12) deki gibi hesapla.
- d) $k=0$


2: Ardışıl Öğrenme Aşaması: TKİBA modelini $(k+1)$ 'inci yığın için güncellenir.

- a) Gizli katman çıkış matrisi H_{k+1} ' i eşitlik (16)'daki gibi hesapla.
 - b) K_{k+1}^{-1} ve gizli katman ile çıkış katmanı arasındaki ağırlıkları $\beta^{(k+1)}$ ' i eşitlik (17) ve (15)' deki gibi hesapla.
 - c) $\beta^{(k+1)}$ ve $f(\mathbf{x})$ ' i geri döndür.
-

Literatüre göre ÇA-AÖM kademeli oluşan içerik farklılaşmasına iyi bir şekilde uyum sağlayabilmektedir. Ancak ani oluşan içerik farklılaşmasına adaptasyon konusunda yöntemin başarısız kaldığı raporlanmaktadır. Bu yüzden akan veri için geliştirilecek yapı içerisinde bir içerik farklılaşması adaptasyonu sağlayacak bir mekanizma olması gerekmektedir. Literatürde bunu sağlayabilmek için topluluk öğrenmesi önerilmiştir. Topluluk öğrenmesi çoklu sınıflandırıcı veya komite olarak da adlandırılan bir topluluğa dayanmaktadır. Bu topluluk yeni gelen örnekleri tahmin etmek için bireysel tahminleri birleştirilen bir dizi bağımsız bileşen sınıflandırıcıdır. Topluluklar, tahmin doğruluğunu iyileştirmenin veya karmaşık zor bir öğrenme problemini daha kolay alt problemlere ayırmanın etkili bir yoludur. Topluluk öğrenmesi akan veri yaklaşımlarında kullanılan yaygın bir tekniktir ve literatürde bu tekniği kullanan birçok yaklaşım mevcuttur [19]. Sınıflandırıcı toplulukları, veri dağılımındaki değişikliklere uyumu kolaylaştırdıklarından akan veri sınıflandırıcıları oluşturmak için ilgi çekici bir yaklaşımdır. Uyum sağlamaları, topluluğun dizilişini değiştirerek, eski sınıflandırıcıları kaldırarak veya topluluk bileşenlerini yeniden eğiterek yapılabilir.

Topluluk öğrenmesinde karar bir kombinasyon kuralı ile verilmektedir. Bu kombinasyon kuralı popüler olarak oylama mekanizmasından meydana gelmektedir. En popüler oylama tekniği çoğunluk oylamasıdır. Çoğunluk oylamasında karar bireysel çıktılardan en fazla oy alan olarak verilmektedir. Bunun dışında ağırlıklı oylama mekanizması da mevcuttur. Bu mekanizmada Bayes olasılığı göz önüne alınarak olasılık dağılımları üzerinden ya da en yüksek çıktı değeri veren sınıflandırıcı sonucuna yüksek

ağırlık değeri atanarak oylama yapılmaktadır ve karar verilmektedir. Bunun dışında Borda sayısı da bir oylama tekniği olarak kullanılmaktadır. Topluluk öğrenmesine ait genel model Şekil 12’ de verilmektedir.



Şekil 12. Topluluk öğrenmesi genel modeli

Literatürde, akan veri sınıflandırması için ÇA-AÖM’ yi kullanan birçok çalışma yer almaktadır. Lan vd. [87] bir topluluk öğrenmesine dayalı çevrim içi ardışıl öğrenme makinesi (Ensemble Online Sequential-Extreme Learning Machine, EOS-ELM) önermişlerdir. EOS-ELM, sınıflandırma kararlılığını iyileştirmek için farklı rastgele atanmış giriş katmanı ağırlıklarına sahip birden çok ÇA-AÖM kullanmaktadır. EOS-ELM’ nin sonuçları, topluluk yaklaşımının ÇA-AÖM’ den daha başarılı olduğunu göstermektedir.

Pan vd. belirsiz akan verileri işleyebilmek için statik ve dinamik sınıflandırıcılardan oluşan iki tür topluluk tabanlı yaklaşım sunmuşlardır [88].

Zhao vd. EOS-ELM’ i iyileştirme çalışması gerçekleştirmişlerdir [89] ve çalışmalarına unutma mekanizmasına sahip çevrimiçi bir sıralı AÖM (Online Sequential-Extreme Learning Machine with Forgetting Mechanism, FOS-ELM) olarak adlandırmışlardır. FOS-ELM, öğrenme üzerindeki olumsuz etkilerini azaltmak için güncel olmayan verileri atma fikrini benimseyen bir yaklaşımdır.

Mirza vd. [90] tarafından dengesiz akan veriler için ağırlıklı bir çevrimiçi sıralı uç öğrenme makinesi (Weighted- Online Sequential-Extreme Learning Machine, WOS-ELM) önermişlerdir. WOS-ELM, sınıflandırma yaklaşımının temeli olarak ÇA-AÖM’ i kullanmaktadır. Sınıf dengesizliği sorununu çözmek için ÇA-AÖM’ ye bir ağırlıklandırma

mekanizması dahil edilmiştir. WOS-ELM, akan verinin içeriğinin kararlı olduğunu varsayma üzerine geliştirilmiştir.

Cao vd. [91] oylama tabanlı çevrim içi ardışıl aşırı öğrenme makinesini (Voting base Online Sequential- Extreme Learning Machine, VOS-ELM) nihai kararı çoğunluk oylaması ile elde eden bir yaklaşım olarak sunmuşlardır. VOS-ELM, yalnızca yedi bağımsız ÇA-AÖM ağı kullanarak EOS-ELM' den daha yüksek sınıflandırma doğruluğuna ulaşmıştır.

Gu vd. [92] verilerin merkezi eğilim ve dağılım özellikleriyle birlikte ÇA-AÖM' yi iyileştiren zamansız çevrim içi ardışıl aşırı öğrenme makineleri (Timeliness Online Sequential Extreme Learning Machine, TOS-ELM) adlı başka bir zamanlama tabanlı yaklaşım önermişlerdir.

Cao vd. ilk olarak, belirsiz verilerde ve içerik farklılaşmasına uygulamak için uygun olan ağırlıklı topluluk sınıflandırıcı (Weighted Ensemble Classifier based on Extreme Learning Machine, WEC-ELM) yaklaşımını önermişlerdir [93].

Başka bir çalışmada, içerik farklılaşması karakteristiğine sahip akan verilerdeki dengesiz sınıf problemini ele almak için topluluk öğrenmesinin bir alt kümesine dayalı çevrim içi sıralı aşırı öğrenme makinesi (Ensemble of Subset Online Sequential-Extreme Learning Machine, ESOS-ELM) sunmuşlardır [94]. Topluluk yapısı, bu algorithmada EOS-ELM' ye benzerdir, ancak ESOS-ELM içerik farklılaşmasını tespit etmek için sonraki olasılığı kullanmaktadır. Yaklaşımda ardışıl yığınların sonraki olasılığı bir eşik değerinden büyükse, ESOS-ELM farklılaşmayı tespit ederek derhal yeni verilerle yeni bir sınıflandırıcıyı eğitmektedir.

Ağ saldırı tespit sistemleri için ÇA-AÖM tabanlı sınıflandırma yaklaşımı [95] önerilmiştir. Bu yaklaşım, izinsiz girişi algılamak için ÇA-AÖM' i ve akan verilerin gereksiz özniteliklerini indirgemek için bir özellik seçme tekniğini kullanmaktadır.

Bir diğer çalışmada ise Mao vd. [96] durağan olmayan koşulları ve çarpık sınıf dağılımlarını içeren akan verilere içerik farklılaşmasına hızlıca uyum sağlayabilen bir yaklaşım sunmuşlardır.

Han vd. dağıtık aşırı öğrenme makineleri üzerinde ağırlıklandırılmış topluluk sınıflandırıcıdan oluşan (Weighted Ensemble Classifier based on Distributed Extreme Learning Machine, WE-DELM) (Dağıtılmış Aşırı Öğrenme Makinesine dayalı Ağırlıklı Topluluk Sınıflandırıcı) bir yaklaşım sunmuşlardır [97]. Yaklaşım içerik farklılaşmasına sahip belirsiz akan verileri verimli bir şekilde sınıflandırmak için çevrim içi ve tek geçişli bir algorithmadan oluşmaktadır.

Cavalcante vd. [98] içerik Algılama Mekanizması (Drift Detection Mechanism, DDM) ve İçerik Farklılaşması Algılama Mekanizması için Üstel Ağırlıklı Hareketli Ortalama (Exponentially Weighted Moving Average for Concept Drift Detection Mechanism, ECDD)' na sahip doğruluğu koruyan ve işlem zamanını hızlandıran bir çevrim içi AÖM önermişlerdir.

Bir başka çalışmada Çekirdek tabanlı çevrim içi ardışıl aşırı öğrenme makineleri (Kernel-based Online Sequential Extreme Learning Machine, KOS-ELM) yöntemi önerilmiştir [99]. KOS-ELM, AÖM teorisini doğrusal olmayan uyarlamalı filtreleme ile birleştirdiği için WOS-ELM' den farklı bir yaklaşım olmaktadır. Ancak KOS-ELM, gelen her örnek için yeni bir merkez hesaplaması gerektiği için yalnızca verilerin birer birer işlenmesi şekline çalışabilmektedir. Bu yaklaşım, büyük akan verilere ve çoklu sınıflandırmalar için uygun olmamaktadır. Bu nedenle, çok sınıflı çevrim içi sıralı öğrenmedeki dengesizlik sorununu ele alabilen, kapalı öznitelik eşlemesine sahip çekirdek tabanlı bir ÇA-AÖM yöntemine ihtiyaç duymaktadır.

Mirza vd. akan verinin içerik farklılaşmasındaki çok sınıflı dengesizlik sorununu çözmek için bir oylama tabanlı çevrim içi ardışıl aşırı öğrenme makinesi (Voting based Weighted Online Sequential Extreme Learning Machine, VWOS ELM) tanıtmışlardır [100]. VWOS-ELM, çok sınıflı akan verilerdeki sınıf dengesizliği sorununu çözebilen ilk ardışıl sınıflandırıcıdır ve orijinal WOS-ELM yöntemine göre yeni gelen verilere daha iyi uyum sağlayabilme yeteneğine sahiptir.

Huang vd. [101], dengesiz büyük akan veri için AÖM (Dynamic Cost-Sensitive Ensemble Classification for Imbalanced Massive Data Stream, DCECIMDS) tabanlı dinamik maliyete duyarlı topluluk sınıflandırması önermişlerdi. İlk olarak, dengesiz bir büyük akan veri öznitelik karakterlerini çıkararak içerik farklılaşması algılama yöntemini verir ve dinamik maliyet matrisi ile optimum maliyet işlevini tanımlamaktadır. Önerilen topluluk sınıflandırıcı, MapReduce çerçevesi altında oluşturulmuştur ve ortalama yanlış sınıflandırma maliyetini azaltabilir ve sınıflandırmayı daha güvenilir hale getirebilmektedir.

Mirza vd. [102] dengesiz içerik farklılaşmasına sahip akan veriler için öğrenme mekanizmasına sahip bir meta-bilişsel çevrim içi sıralı ardışıl öğrenme makinesi (Meta-Cognitive Online Sequential-Extreme Learning Machine, MOS-ELM) önermişlerdir. MOS-ELM, içerik farklılaşmasını öğrenmek için uyarlanabilir bir pencere mekanizması kullanmaktadır. Uyarlanabilir pencere mekanizması yapısı, pencerenin boyutunu dinamik ortama uyum sağlanması için ayarlamak için benimsenmiştir. Doğruluk oranına göre eski

konseptli örnekler pencereden çıkarılmaktadır. Yeni konseptlere sahip yeni örnekler sadece pencerede tutulmaktadır. MOS-ELM, örnekleri ağırlıklandıran bir ÇA-AÖM tabanlı sınıflandırıcı kullanmaktadır.

Bir diğer çalışma ile akan veri sınıflandırması için Çevrim içi Sıralı Düzenli Aşırı Öğrenme Makinesi (Online Sequential-Regularized Extreme Learning Machine, OS-RELM) yaklaşımı sunulmuştur [103]. OS-RELM, ilklendirme aşamasını önceden tanımlanmış parametreler ile tekillik problemi gerektiren ÇA-AÖM sınırlamalarını ele almak için önerilmiştir. Yaklaşımda düzenli hale getirme yöntemi, genelleme performansını iyileştirmek için kullanılmaktadır ve ilklendirme aşamasını ortadan kaldırmak için yeni bir güncelleme formülü benimsemiştir. Yeni verilere uyum sağlamak için birini dışarıda bırakan çapraz doğrulama yöntemi kullanılmaktadır. Bununla birlikte, OS-RELM tekillik probleminden mustarıptır.

Tekillik sorununu çözmek için, Çevrim içi Sıralı Azaltılmış Çekirdek Aşırı Öğrenme Makinesi (Online Sequential-Regularized Kernel Extreme Learning Machine, OS-RKELM) önerilmiştir [104]. OS-RKELM, gizli katmanda çeşitli çekirdek türlerini kullanmaktadır.

Venkatesan vd. [105], akan veriye gerçek zamanlı yanıt için yeni bir çevrim içi çok etiketli sınıflandırma yaklaşımı (Online Sequential-Multi Label Extreme Learning Machine, OS-MLELM) önermişlerdir. Çalışma gerçek zamanlı yüksek hızlı çok etiketli akan veri sınıflandırmasında ilk çevrim içi teknik olarak rapor edilmiştir. Önerilen yaklaşım daha sonra yüksek hızlı akan veri örneklerinin çok etiketli tanımlanması için eşik temelli bir tekniğe genişletilmiştir [106]. Buradaki eşik, eğitim aşamasında belirlenmektedir ve giriş verisi örneklerine ait sınıf etiketleri ile girdi veri örneklerine ait olmayan sınıf etiketleri arasındaki farklılığı en üst düzeye çıkaran değer olarak seçilmektedir.

Xiao vd. [107] ikili ve çok sınıflı sınıflandırma problemleri için uygun olan, dengesiz veri dağılımlarına sahip akan veri sınıflandırma problemleri için sınıfa özel maliyet düzenleme aşırı öğrenme makinesi (Class-specific Cost Regulation Extreme Learning Machine, CCR-ELM) adı verilen bir algoritmasını önermişlerdir. CCR-ELM, yalnızca sınıf örnekleri sayısının etkisini değil, aynı zamanda verilerin dağılım derecesinin etkilerini de dikkate alan bir yaklaşımdır.

Zhang vd. [108] akan verinin sınıf dengesizliği problemini çözmek için çift ağırlıklı bir çevrim içi sıralı uç öğrenme makinesi (Dual-Weighted Online Sequential-Extreme Learning Machine, dw-ELM) yöntemi sunmuşlardır. Bu yöntemde uzay ve zaman açısından veri dağılım özellikleri analiz edilmektedir ve kendi kendine uyarlanabilir bir ikili

ağırlıklandırma stratejisi bu yaklaşımda sunulmuştur. Zaman seviyesindeki sınıf dengesizlik oranına dayalı ağırlıklar ve uzay seviyesindeki örneklerin olasılık yoğunluğuna dayalı ağırlıklar ÇA-AÖM modelini güncellemek birleştirilmektedir. Bununla birlikte, dw-ELM, akan verilerin içerik farklılaşma problemine çözüm üretememektedir.

Yang vd. [109] akan veri için içerik farklılaşması algılamalı (CELM) bir topluluk yaklaşımı geliştirmişlerdir. Yaklaşımda içerik farklılaşması tespit edildiğinde tüm topluluk sınıflandırıcı silinerek yeniden eğitilmektedir.

Xu vd [110] IDS-ELM adı verilen akan veri sınıflandırması için hızlı artımlı aşırı öğrenme makinesi algoritması adı verilen bir yaklaşım sunmuşlardır. Yaklaşım, bir topluluk AÖM metodolojisini kullanmaktadır ve gizli katman nöronlarının sayısını uyarlamalı olarak belirlemektedir. Her topluluk sınıflandırıcısı farklı aktivasyon fonksiyonları kullanmaktadır. IDS-ELM, içerik farklılaşması probleminin üstesinden gelebilmek için Hoeffding Sınır Teoremi' ni kullanmaktadır. Farklılaşma gerçekleştiğinde, IDS-ELM zayıf sınıflandırıcıyı ortadan kaldırarak sınıflandırıcıyı yeni örneklerle yeniden eğitmektedir.

Başka bir çalışmada Xu ve vd. [111] içerik farklılaşması problemini çözmek amaçlı DELM adlı akan veri sınıflandırması için dinamik bir yöntem sunmuşlardır. IDS-ELM' den farklı olarak DELM, sınıflandırıcının performansını iyileştirmek için çift gizli katman yapısı kullanmaktadır. İçerik farklılaşması tespit edildiğinde, konseptteki değişikliğe uyum sağlamak için TKİBA modeline daha fazla gizli katman nöronu eklenmektedir. DELM ani içerik farklılaşması meydana geldiğinde tatmin edici bir performans sergileyememektedir [112].

Ding vd. [113] sınıf dengesizliği öğrenimi için Çekirdekli Ağırlıklı Çevrim içi Sıralı-ELM (WOS-ELMK) adlı bir akan veri sınıflandırma yaklaşımı önermişlerdir. WOS-ELMK, rastgele haritalama kullanmak yerine, çevrim içi sınıf dengesizliği öğrenimi için çekirdek haritalama kullanmaktadır. Ancak bu çalışma içerik farklılaşması problemini dikkate almamaktadır.

Akan verinin içerik farklılaşması problemini işlemek için bir Meta-bilişsel Tekrarlayan Özyinelemeli Çekirdek Çevrim içi Sıralı Aşırı Öğrenme Makinesi, Farklılaşma Algılama Mekanizması ile (meta-RRKOS-ELM-DDM) önerilmiştir [114]. Sunulan yaklaşım öğrenme süresini azaltmaktadır ve parametre bağımlılığını çözmektedir. Bu yaklaşımda, en iyi çekirdek türünün seçimi tartışılması gereken bir konudur.

Yu vd. unutma faktörünü düzenlemek için bir içerik farklılaşması haritası kullanan uyarlanabilir bir çevrim içi aşırı öğrenme makinesi sunmuşlardır [115]. İçerik farklılaşması

haritası, modelin içerik farklılaşmasına uyum sağlanması için kullanılmaktadır. İçerik farklılaşması haritası, sürekli olarak öznitelik uzayında iki dağılım arasındaki mesafenin nicel bir ölçüsü tasarlanarak oluşturulmaktadır. Yaklaşım Gauss dağılımına sahip olmayan akan veri için uygun değildir.

Xiao vd. [116], unutmama mekanizmalı FOS-ELM yaklaşımını çoklu gizli katmanlı aşırı öğrenme makinesini çevrim içi bir yaklaşım olarak geliştirerek FOS-MELM algoritmasını geliştirmişlerdir. FOS-MELM, eğitim çıktısını gerçek çıktıya daha yakın hale getirmeyi amaçlamaktadır. Yaklaşım kaçınılmaz gürültünün etkisini ortadan kaldırabilmektedir ve bu performansı arttırmaktadır.

Yukarıda tartışılan algoritmalar, AÖM' nin rastgele ilklendirme stratejisine bağlıdır. Sınıflandırıcıların başlangıç ağırlıkları ve biasleri rastgele belirlenmektedir. Bu onların istikrarsızlık ve kötü koşullu matris problemlerinden mustarip olmasına neden olmaktadır.

1.8. Video Verilerinde Anomali Tespiti

Teknolojinin ilerlemesi birlikte akan veri üreten birçok uygulama alanı ortaya çıkmaktadır. Bu alanlardan bir tanesi uygulamalarda gerçekleşen anomalilerin tespit edilmesidir.

Anomali tespiti verilerin çoğundan önemli ölçüde farklılık göstererek şüphe uyandıran nadir olayların, maddelerin veya gözlemlerin tanımlanması ve tespit edilmesidir [117]. Anormallik tespiti ifadesi içeriğe bağlıdır ve anlamı alandan alana değişmektedir. Örneğin, bir ağa izinsiz müdahale bir anomalidir. Parkın içerisindeki bir araba da bir anomali durumu oluşturabilmektedir. Anomali tespiti güvenlik, izleme, gözetim gibi birçok sistemde önemli bir bileşen olarak yer almaktadır ve izinsiz giriş tespiti, hata tespiti, dolandırıcılık tespiti ve aykırı değer tespiti olarak da adlandırılır [118]. Bu durum anomali tespiti ve uygulamalarını son zamanda ilgi çeken konularından birisi haline getirmiştir. Literatürde son yıllarda popüler olarak ilgilenilen konuların başında gözetleme videolarındaki anormal olayların tespit edilmesidir ve tez çalışmasında bu konuya odaklanılmıştır.

1.8.1. Gözetleme Videolarında Anomali Tespiti Yaklaşımları

Günümüzde, artan güvenlik endişeleri nedeniyle halka açık ve kapalı alanlarda video gözetim sistemleri kullanımına yavaş yavaş nüfuz edilmektedir. Bina güvenliği, trafik

yönetimi, belediye idaresi gibi kamusal ve şahsi alanlarda gözetleme sistemleri yaygın olarak kullanılmaktadır [119]. Video gözetim sistemleri ile trafik kazaları, doğal afetler, suçlar ve yasadışı işler gibi anormal olayları veya davranışları tespit ederek kamu güvenliğinin artırılması amaçlamaktadır. Bu videolardaki bu tür anormal olaylar, olağan video örüntüsüne kıyasla nadiren görülen video anomalisi olarak tanımlanır [120].

Güvenlik kameralarının yaygın kullanımı ile muazzam miktarda veri üretilmektedir. Artan güvenlik kameraları doğal olarak manuel analiz için son derece sıkıcı ve zaman alıcı olan çok sayıda gözetim video verisine yol açmaktadır. Emek ve zaman kaybını hafifletmek adına otomatik video anomali tespiti için akıllı makine öğrenmesi algoritmaları geliştirmek acil bir ihtiyaçtır. Bu nedenle, araştırmacılar gözetim videolarındaki anomali tespiti için örüntü tanıma tabanlı çalışmalara yoğunlaşmıştır [120, 121, 122, 124, 125].

Literatürde gözetim videolarındaki anormalliği algılama çalışmaları iki kategoriye ayrılmaktadır: el yapımı özelliklere dayalı yöntemler [127-134] ve derin öğrenmeye dayalı yöntemler [122, 123, 124, 135-139]. Günümüzde derin öğrenme tabanlı örüntü tanıma yaklaşımları, gözetim videolarının anormallik tespiti için büyük ilgi görmektedir. Bu yaklaşımlar, normal ve anormal etkinlikleri modelleyerek anormallik algılama görevini başarıyla gerçekleştirir. Bununla birlikte, derin öğrenmeye dayalı anormallik tespit yaklaşımları birçok sorundan mustarıptır. Birçok eğitim örneği için uzun eğitim süresi gerektirirler ve çok sayıda hesaplama yapmalarına neden olan birçok katmana sahiptirler. Eğitim setine bağımlılıkları bulunmaktadır. Yapıları dinamik olaylar için uygun değildir ve bu nedenle derin öğrenmeye dayalı yaklaşımlar, yalnızca önceden depolanmış toplu verileri işlemek için geliştirilmiştir.

Video gözetim sistemleri, sınırlı kaynak ve depolama, artan miktarda büyük ölçekli veri üretimi, veri dağılımdaki değişiklikler gibi zorluklar nedeniyle gerçek zamanlı olarak işlenmesi gereken sonsuz potansiyel veriler üretir. Gözetleme kameraları her zaman bölgelerini izler ve her an sürekli olarak yeni veriler üretmektedir. Her veri sürekli bir akış olarak gelmektedir. Bu nedenle depolama, video gözetim sistemlerinin sorunlarından biridir. Ayrıca güvenlik kameraları genellikle alışveriş merkezleri, meydanlar, trafik gibi dinamik alanları izlemektedir. İçerik genellikle değişir ve olaylar önceki olayları anlamsız hale getirerek gelişmektedir. Literatürde sadece birkaç araştırma bu zorluğu ele almıştır [140]. Video anormallik algılama yaklaşımları, içerikte herhangi bir değişiklik olup olmadığını her zaman araştırmalı ve tespit edilen değişikliklere dinamik olarak ayak uydurmalıdır. Bu zorluklar, akan veri modelinin özellikleridir. Algoritmalar, akan verileri işlemek için veri

örneklerini sıralı bir şekilde ele alarak aşamalı olarak öğrenmelidir. İçerik farklılaşması adı verilen veri dağılımındaki değişiklikleri tespit etmeli ve değişikliklere uyum sağlamalıdır [2, 8]. Bu nedenle, derin öğrenmeye dayalı klasik örüntü tanıma yaklaşımları, akan veri gereksinimlerini verimli bir şekilde karşılayamaz.

Literatürde gözetim videoların için akan veri tabanlı video anormalliği algılama yaklaşımı yer almamaktadır. Bu nedenle, derin öğrenmeye dayalı yaklaşımların sınırlamalarını vurgulamak için derin öğrenmeye ve artımlı öğrenmeye dayalı video anormallik algılama yaklaşımları incelenmiştir.

Medel vd. [141], video anormallik tespiti için Konvolüsyonel Uzun Kısa Süreli Bellek Otomatik Kodlayıcı ağlarını (Convolutional Long Short Term Memory-Autoencoder, ConvLSTM-AE) önermişlerdir. Konvolüsyonel filtreler, yaklaşımdaki sıralı verileri işlemek için LSTM' de kullanılmaktadır. Yaklaşımda anormal olay tespiti için bir düzenlilik puanına başvurulmuştur. Zhong vd. [142], video anormallik tespiti için bir Graf Konvolüsyonel Ağ (Graph Convolutional Network, GCN) geliştirmişlerdir. Bu ağ, GCN kullanarak gürültülü etiketleri düzeltmek için temizleme ve sınıflandırma aşamalarının döngüsel işlemlerini gerçekleştirir. İki yaklaşım önceden öğrenilen olayları doğru bir şekilde modelleyebilse de öğrenilmemiş yeni olaylara uyum sağlama yeteneğine sahip değildir.

Hasan vd. [143], uzamsal-zamansal yerel özellikleri kullanarak normal davranışları öğrenmek için otomatik kodlayıcı tabanlı bir derin öğrenme yaklaşımı sunmuşlardır. Yaklaşım video dizilerinin zamansal düzenliliğini öğrenmek için bir Konvolüsyonel Sinir Ağı (Convolutional Neural Network, CNN) kullanmaktadır. Anormal davranışları tespit etmek için zamansal düzenliliğin yeniden yapılanma hatasına başvurulmuştur. Ancak, CNN zamansal düzenlilik göz önünde bulundurularak önerilen bir algoritma değildir ve öğrenilen derin özellikler tüm sorunu modellemek için yeterli olmamaktadır.

Xu vd. [144], gözetim videoları için Görünüş ve Hareket Derin Ağı'na (Appearance and Motion DeepNet, AMDN) dayalı denetimsiz bir anormallik algılama yaklaşımı sunmuşlardır. Bu çalışmada, normal olayların ayırt edici görünümünü ve hareket temsillerini öğrenmek için ayrı ayrı yığılmış gürültü azaltan otokodlayıcılar kullanılmıştır. Ancak bu yaklaşım, gerçek zamanlı işleme için test süresinde yüksek bir hesaplama ek yüküne sahiptir ve bu en önemli dezavantajıdır.

Fang vd. [135], gözetim videolarındaki kalabalık sahnelerde anormal olay tespiti için Temel Bileşen Analizi Ağı' na (Principal Component Analysis Network, PCANet) dayalı derin bir mimari sunmuşlardır. Yaklaşımda her video çerçevesinin uzamsal ve zamansal

özniteliklerini ayrı ayrı çıkarılmaktadır. Uzamsal-zamansal özelliklere PCANet tabanlı derin ağ uygulanarak üst düzey öznitelikler elde edilir ve ardından anormal olayı belirlemek için Destek Vektör Makineleri (DVM) kullanılmaktadır. Feng vd. [139], PCANet ve Derin Gauss Karışım Modeline (Gauss Mixture Model, GMM) dayalı bir kalabalık anormalliği algılama yaklaşımı önermişlerdir. Yaklaşım, görünüm ve hareket ipuçlarını temsil etmek için 3-B gradyanları çıkarmak için PCANet'i işleme katmıştır. Bu yaklaşımda GMM kullanılarak yalnızca normal olaylar modellenmiştir. Anormal olaylar, test örneğinin olasılığı ve önceden tanımlanmış eşik kullanılarak belirlenmektedir. Li vd. [136], video anormallik tespiti ve lokalizasyonu için Çekişmeli Otokodlayıcı (Adversarial Autoencoder, AA) tabanlı bir derin öğrenme yöntemi sunmuşlardır. Bu yaklaşımda görünüm ve hareket anormalliklerini tespit etmek için iki akışlı bir çerçeve önerilmiştir. İlk olarak, üç boyutlu gradyan haritaları ve optik akış uygulanmaktadır. Daha sonra, belirli bir önceki dağılımı kullanarak yalnızca normal olayların gizli uzay temsilini eğitmek için Çok Değişkenli Gauss Tam Konvolüsyonel Çekişmeli Otokodlayıcı (Multivariate Gaussian Fully Convolution Adversarial Autoencoder, MGFC-AAE) uygulanmaktadır. Gizli uzay temsillerini çıkarmak için, bu çalışmada ağı kodlayıcısı için CNN kullanılmıştır. Ardından, anomali puanını hesaplamak için enerji bazlı bir tekniğe başvurulmuştur. Zhou vd. [145], AnomalyNet adlı gözetim videoları için derin bir anormal olay ağı önermişlerdir. Bu ağ bir öznitelik çıkarma ve optimizasyon açısından oluşmaktadır. Öznitelik çıkarma aşamasında görüntü sınıflandırması için, ağı bir anomali algılama veri setine ince ayar uygulanmasıyla elde edilen önceden eğitilmiş CNN modelleri kullanılmaktadır. Ayrıca bu yaklaşımda LSTM tabanlı tekrarlı sinir ağı, seyrek gösterimi öğrenmek ve anormal olayı belirlemek için tanıtılmıştır. Duman vd. [146], Konvolüsyonel Otokodlayıcı (Convolutional Autoencoder, CA) ve ConvLSTM kullanarak gözetim videolarındaki anormallikleri tespit etmek için bir yaklaşım sunmuşlardır. Başlangıçta, yoğun optik akışa dayalı öznitelik çıkarma işlemi, ön plandaki nesnelerin hız ve yön bilgilerini elde etmek için uygulanmaktadır. Daha sonra, normal olayların uzaysal ve zamansal kalıpları CA ve ConvLSTM ile öğrenilmektedir. Murugan vd. [147] Bölge Tabanlı Ölçeklenebilir Konvolüsyonel Sinir Ağına (Region-based Scalable Convolutional Neural Network, RS-CNN) dayalı yaya yürüyüş yolları için bir anormallik algılama yaklaşımı geliştirmişlerdir. Bu çalışmada, daha kısa sürede farklı boyutlarda daha hızlı anomali tespiti için bölge bazlı bir yöntem kullanılmıştır. RS-CNN tabanlı anormallik algılama modeli, yaya yürüyüş yollarındaki anormallik bölgelerini belirleme yeteneğine sahiptir. Li vd. [148] anormal olay tespiti için bir uzamsal-zamansal

U-Net yaklaşımı önermişlerdir. Yaklaşım, çerçeve tahmini için normal olayları, tahmin hatasını anormal olay tespiti için kullanmaktadır. Bu yaklaşımda, uzamsal bilgi için U-Net' e ve zamansal bilgi için ise ConvLSTM' e başvurulmuştur. MGFC-AAE' nin aksine, Fan vd. [149], yalnızca normal olayları kullanarak video anormallik tespiti ve lokalizasyonu için varyasyonel otokodlayıcıya sahip Gauss karışım modeli (Gaussian Mixture Model with Variational Autoencoder, GMFC-VAE) geliştirmişleridir. Bu çalışmada, görünüm ve hareket anormalliklerini birleştirmek için iki akışlı bir ağ çerçevesi tasarlanmıştır. İlk olarak hem RGB görüntülerinin hem de dinamik akışların parçaları, GMFC-VAE' nin girdileri olarak yoğun bir şekilde örneklenmektedir. Daha sonra GMFC-VAE ile normal olayların gizli bir temsili öğrenilmektedir. Anormallik örnek enerji bazlı bir yöntem kullanılmasıyla modelle eşleşemezse belirlenmektedir. Her iki yaklaşım da yalnızca modellenmiş normal olaylara bağlıdır. Ancak, tüm normal olay türlerini modellemek oldukça zordur. Dong vd. [150] video anormallik tespiti için çift ayrımcı tabanlı üretici çekişmeli ağları (discriminator-based Generative Adversarial Networks, GAN) sunmuştur. Yaklaşım, normal olayları tahmin etmek için bir üreteç ve eğitim aşamasında bunun gerçek mi yoksa sahte mi olduğunu belirlemek için ayırtaç kullanmaktadır. Nawaratne vd. [140], gerçek zamanlı video anomali tespiti için normal olayları modellemek üzere artımlı bir uzay-zamansal öğrenici (Incremental Spatio-Temporal Learner, ISTL) tanıtmışlardır. ISTL, uzamsal-zamansal öğrenme için CNN, artımlı anormallik tespiti için ise bulanık toplamaya dayalı aktif öğrenme kullanmaktadır. Fakat yaklaşım, bir uzmanın aktif öğrenme sürecinden kaynaklanan anormallikleri doğrulamasını gerektirmektedir. Bu yaklaşımlar, yalnızca normal olayların modellenmesine bağlıdır. Normal olayların gelişen doğası nedeniyle, yalnızca normal olayların modellenmesi, yaklaşımı elverişsiz hale getirmektedir. Çünkü tüm normal olay türlerini modellemek zor bir işlemdir.

Sultani vd. [120], gözetim videolarındaki anormal video segmenti için yüksek anomali skorunu tahmin eden derin çoklu örnek öğrenme (ÇÖÖ) tabanlı bir anormallik sıralama modeli önermişlerdir. Bu yaklaşımda eğitim videolarını video düzeyinde zayıf bir şekilde etiketlemek için ÇÖÖ yaklaşımı benimsenmiştir. Her segmentin üç boyutlu konvolüsyonel özniteliklerini (C3D) çıkarmak için segmentler içindeki çerçevelerin ortalamasını alınmaktadır. Anormallik puanları, tam bağlı derin bir ağ kullanılarak hesaplanmaktadır. Bu çalışmada eğitim sırasında normal ve anormal videolar kullanılmıştır ve bu videolar çanta şeklinde temsil edilmiştir. Video segmentleri ise ÇÖÖ' de yer alan bir örnek olarak kabul edilmektedir. Majhi vd. [151], normal ve anormal videoları kullanarak video anormallik

tespiti için iki akışlı bir CNN modeli geliştirmişlerdir. Yaklaşım, önceden eğitilmiş iki ayrı CNN' den çıkarılan uzaysal ve zamansal özniteliklerin füzyonuna dayanmaktadır. Hao vd. [152], gözetim videolarında anormallik tespiti için iki akışlı bir ConvNet modeli sunmuşlardır. Yaklaşım, video klipleri zayıf bir şekilde etiketlemek için bir ÇÖÖ sıralama yöntemi kullanmaktadır. Bu yaklaşımda, RGB ve akış ağları anomali skorları oluşturmak için kullanılmaktadır ve daha sonra olayların nihai kararı iki ağın sonuçlarının füzyonu ile verilmektedir. Yaklaşımın temeli [120] 'teki çalışmaya dayanmaktadır. Singh vd. [123] bir topluluk CNN tabanlı kalabalık anomali tespit yaklaşımı önermişlerdir. Bu yaklaşım, önceden eğitilmiş CNN' leri (AlexNet, GoogLeNet, VGGNet) kullanarak ConvNets' i sıfırdan eğitime ihtiyacını ortadan kaldırmaktadır. Yaklaşımda hem normal hem de anormal olaylar modellenmiştir. Olayların sınıflandırılmasında toplulukların toplanması kavramı kullanılmıştır. Önceden eğitilmiş ağların kullanımı eğitim süresini kısaltsa da ince ayar süreci de zaman tüketmektedir.

Chu vd. [153], C3D kullanarak uzamsal-zamansal öznitelikleri hesaplamak için yinelemeli bir metodoloji önermişlerdir. Burada girişlerin el yapımı öznitelikleri derin ağı yönlendirmek için kullanılmaktadır. Öğrenilen öznitelikler, bütün video anomali tespit problemini modellemek için yeterli değildir.

Tang vd. [154], avantajlarından yararlanmak için tahmin ve yeniden yapılandırma yöntemlerini birleştiren bir video anormallik algılama yaklaşımı önermişlerdir. Bu yaklaşımda gelecekteki çerçeve tahmini ve yeniden yapılandırma için uçtan uca bir ağı (U-Net) kullanmaktadır. Chen vd. [155], bir video anormallik algılama çerçevesi için U-Net tabanlı çift yönlü bir tahmin ağı sunmuşlardır. Bu çalışmada model sırasıyla aynı hedef çerçeve için ileri ve geri tahmin yapmaktadır. Fakat, yaklaşım için gereken ayarlar tüm veri setlerine uygun olmayabilmektedir ve yeniden ayarlanmaya ihtiyaç duyulmaktadır. Ayrıca, U-Net zamansal diziler için bir dezavantajlı bir ağı modelidir.

Bu yaklaşımlar, normal ve anormal etkinlikleri modelleyerek anormallik algılama görevi gerçekleştirmektedir. Derin öğrenmeye dayalı yaklaşımlar mükemmel bir tanıma performansı elde etse de sıfırdan eğitim, hesaplama açısından yoğun bir görevdir [136]. Bunun nedeni, derin ağların Konvolüsyon, ReLU, havuzlama, SoftMax gibi birçok katmana sahip olmasıdır. Bu nedenle, eğitim veya ince ayar için çok sayıda hesaplama ve çok sayıda etiketli eğitim örneği ile uzun eğitim süresi gerektirirler. [136], sırasıyla 8, 22 ve 16 katmandan oluşan önceden eğitilmiş AlexNet, GoogleNet ve VGGNet kullanır. [139], video anormallik tespiti için toplam 30 katmanlı PCANet kullanan bir yaklaşımdır. Ayrıca,

gözetleme videoları için normal ve anormal olayların çeşitliliği nedeniyle tüm normal ve anormal olayları modellemek mümkün değildir ve farklı olaylar için büyük eğitim örneklerine ihtiyaç duymaktadır. Derin öğrenmeye dayalı yaklaşımlar, eğitim setine bağımlıdır. Bu yaklaşımlar, eğitim seti dahilinde olmayan anormal veya normal olayları tespit etmek için yeniden eğitim gerektirmektedir. Derin öğrenmeye dayalı yaklaşımlarda yeniden eğitim, bir gözetim videosundaki her yeni olay için zorlu ve zaman alıcı bir görevdir. Ayrıca derin öğrenme temelli yaklaşımlar dinamik bir yapıya sahip değildir. Normal olayların gelişen doğasına dinamik olarak uyum sağlayamamaktadır.

1.8.2. Aktif Öğrenme

Danışmanlı öğrenme, bir örneğin gözlemlenen değişkenleri ile etiket arasındaki ilişkiyi modeller. Bir öngörücü oluşturmak için eğitim verilerinin gerçek etiketlerinin bilinmesi gerekmektedir. Genellikle gerçek dünya problemlerinde etiketlenmemiş veriler bol miktarda bulunmaktadır ancak etiketleme çok maliyetli bir işlemdir. Gerekli uzman bilgisi nedeniyle etiketlerin elde edilmesi maliyetli olabilmektedir [156].

Aktif öğrenme, tüm gerçek etiketleri istemek yerine seçici olarak nasıl etiketleneceğini inceler. Sınıflandırma bağlamında aktif öğrenme, seçilen bazı veri örneklerinin bir uzman tarafından bazı seçim kriterlerine göre etiketlenmesine izin vermektedir. Aktif öğrenmenin amacı, mümkün olduğunca az örneği etiketleyerek sınıflandırma performansını en üst düzeye çıkarmaktır. Aktif öğrenme, etiketsiz örnekler havuzundan manuel olarak etiketlemeye kadar her yinelemede mevcut sınıflandırma modelini iyileştirmek için en bilgilendirici olan bir örneği veya bir grup örneği çıkaran yinelemeli bir prosedür yürütür. Daha sonra sınıflandırma modeli, genişletilmiş eğitim seti ile güncellenebilir. Süreç, önceden tasarlanmış bir durdurma kriterini [157] karşılayana kadar yinelemeli olarak yürütülür [158].

Aktif öğrenme havuz tabanlı ve çevrim içi olarak iki kategoriye ayrılmaktadır. Havuz tabanlıda, hangi örneklerin etiketleneceğine ilişkin karar tüm geçmiş verilerden alınmaktadır. Çevrim içi aktif öğrenme sabit bir eşik değere göre işlem yapmaktadır. Eşiğin aşılması durumunda gerçek etiketin istenmesi gerekmektedir.

Aktif öğrenmeyi benimseyen bir sınıflandırma modeli, yalnızca etiketleme için en önemli örnekleri seçmek ve performansını olabildiğince hızlı bir şekilde daha da artırmak için insan uzmanlarla yinelemeli olarak etkileşime girebilir. Bu nedenle, aktif öğrenmenin

faydaları hem insan uzmanların yükünü hem de eğitim vakalarının karmaşıklığını azaltmak, ancak tüm örnekleri etiketleyerek modele üstün veya karşılaştırılabilir performans sağlayan bir sınıflandırma modeli elde etmektir.

Akan veriler için aktif öğrenme yaklaşımlarının göz önüne alması gereken birkaç durum söz konusudur. Bunlar:

- Bir veri kaynağına sürekli erişime sahip olunmalı.
- Her gelen veri için hızlı ve gerçek zamanlı işlem yapılabilmesi ve gerektiğinde bir etiket talep edip etmemeye karar verebilmeli.
- Model periyodik olarak güncellenmeli ve yeni örneklerle uygulanmalı.

Bu durumların ışığında literatürde akan veriler için geliştirilen yaklaşımlar mevcuttur.

Zhu vd. [159] akan verilerden alınan bir toplu veri grubu içindeki örnekleri etiketlemek için belirsizlik örneklemesini kullanmışlardır.

Zhu vd. [160], değişken akan veriler üzerindeki adaptasyonun ilerlemesini kontrol etmek için topluluk tabanlı aktif öğrenme önermişlerdir. Yaklaşımda minimum varyanslı örnek seçim yöntemlerinin temeli olarak topluluk hatasının bias-varyans ayrıştırmasını kullanılmıştır.

Z˘liobaite vd. [156], belirsizliğe, etiketleme çabalarının zaman içinde dinamik tahsisine ve arama alanının rasgeleleştirilmesine dayanan akan veri aktif öğrenme stratejisi önermişlerdir. Hangi örneklerin etiketleme için en iyi olduğuna karar, tek bir evrimleşen sınıflandırıcı ile verilmektedir.

Kurlej vd. [161], içerik farklılaşmasına sahip akan verilere uygulanan minimum mesafe sınıflandırıcı için aktif öğrenme yaklaşımını önermişlerdir. Burada etiketleme kararı, verilen bir örnek ile karar sınırı arasındaki mesafeye bağlıdır. Yazarlar daha sonra böyle bir yaklaşımda seçilmiş özniteliklerini analiz eden çalışmalar yapmışlardır [162, 163]. Nguyen vd. [164], aynı anda kümeleme ve sınıflandırma gerçekleştiren artımlı aktif öğrenmeye dayalı bir akan veri algoritması geliştirmiştir. Mohamad vd. [165], belirsizlik ve yoğunluğa dayalı sorgulama kriterlerini birleştiren benzer bir akan veri sınıflandırıcısı geliştirmişlerdir. Korycki vd. [166], akan verileri sınıflandırmak ve bunu kendi kendini etiketleme yaklaşımıyla birleştirmek için aktif öğrenme stratejisi uygulamışlardır.

Aktif öğrenme, sınıflandırma modelinin kalitesini eşzamanlı olarak iyileştirebildiğinden ve eğitim örneklerinin karmaşıklığını azaltabildiğinden, dengesizlikte aktif öğrenmenin verimliliğini ve performansını artırmak için Aktif Çevrim içi Ağırlıklı

Aşırı Öğrenme Makinesi (Active Online Weighted- Extreme Learning Machine, AOW-ELM) adlı akan veriler için algoritma önerilmiştir [167].

Abdallah vd. [168] verinin bir akış olarak kabul edildiği ve gerektiğinde aktif öğrenmedeki sorgu etkinliği etiketlerine uygulandığı insan aktivite tanınması için çevrim içi öğrenme yaklaşımı önermişlerdir. Önerilen yaklaşım etiketli bir eğitim seti gerektirmektedir. Çevrim dışı eğitim aşaması ve çevrim içi tanıma ve uyarlama aşaması olmak üzere iki aşamada oluşmaktadır. Çevrim dışı aşamada, model, farklı etkinlikleri temsil eden bir dizi açıklamalı duyuşal veriden oluşturulur. Çevrim içi aşamada, etiketlenmemiş akan verilerin tanınması gerçekleştirilmektedir. Bu yaklaşımda, faaliyet sayısının sabit olduğu varsayılır ve başlangıç aşamasına geçilmesi gerekmektedir.

1.9. Akan Veri ve Gözetleme Videosu Anomali Tespiti Veri Setleri

Bu bölümde tez kapsamında kullanılan veri setlerinin bir özeti verilmektedir. Bu nedenle akan veri setleri ve gözetleme videosundaki anomali tespiti için kullanılan veri setlerden bahsedilecektir.

1.9.1. Akan Veri Setleri

Literatürde akan veri setleri sentetik ve gerçek olmak üzere ikiye ayrılmaktadır. Gerçek veri setleri akan veri uygulamalarından elde edilen veri setleridir. Sentetik veri setleri ise MOA platformu üzerinden akan veri yapısına uygun bir şekilde elde edilmiş veri setleridir.

1.9.1.1. Gerçek Veri Setleri

Akan veriler için kullanılan uygulamalardan elde edilen gerçek veri setleri UCI Makine Öğrenimi Havuzu [169]'dan ulaşılabilen veri setleridir.

Forest Cover Type, (ForestCovType) UCI Makine Öğrenim Havuzu'da mevcut olan gerçek veri setidir [169]. Forest Cover Type veri seti, 30x30 m²'lik hücredeki 7 orman örtüsü tipinin 581.012 gözlemini içermektedir ve her gözlem 54 jeolojik ve coğrafi değişken içermektedir. 30x30 m² hücrenin ortamını tanımlamak için 10 nicel değişken, 40 ikili toprak

tipi değişkeni ve 4 ikili vahşi alan değişkeni kullanılmıştır. Tanımlanamayan türde içerik farklılaşmasına sahip bir veri setidir.

ElecNormNews, M. Harries tarafından açıklanan ve Gama tarafından analiz edilen gerçek veri setidir [169]. Veri seti, Elektrik veri setinin normalleştirilmiş bir sürümüdür. ElecNormNews veri seti Australian New South Wales Electricity Market'inden elde edilmiştir. Bu veri seti piyasadaki arz ve talep ile elektrik fiyatındaki değişim arasındaki ilişkiyi yansıtmaktadır. 45.312 örnek ve 8 öznitelikten oluşur. Her örneğin son niteliği sınıf bilgisini vermektedir ve veri seti 2 sınıf bilgisi içermektedir. ElecNormNews bilinmeyen bir türde içerik farklılaşması içeren bir veri setidir.

KddCup99 [169] ağ girişinin tespiti için oluşturulmuştur bir veri setidir. Veri seti, MIT Lincoln Laboratuvarındaki LAN ağ trafiğinden elde edilen TCP bağlantı kayıtlarını içermektedir. Her kayıt, 41 öznitelikten ve 23 sınıf bilgisinden oluşur. Çalışmada KddCup99 veri kümesinin %10'luk (494021 örnek) alt kümesi kullanılmıştır. Veri setinde kademeli ve ani konsept kaymaları yer almaktadır. Bu veri seti kademeli içerik farklılaşması içermektedir.

PenDigits bir sayı veri tabanıdır ve 44 kişiden 250 örnek toplanarak elde edilmiştir. UCI Makine Öğrenim Deposundan [169] ulaşılabilen PenDigits veri setinde her örnek için 16 öznitelik ve 16 sınıf vardır.

Poker-Hand veri seti, 52'lik standart desteden alınan beş karttan oluşan bir poker elinden oluşmaktadır. 1 milyon örnek, 11 öznitelik ve 2 sınıf bilgisi içerir. Son öznitelik, sınıf bilgilerini açıklar.

Optic-Digits optik karakter tanıma veri setidir. 5620 örnek, 64 öznitelik ve 10 sınıf içermektedir.

Shuttle veri seti tümü sayısal olmak üzere 9 öznitelik içeren 58.000 örnekten oluşmaktadır. Veri setindeki verilerin yaklaşık %80'i 1. sınıfa aittir. Bu veri seti içerik farklılaşması içermemektedir.

EEG Eye veri seti, Stuttgart Almanya'daki Baden-Wuerttemberg Kooperatif Devlet Üniversitesi'nden Rösler ve Suendermann tarafından üretilen bir veri setidir. Tüm veriler, Emotiv EEG neuroheadset ile tek bir sürekli EEG ölçümünden elde edilmiştir. Veri setinde 14980 örnek ve 14 öznitelik bulunmaktadır. Ölçüm süresi 117 saniyedir. Göz durumu EEG ölçümü sırasında bir kamera aracılığıyla tespit edilmiştir ve video çerçeveleri analiz edildikten sonra dosyaya manuel olarak eklenmiştir. Bu veri setinde bilinmeyen bir türde içerik farklılaşması yer almaktadır.

1.9.1.2. Sentetik Veri Setleri

Sentetik veri setleri akan veriler için kullanılan MOA platformu ile akan veri metodolojisine uygun bir şekilde üretilen veri setleridir.

LED veri seti 7 LED dijital tüp ekranının sonucunda elde edilmiştir. Işığın açık olup olmamasına bağlı olarak onluk taban için karşılık gelen ve tüm öznitelik değerleri 0 veya 1 olan bir setidir. Veri kümesi 50.000 örnek ve 24 öznitelik içermektedir; son 17 öznitelik gereksizdir. LED veri seti hem ani hem de kademeli içerik farklılaşması içermektedir.

Hyperplane veri seti MOA' nın Hyperplane üretici kademeli içerik farklılaşması içerecek şekilde üretilmiştir. D-boyutlu uzayda $\sum_{i=1}^d w_i x_i = w_0$, $x_i \in [-10, 10]$ ve $w_0 = \frac{1}{2} \sum_{i=1}^d w_i$ olarak ifade edilmenin sonucunda elde edilmiştir. Eğer $\sum_{i=1}^d w_i x_i \geq w_0$ ise nokta pozitif olarak işaretlenmiştir; eğer $\sum_{i=1}^d w_i x_i \leq w_0$ ise nokta negatif olarak işaretlenmiştir. Hyperplane veri seti 50000 örnek, 40 öznitelik ve 2 sınıftan oluşmaktadır.

Waveform veri seti 3 farklı dalgayı ifade eden ve 40 öznitelikten oluşmaktadır vardır. Veri kümesi, standart normal dağılıma uyan bir miktar gürültü ve ani ve kademeli içerik farklılaşması içermektedir. İçerisinde 50000 örnek yer almaktadır.

Stagger veri seti 3 öznitelik ve 50,000 örnek içeren bir veri setidir. Her öznitelik 3 karakteristik değere denk gelmektedir. İlki yeşil, mavi ve kırmızı olan renk bilgisi; ikincisi üçgen, daire ve dikdörtgen olan şekil bilgisi ve sonuncusu küçük, orta ve büyük olan boyut bilgisidir. Bu veri setinde de içerik farklılaşması yer almamaktadır.

RandomTree veri seti bir karar ağacı oluşturulması ile elde edilmiş bir veri setidir. Yeni örneğin etiketi, ağacı yukarıdan aşağıya geçerek belirlenebilmektedir. Veri seti 6 sınıf ve 30 öznitelikten oluşmaktadır. Bu veri setinde kademeli içerik farklılaşması yer almaktadır.

Agrawal veri seti, MOA platformundaki Agrawal üretici ile elde edilmiştir. Veri seti belirli bir miktarda kredi almaya istekli kişilerin bilgilerini depolamaktadır. Bu verilerden A veya B grubuna ait olarak 2 sınıf bulunmaktadır. Veri setindeki öznitelikler maaş, komisyon, yaş, eğitim seviyesi, arabalarının markası, posta kodu, evin değeri, evin sahip olduğu yıl sayısı ve kredinin toplam tutarıdır. Toplam olarak 50000 örnek yer almaktadır. Bununla birlikte Agrawal veri seti bilinmeyen bir türde içerik farklılaşmasına sahiptir.

Son olarak DS1 veri seti 26733 örnek, 10 öznitelik ve 2 sınıftan oluşan bir sentetik veri setidir ve MOA ile üretilmiştir. Bu veri setine ait içerik farklılaşması bilgisi yer almamaktadır.

Tablo 1. Gerçek ve sentetik veri setleri

Veri Seti	Örnek Sayısı	Öznitelik Sayısı	Sınıf Sayısı	Karakteristik
ForestCovType	100000	54	7	Gerçek
ElecNormNews	45312	8	2	Gerçek
PenDigits	7494	16	10	Gerçek
KddCup99	494021	41	23	Gerçek
Poker-Hand	1000000	11	2	Gerçek
Optic-Digits	5460	64	10	Gerçek
Shuttle	58000	8	5	Gerçek
EEG Eye	14980	14	2	Gerçek
Hyperplane	50000	40	2	Sentetik
LED	50000	24	10	Sentetik
Waveform	50000	40	3	Sentetik
Stagger	50000	3	2	Sentetik
RandomTree	50000	30	6	Sentetik
Agrawal	50000	9	2	Sentetik
DS1	26733	10	2	Sentetik

1.9.2. Anomali Tespiti için Gözetleme Videosu Veri Setleri

UCF-Crimes [120], büyük bir gözetim video veri setidir. 14 farklı gerçek dünya olayı içeren 290 test videosu vardır. Bunlardan 140' i anormal içeren videolardır. Geri kalan 150 video ise tamamen normal olay içermektedir. Olaylar kötüye kullanım, tutuklama, kundakçılık, saldırı, kaza, ev soygunu, kavga, soygun, ateş etme, araklama, hırsızlık, vandallık ve normaldir. Normal olay videoları herhangi bir anormallik içermez. Ancak anormal olay videoları normal davranışlar içerebilir ve bazı videolarda anormal olay sadece bir süre görülebilmektedir.

USCD yaya veri seti [170], Ped1 ve Ped2 olarak adlandırılan iki farklı yaya yürüyüş yolundan oluşur. Anormal olaylar, bu veri setindeki yürüyüş yollarında yaya olmayan olaylara ait durumlardır. Bunlar bisikletliler, küçük arabalar, patenciler ve tekerlekli sandalyedeki insanlar ve çimlere basan insanlar olarak söylenebilmektedir. Ped1 ve Ped2 sırasıyla 36 ve 12 test videosu içerir. Tüm test videoları çeşitli dönemlerde anormallikler içerir.

Her iki veri seti de anomali algılama görevi için kullanılan veri setleridir. Bununla birlikte, 14 farklı anormallik türü içerdiğinden, UCF-Crimes veri seti anormal olay türü tespiti için de kullanılmaktadır.



2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

Bu çalışmada, akan verilerin analizi ve akan veriler için yeni ve etkili öğrenme yaklaşımlarının geliştirilmesi irdelenmiştir. Akan veriler için öznitelik çıkartma ve boyut indirgeme ile öğrenme yaklaşımları incelenirken, uygulama alanı olarak gözetim videolarındaki anomali tespiti akan veri metodolojisi ile çözüm üretme çalışması yapılmıştır. Literatürde yer alan gerçek ve sentetik veri setleri üzerinde gerçekleştirilen çalışmalar temel olarak 5 unsurun iyileştirilmesini hedeflemiştir.

- Akan veri öğrenmesi için geliştirilecek yaklaşımların akan veri karakteristiklerine uygun gelecek şekilde tasarlanması ve yüksek performans elde etmesi önemli bir durumdur.
- Geliştirilen öğrenme yaklaşımının orijinal algoritmasındaki var olan problemlerin giderilerek tutarlı ve yüksek bir performans elde etmesi hedeflenen bir unsurdur.
- Akan veri öznitelik çıkartma ve boyut indirgeme yaklaşımlarının düşük işlem zamanı ile en iyi öznitelik setini belirlemesi öğrenme yaklaşımlarının performansını artırması istenmektedir.
- Akan veri uygulaması için belirlenen gözetim videolarındaki anomali tespiti yaklaşım ile literatürdeki diğer video anomali tespiti yaklaşımlarının aksine akan veri tabanlı bir çözüm üretilmesi ile var olan yaklaşımlardaki problemlerin elemine edilmesini sağlaması ve performans katkısı yapması istenmektedir.
- Etiket verilerine minimum ihtiyaç duyan akan veri tabanlı bir video anomali tespitinin geliştirilmesi ile gerçek dünya uygulamalarına uygun gelecek bir çözüm üretilmesi hedefler arasında yer almaktadır.

Bu bölümde akan tez kapsamında bahsedilen akan veri öğrenmesi için önerilen çalışmalar gerçek ve sentetik veri setleri üzerinde irdelenerek hedefler doğrultusunda yeni akan veri öğrenme yaklaşımlarının önerilmektedir. Ayrıca gerçek dünya problemine geliştirilen yaklaşımların uygulanması ile elde edilen yaklaşımlar ile video anomali tespitine yeni çözümler üretilmesi için çalışmalar sunulmaktadır.

Akan veri öğrenme yaklaşımını geliştirilmesi olarak ilk çalışma öznitelik çıkartma ve boyut indirgeme yaklaşımını geliştirilmesidir. Bu nedenle AKD ve HPSO' ya dayalı otomatik öznitelik setinin belirlendiği akan verilerin karakteristiklerine ve özelliklerini göz önüne alan artımlı bir yaklaşım geliştirilmiştir. Yaklaşım literatürdeki popüler artımlı

öğrenme gerçekleştiren öznelilik çıkartma yaklaşımları ile karşılaştırılarak performansı incelenmiştir.

Akan veri öğrenme yaklaşımı geliştirilmesi için bir diğer irdelenen konu AÖM tabanlı bir akan veri sınıflandırma yaklaşımını geliştirilmesidir. Bu nedenle ÇA-AÖM ve AÖM-OK' ya dayalı bir akan veri öğrenme yaklaşımı önerilmiştir. Bu yaklaşım tez kapsamındaki hedefleri göz önüne alarak var olan problemleri çözümleyen bir yaklaşım olarak sunulmaktadır. Literatürdeki genel bilgiler bölümünde verilen akan veri setleri üzerinde performans irdelemesi yapılarak kıyaslamalı olarak yaklaşım incelenmiştir.

Bir önceki geliştirilen yaklaşımın akan verinin tüm karakteristiklerine uygun olmaması bir diğer yaklaşım olarak DÖTÇA-AÖM adı verilen yaklaşımın geliştirilmesine neden olmuştur. Bu nedenle akan verinin içerik farklılaşmasını tespit edip, bu farklılaşmaya adapte olabilen bir yaklaşım literatür kıyaslamalarıyla irdelenerek sunulmuştur.

Geliştirilen DÖTÇA-AÖM yaklaşımı gerçek dünya problemi olan gözetim videolarındaki anomali tespiti ve anormal olayların belirlenmesi problemine akan veri tabanlı bir çözüm üretmesi açısından sunulmuştur. Bu çözüm zayıf etiketleme içeren önışleme aşaması ve topluluk DÖTÇA-AÖM' den oluşan belirlenen hedefler doğrultusunda çözüm üretecek şekilde bir yaklaşım olarak geliştirilmiştir. Literatürdeki popüler ve son yılların en sık kullanılan derin ağ tabanlı yaklaşımlar ile karşılaştırma gerçekleştirilerek irdeleme yapılmıştır. Daha sonra yaklaşım otomatik öznelilik çıkartacak şekilde önışleme aşamasında AKD ve HPSO' ya dayalı yaklaşımın DÖTÇA-AÖM ile birleştirilmesiyle anomali tespiti probleminde iyileştirme gerçekleştiren yaklaşım sunulmuştur. Bu yaklaşımın performans irdelemesi de hedefleri karşılayacak şekilde gerçekleştirilmiştir.

Tezde yapılan son çalışma ise akan veri öğrenmesi tabanlı video anomali tespiti çalışmasının gerçek dünya problemlerine uygun gelecek şekilde tasarlanması gerçekleştirilmiştir. Burada anomali skoru kullanan aktif öğrenmeye dayalı bir yaklaşım ile DÖTÇA-AÖM öğrenme algoritması iyileştirilmiş ve değiştirilmiştir. Böylelikle akan veri tabanlı gerçek dünya uygulaması gerçekleştirilmiştir ve kıyaslaması yapılmıştır.


Bu tez çalışmasında gerçekleştirilen tüm yaklaşımlar Windows 10 (64-bit OS) altında MATLAB (R2016b) ortamında hazırlanmıştır. Bilgisayarın MİB' i, 8 GB rasgele erişimli belleğe sahip bir Intel® Core™ i7-7500 (2.70 GHz)' dir. Kıyaslama olarak kullanılan çalışmaların birçoğu raporlandıkları şekilde yine MATLAB ile kodlanarak sonuçları elde edilmiştir. Tez kapsamında önerilen çalışmaların detayları sırasıyla ilerleyen bölümlerde verilmektedir.

2.1. Ayrık Kosinüs Dönüşümü ve Sürü Zekasına Dayalı Akan Veri Özellik Çıkartımı Yaklaşımı

Akan veri özellik çıkartma işlemini kolaylaştırmak için tasarlanan artımlı özellik çıkarma yaklaşımları, geleneksel yöntemler ile karşılaşılan zorlukları elemine ederek sorunları çözmeyi amaçlamaktadır. Artımlı özellik çıkarma tekniklerinde geleneksel yöntemlerde olması gerektiği gibi başlangıçta tüm verilere erişim zorunluğu bulunmamaktadır. Bu nedenle bu teknikler verileri akış şeklinde ele almaktadır ve akan verileri tek tek işlemektedir. Böylelikle öğrenme uygulamalarında bellek kullanımı en düşük seviyeye indirgenmektedir. Her ne kadar artımlı özellik çıkarma teknikleri akan verilerin ihtiyaçlarının büyük bir çoğunluğunu karşılayabilmek için tasarlanmış olsa da literatürde temel olarak görülen ATBA tabanlı teknikler içerdikleri zaman karmaşıklığı hesaplama maliyetleri, veri bağımlılığı içermesi açısından yüksek boyutlu akan veriler için uygun yöntemler olmamaktadır. Veri bağımlılığı olan ATBA algoritmalarının büyük ölçekli veriler için öz uzayı belirlemede yüksek hesaplama maliyetine sahip olması, gelen her veri için öz uzayın anında güncellenmesi ve sonuç üretilmesinin uzun zaman alması problemleri, ATBA' nın akan veri için kullanılmasını zorlaştırmaktadır. Bu alternatif yaklaşımların kullanılmasının ihtiyacı doğurmaktadır.

AKD, TBA' dan sonra gelen en popüler özellik çıkartma yaklaşımlarından birisidir ve birçok açıdan TBA' ya göre bir avantaj elde etmektedir. AKD, veri bağımlılığı olan bir algoritma değildir ve veri tabanına yeni veri eklerken yeniden hesaplama yapılmasını gerektirmemektedir. Böylece hesaplama maliyeti ve zaman karmaşıklığı AKD için sorun teşkil etmemektedir. Ayrıca, AKD hızlı algoritmalar kullanılarak kolayca uygulanabilen basit yapıya sahiptir. Bu avantajları TBA ile karşılaştırıldığında akan veri yapısına hızlı yanıt verilebileceğini göstermektedir. Bu nedenle bu çalışmada akan veriler için AKD tabanlı ATBA yaklaşımlarına alternatif olabilecek artımlı bir özellik çıkartma yaklaşımını önerilmektedir.

Önerilen çalışma AKD tabanlı özellik çıkartma ve sürü zekasına dayalı otomatik en güçlü ve yüksek başarı üreten özellik setini bulma işlemine dayanmaktadır. Çalışmanın genel şeması Şekil 13' te gösterilmektedir.



Şekil 13. AKD ve sürü zekasına dayalı yaklaşımın genel modeli

Yaklaşım iki aşamadan oluşmaktadır. Her iki aşama da belirli sayıda akan veri örneğinden oluşan sabit boyutlu kayan pencereyi modeli kullanmaktadır. İlklendirme aşaması yaklaşımın temelini oluşturacak olan ilk modeli oluşturmak için sadece ilk pencereye uygulanmaktadır. Bu aşamada normalizasyon ve AKD pencere içindeki her örneğe uygulanmaktadır. Ardından sürü zekasına dayalı bir metot ile en etkili öznitelik alt kümesi otomatik olarak belirlenerek başlangıç modeli elde edilmektedir. Başlangıç modeli oluşuktan sonra, ardışıl aşama başlamaktadır. Bu aşama da her yeni oluşan akan veri örneğine normalizasyon ve AKD süreçleri ilklendirme aşamasındaki uygulanmaktadır.

Akabinde oluşturulan başlangıç modeline dayanarak mevcut veride öznitelik seçimi yapıldıktan sonra kayan pencere yapısına göre başlangıç modeli yeni veri ile güncellenmektedir. Böylelikle model yeni veriler ile güncel tutularak bir nebze de olsa içerik farklılaşmasına karşı güçlü olması sağlanmaya çalışılmıştır.

Çalışmanın katkıları aşağıdaki gibi sıralanabilmektedir.

- Akan veri için hesaplama maliyeti ve zaman karmaşıklığı sorunlarının üstesinden gelen AKD ve HPSO' ya dayalı yeni, verimli bir artımlı öznitelik çıkarma yaklaşımı geliştirilmiştir.

- Yaklaşım akan verinin tüm özelliklerine uygun gelecek şekilde tasarlanmıştır. Zaman eve hesaplama maliyeti diğer yaklaşımlara göre oldukça düşüktür.

- Önerilen yaklaşım AKD ve HPSO' ya dayanan ilk akan veri akan veri öznitelik çıkartma yaklaşımıdır.

Önerilen çalışmanın tüm aşamaları alt başlıklarla detaylandırılacaktır.

2.1.1. İlkendirme Aşaması

Bu aşama akan veri özellik çıkartmak için ilk modelin oluşturulduğu aşamadır. $X = \{(x_i, t_i) | i = 1, \dots, S\}$ olarak ifade edilen ilk S tane akan veri örneği için icra edilmektedir. Dolayısıyla ilk model S tane verinin oluşması ve işlenmesiyle oluşturulur. Bunun için $W [t_c - S + 1, t_c]$ ile ifade edilen kayan pencere yapısı çalışmada yer almaktadır. Burada W kayan pencere, t_c zaman bilgisi ve S en son ilgilenilen ve pencerenin kapasitesinin oluşturan veri sayısıdır.

İlk aşamada sırasıyla her veri için veri normalizasyonu, AKD ve pencere güncelleme süreçleri yer almaktadır. İlkendirme aşamasında sadece ilk S veriden oluşan bir pencere kullanılır ve bu pencereye başlangıç seti denilmektedir. Başlangıç seti oluştuktan sonra öznitelik seçme işlemi uygulanmaktadır. Öznitelik seçme işlemi sonucunda öznitelik alt kümesi belirlenmektedir ve belirlen bu küme tüm özniteliklerin bir alt kümesidir. Aslında burada belirlenen ilgili özniteliklere karşılık gelen indeks değerleridir ve bu değerler başlangıç öznitelik kümesinde saklanmaktadır. İlkendirme aşaması sonunda başlangıç seti adı verilen ve (18) eşitliğindeki ifade edilen bir model oluşturulmaktadır.

$$BS = \langle X, Xf \rangle \quad (18)$$

2.1.1.1. Öznitelik Normalizasyonu

Çalışmada mevcut akan veri örneğinin öznitelikleri arasındaki ölçüm farklılıklarını ortadan kaldırmak için normalleştirme tekniği kullanılmıştır. Örneklerin öznitelikleri farklı ölçüm cihazlarından elde edilen farklı niteliklere sahip olabilmektedir ve öznitelik değerleri farklı aralıklarda olabilmektedir. Bu nedenle çalışma (19) ile formülize edilen standart sapma normalizasyonu [171], öznitelik değerlerini aynı aralığa getirmek için her gelen akan veri örneğine ayrı ayrı uygulanmaktadır. (19) eşitliğinde x_i , i anındaki akan veri örneği, μ_i i anındaki akan veri örneğinin özniteliklerinin ortalama değeri ve σ_i ise i anındaki akan veri örneğinin özniteliklerinin standart sapma değeridir.

$$x_i = \frac{x_i - \mu_i}{\sigma_i} \quad (19)$$

2.1.1.2. Ayırık Kosinüs Dönüşümü ile Frekans Uzayında Öznitelik Çıkartımı

Yaygın olarak kullanılan bir sinyal ayrıştırma, sıkıştırma ve özellik çıkartma tekniği olan AKD, esas olarak veri sıkıştırma ve görüntü sıkıştırma için kullanılmaktadır. Sinyali uzamsal alandan daha iyi korelasyon performansına sahip olan frekans alanına dönüştürebilmektedir. AKD, Fourier Dönüşümü'nde (FD) yer alan karmaşık işlemi engelleyen özel bir FD durumudur ve gerçek sayı alanında işlem yapan bir dönüşümdür.

AKD, bir sinyalin temel frekans bileşenlerine dönüştürülmesine izin veren bir tekniktir. Daha özel olarak, AKD giriş sinyali, frekans bileşenleri ile ilişkili ağırlıklı temel fonksiyonların doğrusal bir kombinasyonu olarak temsil edilmektedir. AKD genellikle görüntüleri, zaman serisi sinyalleri veya sonlu veri noktaları sırasını temel frekans bileşenlerine dönüştürmek için kullanılır. AKD, verileri farklı frekanslarda salınan kosinüs fonksiyonlarının bir toplamı olarak gösterme yöntemidir. 1-boyutlu (1-B) AKD katsayıları (20) eşitliği ile hesaplanmaktadır.

$$F(u) = \sqrt{\frac{2}{N}} \alpha(u) \sum_{x=0}^{N-1} f(x) * \cos\left(\frac{\pi u(2x+1)}{2N}\right), \quad u = 0, 1, \dots, N-1 \quad (20)$$

$f(\mathbf{x})$, N tane özniteliğe sahip 1-B bir giriş vektörü; $F(u)$ ise N özniteliğe sahip 1-B AKD katsayıları vektörüdür. (20) eşitliğindeki $\alpha(u)$ katsayısı (21) eşitliğindeki gibi hesaplanmaktadır.

$$\alpha(u) = \begin{cases} \frac{1}{\sqrt{2}} & u = 0 \\ 1 & \text{aksi takdirde} \end{cases} \quad (21)$$

AKD katsayıları, düşük ve yüksek frekans bileşenlerinden oluşmaktadır ve AKD katsayı vektörünün ilk katsayısı DC bileşen olarak adlandırılmaktadır. DC bileşen sinyalin ortalama bilgisini tutar. Geriye kalan katsayılar ise AC bileşenler olarak adlandırılmaktadır. AKD vektörünün son elemanları, sinyal hakkında ayrıntılı bilgi veren yüksek frekanslı bileşenlerdir.

Çalışmada AKD akan veri örneklerinin özelliklerini çıkarmak için kullanılmıştır. Özellik normalizasyonu kullanılarak niteliklerinin ölçüm farklılıkları kaldırıldıktan sonra, pencere içindeki akan veri $\mathbf{x}_i$ 1-B AKD uygulanmaktadır. AKD işleminin sonunda her $\mathbf{x}_i$ için N frekans değerlerine sahip bir 1-B AKD katsayı vektörü elde edilmektedir. Böylelikle, akan veri $\mathbf{x}_i$, daha ayırt edilebilir olduğu frekans uzayına veri düşük ve yüksek bileşenleri elde edilerek iz düşürülmüş ($\mathbf{x}\mathbf{k}_i$) olunmaktadır.

2.1.1.3. Öznitelik Seçme

Akan verinin büyük ölçekli yapısı ve içerdiği tutarsız öznitelikleri bir özellik seçme tekniğinin uygulanmasını gerekli kılmaktadır. Öznitelik seçim süreci, öznitelik vektöründen en tutarlı, uygun ve doğru özniteliklerin alt kümesinin seçilmesine dayanmaktadır. Önerilen çalışmada, öznitelik seçimi ilklendirme aşamasında gerçekleştirilmiştir. Seçilen öznitelikler ve bu özniteliklerin indeksleri başlangıç özellik kümesinde tutulmaktadır ve ardışıl aşamada gelen her akan verinin ($\mathbf{x}\mathbf{k}_i = (\mathbf{x}\mathbf{k}_{i1}, \mathbf{x}\mathbf{k}_{i2}, \dots, \mathbf{x}\mathbf{k}_{iN})$) alt özellik kümesini belirlemede önemli bir yere sahiptirler. Çalışmada iki farklı öznitelik seçme mekanizması kullanılmıştır. İlki, deneysel bir öznitelik seçimidir. Deneysel seçim, zamanı ve hesaplama maliyetini artıran ek modüller olmadan AKD tabanlı özellik çıkarma yaklaşımının hızlılığını göstermeyi amaçlamaktadır. Diğeri, ise Sürü Zekasına dayalı otomatik öznitelik seçimidir. Her otomatik öznitelik seçiminde optimizasyon teknikleriyle en iyi özellik setini otomatik olarak belirleyerek AKD 'nin performansını artırmak amaçlanmaktadır. Otomatik özellik

2.1.1.3.2. Otomatik Öznitelik Seçimi

Deneysel özellik seçimi, farklı veri kümeleri için en iyi özellik kümesini belirlemek üzere bir uzmana ihtiyaç duymaktadır. Ancak, akan veri uygulamalarında deneysel analiz için yeterli zaman bulunmamaktadır. Yaklaşım, bir uzman olmadan en iyi alt kümeyi aramalıdır. Bu nedenle, bu çalışmada otomatik özellik seçme mekanizması kullanılmıştır. Literatürde, akan verilerin özellik seçimi için sürü zekasına dayanan uygulamalar yer almaktadır [172-175].

Sürü zekâsı, merkezi olmayan, kendi kendine organize olan, doğal veya yapay sistemlerin toplu davranışdır. Bu sistemler tipik olarak, yerel bir şekilde birbirleriyle ve çevreleriyle etkileşime giren basit ajanlardan oluşan bir popülasyondan oluşmaktadır. En popüler algoritmaları Parçacık Sürü Optimizasyonu (PSO) ve Hızlandırılmış Parçacık Sürü Optimizasyonu (HPSO) örnek verilebilir. Genellikle optimizasyon işlemi için kullanılan bu yaklaşımlar akan veri öznitelik seçimi için de kullanılmaktadır [172-175].

2.1.1.3.2.1. Parçacık Sürü Optimizasyonu ile öznitelik seçimi

PSO, Dr. Eberhart ve Dr. Kennedy tarafından 1995 yılında önerilen popüler bir optimizasyon algoritmasıdır [176]. Günümüzde birçok çalışmada öznitelik seçme tekniği olarak kullanılmaktadır. PSO, sürü arama stratejisine dayanmaktadır ve öznitelik seçim alanında yerel ve genel aramalarla özyinelemeli bir şekilde optimum öznitelikleri bulmak için kullanılmaktadır. Algoritmada, sürü rastgele bir parçacık grubundan oluşmaktadır. Parçacıklar, yakınsama olana kadar her yinelemede güncellenmektedir. Böylece problemin çözüm uzayında optimum çözümü elde etmek için dolaşmaktadır. Optimum çözüme bir amaç fonksiyonu kullanılarak elde edilmektedir.

PSO, bir grup rastgele üretilmiş parçacıklarla başlatılmaktadır ve güncellenerek en uygun değer araştırılmaktadır. Başlangıç popülasyonu, hızları ve konumları rastgele belirlenen bir sürü ile ifade edilmektedir. Her özyinelemede, her parçacık iki en iyi değere göre güncellenmektedir.

İlk en iyi değer parçacığın kendisinin o ana kadar ürettiği en iyi uygunluk değerini veren çözümdür ve “pbest” olarak isimlendirilmektedir. Bu değer amaç fonksiyonu ile elde edilmektedir ve daha sonra kullanılmak üzere saklanmaktadır. Diğer en iyi değer “gbest” olarak isimlendirilen popülasyondaki herhangi bir parçacık tarafından o ana kadar üretilen

global en iyi değeri veren çözümdür. PSO algoritmasında N boyutlu arama uzayına sahip i . parçacığın konum vektörü eşitlik (22) ile ifade edilmektedir.

$$\mathbf{k}_i = (k_{i1}, k_{i2}, \dots, k_{iN}) \quad (22)$$

k_i parçacığı optimum çözümü elde etmek için hareket ettiği uzaydaki sahip olduğu hız vektörü ise eşitlik (23) ile gösterilmektedir.

$$\mathbf{h}_i = (h_{i1}, h_{i2}, \dots, h_{iN}) \quad (23)$$

Pbest ve gbest çözümleri elde edildikten sonra parçacıkların hız ve konum vektörleri (24) ve (25) eşitlikleri ile güncellenmektedir.

$$\mathbf{h}_i^{t+1} = w * \mathbf{h}_i^t + c_1 * r_1 * (\mathbf{pbest} - \mathbf{k}_i^t) + c_2 * r_2 * (\mathbf{gbest} - \mathbf{k}_i^t) \quad (24)$$

$$\mathbf{k}_i^{t+1} = \mathbf{k}_i^t + \mathbf{h}_i^{t+1} \quad (25)$$

Burada t özyineleme sayısını, w atalet ağırlığını, c_1 ve c_2 hızlandırma sabitlerini, r_1 ve r_2 (0,1) arasında değer alan rastgele katsayıları göstermektedir.

Çalışmada PSO algoritmasının girdisi $\langle BS \rangle$, çıktısı ise $\langle BÖS \rangle$ ile ifade edilen etkili, en tutarlı alt öznitelik setidir. Parçacıkların gezindiği ve optimum çözümü elde etmek için özyinelemeli olarak güncellendiği arama uzayı a özniteliklerin sayısı kadardır. Her özyineleme de bir alt özellik setine ait çözüm üretilerek pbest ve gbest değerleri elde edilmektedir. Bu değerleri elde etmek için çalışmada kullanılan amaç fonksiyonu K-Katlamalı-Çapraz Doğrulama tekniğine dayanmaktadır. İlgili amaç fonksiyonu Algoritma 3'te verilmiştir.

Algoritma 3: Amaç Fonksiyonu – Çapraz Doğrulama

Girdi: Eğitim kümesi $X = \{(\mathbf{x}_i, t_i) \mid i = 1, \dots, S\}$, çapraz doğrulama sayısı k

Çıktı: skor dizisi

1. Veriyi k parçaya böl.
2. k parça içindeki her i değeri için

- a. i . parçayı test verisi olarak ata ve $skor$ değerini ilklendir.
- b. kalan parçaları eğitim verisi olarak ata.
- c. test verisi içindeki her x için
 - i. x ile eğitim verisi arasındaki Öklid uzaklığını hesapla.
 - ii. minimum uzaklığı veren eğitim verisinin indeks değerini ve uzaklık değerini belirle
 - iii. indeks değeri alınan eğitim verisinin etiket değeri x 'in etiket değerine eşit değilse

$$skor = skor + 1 \quad (26)$$

- d. $skor dizisi$ ' nin i . değerine skoru ata. ($skor dizisi(i) = skor$)

3. $skor dizisi$ ' nin ortalamasını ($Ort(skor dizisi)$) al.

2.1.1.3.2.2. HPSO ile Öznitelik Seçimi

PSO' da yer alan bireysel en iyi değerleri veren çözüm pbest, nitelikli çözümler için çeşitliliği artırmak için kullanılmaktadır. Ancak, çeşitlilik farklı rastgele yöntemleri kullanılarak elde edilebilmektedir. Bu nedenle yalnızca global en iyi değer olan gbesti kullanarak yakınsamayı hızlandıran ve çeşitliliği arttıran HPSO [177] algoritması ortaya atılmıştır. HPSO' da algoritmayı hızlandırmak için hız ve konum vektörleri daha basit hale getirilmiştir. Basit hale indirgenen i . parçacık için yeni hız ve konum vektörleri eşitlik (27) ve (28)' de verilmiştir.

$$h_i^{t+1} = h_i^t + c_1 * r1 + c_2 * (gbest - k_i^t) \quad (27)$$

$$k_i^{t+1} = (1 - c_2) * k_i^t + c_2 * gbest_i^t + c_1 * r_1 \quad (28)$$

(28) eşitliğinde de görülebileceği gibi, i . parçacığın konum vektörünün yeni ifadesi, hız vektörünün hesaplanmasına gerek kalmamasını neden olmaktadır. Bu nedenle HPSO' da bir parçacık yalnızca bir konum vektörü ile tanımlanabilmektedir. Bunun dışında, konum vektörü, yalnızca global en iyi değere elde eden çözüm (gbest) kullanılarak güncellenmektedir. Tüm bu nedenler, HPSO algoritmasının PSO' dan daha hızlı

yakınsamasını sağlamaktadır. Bu hızlı yakınsama avantajı nedeniyle HPSO algoritması akan veri için kullanılmaya daha uygun olduğu söylenebilmektedir. Bu nedenle, çalışmada öznitelik seçimi için HPSO algoritması da uygulanmıştır. HPSO ile öznitelik seçme adımı PSO ile aynı şekildedir ve aynı amaç fonksiyonunu kullanılmaktadır.

2.1.2. Ardışıl Aşaması

Ardışıl aşama, ilk model oluştuktan sonra yeni oluşan $((x_i, t_i) | i = S + 1, \dots, \infty)$ akan veri örneklerinin aşamalı olarak tek tek ele alındığı aşamadır. Bu aşamada her veri ayrı ayrı bir şekilde ilk model kullanılarak analiz edilmektedir ve ilk model de yeni veriler ile güncellenmektedir. Ardışıl aşama üç adımdan oluşmaktadır: öznitelik normalizasyonu, AKD ve öznitelik alt kümesi seçimi.


Öznitelik normalizasyonu ve AKD adımları, ilklendirme aşamasıyla aynı şekilde mevcut akan veri örneğine uygulanmaktadır. Daha sonra, mevcut örneğe AKD uygulanması ile elde edilen 1-B AKD katsayıları üzerinde alt küme öznitelik seçme işlemi gerçekleştirilir. Öznitelik seçme işlemi ilklendirme aşamasında belirlenen başlangıç öznitelik alt kümesi kullanılarak seçilmektedir. Yani, başlangıç öznitelik alt kümesinin içerdiği en uygun özniteliklere ait indeks değerlerine karşılık gelen öznitelikler bu aşamada seçilmektedir. Böylelikle i . akan veri örneği için öznitelik indirgeme işlemi gerçekleştirilerek öznitelik sayısı indirgenmiş olunmaktadır. Bu durumda katsayı vektörü eşitlik (29)'deki gibi ifade edilmektedir.

$$xk_i = (xk_{i1}, xk_{i2}, \dots, xk_{im}), m < N \quad (29)$$

Ardışıl aşamadaki son işlem model güncellenmesidir. Bu aşamada öznitelik indirgemesi yapılan veri, mevcut modelin değişikliklere ve yeni verilere adapte olabilmesi için modelin güncellenmesinde kullanılmaktadır. Bu işlem için üç farklı yaklaşım kullanılmıştır. Bunlardan ilki çalışmanın temelini oluşturan kayan pencere tekniği ile model güncellenmesidir ve çalışmada M1 olarak isimlendirilmiştir. Literatürdeki akan veri için artımlı öğrenme yaklaşımlarında kullanılan geleneksel bir yapıya sahiptir. Diğerlerine ise M2 ve M3 teknikleri adlandırması yapılmıştır. Bu teknikler alt başlıklar altında detaylandırılacaktır.

2.1.2.1. M1 Güncelleme Yaklaşımı

M1 güncelleme yaklaşımı kayan pencere tekniğine dayalı bir model güncelleme mekanizmasıdır. Bu yaklaşımda ardışıl aşamada işlenen akan veri örneği modeli güncel tutabilmek için başlangıç setine eklenmektedir. Başlangıç setinde yer alan en eski akan veri örneği de başlangıç setinden çıkartılmaktadır. Böylelikle güncelliğini yitiren eski veriler setten çıkartılarak model yeni veriler ile güncel tutulmaktadır. Ayrıca veri sayısı da bu yaklaşımda sabit S olarak tutulmaktadır. Bu yaklaşım Şekil 15’ de gösterilmiştir.




Şekil 15. M1 güncelleme yaklaşımı. (a) $(i + 1)$. veriler mevcut akan veri örneğidir ve ilk model S veriden oluşmaktadır. (b) Mevcut yeni örnek, ilk modelin sonuna eklenir. (c) İlk modelin ilk örneği modelden çıkarılır. (d) Mevcut örnekle güncellenmiş başlangıç modeli.

2.1.2.2. M2 Güncelleme Yaklaşımı

M2 güncelleme yaklaşımı sadece ilklendirme aşamasında oluşturulan modelin kullanıldığı yaklaşımdır. Bu yaklaşımda model güncellenmesi yapılmamaktadır ve sadece ilklendirme aşamasında oluşturulan S veri içeren başlangıç seti kullanılmaktadır. Ardışıl aşamadaki veriler sadece işlenmektedir ve modele katılmamaktadır. Bu yöntem, toplu öğrenmeye benzer bir yapıya sahiptir.

2.1.2.3. M3 Güncelleme Yaklaşımı

M3 güncelleme yaklaşımı ise eski ve güncelliğini yitirmiş örnekleri elimine etmeden ilk modele yeni gelem örneklere eklemeye dayanmaktadır. Yaklaşımında, ilk modelin örnek sayısı S olarak sabit kalmamaktadır. Bu sayı ardışıl aşamada her gelen verinin eklenmesiyle zaman geçtikçe artmaktadır. Aslında bu yaklaşım dönüm noktası pencere tekniğinin uygulaması olarak açıklanabilmektedir. Yaklaşım Şekil 16’ da gösterilmiştir.



Şekil 16. M3 güncelleme yaklaşımı. (a) $(S + 1)$. veriler mevcut olan veri örneğidir ve ilk model S veriden oluşmaktadır. (b) Mevcut yeni örnek, ilk modelin sonuna eklenir ve son örnek modelden çıkarılmaz (c) Yeni örnek geldiğinde verinin en sonuna tekrar eklenir (d) Yeni örnekle modelin güncellenmiş hali.

2.1.3. Deneysel Sonuçlar

Bu bölümde, AKD ve sürü zekasına dayalı akan veri özellik çıkartma yaklaşımının değerlendirilmesi gerçek ve yapay veri setlerinde üzerinde sunulmuştur. Karşılaştırma için doğrusal ve doğrusal olmayan ATBA tabanlı özellik çıkartma algoritmaları kullanılmıştır. Doğrusal algoritmalar, geleneksel TBA [62], Li tarafından önerilen ATBA-Li [67], Ozawa tarafından önerilen ATBA-Ozawa [68] ve GKATBA [73]; doğrusal olmayan algoritma YAÇTBA’ dır [76].

Önerilen yaklaşım, TBA ve ATBA algoritmaları, MATLAB (R2016b) ortamında hazırlanmıştır. Tüm algoritmalar orijinal çalışmalarında raporlandığı gibi uygulanmıştır. Sadece HKATBA’ nın sonuçları orijinal çalışmalarında raporlandığı gibi kullanılmıştır.

Çalışmada üç ana analize odaklanılmıştır. Birincisi, öznitelik seçimi olmadan AKD ile öznitelik çıkarma yaklaşımının performansı üzerindeki etkisini araştırmaktır. Doğruluk oranı (DO) [%], doğru sınıflandırılan akan veri sayısı (DSAVS) ve F1-skoru, ilk deneydeki

değerlendirme ölçütleridir. Diğer deney, AKD katsayılarının varyasyonunun etkisini incelemektir. Son deney ise önerilen AKD tabanlı özellik seçimi yaklaşımında otomatik öznitelik seçiminin yani sürü zekasının etkisini araştırmaktır. Otomatik özellik seçimini işlemek için PSO ve HPSO algoritmaları uygulanmıştır. Bu analizde yer alan PSO ve HPSO öznitelik seçme algoritmalarının kullandığı k-Katlamalı Çapraz Doğrulama tekniğinde $k = 3$ olarak belirlenmiştir. Bunların dışında önerilen yaklaşımın sağlamlığını, verimliliğini ve performansını ölçmek için, Öklid Mesafesine dayalı K En Yakın Komşuluk (K-EYK) sınıflandırıcı kullanılmıştır. K-EYK' nın tercih edilmesinin sebebi önceden bir sınıflandırıcı modeli oluşturmaya gerek olmamasıdır [178]. Bu özellik, K-EYK' yı akan veriye uygun kolayca uygulanabilir kılmaktadır [179, 180]. Karşılaştırma için kullanılan diğer özellik çıkartma algoritmalarında da performans ölçümü için aynı K-EYK sınıflandırıcısı kullanılmıştır. Sınıflandırıcı da ek iş yükü getirmemesi açısından $K = 1$ olarak seçilmiştir. Ayrıca kayan pencere tekniğindeki penceredeki veri sayısı deneysel sonuçlara göre belirlenmiştir ve 1000 olarak atanmıştır. Yani ilk modeli oluşturmak için ilk model için tüm veri setlerinin ilk 1000 örneği kullanılmıştır.

Bu çalışmada gerçek veri setleri olarak ForestCovType, ElecNormNews, PokerHand ve Optic-Digit kullanılırken; yapay veri seti olarak Waveform ve DS1 veri setleri kullanılmıştır. ForestCovType ve PokerHand veri setlerinin rastgele olarak 100000 veriden oluşan alt kümesi kullanılmıştır. Veri setlerinin küçük bir özeti Tablo2'de verilmiştir.

Tablo 2. AKD ve sürü zekasına dayalı öznitelik çıkartma yaklaşımında kullanılan veri setleri

Veri Seti	Veri Sayısı	Öznitelik Sayısı	Sınıf	Karakteristik
ForestCovType	100000	54	7	gerçek
ElecNormNews	45312	8	2	gerçek
Poker	100000	10	8	gerçek
Optic-Digit	5620	64	10	gerçek
Waveform	5000	21	3	sentetik
DS1	26733	10	2	sentetik

2.1.3.1. AKD ile Özellik Çıkartma Yaklaşımının Performans Analizi

Çalışmada önerilen yöntemin performansı, doğrusal ve doğrusal olmayan öznitelik çıkarma algoritmaları ile karşılaştırılarak değerlendirilmektedir. Bölüm 2.1.2.'de bahsedilen M1, M2 ve M3 güncelleme yaklaşımlarının üçü de kullanılarak performans analizi gerçekleştirilmiştir ve AKD' nin etkisini görebilmek için öznitelik seçimi

gerçekleştirilmemiştir. Tablo 3 geleneksel TBA ile önerilen yaklaşımın karşılaştırılmasını göstermektedir. Bu karşılaştırmada, geleneksel TBA' nın M2 güncelleme tekniğine sahip bir yapıda olması nedeniyle sadece M2 tekniğine ait sonuçlar verilmiştir. Tablo 4 ATBA-Li ve GKATBA ile önerilen yaklaşımın M1, M2 ve M3 teknikleri kullanılarak karşılaştırılmasını DO ve DSAVS üzerinden göstermektedir. Tablo 5 ise, YAÇTBA ile önerilen yaklaşımın karşılaştırılmasını sadece M1 tekniğine ait DO sonuçları üzerinden göstermektedir. YAÇTBA yöntemi orijinal çalışmalarında sadece Waveform ve Optic-Digit veri setlerini DO sonuçlarıyla kullandığı için Tablo 5 yalnızca bu veri setlerinin sonuçlarını içermektedir.

Tablo 3. Geleneksel TBA [62] ve önerilen yaklaşımın karşılaştırılması

Veri Seti	Geleneksel TBA [62]			Önerilen Yaklaşım		
	DO	DSAVS	F1- skoru	DO	DSAVS	F1-skoru
ForestCovType	0.4567	45216	0.15	0.6687	66209	0.25
DS1	0.9700	24963	0.50	0.9607	24724	0.52
ElecNormNews	0.4276	18950	0.50	0.6442	28548	0.63
PokerHand	0.4859	48106	0.15	0.4838	47897	0.31

Tablo 4. ATBA-Li [67], GKATBA [73] ve önerilen yaklaşımın karşılaştırılması

Veri Seti	ATBA-Li [67]		GKATBA [73]		Önerilen Yaklaşım	
	M1	M3	M1	M3	M1	M3
(a) DO						
ForestCovType	0.6603	0.6363	0.8389	0.8399	0.9314	0.9182
DS1	0.9440	0.9482	0.9406	0.9538	0.9709	0.9719
ElecNormNews	0.6254	0.5913	0.6441	0.6220	0.8135	0.7906
PokerHand	0.5164	0.4759	0.7510	0.7323	0.8911	0.8425
(b) DSAVS						
ForestCovType	45216	65300	83059	83157	92216	90903
DS1	24293	24401	24207	24546	24986	25011
ElecNormNews	27713	26203	28545	27566	36049	35034
PokerHand	51131	47122	74354	72505	88220	83412

Tablo 5. YAÇTBA [76] ve önerilen yaklaşımın karşılaştırılması

Veri Seti	YAÇTBA [76]	Önerilen Yaklaşım
Waveform	0.748	0.754
Optic-Digit	0.883	0.975

Tablo 3 incelendiğinde geleneksel TBA algoritmasının, yalnızca PokerHand ve DS1 veri seti için önerilen yaklaşımdan daha yüksek DO ve DSAVS' ına ulaştığı; fakat önerilen


yaklaşımın bu veri setlerinde daha yüksek F1-skoru elde ettiği görülmektedir. M2 yönteminin TBA ile aynı yapıya sahip olması ve önerilen yaklaşımın aşamalı öğrenme yaklaşımı olarak tasarlanmış olması TBA' nın daha başarılı olmasına neden olmaktadır. F1-skor sonuçları ise, önerilen yaklaşımın ne kadar kesin olduğunu ve geleneksel TBA ile karşılaştırıldığında ne kadar sağlam olduğunu göstermektedir.

Tablo 4 incelendiğinde, önerilen AKD tabanlı öznitelik çıkartma yaklaşımının neredeyse tüm veri setleri için en iyi DO ve DSAVS' yı elde ettiğini göstermektedir. Önerilen yaklaşımın başarısının nedeni, frekans alanındaki özellikleri çıkarmaktır. AKD, frekans alanındaki en iyi ve ayırt edici özellikleri çıkarmaktadır. Acan verilerin frekans uzayındaki temsiline kullanılması, farklı sınıfların daha iyi ayrılmasını sağlamaktadır. Ayrıca, TBA, ATBA-Li ve GKATBA doğrusal dönüşüm teknikleridir. Veri setlerinin dağılımı ve karmaşıklığı, acan verinin doğrusal olarak dönüştürmek için uygun olmadığı sonuçlardan görülebilmektedir.

Tablo 5' e göre, önerilen yaklaşım YAÇTBA' dan daha başarılıdır. Bu, frekans alanındaki işlemenin çekirdek uzayında işlemeye göre daha verimli olduğunu gösterebilmektedir. Ayrıca, acan veri içeriği zaman içinde değişebilme özelliğine sahiptir. Kullanılan çekirdek türü, içerik farklılaşması sorunu nedeniyle etkisiz kalabilmektedir. Acan veri için en iyi çekirdek türünün belirlemek bir zorluk olarak yer almaktadır.

2.1.3.2. Ayrık Kosinüs Dönüşümünün Katsayılarının Deneysel Seçiminin Analizi

AKD katsayılarının varyasyonunun ve boyut indirgemenin etkileri bu deneyde incelenmiştir. Çalışmada, Bölüm 2.1.1.3.1'de anlatıldığı gibi aralık adı verilen katsayı vektörlerinden deneysel olarak ilk veya son m tane öznitelikler seçilerek gerçekleştirilmiştir. Burada amaç yüksek frekanslı bileşenlerin ve alçak frekanslı bileşenlerin etkisini görmek için yapılmıştır. DSAVS bu çalışmadaki değerlendirme ölçütüdür ve model güncellemek için M1 tekniği kullanılmıştır. Şekil 17 AKD katsayılarının deneysel olarak farklı aralık boyutlarında seçilmesinin DSAVS sonuçlarını göstermektedir. Şekil 17'de yer alan M1-İY, M1 tekniği ile ilk yarıdaki katsayıların seçilmesine ve M1-SY ise M1 tekniği ile son yarıdaki katsayıların seçilmesine denk gelmektedir.




Şekil 17. Önerilen yöntemde AKD katsayılarının deneysel olarak ilk yarısının ve son yarısının seçilmesinin (a) ElecNormNews, (b) PokerHand, (c) ForestCovType ve (d) DS1 veri setlerine göre performans analizi

Şekil 17 incelendiğinde, aşağıdaki gibi bazı ilginç çıkarımlar yapılabilmektedir. Aralığın uzunluğu kısaltıldığında DSAVS' nin düşme eğilimi gösterdiği görülmektedir. Bununla birlikte, bazı durumlarda DSAVS' nin düşmesi tüm veri setleri için tekdüze bir şekilde gerçekleşmemektedir. Nedeni tüm özelliklerin aynı şekilde katkı sağlayamamasıdır. Bazı öznitelikler sonuçları olumsuz etkilemektedir. Ayrıca, katsayıların etkisinin ilk başta tüm veri setlerinde M1-SY ve M1-İY için aynı davranışı sergileme eğiliminde olduğu görülmektedir. Aralığın uzunluğu kısaltıldığında, DSAVS beklendiği gibi düşme eğilimindedir ve her iki yarının performansı farklı hale gelmektedir. Aralık uzunluğunun

azaltılmasıyla AKD vektörünün son katsayıları, ForestCovType ve ElecNormNews veri kümeleri için daha verimli olma eğiliminde iken; ilk katsayıları ise Poker ve DS1 veri kümeleri için verimli olmaktadır. DSAVS, tüm veri kümeleri için farklı aralık seviyelerinde farklı performans sergilemektedir. Bu durum, veri setinin özelliklerinin en iyi şekilde temsil edilmesi için otomatik özellik seçiminin gerekliliğini göstermektedir.

2.1.3.3. Sürü Zekasına Dayalı Otomatik Öznitelik Seçiminin Analizi

Bu bölümde, otomatik bir öznitelik seçiminin etkisi değerlendirilmektedir. Amaç, en iyi ayırıcı öznitelikleri seçip, öznitelik setinden etkisiz olanları atarak sonuçlara sağlayacağı olumlu bir katkıyı incelemektedir. Çalışmada otomatik özellik seçimi PSO ve HPSO algoritmaları ile gerçekleştirilmektedir. Bu deneyde sadece M1 tekniği kullanılmıştır ve Şekil 18 AKD, PSO-AKD ve HPSO-AKD'nin kıyaslamasını göstermektedir.



Şekil 18. Önerilen yöntemde otomatik ve deneysel öznitelik seçiminin (a) ElecNormNews, (b) PokerHand veri setlerine göre performans kıyaslaması

Şekil 18 incelendiğinde PSO ve HPSO otomatik özellik seçim yöntemlerinin öznitelik kümesinden en iyi öznitelikleri seçebildiği sonucuna ulaşılabilmektedir. Her iki yöntem arasında küçük bir fark olduğu da görülmektedir. Üç yöntemin arasında en başarılı sonuçları HPSO-AKD yaklaşımının elde ettiği söylenebilmektedir. Otomatik öznitelik çıkartma

yaklaşımın daha başarılı olmasının nedeni, PSO ve HPSO tabanlı yöntemlerin, veri setlerinin yapısını değerlendirerek özellikleri otomatik olarak seçmesi verilebilmektedir.

Çalışmada önerilen yaklaşımlardan en başarılı olan HPSO-AKD yaklaşımı literatürdeki çalışmalarla da Tablo 6’ da ki gibi DO metriği üzerinden kıyaslanmıştır. Bu kıyaslamaya göre HPSO-AKD yaklaşımı diğer öznitelik çıkartma yaklaşımlarına göre daha başarılı olduğu açıkça görülebilmektedir.

Tablo 6. Literatürdeki çalışmaların önerilen HPSO-AKD ile kıyaslaması

Veri Seti	HPSO-AKD	ATBA-Ozawa [68]	ATBA-Li [67]	GKATBA [73]
ForestCovType	0.9393	0.1894	0.6603	0.8389
DS1	0.9716	0.4663	0.9440	0.9406
ElecNormNews	0.8174	0.2378	0.6254	0.6441
PokerHand	0.9149	0.2189	0.5164	0.7510

2.1.3.4. Otomatik Öznitelik Seçmenin Zaman Maliyetinin İncelenmesi

Bu bölümde son deney yaklaşımın ortalama öğrenme süresinin analiz edilmesidir. Deneysel seçime dayalı AKD öznitelik çıkartma yaklaşımı öğrenme açısından bir zaman yükü içermediğinden, otomatik öznitelik seçmeye dayalı yaklaşımın öğrenme için zamansal maliyeti analiz edilmiştir.

Tablo 7 HPSO-AKD ile PSO-AKD’ nin öğrenme zamanı saniye cinsinden kıyaslamasını göstermektedir. GKATBA [73] ‘nın yapısının önerilen yaklaşımlara benzerliği nedeniyle diğer ATBA algoritmalarından ayrı kıyaslanmıştır. Sonuçlara göre önerilen HPSO-AKD öğrenme zamanı açısından GKATBA ile rekabetçi bir yapıya sahiptir. Tablo 8 ise HPSO-AKD’ nin ATBA-Ozawa [68], ATBA-Li [67] ile veri setlerinin 2000 verilik bir alt kümesi üzerindeki zaman karşılaştırmasını göstermektedir. Alt kümenin kullanılmasının nedeni, ATBA yaklaşımlarının küçük bir alt küme de bile bir zaman yükü getirdiğini göstermektir. Tablo 8’deki sonuçlar bu durumu doğrulamaktadır.

Tablo 7. HSO-AKD ve PSO-AKD’ nin GKATBA ile öğrenme zamanı karşılaştırılması

Veri Seti	HPSO-AKD	PSO-AKD	GKATBA [73]
ForestCovType	1.062	3.597	1.546
DS1	1.288	3.589	1.473
ElecNormNews	1.117	3.237	0.962
PokerHand	1.186	3.492	0.922

Tablo 8. HPSO-AKD ve PSO-AKD' nin ATBA-Ozawa ve ATBA-Li algoritmaları ile öğrenme zamanı karşılaştırılması

Veri Seti	HPSO-AKD	PSO-AKD	ATBA-Ozawa [68]	ATBA-Li [67]
ForestCovType	0.106	0.35	140.3	760.61
DS1	0.128	0.35	15.11	702.09
ElecNormNews	0.111	0.32	14.43	702.21
PokerHand	0.118	0.34	16.48	840.61

2.2. Aşırı Öğrenme Makineleri ve Temsili Öğrenmeye Dayalı Akan Veri Öğrenme Yaklaşımı


AKD ve sürü zekasına dayalı akan veri öznitelik çıkartma ve öznitelik seçme yaklaşımı tek başına başarılı sonuç elde etmiştir. Fakat bu çalışmadan çıkarılan önemli bir sonuç öznitelik çıkartma ve indirgeme yaklaşımının başarısının akan veri yapısına uygun bir öğrenme yaklaşımı ile daha da artacağıdır. Bu nedenle bu çalışmada sınıflandırma temelli akan veri öğrenme yaklaşımı gerçekleştirilmiştir.

Akan veri sınıflandırılması son yıllarda büyük ilgi gören bir alandır ve araştırmacılar akan veri sınırlamalarını göz önünde bulundurarak akan veri sınıflandırma algoritmaları tasarlamaktadırlar [181]. Sinir ağlarının hızlı evrimi ve artımlı öğrenme yapısına bir nebze benzerliği araştırmacıların sinir ağı tabanlı akan sınıflandırma yaklaşımları geliştirmeye başlamasına yol açmıştır. Literatürde son yıllarda AÖM' nin artımlı öğrenmeye sahip bir versiyonu olan Çevrim içi Ardışıl-Aşırı Öğrenme Makineleri (ÇA-AÖM)' ne [86] dayalı genel bilgiler bölümünde de anlatıldığı gibi birçok akan veri sınıflandırma yaklaşımı önerilmiştir.

Artımlı öğrenme algoritması olan ÇA-AÖM akan verinin tüm gereksinimlerini karşılamaktadır. Algoritma, yeniden eğitime gerek kalmadan sınıflandırma modelini aşamalı olarak güncellemektedir. Bu durum, ÇA-AÖM' nin diğer algoritmalarla göre hız avantajına sahip olmasını sağlamaktadır. Fakat AÖM ve AÖM' den türetilmiş algoritmalar, giriş ve gizli katmanlar arasında rastgele ağırlık tayinine dayanmaktadır. Rastgele atanan giriş katmanı ağırlıkları, kötü koşullu bir matris problemi oluşmasına, istikrarsız ağ davranışı sergileyerek istikrarsız çözümler üretmesine ve verilerin gizli katmanda iyi ayrıştırılamayacağı ve temsil edilemeyeceği uzaya iz düşürülmesine neden olabilmektedir [17, 182-186]. Kötü koşullandırılmış matris nedeniyle ağ modeli geleneksel sinir ağlarının sahip olduğundan daha fazla gizli katman düğümleri gerektirme eğiliminde olabilmektedir [187-190]. Bu durum da anında cevap verilmesine gereken akan veri için zaman maliyeti

demektir. Bu problemlerin üstesinden gelmek için rastgele atama yerine giriş katmanı ağırlıklarının Kısıtlı Boltzmann Makineleri (KBM) [184], AÖM otokodlayıcı (AÖM-OK) [186, 191], Hatayı Geri Yayan Sinir ağları [182] ve TBA [182] gibi yaklaşımlarla hesaplanmasına dayanan AÖM yaklaşımları geliştirilmiştir [192].


AÖM-OK' nin orijinal verilerin ana özelliklerini elde eden bir ön öğrenme yaklaşımı olması, giriş olarak aldığı verileri tekrar üretebilen bir ağ yapısı elde etmeye dayanması ve yapı olarak akan verilere en uygun yapıya sahip olması ve giriş verilerini temsil eden temel bileşenleri bulabilmesi bu çalışmanın AÖM-OK temsili öğrenme yaklaşımına dayalı danışmanlı bir akan veri öğrenme yaklaşımı kurulmasına neden olmuştur. Çalışmada ÇA-AÖM artımlı öğrenme algoritması ile AÖM-OK temsili öğrenme algoritması birleştirilerek daha tutarlı ve içerik farklılaşmasına dayanıklı akan veri sınıflandırma yaklaşımı önerilmiştir. Bu çalışmanın en büyük katkısıdır. Ayrıca yaklaşımın tutarlılığı topluluk öğrenme yapısı kullanılarak güçlendirilmiştir.



Şekil 19. ÇA-AÖM ve AÖM-OK' dan oluşan akan veri öğrenme yaklaşımının akış şeması

Şekil 19' da algoritmasına ait akış şeması verilen yaklaşım topluluk öğrenmesine dayanmaktadır. Yani birden çok sınıflandırıcı kullanılmaktadır karar çoğunluk oylamasına göre verilmektedir. Çoğunluk oylaması kullanıldığı için sınıflandırıcı sayısı tek sayı olarak

belirlenmiştir. Her sınıflandırıcı ÇA-AÖM’ de olduğu gibi ilklendirme ve ardışıl öğrenme olmak üzere iki aşamadan oluşmaktadır. AÖM-OK ilklendirme aşamasında yer almaktadır ve ilklendirme aşamasında TKİBA yapısının ilk modeli oluşturulmaktadır. Ardışıl öğrenme aşamasında ise yeni gelen her veri ile mevcut TKİBA modeli güncellenmektedir. Yaklaşımda önce test sonra eğitim mantığı benimsenmiştir. Yani ardışıl öğrenme aşamasında her veri önce bir önceki veri ile güncellenen mevcut TKİBA ile test edilmektedir ve sonra o anki veri ile TKİBA güncellenmektedir. Topluluk öğrenmesine dayanan yaklaşımın genel yapısı ise Şekil 20’ deki gibidir.




Şekil 20. Yaklaşımdaki topluluk öğrenmesinin genel yapısı

2.2.1. İlklendirme Aşaması

Bölüm 1.7.4.’ te de bahsedildiği gibi ÇA-AÖM’ nin ilk aşaması olan ilklendirme aşaması, TKİBA’ ın ilk modelini oluşturmayı amaçlamaktadır. ÇA-AÖM verileri ardışıl olarak teker teker ya da yığınlar halinde ele alarak ağ yapısını oluşturmaktadır. İlklendirme

aşamasında eşitlik (30) şeklinde ifade edilen N_0 ilk veri yığını kullanılmaktadır ve bu veri yığınınına göre ağ modeli inşa edilmektedir.

$$X = \{(x_i, t_i) | i = 1, \dots, N_0\}, \quad x_i = [x_{i1}, x_{i2}, \dots, x_{ia}] \quad (30)$$




Şekil 21. ÇA-AÖM ve AÖM-OK ile kurulan ilklendirme aşamasının gösterimi

ÇA-AÖM’deki ilklendirme aşamasında giriş katmanı ile gizli katman arasındaki ağırlıkları (gizli katman ağırlıkları da denilmektedir.) rastgele atamaktadır ve bir daha asla değiştirilmemektedir. Bu yapı ile iyi bir genelleştirme performansı kazanmayı hedeflenmiştir [81]. Rastgele atanan girdi ağırlıkları, TKİBA’ya iyi bir genelleme yeteneği sağlasa da giriş verilerinin gizli katmanda en iyi temsil edecek uzaya iz düşürmesini garanti etmemektedir. Ayrıca tutarsız davranışa sahip sınıflandırıcıların oluşmasına ve buna bağlı olarak tutarsız sonuçlar elde edilmesine neden olabilmektedir. Çalışma sırasında kötü koşullandırılmış matrisin oluşturulması ve ağ sonucu elde edememe gibi başka bir durumla karşı karşıya kalınmasına da neden olabilmektedir. Bu durum, kötü sonuçlara sahip tutarsız ve kötü yapılandırılmış bir TKİBA’ oluşmasına neden olabilmektedir. Çalışmada bu sorunları önlemek için [191] giriş katmanı ve gizli katmanı arasındaki ağırlıkların temsili öğrenme yaklaşımı olan AÖM-OK kullanılarak verinin kendisinden elde edilmesi gerçekleştirilmiştir. Ağırlıklar hesaplandıktan sonra ÇA-AÖM’lerinde olduğu gibi ağ modeli öz yineleme olmadan analitik bir şekilde hesaplanarak oluşturulmaktadır. Sürecin genel görünümü Şekil 21’de verilmektedir. Bu iki kısım ayrı başlıklar altında detaylandırılacaktır.

2.2.1.1. Aşırı Öğrenme Makineleri Tabanlı Otokodlayıcı

Otokodlayıcı [193] yapay sinir ağı modelinden türetilmiş danışmansız bir makine öğrenmesi yöntemidir. Klasik bir yapay sinir ağı modeli gibi giriş, gizli ve çıkışı katmanı olmak üzere üç katmandan oluşmaktadır. Otokodlayıcı yapısı ile AÖM yapısı birbirine oldukça benzemektedir. İki yapıda da tek gizli katmandan oluşmaktadır. Bu benzerlikten yola çıkarak otokodlayıcı yapısını AÖM mantığıyla gerçekleştiren AÖM tabanlı otokodlayıcı (AÖM-OK) fikri ortaya atılmıştır [194].



Şekil 22. AÖM-OK ağ modeli

AÖM-OK, AÖM' den türetilmiş etiketsiz veriler üzerinde danışmansız bir öğrenme sağlayan temsili öğrenme algoritmasıdır. Orijinal veriyi başka bir özellik uzayında temsil etmeyi sağlamaktadır. Özyinelemeli geleneksel otokodlayıcının aksine ağırlıkları özyineleme kullanmadan AÖM'nin temel teorisine göre hesaplayan ileri beslemeli bir yöntemdir. Şekil 22' de gösterildiği gibi AÖM-OK bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşmaktadır. AÖM-OK' de de tıpkı AÖM'de olduğu gibi giriş katmanı ile gizli katman ağırlıkları a_{AE} rastgele olarak atanırken, gizli katman ile çıkış katmanı arasındaki ağırlıklar (β_{AE}) analitik olarak belirlenmektedir. Bir kez gizli katman ağırlıkları belirlendikten sonra güncelleme olmamaktadır. Gizli katman ağırlıklarını belirlerken AÖM-AE, AÖM' nin tersine etiket değerleri (T) kullanmaz. Bu değer yerine (X) giriş verisini kullanır. Böylelikle giriş verisini girdi olarak verip, çıkışta bu değeri üretebilecek en iyi ağırlıklar elde edilmiş olunmaktadır. Otokodlayıcının amacı giriş olarak aldığı verileri ağırlık çıkışında minimum hata ile üretebilecek ağ yapısını elde etmektir. Bu nedenle çıkış

katmanındaki nöron sayıları giriş sayıları ile aynıdır. AÖM-OK giriş verisinin özelliklerini 3 farklı yapıda öğrenebilmektedir:

- Sıkıştırılmış temsil: Gizli katman nöron sayısının giriş katmanı nöron sayısından küçük olduğu durumda gerçekleşmektedir. Bu durumda (β_{AE}) eşitlik (31)' deki gibi hesaplanmaktadır.

$$\beta_{AE} = \left(\frac{I}{C} + H^T H\right)^{-1} H^T X \quad (31)$$

- Eşit boyutta temsil: Gizli katman nöron sayısının giriş katmanı nöron sayısına eşit olduğu durumda gerçekleşmektedir. Bu durumda (β_{AE}) eşitlik (32)' deki gibi hesaplanmaktadır.

$$\beta_{AE} = H^{-1} X \quad (32)$$

- Seyrek temsil: Gizli katman nöron sayısının giriş katmanı nöron sayısından büyük olduğu durumda gerçekleşmektedir. Bu durumda (β_{AE}) eşitlik (33)' deki gibi hesaplanmaktadır.

$$\beta_{AE} = H^T \left(\frac{I}{C} + H^T H\right)^{-1} X \quad (33)$$

Bu çalışmada da AÖM-K ile giriş verilerini çıkış katmanında çıktı olarak yeniden üretebilen en iyi TKİBA parametrelerinin (β_{AE}) hesaplanması amaçlanmaktadır. Bunu gerçekleştirmek için, AÖM-OK 'nın çıkış katmanı ağırlıkları, AÖM algoritmasıyla aynı algoritma kullanılarak belirlenmektedir. Kullanılan algoritma, Algoritma 4'te verilmiştir. Burada hesaplanan ağırlıklar, girdileri en iyi ayırt edici özellik uzayına iz düşürebilme özelliğine sahiptir. AÖM-OK ilk veri yığını olan N_0 için icra edilmektedir ve elde edilen ağırlıklar bu yığın kullanılarak hesaplanmaktadır.

Algoritma 4 : AÖM-OK

Girdi: Eğitim seti $X = \{(x_i, t_i) | i = 1, 2, \dots, N_0\}$, aktivasyon fonksiyonu $g(x)$, gizli katmandaki, nöron sayısı L

Çıkış: Çıktı katmanı ağırlıkları β_{AE}

1: Giriş katmanı ile gizli katman arasındaki ağırlıkları a_{AEj} ve gizli katman biası b_{AEj} rastgele olarak ata. $j = 1, 2, \dots, L$

2: Gizli katman çıkış matrisi H_{AE} eşitlik (34)' deki gibi hesapla.

$$H_{AE} = \begin{pmatrix} g(a_{AE1}, b_{AE1}, x_1) & \cdots & g(a_{AEL}, b_{AEL}, x_1) \\ \vdots & \ddots & \vdots \\ g(a_{AE1}, b_{AE1}, x_{N_0}) & \cdots & g(a_{AEL}, b_{AEL}, x_{N_0}) \end{pmatrix} \quad (34)$$

3: Çıkış ağırlıkları β_{AE} 'yi hesapla.

$$\beta_{AE} = \begin{cases} H^{-1}X, & L = N \\ H^T (\frac{I}{C} + H^T H)^{-1} X, & \text{aksi takdirde} \end{cases} \quad (32)$$

$$(33)$$

4: β_{AE} geri döndür.

2.2.1.2. Ağ Modelini Oluşturma

AÖM-OK ile elde edilen β_{AE} ağırlıkları N_0 yığınının temel özelliklerini çıkarmak için temel bir rol oynamaktadır. AÖM-AE simetrik yapıdadır ve üretilen çıkış verileri ile giriş verilerini tekrar üretmek istendiğinde hesaplanan ağırlık olan β_{AE} 'nin transpozesi β_{AE}^T ile geriye doğru işlem yapılması gerekmektedir. Tersine yapılan işlemde β_{AE}^T , gizli katmanda verilerin en iyi ayrışabildiği ve temsil edildiği uzaya iz düşürmektedir. Başka bir deyişle, hesaplanan ağırlıklar girdiyi en iyi özellik uzayıyla eşleyebilmektedir. Bu nedenle hesaplanan bu ağırlık değerleri (β_{AE}^T) ÇA-AÖM öğrenme ağının giriş ile gizli katmanı arasındaki ağırlıklara a atanırsa, öğrenme ağında gizli katmanda veriyi en iyi uzaya eşlenebilmesi sağlanabilmektedir. Rastgele atanan ağırlıklar yerine ağırlıkların verinin kendisinden hesaplanması, gizli katmanda en iyi gizli katman matrisinin elde edilmesini sağlamaktadır. Bu nedenle çalışmada β_{AE}^T ilklendirme için giriş ağırlıklarına a eşitlik (35) 'te ki gibi atanmaktadır.

$$a = \beta_{AE}^T \quad (35)$$

Bu işlemden sonrası TKİBA' ın ilk modelinin oluşturma aşamasıdır. Bunun için sınıflandırıcının çıkış katmanı ağırlıklarının ($\beta^{(0)}$) N_0 yığını için hesaplanması

gerekmektedir. Çıkış katmanı ağırlıkları ÇA-AÖM' in ilklendirme aşamasındaki gibi elde edilmektedir. Ağırlıkların hesaplanması eşitlik (36) ve (37)' de gösterildiği gibidir.

$$\mathbf{K}_0 = (\mathbf{H}_0^T \mathbf{H}_0) \quad (36)$$

$$\boldsymbol{\beta}^{(0)} = \mathbf{K}_0^{-1} \mathbf{H}_0^T \mathbf{T}_0 \quad (37)$$

Böylece, TKİBA sınıflandırıcısının gizli katmanında en iyi temsili özellikler ve çıktı ağırlıkları elde edilmektedir ve ilk TKİBA modeli oluşturulmaktadır. Çalışmanın ilklendirme aşaması, Algoritma 5' te açıklanmaktadır.

Algoritma 5: İlklendirme Aşaması

Girdi: Eğitim seti $\mathbf{X} = \{(\mathbf{x}_i, t_i) | i = 1, 2, \dots, N_0\}$, aktivasyon fonksiyonu $g(\mathbf{x})$, gizli katmandaki, nöron sayısı L , yığın indeksi k

Çıkış: $\mathbf{K}_0$ ve Çıktı katmanı ağırlıkları $\boldsymbol{\beta}^{(0)}$

- 1) AÖM-OK' yı N_0 yığına uygula ve otokodlayıcının çıkış katmanı ağırlıkları $\boldsymbol{\beta}_{AE}$ as Algoritma 4 'teki gibi hesapla.
- 2) Eşitlik (35)' teki gibi $\boldsymbol{\beta}_{AE}$ 'nin transpozmesini TKİBA sınıflandırıcının giriş ile gizli katmanı arasındaki ağırlıklara $\mathbf{a}_j$ ata. $j = 1, 2, \dots, L$
- 3) Gizli katman çıkış matrisini $\mathbf{H}_0$ (38)' deki gibi hesapla.

$$\mathbf{H}_0 = \begin{pmatrix} g(a_1, b_1, \mathbf{x}_1) & \dots & g(a_L, b_L, \mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ g(a_1, b_1, \mathbf{x}_{N_0}) & \dots & g(a_L, b_L, \mathbf{x}_{N_0}) \end{pmatrix} \quad (38)$$

- 4) $\mathbf{K}_0$ ve $\boldsymbol{\beta}^{(0)}$ formül (36) ve (37) 'deki gibi hesapla.
 - 5) $k = 0$.
 - 6) Yığının doğruluk değeri A_0 hesapla.
 - 7) A_0 , $\mathbf{K}_0$ and $\boldsymbol{\beta}^{(0)}$ geri döndür.
-

2.2.2. Ardışıl Öğrenme Aşaması

Çalışmadaki ardışıl öğrenme aşaması, ÇA-AÖM' nin sahip olduğu ardışıl öğrenme aşamasıyla aynı mantığı benimsemektedir. Bu aşama ilk TKİBA sınıflandırıcısının oluşturulmasından sonra başlamaktadır. N_0 yığınının sonra oluşan her bir veri ya yığın olarak ya da birer birer olarak TKİBA modelini güncellemek için sırayla işlenmektedir. Akan veri işleme yaklaşımlarında kullanılan önce test sonra eğitim mantığı kullanıldığı için her yığın önce mevcut model ile test edilmektedir. Daha sonra model bu yığın ile güncellenmektedir. Ardışıl öğrenme aşamasının adımları Algoritma 6'da verilmiştir.

Algoritma 6: Ardışıl Öğrenme Aşaması

Girdi: Eğitim seti $\mathbf{X} = \{(\mathbf{x}_i, t_i) | i = 1, 2, \dots, N\}$, aktivasyon fonksiyonu $g(\mathbf{x})$, gizli katmandaki, nöron sayısı L , yığın indeksi $k + 1$

Çıkış: $\mathbf{K}_{k+1}$ ve Çıktı katmanı ağırlıkları $\boldsymbol{\beta}^{k+1}$

- 1) Mevcut ağ modeli ile N_{k+1} yığınını test et ve A_{k+1} doğruluğunu hesapla.
- 2) Gizli katman çıkış matrisini $\mathbf{H}_{k+1}$ (39)' deki gibi hesapla.

$$\mathbf{H}_{k+1} = \begin{bmatrix} g(\mathbf{a}_1, b_1, \mathbf{x}_{(\sum_{j=0}^k N_j)+1}) & \cdots & g(\mathbf{a}_L, b_L, \mathbf{x}_{(\sum_{j=0}^k N_j)+1}) \\ \vdots & \ddots & \vdots \\ g(\mathbf{a}_1, b_1, \mathbf{x}_{(\sum_{j=0}^{k+1} N_j)}) & \cdots & g(\mathbf{a}_L, b_L, \mathbf{x}_{(\sum_{j=0}^{k+1} N_j)}) \end{bmatrix} \quad (39)$$

- 3) $\mathbf{K}_{k+1}^{-1}$ ve çıkış katman ağırlıkları $\boldsymbol{\beta}^{(k+1)}$ 'i N_{k+1} yığını ile güncelle.

$$\mathbf{K}_{k+1}^{-1} = \mathbf{K}_k^{-1} - \mathbf{K}_k^{-1} \mathbf{H}_{k+1}^T (\mathbf{I} + \mathbf{H}_{k+1} \mathbf{K}_k^{-1} \mathbf{H}_{k+1}^T)^{-1} \mathbf{H}_{k+1} \mathbf{K}_k^{-1} \quad (40)$$

$$\boldsymbol{\beta}^{(k+1)} = \boldsymbol{\beta}^{(k)} + \mathbf{K}_{k+1}^{-1} \mathbf{H}_{k+1}^T (\mathbf{T}_{k+1} - \mathbf{H}_{k+1} \boldsymbol{\beta}^{(k)}) \quad (41)$$

- 4) A_{k+1} , $\mathbf{K}_{k+1}^{-1}$ and $\boldsymbol{\beta}^{(k+1)}$ geri döndür.
-

2.2.3. Topluluk Öğrenmesi ile Nihai Karar

Çalışmada nihai karar topluluk öğrenmesi ile birden çok TKİBA sınıflandırıcısının her veri ya da veri yığını için ürettikleri sonuçların oylanması ile verilmektedir. Birden çok sınıflandırıcı yer almaktadır ve her biri kendi bireysel sonuçlarını mevcut veri yığını için vermektedir. Bu sınıflandırıcıların hepsi aynı ağ yapısına sahiptir. AÖM-OK ile giriş ile gizli katman arasındaki ağırlıklar belirlenir ve ağ modeli oluşturulur. Sonra her yeni veri yığını için ardışıl öğrenme ile ağ güncellenmektedir. Sınıflandırıcıların farklılaştığı nokta AÖM-OK' ın giriş ile gizli katmanı arasındaki ağırlıkların rastgele üretilmesidir. Böylelikle otokodlayıcı tutarsızlığı önlemenin yanı sıra sınıflandırıcıların farklılaşmasını da sağlamaktadır.

Topluluk çalışmasında nihai karar her bir sınıflandırıcının sonuçlarının çoğunluk oylaması ile elde edilmesi ile verilmektedir. Çoğunluk oylaması kullanıldığı için sınıflandırıcı sayısı tek sayı olarak belirlenmiştir. Topluluk öğrenmesi ile tek bir öğrenme yaklaşımına bağlı kalmadan birden çok yaklaşıma göre karar verilmesi amaçlanmıştır. Böylelikle akan verilerin sahip olduğu önemli karakteristiklerden biri olan içerik farklılaşmasına sağlamlık artırılması hedeflenmiştir. Ayrıca tüm öğrenme yaklaşımlarının birbirine destek vererek performans artışı sağlanması da amaçlanmıştır.

2.2.4. Deneysel Sonuçlar

Bu bölümde, temsili öğrenme yaklaşımı olan AÖM-OK ile ağ parametresinin hesaplanmasına dayanan ÇA-AÖM akan veri öğrenme yaklaşımının değerlendirilmesi gerçek ve yapay veri setlerinde üzerinde sunulmuştur. Sunulan yaklaşımın performansını ölçmek ve tutarlılığını görebilmek için orijinal ÇA-AÖM [86] karşılaştırma yaparak analiz gerçekleştirilmiştir.

Önerilen yaklaşım ve orijinal ÇA-AÖM, MATLAB (R2016b) ortamında hazırlanmıştır. ÇA-AÖM orijinal çalışmasında raporlandığı gibi uygulanmıştır.

Çalışmada üç ana analize odaklanılmıştır. Birincisi, sınıflandırma performansını karşılaştırmalı olarak incelenmesidir. Burada Doğruluk oranı (DO) [%] ve Yanlış Sınıflandırılan Veri Sayısı (YSVS) ilk deneydeki değerlendirme ölçütleridir. Diğer deney, farklı sınıflandırıcı sayılarında yaklaşımın davranışının analizidir. Son analiz ise ardışıl

öğrenme aşamasındaki yığınlardaki veri sayısının etkisini incelemektedir. AKD katsayılarının varyasyonunun etkisini incelemektir.

Bu çalışmada gerçek veri setleri olarak ForestCovType, ElecNormNews, Pendigits ve EEG-Eye kullanılırken; sentetik veri seti olarak Hyperplane ve Led veri setleri kullanılmıştır.

2.2.4.1. Sınıflandırma Performansı

Çalışmada önerilen yöntemin sınıflandırma performansının analizi, orijinal ÇA-AÖM yaklaşımı kullanılarak gerçekleştirilmiştir ve sonuçlar Tablo 9’ da verilmiştir. Bu analiz gizli katman nöron sayısının (L) 35, 70 ve 100 olduğu 3 farklı durum için gerçekleştirilmiş ve performans karşılaştırılmalı olarak incelenmiştir. N_0 100 olarak belirlenmiş ve topluluk sınıflandırıcı sayısının 1 olduğu durumda sonuçlar elde edilmiştir.

Tablo 9 incelendiğinde AÖM-OK ile AÖM TKİBA yapısındaki giriş ile gizli katman arasındaki ağırlıkların veri kullanılarak elde edilmesinin öğrenme yaklaşımının performansına pozitif bir katkı yaptığı görülmektedir. Bu katkı üç nöron sayısındaki sonuçlarda da gözükmemektedir. Genelleme yapmak gerekirse $L = 70$ nöron sayısında en iyi sonuçların elde edildiği söylenebilmektedir.

Tablo 9. AÖM-OK dayanan ÇA-AÖM yaklaşımının orijinal ÇA-AÖM ile YSVS ve DO üzerinden karşılaştırılması

Veri Setleri /Veri Sayısı	ÇA-AÖM+AÖM-OK			ÇA-AÖM [86]		
	L=35	L=70	L=100	L=35	L=70	L=100
a) YSVS						
ForestCovType / (581012)	188155	201065	314350	204091	184086	421160
ElecNormNews / (45312)	10768	19928	22232	10866	21834	22605
Pendigits / (7494)	383	717	328	750	444	334
Hyperplane / (50000)	11686	8846	9408	14198	11069	10069
Led / (50000)	14942	13814	17231	15460	14103	13908
EEG eye / (14980)	6237	6171	6397	6259	6175	6103
b) DO						
ForestCovType / (581012)	0.6762	0.6539	0.4590	0.6487	0.6832	0.2751
ElecNormNews / (45312)	0.7624	0.5602	0.5094	0.7602	0.5181	0.5011
Pendigits / (7494)	0.9489	0.9043	0.9562	0.8999	0.9408	0.9554
Hyperplane / (50000)	0.7663	0.8231	0.8118	0.7160	0.7786	0.7986
Led / (50000)	0.7012	0.7237	0.6554	0.6908	0.7179	0.7218
EEG eye / (14980)	0.5836	0.5881	0.5730	0.5822	0.5878	0.5926


2.2.4.2. Topluluk Sınıflandırıcı Sayısının Analizi

Bu bölümde topluluk öğrenmesinde yer alan sınıflandırıcı sayılarının yaklaşımının performansına etkisini incelenmektedir. Bunun için sınıflandırıcı sayısı (SS) 1, 3, 5, 7 ve 9 olduğu durumlarda YSVS ve DO sonuçları elde edilmiştir. Tüm SS durumlarında $N_0 = 100$ olarak belirlenmiş, gizli katman nöron sayısı da bir önceki analizin sonuçlarından biri olarak $L = 70$ şeklinde atanmıştır. Bu analizin sonuçları Tablo 10' da verilmiştir.


Tablo 10'daki sonuçlara göre, sınıflandırıcı sayısının artması yaklaşımın daha iyi bir performans sergilemesini sağlamaktadır. Bunun en önemli sebebi olarak sınıflandırıcıların birbirlerine katkı sağlaması ve bu katkı ile içerik farklılaşması durumunda daha doğru karar alınmasını sağlaması verilebilmektedir. Tablo 10'daki sonuçların geneli incelendiğinde topluluk sınıflandırıcısı sayısının optimum değerinin 7 olarak belirlenmesi sonucuna ulaşılabilmektedir. Çünkü 9 olduğu durumda veri setlerinin çoğunda performans düşüşü gerçekleşmiştir. Bu nedenle, sınıflandırıcı sayısının artması her zaman yüksek performansa ulaşılabileceğinin garantisini olmadığını ve bir optimum değer belirlenmesinin gerektiğini göstermektedir.

Tablo 10. AÖM-OK dayanan ÇA-AÖM yaklaşımının topluluk öğrenmesi performansı


Veri Setleri /Veri Sayısı	ÇA-AÖM+AÖM-OK				
	SS=1	SS=3	SS=5	SS=7	SS=9
a) YSVS					
ForestCovType / (581012)	188155	188637	188407	187405	187363
ElecNormNews / (45312)	19928	12972	11564	11350	10785
Pendigits / (7494)	383	323	288	248	248
Hyperplane / (50000)	8846	8811	8792	8741	8735
Led / (50000)	13814	13121	13071	12997	13001
EEG eye / (14980)	6181	6153	6144	6140	6179
b) DO					
ForestCovType / (581012)	0.6762	0.6753	0.6757	0.6757	0.6775
ElecNormNews / (45312)	0.7624	0.7137	0.7448	0.7495	0.7620
Pendigits / (7494)	0.9489	0.9569	0.9616	0.9669	0.9669
Hyperplane / (50000)	0.7663	0.8238	0.8242	0.8252	0.8253
Led / (50000)	0.7012	0.7376	0.7386	0.7205	0.7400
EEG eye / (14980)	0.5836	0.5893	0.5899	0.5901	0.5875




(a)




(b)



(c)



(d)



(e)

Şekil 23. Ardışıl yığınlardaki veri sayısının yaklaşımın performansına (a) Pendigits (b) ElecNormNews (c) EEG Eye (d) ForestCovType ve (e) Hyperplane veri setleri üzerinde etkisinin analizi

2.2.4.3. Ardışıl Yığınlardaki Veri Sayısının Performansa Etkisinin Analizi

Bu bölümde ardışıl yığınlardaki veri sayısının önerilen yaklaşımın performansına etkisi incelenmiştir. Bunun için 1 ve 9 sınıflandırıcı sayılarında ardışıl yığın veri sayılarının (N_{k+1}) 25, 50, 75 ve 100 olduğu durumlarda DO üzerinde analiz gerçekleştirilmiştir. Analize ait sonuçlar Şekil 23’ te verilmektedir.

Sonuçlar incelendiğinde ardışıl yığındaki veri sayısının artması performansa olumsuz bir etki yaptığı söylenebilmektedir. En iyi durum tüm veri setleri için 1 ve 9 sınıflandırıcı koşullarında veri sayısının 25 olduğu durumda elde edilmektedir.

2.3. İçerik Farklılaşmasına Dayanıklı Danışmansız Özellik Temsiline Dayanan Çevrimiçi Ardışıl Aşırı Öğrenme Yaklaşımı

ÇA-AÖM ve AÖM-OK’ ye dayanan akan veri topluluk öğrenme yaklaşımı, ÇA-AÖM’ nin ağ yapısında olan ve sonuçlara yansıyan tutarsızlık, kötü koşullandırılmış matris oluşması gibi sorunları ortadan kaldıran bir yaklaşım olarak önerilmiştir. Buna bağlı olarak elde edilen sonuçlar bunu destekler niteliktedir. Fakat bu yaklaşımın eksik yönü akan verinin en önemli karakteristiği olan içerik farklılaşmasına çok fazla çözüm üretememesidir. Yaklaşım her ne kadar kademeli içerik farklılaşmasını algılayıp uyum sağlayabilse de ani gerçekleşen içerik farklılaşmalarına çözüm üretememektedir. Bu nedenle bu çalışma içerik farklılaşması adaptasyon ve algılama mekanizmasına sahip bir akan veri öğrenme yaklaşımı sunulmaktadır. Bu yaklaşım ÇA-AÖM ve AÖM-OK’ ye dayanan çalışmaya içerik farklılaşması mekanizması eklenerek geliştirilmiştir.

Kısa bir öğrenme süresine sahip olduğu için, AÖM tabanlı sınıflandırma yaklaşımları, verilere hızlı yanıt verme açısından akan veriler için uygundur. Fakat mevcut AÖM sınıflandırıcılarının birçoğu, akan verinin içerik farklılaşması karakteristiğini ele almak için yetersiz kalmaktadır. Her ne kadar ÇA-AÖM kademeli içerik farklılaşmasına bir nebze de olsa adapte olabilse de diğer türlere adaptasyon da başarılı olamamaktadır. Giriş verilerinin en iyi özellikleri elde edilerek oluşturulmuş doğru, kararlı ve iyi yapılandırılmış bir akan veri sınıflandırıcısına ihtiyaç vardır. Kararlı yapılandırılmış sınıflandırıcı, akan verinin içerik farklılaşması karakteristiğini de dikkate almalıdır. Bu motivasyonla, çalışmanın bu aşamasında akan veri için içerik farklılaşması mekanizmasına sahip yeni ve iyi yapılandırılmış bir sınıflandırma yaklaşımı sunulmuştur. Amaç, akan verinin tüm

özelliklerini göz önünde bulundurarak tüm gereksinimlerine yanıt veren bir akan veri sınıflandırma yaklaşımı oluşturmaktır. Sunulan yaklaşım, denetimsiz özellik temsili çevrimiçi ardışıl-AÖM (DÖTÇA-AÖM) olarak adlandırılmıştır. Bir önceki çalışmaya bir Hoeffding Sınırı' na dayanan bir içerik farklılaşması algılama ile AÖM-OK' ya dayanan içerik farklılaşmasına adaptasyonu sağlayan yeniden ağ inşası aşamaları eklenerek TKİBA sınıflandırıcısı geliştirilmiştir.

DÖTÇA-AÖM, ilklendirme ve ardışıl öğrenme aşamalarından oluşmaktadır. İlklendirme aşamasında bir önceki çalışmada olduğu gibi ilk veri yığını ile TKİBA sınıflandırıcısı oluşturulmaktadır ve bunun için yine AÖM-OK ile giriş katmanı ile gizli katmana ağırlıkları hesaplanmaktadır. Ardışıl öğrenme aşamasında, yığınlar TKİBA sınıflandırıcısını güncellemek için sırayla ele alınmaktadır. İçerik farklılaşması tespiti ve yeni içeriğe adaptasyon bu aşamada gerçekleştirilmektedir. Bu aşamada ilk önce Hoeffding Sınır Teoremi kullanılarak içerik farklılaşması olup olmadığı araştırılmaktadır. Eğer bir değişiklik algılanmazsa TKİBA mevcut yığın ile güncellenmektedir. İçerik farklılaşması tespit edildiğinde, yeni konsepte uygun bir şekilde ağ modeli inşa etmek, en iyi özellikleri ve parametreleri elde etmek için kullanılan AÖM-OK yeniden etkinleştirilir ve ilklendirme aşamasındaki ağ modeli yeni konsept için yeniden kurulmaktadır. Çalışma topluluk öğrenmesine dayalı bir yaklaşımdır. Her veri yığını için kara birden çok DÖTÇA-AÖM' nin sonuçlarının çoğunluk oylamasına dayalı olarak alınmaktadır. Sunulan çalışmanın katkıları aşağıdaki gibi sıralanabilmektedir:


- Akan veri için DÖTÇA-AÖM adlı yeni, verimli ve sıralı bir sınıflandırma algoritması geliştirilmiştir. Akan verinin kademeli ve ani içerik farklılaşması karakteristikleri ile başarılı bir şekilde başa çıkabilmektedir. DÖTÇA-AÖM, ÇA-AÖM ve AÖM-OK' nın bir kombinasyonuna dayanmaktadır. Bu kombinasyon, akan veri ve akan veri sınıflandırması için yenidir ve akan verinin tüm özelliklerine yanıt verebilmektedir.

- AÖM tabanlı akan veri yaklaşımları, giriş katmanı ağırlıklarının rastgele atamaktadır. Çalışmada AÖM-OK, giriş katmanı ağırlıklarını hesaplamak için kullanılmıştır. Hesaplanan ağırlıklar, girişleri daha ayırt edici alana eşleyebilme ve kararsız sınıflandırıcı modelinin oluşturulmasını engelleyebilme özelliklerine sahiptir. Giriş katmanı ağırlıklarının rastgele atanmasından kaynaklanan sorunları da ortadan kaldırabilmektedirler. Mevcut akan veri sınıflandırma yaklaşımlarıyla karşılaştırıldığında, DÖTÇA-AÖM daha kararlı davranış gösterme eğilimindedir ve daha yüksek doğruluk oranları elde etmektedir.

- Sunulan yaklaşım, içerik farklılaşması algılama ve uyum sağlama mekanizmasına sahiptir. İçerik farklılaşması tespit edildiğinde AÖM-OK değişim tespit edilen yığını kullanarak sınıflandırıcıyı mevcut konsepte uyarlamak için görev alır. AÖM-OK tabanlı ilklendirme stratejisi, daha düşük ek zaman yükü ile doğruluğu arttırmaktadır.

- Sunulan yaklaşım, çoklu DÖTÇA-AÖM 'ye dayalı bir topluluk öğrenme stratejisi kullanmaktadır. Topluluk DÖTÇA-AÖM, akan veri sınıflandırma performansını iyileştirmektedir ve içerik farklılaşmasına karşı daha sağlamlık sağlamaktadır.

DÖTÇA-AÖM' nin akış şeması Şekil 24' te verilmiştir. Aşamalar alt başlıklarda detaylandırılacaktır.



Şekil 24. DÖTÇA-AÖM yaklaşımının akış şeması

2.3.1. İlklendirme Aşaması

DÖTÇA-AÖM' nin ilklendirme aşaması bir önceki çalışmanın ilklendirme aşaması ile aynı yapıya sahiptir. Bu aşama, TKİBA' ın ilk modelini oluşturmayı amaçlamaktadır. Bu model oluştururken eşitlik (42) şeklinde ifade edilen ilk veri yığını olan N_0 kullanılmaktadır.

$$X = \{(x_i, t_i) | i = 1, \dots, N_0\}, \quad x_i = [x_{i1}, x_{i2}, \dots, x_{ia}] \quad (42)$$

Ağ modelini oluştururken yine aynı şekilde giriş katmanı ile gizli katman arasındaki ağırlıklar AÖM-OK kullanılarak hesaplanmaktadır. AÖM-OK giriş olarak adlıği N_0 veri yığınını çıkış olarak da üretebildiği en iyi ağ modelini inşa etmektedir. Böylelikle veriler en iyi ayrıştırılabileceği uzaya iz düşürülerek en ayırıcı özellikleri gizli katmanda elde edilmektedir. Ağın oluşturulması bir önceki çalışmayla aynıdır. Bu aşamaya ait algoritma Algoritma 5 olarak Bölüm 2.2.1.2’ de verilmiştir. Ayrıca sürecin genel görünümü Bölüm 2.2.1’ deki Şekil 21 olarak verilmektedir.

2.3.2. Ardışıl Öğrenme Aşaması

Bu aşama, iklendirme aşamasında TKİBA’ ın ilk modelinin oluşturulmasından sonra başlamaktadır. İlk yığından sonra oluşan her bir veri ya da yığınlar bu aşamada birer birer işlenmektedir. Bu aşamanın bir önceki çalışmanın ardışıl öğrenme aşamasından önemli farkı, içerik farklılaşması algılama ve adaptasyon mekanizmasını içermesidir. İçerik farklılaşmasının olup olmadığını araştıran içerik farklılaşması algılama adımı ağ modeli güncellemeden önce devreye girer. Burada Hoeffding Sınırı Teoremi’ ne dayalı bir algılama işlemi gerçekleşmektedir. İçerik farklılaşması adaptasyon adımı ise herhangi bir farklılaşma tespit edildiğinde icra edilir ve mevcut ağ modelini yeni konsepte göre yeniden inşa eder. Akan veri öğrenme yaklaşımlarında kullanılan önce test-sonra eğitim bu yaklaşımda da benimsenmektedir. Test-sonra-eğitime göre, mevcut veri yığını önce mevcut model ile test edilerek doğruluk oranı elde edilir ve sınıflandırılır. Ardından mevcut TKİBA o anki yığınla ya güncellenir ya da yeniden oluşturulur.

2.3.2.1. İçerik Farklılaşması Algılanması

Akan verilerde içerik farklılaşması çok yaygın bir durumdur ve farklı içerik farklılaşması türleri farklı işleme yöntemlerine sahip olabilmektedir [17]. Akan verideki içerik büyük ölçüde değiştiğinde, mevcut sınıflandırma modelleri mevcut akan veriye uygun olmadığı için hata oranı belirgin bir şekilde artar. Bu nedenle modelin silinmesi ya da yeni konsepti öğrenmesi gerekmektedir. Akan veri sınıflandırma problemlerinde, doğruluk genellikle içerik farklılaşmasını tespit etmek için kullanılan bir metriktir. Doğruluk önemli bir ölçüde değişirse, algoritma bir içerik farklılaşmasının ortaya çıktığını

varsayabilmektedir. Literatürde akan verilerin doğruluklarındaki değişimin anlamlılığını ölçmek için ve değişimi algılamak için Hoeffding Sınır Teoremi [31, 196] kullanılmaktadır.

- Teorem 1 (Hoeffding Sınır Teoremi): Rastgele bağımsız değişken olan r 'in n kere alınan örnekleme olayında; R , r 'nin aralık değeri ve $\bar{r}$, r 'nin ortalama değeri olsun. $1 - \alpha$ güven düzeyiyle, R 'nin gerçek değeri en az $\bar{r} - \varepsilon$ olmaktadır. Burada $\varepsilon = \sqrt{\frac{R^2 \ln(\frac{1}{\alpha})}{2n}}$ olarak ifade edilmektedir.

İçerik farklılaşması algılama mekanizması, iki ardışık yığının doğruluk farkını Hoeffding Teoremi' ne göre inceleyerek karar vermektedir. Hoeffding Sınır Teoremine [31, 110] göre, birbirini izleyen yığınların dağılımı, eğer ikisi de aynı konsepte sahiplerse belirgin bir şekilde değişmez. Bu nedenle, yığınların doğruluk farkı, Hoeffding Sınırı' na göre hesaplanan ε eşik değerinin altında olmalıdır. Bu konu bir örnek ile açıklamak gerekirse, N_1 ilklendirme aşamasından sonra yeni gelen bir yığın olduğunu varsayalım. İlk olarak, N_1 'in doğruluk değeri (A_1) ilk oluşturulan TKİBA öğrenme modeli ile ölçülür. Önceki yığın olan N_0 ile mevcut yığın N_1 arasındaki doğruluk farkı $(A_0 - A_1) \leq \varepsilon$ ise, içerik farklılaşması algılama mekanizması N_1 yığını için içerik farklılaşması olmadığına karar vermektedir. Aksi durumda yani $(A_0 - A_1) > \varepsilon$ ise, TKİBA modeli artık yeni bir konsepte sahip olan mevcut yığını temsil etmek için yeterli olamadığına hata oranını belirgin bir şekilde artacağı sonucuna ulaşılmaktadır. İçerik farklılaşması olup olmadığına göre ardışıl öğrenme aşaması iki şekilde dallanmaktadır.

2.3.2.2. İçerik Farklılaşması Algılanmadığı Durumda Ağ modelini Güncelleme

İçerik farklılaşması tespit mekanizması içerik farklılaşmasının olmadığına karar verdiği durumda mevcut TKİBA modeli o an mevcut olan yığın ile ardışıl olarak güncellenmektedir. Güncelleme işlemi bir önceki çalışmada yer alan (40) ve (41) eşitliklerindeki gibi gerçekleşmektedir. Güncelleme işleminden kasıt β^{k+1} ve K_{k+1}^{-1} ağ ağırlık değerlerinin mevcut yığına ait bilgileri de içermesi için yeni değerlerinin hesaplanmasıdır.

2.3.2.3. İçerik Farklılaşması Algılandığı Durumda Yeni Konsepte Adapte Olma

Hoeffding Sınır Teoremi' ne göre iki komşu yığının doğrulukları arasındaki fark eşik değerden fazla çıkmış ise bu aşama icra edilmektedir. Mevcut ağ yeni konsepti temsil edememekte olduğu için hata oranı bu durumda artmaktadır. Bu nedenle, bu aşamada bir yeniden ilklendirme stratejisi kullanılmaktadır. Yeniden ilklendirme stratejisi, sınıflandırıcısının TKİBA parametrelerinin yeniden hesaplanması demektir. İlklendirme aşamasında giriş ile gizli katman arasındaki ağırlıkları mevcut veri yığını üzerinden hesaplayan AÖM-OK, bu aşamada yeniden etkinleştirilir. Mevcut yığın için yeni giriş ile gizli katman arasındaki ağırlıkları belirler ve ardından yeni TKİBA modeli belirlenen ağırlıklarla yeniden yapılandırılır. Başka bir deyişle, içerik farklılaşması algılayıcı değişiklik algıladığında, DÖTÇA-AÖM' nin ilklendirme aşaması, mevcut TKİBA sınıflandırıcısını değişikliklere uyum sağlamasını sağlamak için ardışıl öğrenme aşamasına dahil olmaktadır. Ardışıl öğrenme aşamasının tüm adımlarını içeren algoritma, Algoritma 7' de verilmiştir.

Algoritma 7: Ardışıl Öğrenme Aşaması

Girdi: Eğitim seti $X = \{(x_i, t_i) | i = 1, 2, \dots, N\}$, aktivasyon fonksiyonu $g(x)$, gizli katmandaki, nöron sayısı L , yığın indeksi $k + 1$

Çıkış: K_{k+1} ve Çıktı katmanı ağırlıkları β^{k+1}

- 1) Mevcut ağ modeli ile N_{k+1} yığınını test et ve A_{k+1} doğruluğunu hesapla.
 - 2) Eğer $A_k - A_{k+1} \leq \varepsilon$
 - a. Gizli katman çıkış matrisini H_{k+1} (39)' deki gibi hesapla.
 - b. K_{k+1}^{-1} ve çıkış katman ağırlıkları $\beta^{(k+1)}$ 'i N_{k+1} yığını ile (40) ve (41) eşitliklerindeki gibi güncelle.
 - 3) Aksi takdirde;
 - a. N_{k+1} yığınınında içerik farklılaşması algılandığı için İlklendirme Aşaması'na (Algoritma 5) atla.
 - b. Bu yığın için TKİBA modelini İlklendirme Aşamasındaki gibi yeniden inşa et.
 - 4) A_{k+1} , K_{k+1}^{-1} and $\beta^{(k+1)}$ geri döndür.
-

2.3.3. Topluluk Öğrenmesi ile Nihai Karar

Çalışmada nihai karar, topluluk sınıflandırıcıların her bir veri ya da yığın için ürettikleri bireysel kararların çoğunluk oylamasına tabi tutularak alınmaktadır. Bu kısım bir önceki çalışma ile aynıdır.

2.3.4. Deneysel Sonuçlar

Bu bölümde, DÖTÇA-AÖM' nin değerlendirilmesi yapay ve gerçek veri setleri üzerinde sunulmuştur. ForestCovType, ElecNormNews, KDDCup99, PenDigits, EEG Eye ve Shuttle veri setleri gerçek veri setleri olarak, Hyperplane, Stagger, Waveform, LED, Agrawal ve RandomTree da sentetik veri setleri olarak seçilmiştir. Tüm veri kümeleri akan veri işlenmesi için uygundur ve Pendigits ve Shuttle dışındaki tüm veri kümeleri içerik farklılaşması içermektedir. KDDCup99, Hyperplane ve RandomTree veri kümeleri kademeli içerik farklılaşmasına sahipken, ElecNormNews, ForestCovType, Agrawal ve EEG Eye veri setleri de bilinmeyen türden içerik farklılaşmasına sahiptir [197]. LED ve Waveform veri setleri hem ani hem de kademeli kavram sapmalarına sahiptir. ForestCovType çok büyük ve seyrek bir veri kümesidir ve [44] 'nin bu veri kümesini işleminin zor olduğu bildirilmektedir. Veri setlerinin açıklaması Bölüm 1.6.1' de ayrıntılı olarak verilmiştir. Yaklaşım, MATLAB (2016b)' de uygulanmıştır. Çalışma akan verinin gereksinimlerini daha iyi performansla karşılayan bir sınıflandırma algoritması geliştirmeyi amaçlamaktadır. Bu amaca ulaşmak için performans karşılaştırması için orijinal ÇA-AÖM [86], IDS-ELM [110], DELM [111] ve EOS-ELM [87] algoritmaları kullanılmıştır. ÇA-AÖM ve EOS-ELM, orijinal çalışmalarında raporlandığı şekilde uygulanmıştır. Deneyler, önerilen yaklaşımın başarıldığını göstermek için hem gerçek hem de sentetik veri setleri üzerinde gerçekleştirilmiştir. Deneyler, akan verilerdeki çevrimiçi ve artımlı öğrenme için standart değerlendirme tekniği olan test-sonra-eğitim ile yapılmıştır. Bu tekniğe göre, gelen akan veri örneği veya veri yığınları, mevcut TKİBA modeli tarafından ayrı ayrı test edilir ve doğruluk oranı ölçülür. Daha sonra, TKİBA sınıflandırıcısı, mevcut akan veri örnekleri veya yığınları tarafından sıralı olarak güncellenir.

Çalışmada beş ana analize odaklanılmıştır. Birincisi, sınıflandırma performansını karşılaştırmalı olarak incelenmesidir. Diğer analiz gizli katman nöron sayısının etkisinin araştırılmasıdır. Bir başka analiz içerik farklılaşmasının belirlenmesindeki eşik değerin

etkisinin incelenmesidir. Bu analizler tek bir sınıflandırıcı üzerinden gerçekleştirilmiştir. Bu nedenle analizlerin birisi de topluluk sınıflandırıcıların performansını araştırmaktır. Son olarak içerik farklılaşması ve AÖM-OK' ya bağlı iklendirme mekanizmalarının olmadığı durumlardaki ablasyon deneyleri ile performans incelemesidir.

2.3.4.1. Sınıflandırma Performansı Analizi

Bu bölümde, önerilen DÖTÇA-AÖM' nin performansı, orijinal ÇA-AÖM, IDS-ELM ve DELM ile karşılaştırılarak değerlendirilmektedir ve sonuçlar Tablo 11 ve Tablo 12 'de verilmektedir. Bu analizlerde performans ölçütleri, DO ve YSVS' dir. Tablo 11, on veri seti için elde edilen DÖTÇA-AÖM ve ÇA-AÖM' ye ait sonuçları göstermektedir. Bu analizde her iki yaklaşımda gizli katman nöron sayısı ve her yığındaki veri sayısı deneysel şekilde belirlenerek 100 olarak atanmıştır. DÖTÇA-AÖM' nin içerik farklılaşmasının algılamasında gerekli olan eşik değeri $\varepsilon = 0.1$ olarak hesaplanmıştır ve tek bir sınıflandırıcı kullanılmıştır.

Tablo 11. DÖTÇA-AÖM ve ÇA-AÖM' nin DO ve YSVS sonuçları

Veri Setleri /Veri Sayısı	DÖTÇA-AÖM		ÇA-AÖM [86]	
	DO	YSVS	DO	YSVS
KddCup99 / (494021)	0.99900	495	0.99513	2405
ForestCovType / (581012)	0.98359	9534	0.27510	421160
ElecNormNews / (45312)	0.98756	565	0.50108	22605
Pendigits / (7494)	0.97667	175	0.95543	334
Hyperplane / (50000)	0.95898	2050	0.79862	10069
Led / (50000)	0.94198	2901	0.72183	13908
EEG eye / (14980)	0.99687	47	0.59303	6103
Shuttle / (58000)	0.99395	354	0.99312	399
Agrawal / (50000)	0.94724	2638	0.73740	13130
RandomTree / (50000)	0.94930	2535	0.69564	15218

Tablo 11 incelendiğinde DÖTÇA-AÖM' nin sonuçlarının değerlerinin tüm veri setlerinde orijinal ÇA-AÖM' den daha iyi olduğu görülebilmektedir. Başka bir deyişle, önerilen akan veri sınıflandırma yaklaşımı, orijinal ÇA-AÖM ile karşılaştırıldığında daha düşük yanlış sınıflandırılmış verilerle daha yüksek sınıflandırma sonuçları elde etmektedir. Her iki yaklaşım da basit bir yapıya sahip olan ve içerik farklılaşması olmayan Pendigits ve Shuttle veri setlerinde beklenen yüksek DO değerlerine ulaşmaktadır. Ayrıca, DÖTÇA-AÖM, bilinmeyen türde bir içerik farklılaşmasına sahip olan ForestCovType,

ElecNormNews ve EEG Eye veri kümelerinde de oldukça etkilidir. Tablo 11'ye göre YSVS değerleri ElecNormNews için 22605'ten 565'e, ForestCovType için 421160' tan 9534'e ve EEG Eye için 6103'ten 47'ye düşürülmüştür. Önerilen yaklaşım işlenmesi zor bir veri seti olan ForestCovType' da iyi bir iyileştirme performansına sahiptir. KddCup99'un sonuçları DÖTÇA-AÖM' nin başarısını kanıtlar niteliktedir. Orijinal ÇA-AÖM, KddCup99 veri kümesinde oldukça başarılıdır. Bu veri seti doğrusal olarak ayrılabilir ve kademeli bir içerik farklılaşmasına sahip olduğu bildirilmektedir [198] ve bu nedenle ÇA-AÖM bu veri seti üzerinde yüksek sınıflandırma sonuçlarına ulaşabilmektedir. Ancak DÖTÇA-AÖM' nin elde ettiği YSVS' na göre ÇA-AÖM' den 1910 fazla örneği daha doğru sınıflandırdığı görülmektedir. Bu, DÖTÇA-AÖM' nin içerik farklılaşması mekanizmasının pozitif bir katkı yaptığını göstermektedir. ÇA-AÖM, AÖM tabanlı artımlı öğrenme için temel bir algoritma olmasına ve akan veri ortamı için uygun olmasına rağmen, içerik farklılaşması problemini başarılı bir şekilde çözememektedir. Sonuçlara göre, ÇA-AÖM kademeli bir içerik farklılaşması (Hyperplane ve KddCup99) ile biraz başa çıkabilmektedir. Ancak, ani içerik farklılaşması (Led) ile başa çıkamamaktadır. Sonuç olarak, ÇA-AÖM bu analizde içerik farklılaşması olan tüm veri setlerinde en düşük sınıflandırma sonuçlarına sahiptir. Fakat, DÖTÇA-AÖM bir içerik farklılaşması mekanizmasına sahiptir ve bu nedenle her iki tür içerik farklılaşması durumunu da ustaca idare edebilmektedir.

Tablo 12. DÖTÇA-AÖM ve IDS-ELM ve DELM ile karşılaştırılması

	DÖTÇA-AÖM	IDS-ELM	DELM
Veri Setleri	DO	DO	DO
Hyperplane	0.95898	0.7775	0.7831
Led	0.94198	0.7995	0.899
Waveform	0.95954	0.795	0.8453
EEG eye	0.99687	0.6250	0.3343
Shuttle	0.99395	0.9218	0.9475
Agrawal	0.94724	0.6722	0.6722
RandomTree	0.94930	0.4069	0.4024

Tablo 12, DÖTÇA-AÖM' nin sınıflandırma performansını, içerik farklılaşması algılama ve uyarılama mekanizmalarına sahip son teknoloji akan veri sınıflandırma yaklaşımlarıyla karşılaştırmalı olarak göstermektedir. Üç algoritmanın ortak noktası, içerik farklılaşması tespiti için Hoeffding Sınır Teoremi kullanılmasıdır. IDS-ELM ve DELM, Hyperplane, Led, Waveform, EEG Eye, Shuttle, Agrawal ve RandomTree veri setlerini

orijinal çalışmalarında kullandıkları için bu deneyde de sadece bu veri setleri kullanılmıştır. Sonuçlar incelenirse, DÖTÇA-AÖM' nin diğer yaklaşımlardan daha verimli bir yaklaşım olma potansiyeline sahip olduğu sonucuna varılabilmektedir. DÖTÇA-AÖM tüm veri setlerinde oldukça etkili bir performans elde etmektedir. En iyi performans gösterdiği veri setleri Hyperplane, RandomTree, EEG Eye ve Agrawal veri setleridir. Hyperplane ve RandomTree, kademeli içerik farklılaşmasına sahip veri kümeleridir ve DÖTÇA-AÖM, elde edilen sonuçlara göre kademeli içerik farklılaşmasına uyum sağlayan en iyi yaklaşımdır. DELM' nin ani içerik farklılaşması durumunda yetersiz olması Led veri setinde düşük bir DO sahip olmasının nedenidir. Bununla birlikte DÖTÇA-AÖM' nin Led veri setine ait sonuçları incelendiğinde, ani içerik farklılaşmasını ele alınmasında diğerlerine göre oldukça etkili olduğu görülebilmektedir. Bunun nedeni, DÖTÇA-AÖM' nin AÖM-OK tabanlı içerik farklılaşması adaptasyon mekanizmasını kullanması verilebilmektedir. Farklılaşma tespit edildiğinde, sınıflandırıcı yeni konsepte uyum sağlamak için yeni konsepte sahip veriler kullanılarak belirlenen ağırlıklarla yeniden yapılandırılmaktadır. Burada kullanılan içerik farklılaşmasına adaptasyon mekanizması, sınıflandırıcının mevcut yığının ana bileşenlerine göre yeniden inşa edilmesini sağlamaktadır. Bununla birlikte, IDS-ELM ve DELM, giriş verilerinin en iyi ayırt edici özelliklerini kullanmadan çalışmaktadır. Her iki algoritma da rasgele atanan giriş ile gizli katman arasındaki ağırlıkları kullanarak AÖM modeli oluşturmaktadır. İçerik farklılaşması tespiti durumunda, IDS-ELM zayıf sınıflandırıcıyı rastgele atanmış giriş katmanı ağırlıklarıyla yeniden yapılandırırken, DELM rastgele atanmış giriş katmanı ağırlıklarına sahip yeni gizli katman nöronları eklemektedir. Rastgele atama, yeni içeriğin doğru bir şekilde öğrenilmemesine neden olabilmektedir. Giriş ile gizli katman arasındaki ağırlıkların belirlenmesi, IDS-ELM ve DELM ile karşılaştırıldığında daha iyi sınıflandırma sonuçları elde etmek için DÖTÇA-AÖM' ye fayda sağlamaktadır.

2.3.4.2. Gizli Katmandaki Nöron Sayısının Etkisi

Bu bölümde, gizli katman nöron sayısının DÖTÇA-AÖM' nin performansı üzerindeki etkisi incelenmiştir. Analiz, ForestCovType, KddCup99, ElecNormNews, Pendigits, Hyperplane ve LED veri setlerinde üzerinde 35, 70 ve 100 nöron sayılarında gerçekleştirilmiştir. Bu deneyde her yığındaki veri sayısı 100 olarak seçilmiştir. Bu nedenle, gizli katmandaki nöronun maksimum değeri AÖM' nin temel teorisine göre 100 olarak

belirlenmiştir [81]. Tablo 13, orijinal ÇA-AÖM ile karşılaştırmalı olarak DÖTÇA-AÖM' nin YSVS skorlarını göstermektedir.


Tablo 13. Nöron sayısının performansa etkisi analizinin DÖTÇA-AÖM ve ÇA-AÖM sonuçları

Veri Setleri / Veri Sayısı	DÖTÇA-AÖM YSVS			ÇA-AÖM YSVS		
	35	70	100	35	70	100
KddCup99 / (494021)	553	542	100	4728	3023	2405
ForestCovType / (581012)	13266	2989	9534	204091	184086	421160
ElecNormNews / (45312)	898	162	565	10866	21834	22605
Pendigits / (7494)	591	298	175	750	444	334
Hyperplane / (50000)	8156	616	2050	14198	11069	10069
Led / (50000)	3656	73	2901	15460	14103	13908
EEG eye / (14980)	125	54	47	6259	6175	6103
Shuttle / (58000)	807	409	354	1025	458	951
Agrawal / (50000)	5597	1649	2638	19483	13850	13130
RandomTree / (50000)	8023	668	2535	17382	15358	15218

Tablo 13 incelendiğinde DÖTÇA-AÖM' nin ÇA-AÖM ile karşılaştırıldığında üç gizli katman nöron sayısı için daha düşük YSVS skorlarına sahip olduğu görülmektedir. Düşük YSVS, DÖTÇA-AÖM' nin farklı gizli katman nöron sayılarında akan verinin beklentilerini karşılamak için oldukça etkili olduğu anlamına gelmektedir. Nöron sayısı 100 olduğu durumda DÖTÇA-AÖM, Pendigits, KDDCup99, Shuttle ve EEG Eye en iyi YSVS skorlarını elde etmektedir. 35 olduğu durumda Pendigits ve KddCup99 için en kötü YSVS skorları alınmaktadır. Nöron sayısı 100'e çıktıkça YSVS skorları doğrusal olarak azalmaktadır ve dolayısıyla DÖTÇA-AÖM sınıflandırma performansı artmaktadır. Fakat ForestCovType, ElecNormNews, Hyperplane, Led, Agrawal ve RandomTree veri setleri için en iyi sonuçlar 70 durumunda elde edilmektedir. Nöron sayısı 35'e düştükçe, DÖTÇA-AÖM bu veri kümeleri üzerinde yanlış sınıflandırma yapma eğilimindedir. DÖTÇA-AÖM' nin farklı veri setlerinde en iyi performansının farklı gizli katman nöron sayısında elde ettiği söylenebilmektedir. Uygun nöron sayısı, akan veri setlerinin özelliklerine göre değişebilen bir durumdur.


2.3.4.3. İçerik Farklılaşması Tespitindeki Eşik Değerin Etkisi

Bu bölümde, eşik değerin sınıflandırma performansı üzerindeki etkisini analiz etmek için iki farklı yığın boyutunda beş farklı eşik değeri üzerinde DO elde edilmiştir.




Şekil 25. Eşik Değerin DO üzerindeki etkisinin (a) ForestCovType (b) KddCup99 (c) ElecNormNews (d) Pendigits (e) Hyperplane (f) LED (g) Agrawal (h) RandomTree (i) Shuttle (j) EEG Eye


Şekil 25' in devamı




(e)




(f)




(g)



(h)



(i)



(j)

Bu deneyde analiz, DÖTÇA-AÖM' nin davranışını daha iyi incelemek için 100 ve 1000 yığın boyutu kullanılarak gerçekleştirilmiştir. Çalışmada eşik değer Hoeffding Sınır Teoremine göre belirlenmektedir. Kullanılan parametreler ile birlikte bu değer en az 0.1 olarak hesaplanmıştır. Yine de bu deneyde farklı eşik değerlerin etkisi ve DÖTÇA-AÖM' nin buna cevabı incelenmektedir. Bu deneyin amacı hesaplanan eşik değer üstünde ve altındaki durumlarda performansın değişimini görmektedir. Şekil 25 bu deneyin sonuçlarını göstermektedir. Elde edilen sonuçlara göre eşik değer DÖTÇA-AÖM' nin sınıflandırma performansını etkilediği görülmektedir. DO değerleri, eşik arttığında neredeyse tüm veri setlerinde azalma eğilimi göstermektedir. Bunun nedeni, yüksek eşik değerlerinin içerik farklılaşması problemine cevap vermeye yeterli olmamasıdır. DÖTÇA-AÖM, daha düşük bir eşik değerinde içerik farklılaşması tespitinde ve uyarlanmasında daha etkilidir. Diğer bir deyişle, içerikteki değişiklikler daha düşük eşik değerlerinde kapsamlı bir şekilde tespit edilebilmektedir. Sunulan çalışma, her bir yığındaki veri sayılarının 100 ve 1000 olduğu her iki durumda da tüm veri setlerinde 0.01 eşik değerinde en iyi DO değerlerine ulaşılmaktadır. Fakat, daha düşük eşik değerleri, TKİBA modelinin sık sık yeniden yapılandırılmasına neden olmaktadır. Ayrıca bu değer Hoeffding Sınır kriterine uymamaktadır. Eşik 0.01'den 0.1'e yükseltildiğinde, DO değerlerinde fark edilemeyen ve kabul edilebilir düşüşler tüm veri setlerinde görülmektedir. Pendigits ve Shuttle veri setleri dışında tüm veri setlerinde ise 0.1'in üzerindeki eşik değerler de DO değerlerinde açık bir düşüş gözlenmektedir. DÖTÇA-AÖM, bu veri setlerinde daha yüksek bir eşik değerinde içerik farklılaşmasını algılayamamaktadır. Bunun dışında, her yığındaki veri sayısının, DO sonuçları üzerinde önemli bir etkiye sahip olduğu sonuçlardan görülmektedir.

2.3.4.4. Topluluk Sınıflandırıcı Sayısının Etkisi

Bu bölümde, DÖTÇA-AÖM tabanlı topluluk öğrenme yaklaşımı ve topluluk sınıflandırıcı sayısının etkisi incelenmektedir. Bu deneyde akan veri sınıflandırma performansı TÇA-AÖM ile karşılaştırılarak analiz edilmiştir. Topluluktaki sınıflandırıcı sayısı deneysel şekilde 9 olarak belirlenmiştir. Tablo 14, veri setleri üzerindeki sınıflandırma sonuçlarını göstermektedir.

Tablo 14' deki sonuçlar incelenirse DÖTÇA-AÖM topluluğunun TÇA-AÖM ile karşılaştırıldığında daha iyi sınıflandırma sonuçlarına sahip olduğu anlaşılabilmektedir. Topluluk öğrenme stratejisi, ÇA-AÖM' nin de sınıflandırma performansını artırmaktadır.

Ancak içerik farklılaşması problemini çözebilmek için yeterli değildir. Fakat, topluluk öğrenme stratejisi, DÖTÇA-AÖM 'nin tüm veri setindeki sınıflandırma performansını iyileştirme potansiyeline sahiptir. Topluluk yapısının, tek DÖTÇA-AÖM ile karşılaştırıldığında sınıflandırma performansına olumlu bir katkısı olduğu söylenebilmektedir. Topluluk stratejisi, sunulan çalışmanın kararlı bir yapıya sahip olmasına ve içerik farklılaşmasına karşı daha sağlam olmasına yardımcı olmaktadır.

Tablo 14. Topluluk DÖTÇA-AÖM'nin sınıflandırma performansı ve karşılaştırılması

Veri Setleri	TDÖTÇA-AÖM		DÖTÇA-AÖM		Topluluk ÇA-AÖM	
	DO	YSVS	DO	YSVS	DO	YSVS
KddCup99	0.99968	158	0.999	495	0.99539	2279
ForestCovType	0.99935	380	0.98359	9534	0.29383	410307
ElecNormNews	0.99971	13	0.98756	565	0.50344	22500
Pendigits	0.99997	2	0.97667	175	0.96637	252
Hyperplane	0.9992	4	0.95898	2050	0.81718	9141
Led	1	0	0.94198	2901	0.7313	13435
EEG eye	0.99983	1	0.99687	47	0.60454	5924
Shuttle	0.99624	218	0.99395	354	0.99614	224
Agrawal	0.99994	3	0.94724	2638	0.76828	11586
RandomTree	0.99980	1	0.94930	2535	0.70636	14682

2.3.4.5. AÖM-OK Tabanlı Ağırlıkların İklendirilmesinin ve İçerik Farklılaşması Mekanizmasının Etkisinin Analizleri

Bu bölümde, giriş ile gizli katman arasındaki ağırlıklarının AÖM-OK ile belirlenmesinin bu çalışmaya etkileri ve içerik farklılaşması mekanizmasının başarısı ablasyon deneyleri ile ölçülmüştür. Ablasyon deneyinde, karşılık gelen modül önerilen yaklaşımdan çıkarılmaktadır ve ardından etkisini analiz etmek için performans ölçülümü yapılmaktadır.

AÖM-OK tabanlı ağırlık iklendirme modülü, en iyi temsili ağırlıkları hesaplamayı amaçlamaktadır. Hesaplanan ağırlıklar, girdileri daha ayırt edici uzaya eşleyebilme özelliğine sahiptir. Ayrıca AÖM-OK tabanlı yöntemin kullanılmasıyla giriş ile gizli katman arasındaki ağırlıkların rastgele atanmasından kaynaklanan sorunların giderilmesi amaçlanmıştır. Temel sorun, rastgele girdi ağırlıkları kullanılarak kararsız bir sınıflandırıcının oluşturulmasıdır. Kararsız bir sınıflandırıcı modeli, performansı önemli ölçüde etkilemektedir ve ortalamasından çok büyük bir standart sapmaya sahip farklı DO ve YSVS sonuçları elde edilmesine neden olmaktadır. Bu nedenle, YSVS skorlarının

ortalaması ve standart sapması (std), analiz için bu deneyde ölçüt olarak kullanılmaktadır. Analiz, bu deneyde bir tane DÖTÇA-AÖM sınıflandırıcı ve dokuz tane topluluk DÖTÇA-AÖM sınıflandırıcıları üzerinde yapılmıştır. Tablo 15, AÖM-OK bazlı ağırlık ilklendirme stratejisinin ablasyon deneyini göstermektedir. Tablo 15’ te (+), yaklaşımda AÖM-OK bazlı ağırlık ilklendirme modülünün kullanılması durumunda elde edilen sonuçları gösterirken; (-) AÖM-OK tabanlı ağırlık ilklendirme modülünün yaklaşımdan çıkarılması durumunda elde edilen sonuçları göstermektedir. Başka bir deyişle, (-) giriş katmanı ile gizli kaman arasındaki ağırlıklar için rastgele ilklendirme tekniği kullanıldığı durumdur. Bu deneyde gizli katman nöron sayısı, yığın boyutu ve eşik değeri sırasıyla 100, 100 ve 0.1 olarak belirlenmiştir.

Tablo 15 'e göre, AÖM-OK tabanlı ağırlık ilklendirme modülleri ile oluşturulan DÖTÇA-AÖM ve TDÖTÇA-AÖM yaklaşımları, rastgele ilklendirme stratejisine kıyasla tüm veri setlerinde en düşük std değerine ulaşmaktadır. Rastgele ilklendirmeye dayalı sınıflandırıcı modeli YSVS’ nın ortalama değerinden daha yüksek sapma elde etmektedir. Yüksek standart sapma, sınıflandırıcı modelinin doğru ve güvenilir olmasını engelleyen bir durumdur. Bu nedenle rastgele ilklendirme stratejisinin kararsız yapılı ve kararsız performansa sahip sınıflandırıcılara neden olduğu söylenebilmektedir. Ancak önerilen modül, daha düşük standart sapma ve ortalama YSVS değerine sahip kararlı bir sınıflandırıcının inşa edilmesine olumlu bir katkı sağladığı açıktır.

Tablo 15. AÖM-OK’ ya dayalı ağırlık hesaplama stratejisinin etkisinin ortalama ve standart sapma üzerinden incelenmesi ((+) AÖM-ile ağırlık hesaplama aşaması var, (-) yok)

Veri Setleri	DÖTÇA-AÖM				TDÖTÇA-AÖM			
	(+)	(-)	(+)	(-)	(+)	(-)	(+)	(-)
	Ortalama	std	Ortalama	std	Ortalama	std	Ortalama	std
KddCup99	410	37.7	532.5	67.7	148.5	9.8	183.3	11.4
ForestCovType	9794.1	526.6	10170	990.4	372.4	30.6	3542.2	188.6
ElecNormNews	551.1	84.9	856.8	416.5	13.9	3.7	210.3	22.4
Pendigits	161.4	29.8	203.3	45.1	0.8	0.7	12.6	10.1
Hyperplane	2139.1	302.2	3861.3	3116.3	5.3	2.8	1369.9	1311.4
Led	2341.6	347	6677	3599.2	0	0	3228.6	1374.4
Stagger	0	0	0	0	0	0	0	0
Waveform	2008	103.2	5480.1	2615.5	5.2	3.9	672.2	468.5
Agrawal	2148.2	359.6	13335	745.9	13.3	8.04	11314	433.5
Random Tree	2509	230.6	9002.3	5354.3	11.1	10.6	6149	2863.4
Shuttle	318.1	13.4	339.8	48.15	236	21.7	243.5	24.5
EEG eye	48.2	9.9	101.9	45.07	0.8	0.7	12.8	1.03

Bir diğer ablasyon deneyi ise içerik farklılaşması mekanizmasının incelenmesidir. İçerik farklılaşması mekanizması, çalışmada akan veride oluşan teni içeriği tespit etmek ve buna uyum sağlamak için sunulmuştur. İçerik farklılaşması, akan veri için bir zorluktur. Bu nedenle bu zorluğa çözüm üretilmesi hedeflenmektedir. Bu deneyde, DÖTÇA-AÖM ve TDÖTÇA-AÖM yaklaşımlarının DO ve YSVS performansları içerik farklılaşması mekanizmasının olduğu (+) ve olmadığı (-) durumda elde edilmiştir. İçerik farklılaşması mekanizmasının olmadığı durum aslında bir önceki ÇA-AÖM ve AÖM-OK' ya dayalı çalışma olmaktadır. Bu nedenle son iki çalışmada kıyaslaması burada yapılmaktadır. Deneyde gizli katman nöron sayısı, yığın boyutu ve içerik farklılaşması mekanizması için eşik değeri 100, 100 ve 0.1 olarak belirlenmiştir. Deneyin DO ve YSVS sonuçları Tablo 16' da verilmiştir.

Tablo 16. İçerik farklılaşması mekanizmasının etkisinin DO ve YSVS üzerinden incelenmesi ((+) İçerik farklılaşması mekanizması var, (-) içerik farklılaşması mekanizması yok)

Veri Setleri	DÖTÇA-ELM				TDÖTÇA-ELM			
	(+)		(-)		(+)		(-)	
	DO	YSVS	DO	YSVS	DO	YSVS	DO	YSVS
KddCup99	0.999	495	0.98458	7616	0.99968	158	0.98817	5843
ForestCovType	0.98359	9534	0.65744	199033	0.99935	380	0.67507	188791
ElecNormNews	0.98756	565	0.59152	18479	0.99971	13	0.6728	14826
Pendigits	0.97667	175	0.95863	310	0.99997	2	0.97118	216
Hyperplane	0.95898	2050	0.70672	14664	0.9992	4	0.81962	9019
Led	0.94198	2901	0.72546	13727	1	0	0.73228	13386
Waveform	0.95954	2023	0.7249	13755	0.99992	4	0.81194	9403
Agrawal	0.94724	2638	0.45836	27082	0.99994	3	0.6689	16555
Random Tree	0.9493	2535	0.64202	17899	0.9998	1	0.68004	15998
Shuttle	0.99395	354	0.60143	23117	0.99624	218	0.89922	5845
EEG eye	0.99687	47	0.55932	6607	1	0	0.58224	6258

Tablo 16' ya bakılırsa içerik farklılaşması mekanizmasının kullanımı tüm veri setlerinde sınıflandırma performansını büyük ölçüde etkilediği söylenebilmektedir. Mekanizmanın mevcut olduğu durumda YSVS skorları en düşük değerdedir. Diğer durum olan bir önceki çalışmada ise YSVS skorları daha yüksek değerlere ulaşmaktadır. Bu da konseptteki değişikliğin etkili bir şekilde tespit edilemediği anlamına gelmektedir. Sonuçlar,

önerilen içerik farklılaşması mekanizmasının akan veri sınıflandırma çalışmasına olumlu bir katkı yaptığını kanıtlamaktadır.

2.4. Gözetleme Videolarındaki Anomali Tespiti ve Anormal Olay Türü Tespiti için Akan Veri Tabanlı Yaklaşım

Son yılların popüler bir yaklaşımı olan derin öğrenmeye dayalı gözetleme videolarındaki anomali tespiti çalışmaları her ne kadar mükemmel bir performansa gösterebilir de birçok kısıtlamaya ve problemlere sahiptirler. Bu yaklaşımlar da sıfırdan eğitim yoğun hesaplama ve yüksek hesaplama gücü gerektirmektedir [136]. Bunun nedeni, derin ağların konvolüsyon, RelU, havuzlama, softmax vb. gibi birçok katmana sahip olmasıdır. Bu nedenle, eğitim veya ince ayar için çok sayıda hesaplama ve çok sayıda etiketli eğitim örneği ile uzun eğitim süresine ihtiyaçları vardır. Örneğin [136], sırasıyla 8, 22 ve 16 katmana sahip önceden eğitilmiş AlexNet, GoogleNet ve VGGNet kullanırken, [139] video anomali tespiti için toplam 30 katmanlı PCANet kullanmaktadır. Ayrıca, gözetleme videolarında yer alan normal ve anormal olayların çeşitliliği nedeniyle tüm normal ve anormal olayları modellemek mümkün değildir. Farklı olaylar için büyük eğitim örneklerine ihtiyaç duymaktadırlar. Bunların dışında derin öğrenmeye dayalı yaklaşımlar, eğitim setine bağımlıdır. Eğitim setine dahil olmayan anormal veya normal olayları tespit etmek için yeniden eğitim gerekmektedir. Derin öğrenmeye dayalı yaklaşımlarda yeniden eğitim, videolardaki her yeni olay için zor ve zaman alıcı bir görevdir. Dahası, derin öğrenmeye dayalı yaklaşımlar dinamik bir yapıya sahip olmadıkları için normal olayların gelişen doğasına dinamik olarak uyum sağlayamazlar. Bu zorluklar, derin öğrenme temelli yaklaşımların anormal olaylara anında yanıt vermede dezavantajlı olmasına neden olmaktadır. Bu gibi nedenlerden dolayı çalışmada bu zorlukları ele alan yeni bir anormallik algılama yaklaşımı sunulmaktadır. Çalışma, derin öğrenmeye dayalı örüntü tanıma yerine akan veri metodolojisini kullanarak gözetleme videosunda anomali tespitine yeni bir bakış açısı getirmektedir. Önerilen yaklaşım, video karelerini bir akan veri örneği olarak kullanan artımlı bir öğrenme stratejisine dayanmaktadır.

Önerilen yaklaşımda genel bakış şudur: İlk olarak video akışının başlamasıyla birlikte belirli sayıda çerçeve kullanılarak olayların akışını açıklayan zamansal video segmenti anlık olarak oluşturulur. Elde edilen segment Çok örnekli öğrenme (ÇÖÖ) tabanlı bir yöntem [199] ile zayıf bir şekilde etiketlenir. Zayıf etiketleme, olayların akışını koruyarak kabaca

etiket bilgisi elde etmeyi amaçlar. Ayrıca sadece normal olayları işleyen yaklaşımlarda oluşan yüksek yanlış pozitif oranının önüne geçilmesi amaçlanmaktadır. Zayıf etiketlemenin bir çıktısı olarak 1-d öznitelik vektörü elde edilir. Son olarak, özellik vektörünün anormal veya normal bir olay olduğunu belirlemek için, bir önceki çalışmada akan veri öğrenmesi için önerilen DÖTÇA-AÖM [200] kullanılır ve algoritma her video segmenti için bir bireysel karar üretir. Nihai karar ise, tüm DÖTÇA-AÖM sınıflandırıcılarının sonuçlarının oylanması ile alınmaktadır. Video anomali algılama yaklaşımının sağlamlığının, toplu öğrenme stratejisi ile iyileştirilmesi amaçlanmaktadır. Çalışmanın genel modeli Şekil 26’ da verilmiştir. Bu çalışmanın katkıları aşağıdaki gibi sıralanabilmektedir:


- Gözetim videosu için yeni ve etkili bir anomali algılama yaklaşımı, görevi bir akan veri problemi olarak ele alınarak sunulmaktadır. Bu çalışmada, zayıf bir etiketleme tekniği ile topluluk sınıflandırıcı yöntemine dayanan DÖTÇA-AÖM akan veri öğrenme yaklaşımı birleştirilmiştir. Bu çalışma bahsedilen kombinasyonu kullanarak video anomali algılama problemini akan veri şeklinde çözen ilk çalışmadır.

- Önerilen yaklaşım, anormal olayları tespit etmek için bir önce-test sonra-eğitim stratejisine dayanan artımlı ve aşamalı öğrenmeyi kullanmaktadır. Tüm zamansal segmentler önce test edilir ve daha sonra öğrenme modelini eğitmek için kullanılmaktadır. Artımlı öğrenme ile sıfırdan eğitim ihtiyacı ortadan kalkmaktadır. Bu, yaklaşımın her segment için anında karar vermesini sağlayan bir özelliğidir.

- Önerilen yaklaşım dinamik bir yapıya sahiptir. Her zaman mevcut video gözetleme konseptinde herhangi bir değişiklik varlığını aramaktadır. Bu, akan verinin içerik farklılaşması karakteristiğini hatırlatmaktadır. Farklılaşma tespit edilirse, yaklaşım AÖM-OK tabanlı yeniden ilklendirme stratejisini kullanarak yeni bir konseptte adapte olmak için dinamik olarak kendini yeniden yapılandırmaktadır. Yeniden yapılandırma işlemi öğrenme modelinin değişken ve çeşitli normal olay ortamlarına uyum sağlamasını sağlamaktadır.

- DÖTÇA-AÖM tabanlı anomali algılama yaklaşımının normal veya anormal olaylar olarak iki çıkışı vardır. Bununla birlikte yapı genellikle ikiden fazla çıktıya sahip olan anormal bir olay türü tanıma görevini gerçekleştirmek için kolayca geliştirilebilmektedir. Bu nedenle, gözetim videolarındaki anormal olay türü tanıma da bu çalışmada DÖTÇA-AÖM üzerinde küçük yapısal değişiklikler yapılarak analiz edilmiştir. Literatürde bu görevle ilgili birkaç çalışma vardır ve önerilen çalışma, mevcut yaklaşımlardan daha etkili tanıma performansı sergileme potansiyeline sahiptir.


- Derin öğrenmeye dayalı yaklaşımlar, CNN, PCANet, UNet, AlexNet ve GoogleNet gibi derin bir ağ kullanmaktadır [139, 148]. Bu tür derin ağlar, çok sayıda hesaplama gerektiren birkaç katmandan oluşur. Çok sayıda hesaplama yaklaşımların eğitim ve test için uzun zaman harcamasına neden olmaktadır. Sunulan çalışma ise anomali tespiti için basit bir ağ yapısı kullanmaktadır. DÖTÇA-AÖM, akan veri sorunları için geliştirilmiş olup, AÖM-OK ve ÇA-AÖM tabanlı sınıflandırıcıdan oluşmaktadır. Her modül, tek katmanlı bir ileri besleme ağı olan AÖM 'ye dayanmaktadır. Bu nedenle derin ağlarda olduğu gibi çok fazla katmana ve hesaplama ihtiyacı duyulmamaktadır. Bu, önerilen yaklaşımın daha düşük hesaplama karmaşıklığına sahip olmasını ve iyi performansla zaman alıcı olmasını sağlamaktadır.



Şekil 26. Sunulan yaklaşımın genel akış şeması

2.4.1. Ön işleme Aşaması

Ön işleme aşaması her bir zamansal segmentin oluşturulduğu, zayıf etiket değeri atandığı ve her segmentin bir akan veri örneğine dönüştürüldüğü bir aşamadır. Ön işleme aşamasının gösterimi Şekil 27' deki gibidir.



Şekil 27. Önişleme aşamasının gösterimi

2.4.1.1. Zamansal Segment Oluşturulması

Zamansal Segment $t=0$ anından itibaren anlık olarak kaydedilen belli sayıda video çerçevesinin oluşturduğu bir alt video parçasıdır. Bu alt video parçası zaman bilgisi, çerçevelerin satır ve sütun sayısı olmak üzere 3 boyutlu bir yapıdadır. Bir video segmenti o andaki olay akışını ifade etmektedir. Video segmenti (43) eşitliğindeki gibi gösterilebilir.


$$VS = \{(x_i, y_i), t \mid i = 1, 2, \dots, n\} \quad (43)$$

Burada x_i ve y_i i . çerçevenin eni (satır sayısı) ve boyu (sütun sayısı), t zaman bilgisi ve n ise segmentteki çerçeve sayısıdır. Örnek olarak $VS = \{(x_i, y_i), 0 \mid i = 1, \dots, 5\}$ ifadesi $t=0$ anında 5 çerçeveden oluşan ilk segmenti ifade etmektedir. Segmentteki çerçeve sayısı yani n değeri çalışmada deneysel olarak belirlenmiştir ve maksimum değer olarak videoların saniyedeki çerçeve sayısına göre belirlenmiştir. Çalışmada segmentler artımlı olarak elde edilerek oluşturulmaktadır. Segmentler oluşur oluşmaz diğer aşamada işlenilmektedir. Yani bir segment oluşuktan sonra segment seviyesinde bir zayıf etiketleme tekniği ile zayıf bir etiket bilgisinin atanacağı aşamaya gönderilir.

2.4.1.2. Segment Seviyesinde Zayıf Etiketleme

Zayıf etiketleme, nesne düzeyinden [199, 201, 202] çok çanta düzeyindeki örneklerin etiketleri hakkında daha zayıf bir varsayım yapan bir ÇÖÖ tekniğidir. Bu teknikte, zayıf etiketleme için pozitif ve negatif torbalar kullanılmaktadır. Negatif torba negatif örneklerden oluşmaktadır ve içinde hiç pozitif örnek yer almamaktadır. Öte yandan, pozitif torba ise en az bir pozitif örnek içeren bir torbadır. Torbayı pozitif olarak etiketlemek için içinde sadece bir pozitif örnek olması yeterlidir. Torba düzeyinde ÇÖÖ' nin yapısı incelendiğinde, akan veri işlemenin özelliklerine yanıt veremeyeceği görülmektedir. Çünkü bu zayıf etiketleme tekniği tüm veriye en baştan ulaşılabilen geleneksel bir tekniktir. Halbuki akan veri de tüm veriye en başta erişmek mümkün değildir. Bu nedenle, torba düzeyinde zayıf etiketleme tekniği fikri, bu yaklaşımda akan verilerin artımlı öğrenimini gerçekleştirecek için uyarlanmıştır. Akan veri örneklerini artımlı olarak zayıf bir şekilde etiketlemek için, önerilen yaklaşımda segment düzeyinde bir yöntem kullanılmaktadır.

Önerilen yaklaşımın temeli, zamansal video segmentlerini bir akan veri örneği olarak kullanmaktır. Zamansal segment oluşturulduğunda kaba etiket bilgisi için segment düzeyinde zayıf etiketleme uygulanmaktadır. Segment seviyesinde zayıf etiketleme, çanta seviyesiyle aynı fikri kullanır. Mevcut bir segment, kendisini oluşturan çerçevelerden en az biri anomali içeriyorsa, anormal bir olayı temsil etmek için pozitif olarak etiketlenmektedir. Segmentte hiç anomali çerçevesi bulunmuyorsa, segmente normal duruma denk düşen negatif etiket atanmaktadır. Pozitif ve negatif etiketler, bu yaklaşımda sırasıyla anormal ve normal olayı temsil etmektedir.



Şekil 28. Segment seviyesinde etiketlemenin (a) anormal ve (b) normal olay için gösterimi


Zayıf etiketlemenin amacı, olayların akışını koruyarak kabaca etiket bilgisi elde etmektir. Ayrıca, sadece normal olayların işlenmesi nedeniyle oluşan yüksek yanlış pozitif oranını önlemeyi amaçlamaktadır.

Zamansal segmente zayıf bir etiket atandıktan sonraki işlem, boyut küçültme için segmentteki çerçevelerden ortalama bir akış görüntüsü hesaplanmasıdır. Ortalama akış görüntüsü, zamansal segmentin bir ortalama temsilidir ve segmentteki çerçevelerin ortalaması alınarak elde edilmektedir. Ortalama akış görüntüsü ile amaçlanan, zamansal segmentin boyutunu azaltmaktır ve ÇÖÖ' de kullanılan bir işlemdir [199, 120, 203]. Segment bir alt video bölümüdür ve üç boyuta sahiptir. Boyutu ikiye düşürmek için mevcut segmentteki çerçevelerin ortalaması bu nedenle alınmaktadır. Hesaplanan ortalama akış görüntüsü, görüntü satır taraması yapılarak ortalama akış vektörüne dönüştürülür. Böylece, bu adımın sonunda 3-D video segmentini temsil eden bir 1-D vektör elde edilir. Bu adımda hedeflenen video segmentlerini bir akan veri örneğine dönüştürmek olarak söylenebilmektedir. Anlık olarak oluşturulan her segment bir vektöre çevrildikten sonra akan veri öğrenme algoritması olan DÖTÇA-AÖM' de işlenmesi için yığın yapılarına yerleştirilmektedir.


2.4.2. Anomalinin Akan Veri Öğrenme Algoritması ile Tespiti

2.4.2.1. DÖTÇA-AÖM ile Öğrenme

Bu aşamada akan veri örneğine çevrilen zamansal video segmentleri bir önceki çalışmada sunulan akan veri öğrenme yaklaşımı olan DÖTÇA-AÖM ile işlenmektedir. DÖTÇA-AÖM her segment için anomali ya da normal çıktısını üreterek artımlı bir öğrenme gerçekleştirmektedir. DÖTÇA-AÖM' nin genel modeli ve anomali tespiti için güncellenmiş akış şeması Şekil 29 ve Şekil 30' de verilmektedir.



Şekil 29. DÖTÇA-AÖM' nin anomali tespiti için genel modeli




Şekil 30. DÖTÇA-AÖM' nin anomali tespiti için güncellenmiş akış şeması

2.4.2.2. Topluluk Öğrenmesi ile Nihai Kararın Verilmesi

DÖTÇA-AÖM etkili bir içerik farklılaşması algılama ve yeni içeriğe adapte olma özelliğine sahip bir akan veri öğrenme yaklaşımıdır. Bu yetenek, video akışındaki dinamik ve değişken sahnelerle uyum sağlamasını kolaylaştırır. Fakat normal olayların çok çeşitli olmasından dolayı her durumda anormal olayları fark edemeyebilmektedir. Bu nedenle, topluluk öğrenmesi performans kapasitesini ve anomali tespitinin sağlamlığını artırmak için bu çalışmada kullanılmaktadır. Topluluk öğrenme mekanizması, her segment için birden çok

DÖTÇA-AÖM’ nin ürettiği bireysel kararları çoğunluk oylaması stratejisi uygulayarak nihai kararı üretir. Çoğunluk oylaması kullanıldığı için sınıflandırıcı sayısı tek sayısı olarak belirlenmektedir.

Bu bölümde anomali tespiti için geliştirilen yaklaşım sunulmaktadır. Anormal olay türünün belirlenmesi için geliştirilen yaklaşım anomali tespiti ile aynıdır. Sadece ağ modeli diğerinden farklılık içermektedir. Anormal olay türü tespiti, akan veri tabanlı yaklaşımla gözetim videolarındaki anormal etkinlik türünün belirlenmesine dayanmaktadır. Amaç, gözetim videolarında ne tür anormal olayın meydana geldiğini belirlemektir. Bu bölümde, anormal olay türü tanıma performansının UCF-Crimes veri seti üzerinde analiz de incelenmektedir. Veri seti, biri normal olay, diğerleri farklı anormal olaylar olmak üzere 14 sınıfa sahiptir. Bu nedenle, anormal olay tipi tanıma için daha uygundur. UCF-Crimes veri setindeki anormal aktivite türünü tespit etmek için, DÖTÇA-AÖM’ nin çıkış katmanı çok sınıflı öğrenmeye uyum sağlayacak şekilde değiştirilmelidir. Bu nedenle çıkış katmanı nöron sayısı 2’den 14’e çıkarılmıştır. Çıkış katmanındaki her nöron farklı sınıflara aittir. Bunun dışındaki tüm işlemler anomali tespiti için gerçekleştirilenler ile aynıdır. Bu yapının genel modeli aşağıdaki Şekil 31’ de verilmiştir.



Şekil 31. Anormal olay türü tespiti için geliştirilen ağ modeli

2.4.3. Deneysel Sonuçlar

Bu bölümde, önerilen video anomali tespiti ve anormal olay tanıma yaklaşımının değerlendirmeleri gerçek video veri setlerinde sunulmuştur. Bu çalışma ile derin öğrenme tabanlı örüntü tanıma kullanmak yerine sorunu bir akan veri biçiminde ele alarak gözetleme videosu için bir anomali algılama yaklaşımı geliştirmeyi amaçlamaktadır. Bu nedenle,

önerilen yaklaşımla performans karşılaştırması için son teknoloji derin öğrenme tabanlı video anomali tespit yaklaşımları kullanılmıştır.

Bu çalışmada iki ana konuya odaklanılmıştır: video anomali tespiti ve video anormal olay türü tanıma. Deneyler her iki konu için önce-test-sonra-eğitim tekniği ile gerçekleştirilmiştir. Bu tekniğe göre, her bir zamansal segment, mevcut sınıflandırıcı model tarafından ayrı ayrı test edilir ve doğruluk oranı ölçülür. Daha sonra, DÖTÇA-AÖM sınıflandırıcısı, mevcut örneklerle sıralı olarak güncellenir. Önerilen yaklaşımın parametreleri deneysel olarak belirlenmiştir. Bununla birlikte, gizli katman nöron sayısının maksimum değeri, AÖM 'nin [81] temel teorisine göre yığın boyutuna bağlıdır. Bu nedenle, yığındaki veri sayısı dikkate alınarak belirlenmiştir. Deneylere göre, DÖTÇA-AÖM' nin her katmanındaki aktivasyon fonksiyonu olarak bir sigmoid fonksiyonu seçilmiştir.

Önerilen yaklaşım UCF-Crimes [120] ve UCSD yaya [170] video veri setlerinde analiz edilmiştir. UCF-Crimes, büyük bir gözetleme video veri setidir. UCSD yaya veri seti ise Ped1 ve Ped2 olarak adlandırılan iki farklı yaya yürüyüş yolundan oluşmaktadır. Tüm test videoları çeşitli dönemlerde anormallikler içermektedir. Her iki veri seti de anomali tespit görevi için kullanılmıştır. Bununla birlikte, 14 farklı anormal olay türü içerdiğinden, anormal olay türü tespiti için yalnızca UCF-Crimes veri seti kullanılmıştır.

2.4.3.1. Anomali Tespiti

2.4.3.1.1. Sınıflandırma Performansı

Bu bölümde, önerilen video anomali tespiti yaklaşımı, son teknoloji derin öğrenme tabanlı yaklaşımlar karşılaştırılarak değerlendirilmiştir. Yaklaşımlar UCF-Crimes ve UCSD Yaya veri setlerinin kullanımına göre belirlenmiştir. Değerlendirme ölçütleri, çerçeve tabanlı Eğri Altındaki İlgili Alan (EAA) ve Eşit Hata Oranıdır (EHO). Karşılaştırma için kullanılan derin öğrenme tabanlı yaklaşımların literatürde bildirilen nicel sonuçları kullanılmıştır. DÖTÇA-AÖM' nin gizli katmanındaki nöron sayısı, yığın boyutu ve zamansal video segment boyutu deneysel olarak belirlenmiştir. Deneylere göre, gizli katman nöron sayısının ve ilk yığın boyutunun optimum değerleri 10 olarak; ardışıl yığın boyutu 1 olarak seçilmiştir. Segment boyutu ise problemi akan veri biçiminde ele alabilmek için en iyi sayı olan 5 olarak belirlenmiştir. Bunun sonucu olarak çalışmada kullanılan UCF-Crimes, Ped1 ve Ped2 için zamansal segmentlerin sayıları 93452, 1440 ve 402 olmaktadır. İçerik

farklılaşması tespitinde kullanılan minimum eşik değeri Hoeffding Sınır Teorisi'ne göre hesaplanmıştır ve bu değeri 0.1 olarak belirlenmiştir. Çalışmadaki topluluk sınıflandırıcı sayısı ise 7' dir.

İlk deney, performans değerlendirmesi için UCF-Crimes veri seti üzerinde yapılmıştır. Hasan vd. [143], Lu ve vd. [204], Sultani ve ark. [120] ve Zhong vd. [142], UCF-Crimes veri setinin anomali tespiti için karşılaştırma amaçlı kullanılmıştır. EAA sonuçları Tablo 17' te gösterilmektedir.

Tablo 17. UCF-Crimes veri seti için EAA [%] sonuçları

	Önerilen Yaklaşım		Sultani vd. [120]	Hasan vd. [143]	Lu vd. [204]	Zhong vd.[142]
	TS=5	TS=10				
EAA	0.9959	0.9918	0.7541	0.506	0.6551	0.8212

Sonuçlar, önerilen yaklaşımın diğer yöntemlerle karşılaştırıldığında en iyi EAA' ya sahip olduğunu göstermektedir. Problemin bir akan veri sorunu olarak ele alınması, elde edilen sonuçlara göre video anomali algılama performansını iyileştirdiği söylenebilmektedir. Artımlı öğrenme stratejisinin bu iyileştirme üzerinde önemli bir etkisi vardır. Bununla birlikte, diğer yaklaşımlar tüm verilerin en başta ulaşıldığı toplu öğrenmeye dayanmaktadır. Bu, sabit bir küme kullanarak bir model oluşturdıkları anlamına gelmektedir. Çıkarılan özellikler, anormal olayları ayırt etmek için yeterli değildir. Üstelik UCF-Crimes, işlenmesi zor bir veri setidir. Uzun gözetim videoları içerir ve bazı videolar da kısa süreli anormal olaylara yer almaktadır. Bu tür anormal olay, akan veri ani içerik farklılaşması ile benzer bir yapıya sahiptir. Önerilen topluluk DÖTÇA-AÖM yaklaşımı, artımlı öğrenme stratejisi ve içerik farklılaşması mekanizmasını kullanarak ani içerik değişimini kolayca idare etme potansiyeline sahiptir. Sapmayı algılayabilip ve ardından ağı yeni konsepte kolayca uyarlayabilmektedir. Başka bir deyişle, içerik farklılaşması mekanizması anormal bir olayı tespit etmeyi kolaylaştırır ve içeriğe adaptasyon süreci anormal olay sırasında anomalinin belirlenmesini sağlamaktadır.

İkinci deney, UCSD Yaya veri setinde önerilen yaklaşımın değerlendirilmesidir. UCSD Yaya veri setinde performans karşılaştırması AOE [123], SCG-SF [119], AnomalyNet [145], MGFC-AAE [136], GMFC-VAE [149] ve AMDN [144] çalışmaları ile gerçekleştirilmiştir. Orijinal çalışmalarında raporlandığı gibi, performans değerlendirmesi


için EAA ve EHO kullanılmıştır. Burada da çerçeve düzeyinde bir analizle performans karşılaştırması yapılmıştır. Bu nedenle, önerilen yaklaşımın parametreleri çerçeve düzeyinde analize en uygun olacak şekilde belirlenmiştir. Ardışıl yığın boyutu 1 olarak seçilmiştir. Sonuçlar 5 ve 10 olmak üzere iki farklı zamansal segment boyutunda elde edilmiştir. Tablo 18, UCSD Yaya veri setine ait sonuçlarını göstermektedir.

Tablo 18. UCSD veri seti için EAA [%] ve EHO sonuçları

	Ped1		Ped2	
	EAA	EHO (%)	EAA	EHO (%)
Önerilen Yaklaşım -5	0.952	5.5	0.975	6.8
Önerilen Yaklaşım -10	0.906	16	0.9402	11
AOE [123]	0.946	--	0.959	--
SCG-SF [119]	0.909	16.2	0.902	17.3
AnomalyNet [145]	0.835	25.2	0.949	10.3
MGFC-AAE [136]	0.850	20	0.902	16
GMFC-VAE [149]	0.949	11.3	0.922	12.6
AMDN [144]	0.921	16	0.908	17

Tablo 18'e bakıldığında önerilen yaklaşımın Ped1 ve Ped2 veri setlerinde diğer yöntemlere göre daha verimli olduğu anlaşılabilmektedir. UCSD Yaya veri seti basit bir veri setidir ve sabit bir arka plana sahiptir. Bu nedenle, tüm yaklaşımlar %83' ün üzerinde EAA' ya ulaşmaktadır. Bu durumun aksine, SCG-SF, AnomalyNet, MGFC-AAE, GMFC-VAE ve AMDN önerilen yaklaşımdan daha yüksek EHO elde etmektedir. Başka bir deyişle, yaklaşımlar önerilen yaklaşımdan daha yüksek bir yanlış pozitif oranına (FPR) ve daha düşük bir doğru pozitif oranına (TPR) sahiptir. Yüksek FPR, normal olayları anomali olarak tanımladıklarını göstermektedir. Düşük TPR ise anormal olayların normal olarak tanımlanmasını göstermektedir. Önerilen yaklaşım, anormal ve normal olayları daha doğru bir şekilde ayırt etme eğilimindedir. Segment boyutu 5 olduğunda, önerilen yöntem her iki veri setinde de en iyi EAA ve EHO sonuçlarına sahiptir. Segment büyüklüğünün 10 olması durumunda ise diğer yaklaşımlarla rekabetçi performans sergilemektedir. Önerilen yöntemin dinamik yapısı, başarılı performansın ana nedenidir. Tüm videoyu işlemek yerine akış sırasında segmentleri tek tek işlemektedir. İşleme sırasında, çeşitli normallik türlerini uyarlamak için dinamik prosedür gereklidir. Normal olayların gelişen doğası nedeniyle,

segmentler farklı içeriğe sahip aynı olay türüne ait olabilmektedir. EHO sonuçlarına göre, önerilen yaklaşım bu gereksinimi karşılamaktadır. Sonuçlar, yaklaşımın zamansal video segmentlerini dinamik olarak öğrenme ve benimseme potansiyelini göstermektedir.



Şekil 32. n boyutunun, önerilen yaklaşımın üç veri seti üzerindeki TPR ve FPR sonuçları üzerindeki etkisi. (a) UCF-Crimes TPR ve FPR sonuçları (b) Ped1 ve Ped2’ de TPR sonuçları (c) Ped1 ve Ped2’ de FPR sonuçları

2.4.3.1.2. Zamansal Segment Boyutunun Performansa Etkisi

Önerilen DÖTÇA-AÖM tabanlı algoritma, anomali tespit performansı üzerinde etkili olan bazı parametrelere sahiptir. Bu nedenle, zamansal segment boyutu (n), içerik farklılaşması mekanizmasındaki eşik değer ve ardışıl yığın boyutu bu bölümde analiz edilmektedir. İlk analiz n değerinin etkisi için yapılmıştır. Analiz farklı n boyutları için

UCF-Crimes ve UCSD Yaya veri setlerindeki performansın incelenmesi olarak gerçekleştirilmiştir. UCF-Crimes veri seti uzun süreli gözetim videolarını içermektedir ve veri setinin analizi altı farklı boyutta (5, 10, 15, 20, 25 ve 30) gerçekleştirilmiştir. UCSD kısa süreli videolar içerdiği için yalnızca 5 ve 10 boyutu seçilmiştir. Bu bölümdeki her iki veri seti için bir önceki analizdeki aynı parametreler kullanılmaktadır. Tablo 19-20 ve Şekil 32, UCF-Crimes ve UCSD Yaya veri setlerine ilişkin sonuçları göstermektedir.

Elde edilen sonuçlara göre önerilen yaklaşımın en yüksek performansı daha düşük segment boyutunda ($n = 5$) elde ettiği sonucuna varılabilmektedir. n arttıkça, normal olay çerçevelerini anormal olarak etiketleme olasılığı artmaktadır. Örneğin $n = 30$ durumda segmentte sadece bir anormal ve 29 normal çerçeve varsa, normal çerçevelerin sayısının çok olmasına bakılmaksızın zayıf etiketleme tekniğinden kaynaklı olarak segment anormal olarak etiketlenmektedir. Bu yüksek varyans oluşturur ve yüksek varyans nedeniyle normal ve anormal olayları ayırt etmeyi olumsuz etkilemektedir. $n = 5$ durumunda ise, zayıf etiketleme yöntemi yalnızca dört normal çerçeve ve bir anormal çerçeve içerse bile segmenti bir anormal olarak etiketlemektedir. Bu nedenle, önerilen yaklaşımın anomali tespit performansı, n arttıkça düşme eğilimindedir.

Tablo 19. Segment boyutunun Ped1 ve Ped2 üzerinde etkisinin analizi

	Ped1		Ped2	
	n=5	n=10	n=5	n=10
N=1				
EAA (%)	0.952	0.906	0.975	0.9402
EHO (%)	5.5	16	6.8	11
TPR	0.952	0.903	0.957	0.894
FPR	0.048	0.097	0.043	0.106
Kesinlik	0.952	0.903	0.957	0.894
Özgünlük	0.952	0.903	0.957	0.894
F1 skoru	0.952	0.903	0.957	0.894
N=5				
EAA (%)	0.8254	0.6666	0.8855	0.7810
EHO (%)	20.23	36.46	26.85	39.65
TPR	0.8198	0.6533	0.7954	0.6457
FPR	0.1801	0.3466	0.2045	0.3542
Kesinlik	0.8298	0.6530	0.8023	0.6457
Özgünlük	0.8198	0.6533	0.7954	0.6457
F1 skoru	0.8208	0.6531	0.7988	0.6369

Tablo 20. Segment boyutunun UCF-Crimes üzerinde etkisinin analizi

	n=5	n=10	n=15	n=20	n=25	n=30
N=1						
EAA	0.9959	0.9918	0.9878	0.9838	0.9801	0.9761
EHO (%)	0.7	1.4	2.1	2.8	3.4	4
TPR	0.9949	0.9899	0.9849	0.9801	0.9754	0.9706
FPR	0.0051	0.0101	0.0151	0.0199	0.0246	0.0294
Kesinlik	0.9949	0.9899	0.9849	0.9801	0.9754	0.9706
Özgünlük	0.9949	0.9899	0.9849	0.9801	0.9754	0.9706
F1 skoru	0.9949	0.9899	0.9849	0.9801	0.9754	0.9706
N=5						
EAA	0.9840	0.9681	0.9524	0.9438	0.9299	0.9197
EHO (%)	2.94	5.78	8.02	9.77	1.16	13.30
TPR	0.9699	0.9399	0.9156	0.8954	0.8742	0.8548
FPR	0.0106	0.0210	0.0332	0.0370	0.0480	0.0545
Kesinlik	0.9721	0.9452	0.9141	0.9044	0.8782	0.8616
Özgünlük	0.9893	0.9789	0.9667	0.9629	0.9519	0.9454
F1 skoru	0.9710	0.9425	0.9148	0.8999	0.8762	0.8520


Farklı eşik değerlerde ardışıl yığın boyutunun performansı, bu bölümün ikinci bir deneyi olarak analiz edilmiştir. Analiz, 0.1, 0.3, 0.5, 0.8 ve 1 eşik değerinde 1, 5 ve 10 ardışıl yığın boyutunda gerçekleştirilmiştir. Farklı yığın boyutundaki veri setlerinin yığın sayıları netlik olması açısından Tablo 21’de verilmiştir.

Tablo 21. Üç veri seti için farklı yığın boyutlarındaki veri sayısı

	UCF-Crimes	Ped1	Ped1
Yığındaki veri sayısı=1	93452	1440	402
Yığındaki veri sayısı=5	18690	288	81
Yığındaki veri sayısı=10	9346	144	41

Hoeffding Sınır Teoremi’ne göre içerik farklılaşması için güven aralığını veren minimum eşik değer 0.1 olarak hesaplanmıştır. Burada amaç eşik değerin arttığında performansın değişimini gözlemlektedir. Buna göre UCF-Crimes, Ped1 ve Ped2 için EAA sonuçları Şekil 33’te gösterilmektedir. Şekil 33’ e göre eşik değer arttıkça anomali tespit performansı tüm veri setlerindeki ardışıl yığın boyutlarında bir azalma eğilimi göstermektedir. Bu azalma, daha yüksek eşik değerlerde zamansal segment dizileri arasındaki içerik farklılaşması sapmasının daha az saptanmasının bir nedenidir. Eşiğin 1 olması durumunda en kötü senaryo ortaya çıkmaktadır. İçerik farklılaşması tespit

mekanizması, farklılaşmanın çoğunu tespit edememektedir ve topluluk DÖTÇA-AÖM sınıflandırıcısının yeniden inşa edilme prosedürü bu nedenle gerçekleştirilmemektedir. Bu durum, anomali tespit işleminin güncel olmayan topluluk sınıflandırıcı modelini kullanmasına neden olmaktadır.



Şekil 33. Eşik değerinin. (a) UCF-Crimes (b) Ped1 ve (c) Ped2 veri setlerinin üzerindeki etkisi

Şekil 33' e göre, yığın boyutunun anormallik algılama işlemi için önemli bir yere sahip olduğu sonucuna varılabilmektedir. Önerilen yaklaşım, tüm veri kümeleri için yığın

boyutu 1 olduğunda en iyi sonuçları elde etmektedir. Bu durumda, işlenecek yalnızca bir segment vardır ve bu nedenle doğruluk oranı 1 veya 0 olabilir. Bunun sonucu olarak, sınıflandırıcı eşiğin ne olduğuna bakılmaksızın tüm parçalar için tutarlı bir şekilde yeniden yapılandırabilmektedir. Sınıflandırıcının sık sık yeniden yapılandırılması zaman alıcı bir işlemdir ve yeni sınıflandırıcı modelin eski örneklerin herhangi bir katkısını içermemesine neden olabilmektedir. Bu deneyde, ilk yığın boyutu 10 olarak belirlenmiştir. ÇA-AÖM' nin temel teorisine bağlı olarak, gizli katman nöron sayısı da 10'a olarak belirlenmiştir. Bu durum, ardışıl yığın boyutu 10 olduğunda anomali tespit performansını olumsuz etkilemektedir. Gizli katman nöron sayısı, giriş yığının en ayırıcı özelliklerini çıkarmak için yetersiz kaldığını göstermektedir.

2.4.3.1.3. Çalışma Zamanı Analizi

Bu bölümde, video anomali tespit yaklaşımının ortalama zaman maliyeti analiz edilmektedir. Sonuçlar, tüm veri setleri için 5 ve 10 geçici segment boyutlarında, 50*50 'lık video görüntüsü boyutları üzerinden elde edilmiştir. Parametreler, diğer analizlerle aynı şekilde kullanılmıştır. Topluluk sınıflandırıcısı sayısı ve ardışıl yığın boyutu, bir segment için yaklaşımın zaman maliyetini ölçmek için 1 olarak belirlenmiştir. Önerilen yöntemdeki tüm adımların zaman maliyetleri ölçülmektedir. Bunlar zayıf etiketlemeyle ön işlem süresinin ortalama süresi, ortalama ilkendirme aşaması süresi, yeniden ilkendirme yokken ortalama ardışıl öğrenme süresi ve yeniden ilkendirme varken ortalama ardışıl öğrenme süresidir. Tüm adımların zaman maliyetleri Tablo 22' de verilmiştir.


Tablo 22. Önerilen yaklaşımın tüm süreçlerinin üç veri seti için ms. cinsinden çalışma zamanının analizi

	Ped1		Ped2		UCF-Crimes	
	n=5	n=10	n=5	n=10	n=5	n=10
Önişleme aşaması süresi	0.23	0.21	0.03	0.07	0.58	1.11
İlkendirme aşaması süresi	0.11	0.12	0.19	0.14	0.20	0.17
Ardışıl öğrenme süresi / yeniden ilkendirme yokken	0.007	0.009	0.004	0.004	0.005	0.007
Ardışıl öğrenme süresi / yeniden ilkendirme varken	0.09	0.04	0.12	0.11	0.15	0.11

Tablo 22’deki çalışma zamanı sonuçlarına göre, her adımın zaman maliyetinin bir saniyeden daha kısa olduğu görülebilmektedir. Zayıf etiketleme ile ön işleme, en çok zaman alan adımdır. Bu adım, videonun saniyedeki çerçeve sayısı (fps) hızına bağlı olan zamansal video segmentinin oluşturulmasını içermektedir. Veri kümelerindeki tüm videolar 30 fps hızına sahiptir. Bu nedenle, 5 karenin oluşturma süresi bir saniyenin altıda birine (0,1667) ve 10 karenin oluşturma süresi bir saniyenin üçte birine (0,333) eşittir. Segment oluşturma, zayıf etiketleme ile ön işleme dahilinde zaman tüketen adımdır. Bu adımın dışında, önemli adımlar ilklendirme ve ardışıl öğrenme aşamalarıdır. TKİBA modeli Tablo 22’ ye göre kısa sürede ilklendirilmiş ve güncellenmiştir. Ayrıca TKİBA modelinin yeni bir içeriğe uyum sağlamasının zaman alıcı bir süreç olmadığı görülmektedir. Videoların akan veri şeklinde artımlı olarak işlenmesi daha düşük zaman maliyetinin elde edilmesinin nedeni olarak söylenebilmektedir.

2.4.3.1.4. Anomali Skoru Analizi

Bu bölüm, önerilen yaklaşımın anormallik derecesini sunmaktadır. Bu deneyde anomali derecesini açıklamak için 0 ile 1 arasındaki anomali skoru kullanılmıştır. Anomali skoru, her bir zamansal segment için hesaplanmıştır. Bu hesap olasılık dağılımı kullanılarak yapılmıştır. Bu nedenle önce DÖTÇA-AÖM’ nin çıkışına bir SoftMax fonksiyonu uygulanmış ve ardından SoftMax işlevinin her bir çıkışı minimum-maksimum normalizasyonu ile normalleştirilmiştir. Anomali nöronuna karşılık gelen skor daha sonra segmentin anomali skoru olarak atanmıştır. Şekil 34 her veri setinden sadece iki video için elde edilen anomali skorlarını göstermektedir. Fazla video olması ve hepsinin görselleştirilmesinin zor olması nedeniyle sadece 2 video kullanılmıştır. Anomali skorunun yüksek değeri yani 1’ e yakın bir değer olması, anomalinin varlığını göstermektedir. Şekil 34 ‘den de görülebileceği gibi, akan veriye dayalı video anomali tespiti yaklaşımı anormal olayları iyi bir şekilde ayırt edebilmektedir. Şekil 34’ e göre anormal bölgenin sadece başlangıç ve son kısım segmentleri gözden kaçmıştır. Ancak, yaklaşım bu kısımları içerik farklılaşması olarak algılayıp ve sınıflandırıcıyı yeniden inşa etmektedir. Anormal olaylar tespit edildiğinde, yaklaşım anormal segmentleri gözden kaçırmamaktadır.



Şekil 34. (a) UCF-Crimes (b) Ped1 (c) Ped2 için anormali skoru görselleştirilmesi. Hesaplanan anormali skoru mavi olarak gösterilirken ve temel gerçek kırmızı alan olarak verilmiştir. 0 normal bölgeyi, 1 anormal bölgeyi temsil etmektedir. Çerçeveler üzerindeki anormal olaylar ve gecikmeler kırmızı daire ile vurgulanmıştır.

2.4.3.2. Anormal Olay Türü Tespiti Performansı

Bu bölümde anormal olay türü tespitinin performansı incelenmiştir. Bunun için sadece UCF-Crimes veri seti üzerinde çalışma yapılmıştır. Önerilen yaklaşım, bu amaçla UCF-

Crimes veri setini kullanan son teknoloji yöntemlerle karşılaştırılmıştır. Literatürde UCF-Crimes veri setini sınırlı sayıda yaklaşım bu amaçla kullanmaktadır. Çalışmalardan biri, derin öğrenme uygulamaları olan iki temel yöntem kullanarak UCF-Crimes anormallik türü tespitine odaklanmaktadır [120]. İlki C3D özelliklerine [205], ikincisi ise Tüp Konvolüsyon Sinir Ağı' na (TCNN) [206] dayanmaktadır. EEA sonuçları Tablo 23' te verilmiştir. Önerilen yaklaşımın, veri setinde en iyi anormal olay tipi tanıma sonuçlarını elde ettiği sonucuna varılabilmektedir.

Tablo 23. Anormal olay türünü belirleme performansının literatürdeki çalışmalar ile karşılaştırılması

	Önerilen Yaklaşım	C3D [205]	TCNN [206]
DO	0.9672	0.23	0.284

2.5. Ayırık Kosinüs Dönüşümü ve Sürü Zekasına Dayanan Akan Veri Tabanlı Video Anomali Tespiti ve Anormal Olay Türünün Algılanması Yaklaşımı

Bir önceki çalışma gözetleme videolarında gerçekleşen anormal olayların algılanması ve türünün belirlenmesi için akan veri tabanlı bir yaklaşım sunmaktadır. Yaklaşım video çerçevelerinden oluşan segmentleri ham olarak ele alarak işlem yapmaktadır. Ön işlem aşamasında sadece segmentleri bir akan veriye dönüştürülmektedir. Böyle bir durumda akan veri vektörü bir segmenti ifade etmektedir. Yaklaşımda vektördeki öznitelik sayısı çerçevelerin *satır* * *sütun* sayısı kadardır. Bu durumda gereksiz ve yanıltıcı özniteliklerin hepsi anomali tespiti için kullanılmaktadır. Böyle bir durum yanıltıcı sonuçların elde edilmesine de neden olabilmektedir. Bu nedenle tezin bu aşamasında zayıf etiketleme ile zamansal video segmentinin özellik çıkarımı yaklaşımına ortalama akış vektörünün en iyi özelliklerini otomatik olarak seçen ve ortalama akış vektörünün boyutunda azaltma gerçekleştiren bir yöntem önerilmektedir. Bunun için AKD ve HPSO algoritmalarına dayanan zayıf etiketleme ile zamansal video segmentinin öznitelik çıkarımı yöntemi geliştirilmiştir. Burada AKD kullanılması nedeniyle satır taraması yerine olarak zikzak tarama ile ortalama akış vektörü elde edilmektedir.

Geliştirilen öznitelik çıkartımı yöntemi ön işleme aşamasında yer almaktadır. Bu kısımdan sonra gelen öğrenme yaklaşımı bir önceki yöntem ile aynıdır. Ayrıca ön işleme aşamasına eklenen öznitelik çıkartımı ve boyut indirgeme yöntemi akan veri için tez

çalışmasında geliştirilen AKD ve HPSO yöntemdir. Bu çalışmada bu yöntem ön işleme aşamasına entegre edilmiştir. AKD ve HPSO Bölüm 2.1’ de detaylı anlatılmıştır. Bu aşamada AKD ve HPSO’ nun bu çalışma için nasıl kullanıldığından bahsedilecektir.


Bu çalışmanın katkıları aşağıdaki gibi sıralanabilmektedir:

- Çalışmanın ön işleme aşaması her segmente ait ortalama akış görüntüsüne AKD uygulanmasını içermektedir. Böylelikle ortalama akış görüntüsü daha iyi ifade edilebileceği frekans uzayına iz düşürülmüş olunmaktadır. Akan veriye bir segmenti dönüştürebilmek için gerçekleştirilen zikzak tarama ile anlamlı bir öznitelik vektörü elde edilmektedir. Gerçekleştirilen HSPO’ ya dayalı öznitelik indirgeme işlemiyle birlikte tutarlı olan öznitelik setini belirlenerek tutarlı ve yüksek performans ulaşılmaktadır.

- HPSO ile öznitelik setinin belirlenmesinde kullanılan amaç fonksiyonu bu çalışmanın amacına uygun şekilde geliştirilmiştir.

- AKD ve HPSO’ ya yaklaşımının topluluk sınıflandırıcısına dayalı DÖTÇA-AÖM ile kullanılması video anomali tespiti için geliştirilen akan veri tabanlı ilk çalışmadır.

Çalışmanın akış diyagramı Şekil 35’ te ki gibidir.




Şekil 35. AKD ve HPSO’ ya dayalı akan veri tabanlı video anomali tespiti ve anormal olay türünün belirlenmesi yaklaşımının genel modeli.

2.5.1. Ön İşleme Aşaması

Önişleme aşaması dört ana süreçten oluşmaktadır ve bu aşama Şekil 36' da gösterilmektedir. Bazı süreçlerin bir önceki çalışma ile aynı olması nedeniyle bütün süreçler bu başlık altında detaylandırılacaktır.

İlk aşama bir önceki çalışmada olduğu gibi zamansal segmentlerin oluşturulmasıdır. Yaklaşım video akışı sırasında yakalanan belirli sayıda çerçeve kullanılarak anlık bir zamansal video alt segmentinin oluşturulması ile başlamaktadır. Bir segment oluşuktan sonra segment seviyesinde bir zayıf etiketleme işlemine tabi tutularak segmenti oluşturan çerçevelerin ortalaması alınarak ortalama akış görüntüsü oluşturulmaktadır.



Şekil 36. AKD ve HPSO süreçlerini içeren öznetelik çıkartma aşamasının genel modeli


Mevcut segmente ait ortalama akış görüntüsü elde edildikten sonra bu görüntüye AKD uygulanmaktadır. Böylelikle segment kendisini ifade eden ortalama görüntü aracılığıyla alçak ve yüksek bileşenlerine ayrılarak frekans uzayına aktarılmış olunmaktadır. Burada Bölüm 2.1'deki çalışmadan farklı olarak tek boyutlu bir vektör yerine iki boyutlu bir görüntüye AKD uygulanmaktadır. Görüntüye uygulanan AKD fonksiyonu eşitlik (43)' te verilmiştir.

$$F(u, v) = \sqrt{\frac{2}{n}} \sqrt{\frac{2}{m}} \alpha(u) \alpha(v) \sum_{i=0}^{x-1} \sum_{j=0}^{y-1} f(i, j) * \cos\left(\frac{\pi u(2i+1)}{2n}\right) * \cos\left(\frac{\pi v(2j+1)}{2m}\right) \quad (43)$$

$f(i, j)$, $x * y$ boyutlara sahip ortalama akış görüntüsü; $F(u, v)$ ise $x * y$ boyutlu AKD katsayılarını ifade etmektedir. (43) eşitliğindeki $\alpha(u)$ ve $\alpha(v)$ katsayıları (44) eşitliğindeki gibi hesaplanmaktadır.

$$\alpha(u), \alpha(v) = \begin{cases} \frac{1}{\sqrt{2}} & u = 0, v = 0 \\ 1 & \text{aksi takdirde} \end{cases} \quad (44)$$

$F(u, v)$ AKD katsayılarında sol üst köşede DC bileşeni yer almaktadır. Geri kalan katsayılar simetrik olarak DC bileşeninin etrafında dağılarak simetrik bir matris oluşturmaktadır. Bu matris zikzak olarak taranarak bir tek boyutlu bir öznitelik vektörüne alçak frekans bileşenleri ilk kısımlara, yüksek frekans bileşenleri ise son kısımlara gelecek şekilde gruplama yapılabilmektedir. 6*6' lık bir görüntü için zikzak tarama örneği Şekil 37' te gösterilmiştir.



Şekil 37. 6*6' lık örnek görüntünün zikzak tarama ile vektör elde edilme işlemi

Zikzak tarama ile elde edilen ortalama akış vektörü $x_t = [x_{t1}, x_{t2}, ..., x_{t(x*y)}]$, 3 boyutlu zamansal alt video segmentinden tek boyutlu $x * y$ öznitelik içeren bir öznitelik vektörüne dönüştürülmüş bir vektördür. Bu vektör görüntünün vektöre dönüştürülmesi ile elde edildiği için öznitelik sayısı oldukça fazladır. Ayrıca bu büyük ölçekli durumu ve tutarsız öznitelik içerebilmesi nedeniyle, bir öznitelik seçme tekniği gereklidir. Öznitelik seçme süreci, öznitelik vektörlerinden en tutarlı, uygun ve doğru özellikler alt kümesinin seçilmesine dayanmaktadır. Bu nedenle HPSO' ya dayanan otomatik özellik seçme adımı uygulanarak özellik sayısı indirgenmektedir. HPSO için gerekli olan amaç fonksiyonu AÖM-OK ile giriş verilerinin minimum hata ile çıkışta üretilmesine dayanmaktadır.

Ortalama Karesel Hata (OKH)'nın minimum değerini üreten öznitelik seti belirlenerek öznitelik vektöründen en etkili öznitelik seti otomatik olarak seçilmektedir. Burada kullanılan amaç fonksiyonu aşağıdaki gibidir.

Algoritma 8: Amaç Fonksiyonu- AÖM-OK

Girdi: Eğitim kümesi $\mathbf{X}_0 = \{(\mathbf{x}_{ti}) | i = 1, 2, \dots, N_0\}$, aktivasyon fonksiyonu $g(x)$, gizli katman nöron sayısı L , veri sayısı N_0 , D tane rastgele seçilmiş öznitelik indis dizisi.

Çıktı: hata değeri

1. ELM-AE' in giriş katmanı ağırlıkları a_j ve bias b_j rastgele ata. $j = 1, 2, \dots, L$
2. Gizli katman çıktı matrisi $\mathbf{H}_{AE}$ hesapla.
3. Çıkış katmanı ağırlıkları β_{AE} hesapla.
4. Hesaplanan ağırlıklar kullanarak girdi verisini yeniden üret.

$$\mathbf{X}'_0 = \mathbf{H}_{AE} \beta_{AE} \quad (45)$$

5. $\mathbf{X}'_0$ ile $\mathbf{X}_0$ arasındaki ortalama karesel hata değerini hesapla.

$$OKH = |\mathbf{X}'_0 - \mathbf{X}_0| \quad (46)$$

HSPO ile öznitelik belirlenmesi işlemi sadece ilk N_0 tane vektör için gerçekleştirilmektedir. HSPO sonucunda tutarlı özniteliklere denk gelen öznitelik indis seti N_0 veri ile belirlenmektedir. Geriye kalan vektörlerde amaç fonksiyonu sonunda belirlenen öznitelik indis setine göre sadece boyut indirgemesi yapılmaktadır. Öznitelik indirgeme işlemi sonrasında ortalama akış vektörü $xi_t = [xi_{t1}, xi_{t2}, \dots, xi_{tD}]$, $D < x * y$ şeklinde ifade edilebilmektedir. Anlık olarak oluşturulan her segment bir vektöre çevrildikten ve öznitelik sayısı indirgendikten sonra akan veri öğrenme algoritması olan DÖTÇA-AÖM' de işlenmesi için yığın yapılarına yerleştirilmektedir.

2.5.2. Anomalinin Topluluk Sınıflandırıcısına Dayalı DÖTÇA-AÖM ile Tespiti

Bu aşamada yığınlara yerleştirilen her bir vektör öğrenme topluluk sınıflandırıcısına dayalı DÖTÇA-AÖM algoritmasına tabi tutulmaktadır. Öğrenme ve anomali tespiti Bölüm 2.4.2' deki gibi aynı şekilde gerçekleştirilmiştir.

Bu çalışma ayrıca bir önceki çalışmada olduğu gibi küçük modifikasyonlar ile anormal olay türünü belirleme işlemini de gerçekleştirmektedir.

2.5.3. Deneysel Sonuçlar

Bu aşamada en son olarak gerçekleştirilen video anomali tespiti problemini gözetleme videolarını akan veri olarak ele alarak örüntü tanıma ihtiyacı duymadan çözen bir yaklaşımın AKD ve HPSO ile geliştirildiği çalışma sunulmaktadır. Çalışma bir önceki çalışmada kullanılan gerçek video görüntülerinden oluşan UCF-Crimes [120] veri seti ile UCSD Yaya veri seti [170] üzerinde analiz edilmiştir.

Performans analizi gerçekleştirebilmek için yapılan deneysel çalışmalar hem sadece bir önceki çalışma olan otomatik özellik belirleme işlemi olmayan satır taramasına dayanan yaklaşım için, hem de bu çalışmada önerilen AKD ve HPSO' ya dayanan zikzak tarama tabanlı yaklaşım için verilmektedir. Bu bağlamda analizler 6 farklı senaryo ile gerçekleştirilmektedir. Bunlar zayıf etiketleme ile özellik çıkartılması aşamasının farklı kullanılmasına göre çeşitlenmektedir. Bu senaryolar:

1. Satır taramasına göre vektör oluşturulması (Satır)
2. Zikzak taramaya göre vektör oluşturulması (Zikzak)
3. AKD uygulandıktan sonra satır taramasına göre vektör oluşturulması (AKD-Satır)
4. AKD uygulandıktan sonra zikzak taramasına göre vektör oluşturulması (AKD-Zikzak)
5. AKD uygulandıktan sonra satır taramasına göre oluşturulan vektörün HPSO ile otomatik özellik seçimi ile indirgenmesi (AKD-Satır-HPSO)
6. AKD uygulandıktan sonra zikzak taramasına göre oluşturulan vektörün HPSO ile otomatik özellik seçimi ile indirgenmesi (AKD-Zikzak-HPSO)

Senaryolar içerisindeki 1. ve 6. Senaryolar sırasıyla bir önceki çalışmaya ve bu aşamada sunulan çalışmaya denk gelmektedir. Diğer senaryolar kontrollü deney yapılarak süreçlerin tek başlarına ya da bir kombinasyonları ile performanslarının ne olduğu incelemek için yapılmıştır.

2.5.3.1. Anomali Tespiti Performansı

2.5.3.1.1. Sınıflandırma Performansı

Bu bölümde, önerilen video anomali tespiti yaklaşımı olan AKD-Zikzak-HPSO ‘nun sınıflandırma performansı literatürde yer alan derin öğrenme tabanlı yaklaşımlar karşılaştırılarak analiz edilmiştir. Değerlendirme ölçütleri, çerçeve tabanlı EEA ve EHO’ dur. Ayrıca AKD-Zikzak-HPSO bir önceki çalışma olan Satır senaryosu ile de karşılaştırılmıştır. Her iki yöntemde yer alan DÖTÇA-AÖM aynı parametrelere sahip olacak şekilde analiz yapılmıştır. Bu parametreler deneysel olarak belirlenmiştir. Gizli katmanındaki nöron sayısı ve ilk yığın boyutu 10 olarak seçilmiştir. İçerik farklılaşması için gerekli eşik değeri 0.1 olarak hesaplanmıştır. Zamansal video segment boyutu deneysel olarak belirlenmiş ve bu deneyde problemi akan veri biçiminde ele alabilmek için en iyi sayı olan diğer yaklaşımlara en yakın olacak değeri olan 5 olarak seçilmiştir. Bunun sonucu olarak çalışmada kullanılan UCF-Crimes, Ped1 ve Ped2 için zamansal segmentlerin sayıları sırasıyla 93452, 1440 ve 402 olmaktadır. Ardışıl yığın boyutu UCF-Crimes için 5, UCSD Yaya veri seti (Ped1, Ped2) için 1 seçilmiştir. Çalışmadaki topluluk sınıflandırıcı sayısı ise 7’ dir. Her iki veri seti için elde edilen sonuçlar Tablo 24 ve 25’ te verilmektedir.

Tablo 24. UCSD veri seti için anomali tespit doğruluk değerlerinin diğer yaklaşımlarla karşılaştırılması

	Ped1		Ped2	
	EEA	EHO (%)	EEA	EHO (%)
AKD-Zikzak-HPSO	0.952	5.5	0.975	6.8
Satır	0.952	5.5	0.975	6.8
AOE [123]	0.946	--	0.959	--
SCG-SF [119]	0.909	16.2	0.902	17.3
AnomalyNet [145]	0.835	25.2	0.949	10.3
MGFC-AAE [136]	0.850	20	0.902	16
GMFC-VAE [149]	0.949	11.3	0.922	12.6
AMDN [144]	0.921	16	0.908	17

Tablo 25. UCF-Crimes veri seti için anomali tespit doğruluk değerlerinin diğer yaklaşımlarla karşılaştırılması

Önerilen Yaklaşım		Sultani vd. [120]	Hasan vd. [143]	Lu vd. [204]	Zhong vd. [142]	
AKD-Zikzak-HPSO	Satır					
EAA	0.9846	0.9840	0.7541	0.506	0.6551	0.8212

Tablo 24 ve Tablo 25’ teki sonuçlar, bu aşamada önerilen AKD-Zikzak-HPSO yaklaşımının diğer yaklaşımlarla karşılaştırıldığında en iyi EAA değerine sahip olduğunu göstermektedir. Tablo 24’ e göre AKD-Zikzak-HPSO ile Satır çalışmaları aynı sonuçları elde etmiştir. Bunun nedeni diğer yaklaşımların çerçeve düzeyinde sonuç almasından dolayı en benzer değerlendirmeyi yapabilmek için iki yaklaşımda ardışıl yığın sayısının 1 olarak seçilmesidir. Ardışıl yığın sayısının 1 olduğu durumda her iki çalışma aynı performansa sahiptir. Performanslardaki fark UCSD veri seti için ardışıl yığın sayısının artması ile elde edilmektedir. Tablo 25’ te ise UCF-Crimes veri seti için böyle bir zorunluluk olmadığından yığın sayısının 5 olduğu durum diğer çalışmalar ile karşılaştırılmıştır. AKD-Zikzak-HPSO çalışmasının hem bir önceki Satır çalışmasına göre, hem de diğer çalışmalara göre daha başarılı olduğu görülmektedir. Bu çalışmada 2500 öznitelik içerisinde 1000 tanesi HPSO ile belirlenerek kullanılmıştır. Bu duruma göre daha az öznitelik sayısı kullanıldığında bile yöntem daha başarılı olmaktadır. Bunun nedeni HPPSO ile en iyi öznitelik setinin belirlenmiş olmasıdır. Segment boyutunun ve ardışıl yığın sayısının 5 olduğu durumdaki tüm veri setlerinin anomali tespit performansı AKD-Zikzak-HPSO ile Satır senaryoları için Tablo 26’ teki gibi verilmiştir. Burada AKD-Zikzak-HPSO yaklaşımda HPSO ile seçilen öznitelik setindeki öznitelik sayısı Ped1 için 2000, Ped2 için 1000 ve UCF-Crimes için 1000’ dır.

Tablo 26. Veri setleri için ardışıl yığın ve segment boyutunun 5 olduğu durumdaki AKD-Zikzak-HPSO ile Satır senaryolarının anomali tespit performansı

	Ped1			Ped2			UCF-Crimes		
	YSVS	EAA	EHO	YSVS	EAA	EHO	YSVS	EAA	EHO
AKD-Zikzak-HPSO	229	0,8402	17,8	35	0,9129	23,03	1437	0,9846	2,81
Satır	251	0,8256	20,23	46	0,8855	26,85	1494	0,9840	2,94

2.5.3.1.2. AKD ve Zikzak Taramanın Etkisinin İncelenmesi

Bu bölümde akan veri tabanlı video anomali tespiti yaklaşımı, zayıf etiketleme ile özellik elde edilmesi aşamasının farklı senaryolar kullanıldığında nasıl performans gösterdiği incelenmektedir. Buradaki senaryolar yukarıda bahsedilen Satır, AKD-Satır, Zikzak ve AKD-Zikzak' tır. Zamansal segmentleri oluşturan karelerin sayısının farklı durumlarında EAA, EHO ve YSVS metrikleri elde edilerek senaryoların analizi gerçekleştirilmektedir. Bu sonuçlar gizli katman nöron sayısı ve N_0 değerinin 10, eşik değerin 0.1 ve topluluk sınıflandırıcı sayısının 7 olduğu durumda elde edilmiştir. Ardışıl yığın boyutları ise UCSD veri seti için 1, 3, 5; UCF-Crimes için de 5 olarak belirlenmiştir. Segment boyutu ise UCSD veri seti için 5 ve 10, UCF-Crimes veri seti için de 5, 15 ve 25 olarak seçilmiştir. Bu analize ilişkin sonuçlar Tablo 27, 28 ve 29'da verilmektedir.

Tablo 27, 28 ve 29'daki sonuçlar incelendiğinde, tüm veri setleri için farklı segment ve yığın boyutlarında AKD-Zikzak senaryosunun diğerlerine göre daha iyi performans sergilediği görülebilmektedir. Bunun en önemli nedenlerinden biri segmentlerin AKD ile frekans uzayında temsilinin sağlanmasıdır. Ayrıca zikzak tarama ile benzer frekans bilgilerinin bir araya toplanması performansı arttırmıştır.

Tablo 27. UCSD Ped1 veri seti için 1, 3 ve 5 yığın değerlerindeki EAA, YSVS ve EHO sonuçları

	1			3			5		
Yaklaşım	EAA	YSVS	EHO	EAA	YSVS	EHO	EAA	YSVS	EHO
5-Satır	0,9527	68	5,51	0,8902	158	12,81	0,8256	251	20,23
5-AKD-Satır	0,9527	68	5,51	0,8736	152	12,11	0,8305	244	19,26
5-Zikzak	0,9527	68	5,51	0,8951	151	12,09	0,8312	243	19,14
5-AKD-Zikzak	0,9527	68	5,51	0,8958	150	12,02	0,8388	232	18,88
10-Satır	0,9069	67	11,33	0,7875	153	24,49	0,6666	240	36,46
10-Satır-AKD	0,9069	67	11,33	0,7958	147	24,19	0,6791	231	35,43
10-Zikzak	0,9069	67	11,33	0,7930	149	25,01	0,6791	231	35,68
10-AKD-Zikzak	0,9069	67	11,33	0,8013	143	23,41	0,6847	227	35,4

Tablo 28. UCSD Ped1 veri seti için 1, 3 ve 5 yığın değerlerindeki EAA, YSVS ve EHO sonuçları

	1			3			5		
Yaklaşım	EAA	YSVS	EHO	EAA	YSVS	EHO	EAA	YSVS	EHO
5-Satır	0,9751	10	6,76	0,9477	21	11,76	0,8855	46	26,85
5-AKD-Satır	0,9751	10	6,76	0,9527	19	10,5	0,9029	44	25,96
5-Zikzak	0,9751	10	6,76	0,9552	18	11,67	0,8955	42	25,84
5-AKD-Zikzak	0,9751	10	6,76	0,9601	16	10,48	0,9004	40	23,31
10-Satır	0,9402	12	15,47	0,8756	25	22,64	0,7810	44	39,65
10-Satır-AKD	0,9402	12	15,47	0,8905	22	24,06	0,8009	40	39,0
10-Zikzak	0,9402	12	15,47	0,8855	23	22,41	0,7960	41	39,16
10-AKD-Zikzak	0,9402	12	15,47	0,8905	22	22,3	0,8009	40	38,99

Tablo 29. UCF-Crimes veri seti için 5 ardışıl yığını için farklı segment boyutlarındaki EAA, YSVS ve EHO sonuçları

	n=5			n=15			n=25		
Yaklaşım	EAA	YSVS	EHO	EAA	YSVS	EHO	EAA	YSVS	EHO
Satır	0,9840	1494	2,94	0,9524	1487	8,02	0,9299	1314	11,66
AKD-Satır	0,9840	1493	2,91	0,9536	1450	7,78	0,9303	1307	11,57
Zikzak	0,9840	1491	2,83	0,9533	1461	7,96	0,9308	1296	11,41
AKD-Zikzak	0,9843	1464	2,83	0,9546	1420	7,56	0,9321	1273	11,35

Bir önceki çalışmaya sadece AKD eklendiğinde yaklaşımda performans artışı görülmektedir. Bu durum Ped1 ve Ped2'nin yığın boyutunun 3 ve 5 olduğu durumlarda daha açık görülebilmektedir. Özellikle EHO değeri AKD-Satır senaryosunda belirgin bir şekilde azalmaktadır. Bir önceki çalışma ile Zikzak karşılaştırıldığında sadece zikzak tarama ile yaklaşıma bir katkı sağlandığı da görülmektedir. Hem zikzak hem de AKD içeren senaryo ise tüm veri setlerinde en başarılı sonuçların elde edildiği durumdur. Hem AKD' den hem de zikzak taramadan gelen katkı yaklaşımın performansını arttırmaktadır.

2.5.3.1.3. HPSO ile Otomatik Öznitelik Seçiminin Analizi

Bu bölümde akan veri tabanlı video anomali tespiti yaklaşımındaki HPSO ile otomatik özellik seçiminin analizi incelenmektedir. UCSD ve UCF-Crimes veri setleri üzerinde sonuçlar ara katman nöron sayısı ve N_0 değerinin 10, eşik değeri 0.1, ardışıl yığın sayısının 5 ve topluluk sınıflandırıcı sayısının 7 olduğu durumda elde edilmiştir. Sonuçlar özellik sayısının otomatik olarak 2400, 2300, 2200, 2100, 2000, 1500 ve 1000 tane öznitelik seçildiği 7 durumdaki EHO değerleri üzerinde AKD-Satır-HPSO senaryosu ile karşılaştırılmalı olarak Şekil 38’ de verilmektedir. Tablo 30 ise iki senaryonun segment boyutunun 5 ve 10 olduğu durumlarda elde ettiği EAA, EHO ve YSVS sonuçlarını vermektedir. Tablo 31’ de bu sonuçların elde edildiği en iyi öznitelik setinin içerdiği öznitelik sayısı gösterilmektedir.

Tablo 30. Veri setleri için AKD-Zikzak-HPSO ile AKD-Satır-HPSO’ nun karşılaştırılması


	Ped1			Ped2			UCF-Crimes		
	YSVS	EAA	EHO	YSVS	EAA	EHO	YSVS	EAA	EHO
5-AKD-Zikzak-HPSO	229	0,8402	17,8	35	0,9129	23.03	1437	0,9846	2,81
5-AKD-Satır-HPSO	230	0,8402	17,91	40	0,9004	23.31	1444	0,9845	2,84
10-AKD-Zikzak-HPSO	221	0,6930	34,73	37	0,8159	34.99	1430	0,9694	5,48
10-AKD-Satır-HPSO	228	0,6833	34,84	38	0,8109	36.38	1464	0,9686	5,52

Tablo 31. Tablo 30’ da ki sonuçları veren öznitelik sayısı

	AKD-Zikzak-HPSO		AKD-Satır-HPSO	
	5	10	5	10
Ped1	2000	1000	2000	1500
Ped2	1000	1000	1500	2000
UCF-Crimes	1000	1500	1500	1500

Şekil 38 ile Tablo 30 incelendiğinde önerilen yaklaşımın diğer senaryo olan AKD-Satır-HPSO’ dan daha etkili olduğu görülmektedir. Bunun en büyük nedeni olarak zikzak

tarama ile görüntünün vektöre çevrilirken alçak ve yüksek frekans bileşenlerinin ayrı bir grup altında toplanması verilebilmektedir.



Şekil 38. Farklı özellik sayıları için HPSO' nun 3 veri setinde davranışı

HPSO' nun etkisinin incelenmesi deneyinde son olarak kesinlik, özgüllük, TPR, FPR ve F1 skorunun analizi gerçekleştirilmiştir. Bu analize ait sonuçlar Tablo 32' de verilmektedir. Tablo 32 'de ki sonuçları üreten karmaşıklık matrisleri Tablo 33-35' te gösterilmektedir. Bu tablolarda GN Gerçek Normal Olayları, GA Gerçek Anormal Olayları,

TN Tahmin edilen Normal Olayları ve TA Tahmin edilen Anormal Olayları ifade etmektedir.

Tablo 32-35' teki sonuçlar yaklaşımın başarılı bir şekilde anormal ve normal olayları tanıma kapasitesine sahip olduğunu göstermektedir.

Tablo 32. AKD-Zikzak-HPSO için segment boyunun 5 ve 10 olduğu durumlarda elde edilen bazı metriklerin sonuçları

	Ped1		Ped2		UCF-Crimes	
	n=5	n=10	n=5	n=10	n=5	n=10
EAA	0,8402	0,6930	0,9129	0,8159	0,9846	0,9694
EHO (%)	17,8	34,73	23,03	34,99	2,81	5,48
TPR	0,8366	0,6770	0,8345	0,7018	0,9713	0,9431
FPR	0,1633	0,3229	0,1654	0,2981	0,0102	0,0204
Kesinlik	0,8361	0,6795	0,8549	0,6813	0,9730	0,9467
Özgüllük	0,8366	0,6795	0,8345	0,7018	0,9897	0,9795
F1 skoru	0,8363	0,6783	0,8446	0,6914	0,9721	0,9449

Tablo 33. Ped1 veri seti için segment boyutu 5 ve 10 olduğu durumdaki karmaşıklık matrisi

n=5			n=10		
	TN	TA		TN	TA
GN	508	99	GN	195	93
GA	136	697	GA	139	293

Tablo 34. Ped2 veri seti için segment boyutu 5 ve 10 olduğu durumdaki karmaşıklık matrisi

n=5			n=10		
	TN	TA		TN	TA
GN	58	12	GN	24	10
GA	55	277	GA	50	117

Tablo 35. UCF-Crimes veri seti için segment boyutu 5 ve 10 olduğu durumdaki karmaşıklık matrisi

n=5			n=10		
	TN	TA		TN	TA
GN	65671	1940	GN	31834	1921
GA	264	25577	GA	265	12747

2.5.3.2. Anormal Olay Türü Tespiti Performansı

Bu bölümde AKD ve HPSO' ya dayalı yaklaşımın anormal olay türü tespiti performansı UCF-Crimes veri seti üzerinde incelenmiştir. Yaklaşım bir önceki çalışma olan Satır senaryosu ile karşılaştırılmıştır. Yaklaşımların sonuçları topluluk sınıflandırıcı sayısı 7, gizli katman nöron sayısı ve ilk yığın boyutunun 10 ve ardışıl yığın boyutlarının da 5 olduğu durumda elde edilmiştir. Bu analize ait sonuçlar Tablo 36' te EAA, YSVS ve Hamming Kaybı üzerinden verilmiştir.

Tablo 36. Anormal olay türü tespiti performansı incelenmesi

Segment Boyutu/ Segment Sayısı	Satır			AKD-Zikzak-HPSO		
	EAA	YSVS	Hamming Kaybı	EAA	YSVS	Hamming Kaybı
5 / 93452	0,9839	1504	0,0321	0,9847	1423	0,0304
10/ 46767	0,9681	1491	0,0304	0,9693	1434	0,0613
15/ 31291	0,9539	1440	0,0920	0,9557	1384	0,0884
20/ 23421	0,9409	1382	0,1180	0,9444	1300	0,1110
25/ 18753	0,9290	1330	0,1418	0,9322	1270	0,1354
30/ 15684	0,9179	1287	0,1559	0,9220	1223	0,1559

Tablo 37. AKD-Zikzak-HPSO' daki seçilen öznitelik sayıları

Segment Boyutu	Öznitelik Sayısı
5	2200
10	1000
15	1500
20	2400
25	2100
30	2400

Anormal olay türü tespiti analizinde son olarak kesinlik, özgüllük, TPR, FPR ve F1 skorunun incelenmesi gerçekleştirilmiştir. Bu analize ait sonuçlar Tablo 38' da verilmektedir. Tablo 38 'deki sonuçları üreten karmaşıklık matrisi topluluk sınıflandırıcı sayısı 7 olduğu durum için Tablo 39' da gösterilmektedir. Tek sınıflandırıcı için elde edilen karmaşıklık matrisi Tablo 40' da verilmiştir.


Bu tablolarda satırlar her olaya ait gerçek verileri gösterirken, sütunlar ise tahmin edilen veriler göstermektedir. 14 farklı olay olması nedeniyle matrisin boyutu 14*14' tür. 1 normal olaylara denk gelmektedir. Tablolar incelendiğinde görülen ilk durum yaklaşımın normal olayları diğer anormal olay türleri ile karıştırdığı söylenebilmektedir. Diğer anormal türleri ise normal olaylarla genellikle karıştırmaktadır. İki anormal türleri karıştırmak topluluk sınıflandırıcı durumu 7 iken çok az gerçekleşirken, 1 durumda ise biraz daha fazla gerçekleşmektedir.

2.6. Video Anomali Tespiti için Aktif Öğrenmeye Dayanan Akan Veri Tabanlı Yaklaşım

Anomali tespiti için gerçekleştirilen her iki çalışma her ne kadar öğrenme yaklaşımında zayıf etiket değerlerini kullansa da tüm verilerin etiket değerlerinin bilinmesini gerektirmekteydi. Böyle bir gereksinim gerçek zamanlı gerçek dünya uygulamalarına çok uygun gelmemektedir. Bu nedenle gerçek dünya uygulamalarına uygun gelecek bir şekilde önerilen anomali tespiti yaklaşımı düzenlenmiş ve mümkün olabildiği sürece etiket değerine daha az gereksinimi gerektiren bir yaklaşım geliştirilmiştir. Geliştirilen yaklaşım akan veriler için sıklıkla kullanılan aktif öğrenme stratejisine göre tasarlanmıştır. Yani gerekli olduğu durumda etiket bilgisi bir uzmandan istenmektedir.

Yaklaşım bir varsayım ve bir teoreme dayanmaktadır. Varsayım her videonun başlangıcında belli bir kısmının etiket değerinin bilinmesidir. Böylelikle her video hakkında bir miktar ön bilgi elde edilmiş olunmaktadır. Teorem ise içerik farklılaşması için kullanılan komşu iki yığının olasılık dağılımının çok fazla değişmeyeceğini söyleyen Hoeffding Sınır Teoremi' dir. Bu durum eğer iki yığın arasında çok fazla bir değişim yoksa öğrenme yaklaşımının bir önceki yığın için atadığı etiket değerlerinin mevcut olan için kullanarak ağın güncellenmesine olanak sağlamaktadır. Böylelikle gerçek etiket değerine ihtiyaç olmadan TKİBA yapısı güncellenebilmektedir. Yaklaşım önışleme aşaması, Aktif Öğrenmeye Dayalı TDÖTÇA-AÖM (AÖTDÖTÇA-AÖM) ve nihai kararın çoğunluk oylamasına göre verilmesi olmak üzere 3 aşamadan oluşmaktadır. Önışleme aşaması diğer yaklaşımlardan farklı olarak segment yerine çerçeve bazlı bir algoritma içermektedir. Bu aşamada anlık olarak kaydedilen video çerçeveleri bir akan veriye dönüştürülmektedir. Bu aşamada bir önceki yaklaşımda kullanılan AKD, zikzak tarama ve HPSO algoritmalarına dayanan video çerçevesinin öznitelik çıkarımı yöntemi yer almaktadır. Öğrenme yaklaşımı

olan AÖTDÖTÇA-AÖM ise akan veri için geliştirilen TDÖTÇA-AÖM' nin aktif öğrenme stratejisine göre geliştirilmiş halidir. Her bir akan veri yığınına işleyerek bir anomali skoru üretmektedir. Bu çalışmadaki tüm aşamalar alt başlıklar altında detaylandırılarak anlatılacaktır ve genel modeli ise Şekil 39' da verilmiştir.



Şekil 39. Aktif öğrenmeye dayalı anomali tespit yaklaşımının genel modeli


Çalışmanın katkıları ise şöyle sıralanabilmektedir:

- Çalışmanın konusu olan gözetleme videolarında anomali tespiti aktif öğrenmeye dayanmaktadır. Geliştirilen AÖTDÖTÇA-AÖM akan veri tabanlı aktif öğrenmeye dayanan ilk anomali tespit yaklaşımıdır.
- AÖTDÖTÇA-AÖM ile etiket bilgisine minimum şekilde ihtiyaç duyulmaktadır. Bu durum yaklaşımı gerçek dünya uygulamasına oldukça uygun bir yaklaşım yapmaktadır.

2.6.1. Önışleme Aşaması

Önışleme aşaması her bir çerçeve için ayrı ayrı işlenen bir süreçtir. Bu süreç Şekil 40'ta gösterilmektedir. Bu aşamanın bir önceki çalışmanın ön işleme aşaması ile oldukça benzerdir. En önemli farklılığı ise tüm çerçevelerin etiket bilgisinin bilinmediği bir durum ele alındığı için segment seviyesindeki zayıf etiketleme ve ortalama akış görüntüsünün oluşması bu aşamada yer almamaktadır. Sunulan çalışma her çerçeveyi teker teker işlemektedir.


Anlık olarak oluşturulan bir çerçeve önce AKD ile frekans uzayına izdüşürülür ve elde edilen AKD katsayısı matrisi zikzak tarama ile bir vektöre çevrilir. Bu aşamalar Bölüm 2.5'te ayrıntılı olarak açıklanmıştır. Eğer belli sayıda çerçeveden oluşan ilk yığın (N_0) oluşmuşsa HPSO ile en etkin öznitelik seti otomatik olarak bu yığın üzerinden belirlenmektedir. Bu yığının dışında kalan tüm çerçevelere ait öznitelik vektörlerden ise belirlenen öznitelik seti seçilerek boyut indirgeme gerçekleştirilmektedir. Bu aşamadan sonra indirgenen öznitelik vektörlerinden oluşan yığın eğer N_0 ise ilklendirme aşamasında, N_0 yığından sonra oluşan bir yığın ise ardışıl öğrenme aşamasında işlenmektedir.




Şekil 40. Önışleme aşamasının genel modeli

2.6.2. Anomalinin Topluluk Sınıflandırıcısına Dayalı AÖDÖTÇA-AÖM ile Tespiti

Bu aşama DÖTÇA-AÖM yaklaşımının aktif öğrenme stratejisine adapte edilmiş olan AÖDÖTÇA-AÖM ile öğrenme işlemi gerçekleştirmektedir. AÖDÖTÇA-AÖM akan veri yığınlarının gerçek etiket değerlerini kullanmadan kendisinin atadığı etiket değerleri kullanarak öğrenme işlemi yapmaktadır. Yaklaşım her videonun başlangıcındaki N_0 yığının etiket değerlerinin bilindiği varsayımı üzerine kurulmuştur. Yaklaşımın genel akış modeli Şekil 41’ de, TKİBA modeli ise Şekil 42’ de gösterilmektedir.



Şekil 41. AÖDÖTÇA-AÖM’ nin genel modeli



Şekil 42. AÖDÖTÇA-AÖM’ nin ağ modeli

AÖDÖTÇA-AÖM üç aşamadan oluşmaktadır. İlk aşama ilklendirme aşamasıdır. Bu aşamada DÖTÇA-AÖM’deki ilklendirme aşaması gibi çalışmaktadır. Sadece ilk yığın olan N_0 için icra edilerek Şekil 42’teki ağ modeli kurulmaktadır. DÖTÇA-AÖM’den tek farkı TKİBA yapısının tek çıkışa sahip bir çıkış katmanının bulunmasıdır. Tek çıkış değeri yaklaşımda anomali skorunun üretmektedir. Bu skor değeri ideal şartlarda 1 olduğu durumda normal, 2 olduğu durumda ise anormal olayı ifade etmektedir.

Algoritmanın ikinci aşaması ardışıl öğrenme aşamasıdır. İlk yığın değerlendirilip TKİBA yapısı kurulduktan sonra oluşan tüm ardışıl yığınlar bu aşamada işlenmektedir. Ardışıl öğrenme aşamasının algoritması Algoritma 8’de verilmiştir.

Algoritma 8: Ardışıl Öğrenme Aşaması

Girdi: Eğitim seti $\mathbf{X} = \{(\mathbf{x}_i) | i = 1, 2, \dots, N\}$, aktivasyon fonksiyonu $g(\mathbf{x})$, gizli katmandaki, nöron sayısı L , yığın indeksi $k + 1$, Hoeffding Sınırı ile elde edilen eşik değeri ε , Anomali eşik değeri $\varepsilon_{anomaly}$

Çıkış: $\mathbf{K}_{k+1}$ ve Çıktı katmanı ağırlıkları $\boldsymbol{\beta}^{k+1}$, AS_{k+1}

1) Mevcut ağ modeli ile N_{k+1} yığını test et ve AS_{k+1} anomali skorunu hesapla.

a. Eğer $AS_{k+1} \geq \varepsilon_{anomaly}$

i) Çerçeve çıktısı anomali olarak belirle.

b. $AS_{k+1} < \varepsilon_{anomaly}$

i) Çerçeve çıktısı normal olarak belirle.

2) Eğer $Ort(AS_k) - Ort(AS_{k+1}) \leq \varepsilon$

a. Gizli katman çıkış matrisini $\mathbf{H}_{k+1}$ (47)’deki gibi hesapla.

$$\mathbf{H}_{k+1} = \begin{bmatrix} g(\mathbf{a}_1, b_1, \mathbf{x}_{(\sum_{j=0}^k N_j)+1}) & \cdots & g(\mathbf{a}_L, b_L, \mathbf{x}_{(\sum_{j=0}^k N_j)+1}) \\ \vdots & \ddots & \vdots \\ g(\mathbf{a}_1, b_1, \mathbf{x}_{(\sum_{j=0}^{k+1} N_j)}) & \cdots & g(\mathbf{a}_L, b_L, \mathbf{x}_{(\sum_{j=0}^{k+1} N_j)}) \end{bmatrix} \quad (47)$$

b. $\mathbf{K}_{k+1}^{-1}$ ve çıkış katman ağırlıkları $\boldsymbol{\beta}^{(k+1)}$ ’i N_{k+1} yığını ile güncelle.

$$\mathbf{K}_{k+1}^{-1} = \mathbf{K}_k^{-1} - \mathbf{K}_k^{-1} \mathbf{H}_{k+1}^T (\mathbf{I} + \mathbf{H}_{k+1} \mathbf{K}_k^{-1} \mathbf{H}_{k+1}^T)^{-1} \mathbf{H}_{k+1} \mathbf{K}_k^{-1} \quad (48)$$

$$\boldsymbol{\beta}^{(k+1)} = \boldsymbol{\beta}^{(k)} + \mathbf{K}_{k+1}^{-1} \mathbf{H}_{k+1}^T (\mathbf{T}_{score,k} - \mathbf{H}_{k+1} \boldsymbol{\beta}^{(k)}) \quad (49)$$

3) Aksi takdirde;

- a. N_{k+1} yığnında içerik farklılaşması algılandığı için İlkendirme Aşaması'na atla.
 - b. Bu yığın için TKİBA modelini İlkendirme Aşamasındaki gibi yeniden inşa et.
- 4) AS_{k+1} , K_{k+1}^{-1} and $\beta^{(k+1)}$ geri döndür.
-

Bu aşamada ilk olarak mevcut oluşturulan model ile o anki yığın N_{k+1} test edilerek bir anomali skoru (AS_{k+1}) oluşturulur. Oluşturulan skor, ağın o yığın için ürettiği bir çıktıdır. Bu çıktı değerine bakılarak anomali ya da normal şeklinde karar verilmektedir. Bunun için deneysel olarak belirlenen anomali eşik değeri $\varepsilon_{anomali}$ kullanılmaktadır. Eğer yığın içindeki j . çerçevenin skor değeri ($AS_{k+1,j}$) $\varepsilon_{anomali}$ ' den büyükse çerçeve anomali olarak, aksi durumda ise normal olarak etiketlenmektedir ve sınıflandırıcı bireysel kararını vermektedir. Nihai karar topluluk sınıflandırıcıların kararlarının çoğunluk oylaması ile elde edilmektedir. Skor oluştuktan sonra içerik farklılaşması olup olmadığını algılayabilmek için bir önceki yığın için hesaplanan anomali skoru AS_k kullanılarak bir farklılaşma aranmaktadır. İçerik farklılaşması varlığını arama kısmında DÖTÇA-AÖM' de olduğu gibi Hoeffding Sınır Teoremi benimsenmiştir. Eğer bir önceki yığının AS_k ortalama değeri mevcut yığının ortalama AS_{k+1} değeri arasındaki fark belirlenen güven eşliğinden küçük ise iki yığın arasında bir içerik farklılığı yer almadığını karar verilmektedir. İçerik farklılaşması yer almadığı durumda TKİBA' nın ardışıl olarak güncellenmesi gerekmektedir. Güncelleme işlemi DÖTÇA-AÖM' de gerçek etiket değerlerine göre yapılmaktadır. Bu yaklaşımda ise Hoeffding Sınır Teoremi' ne ağı güncelleme işleminde de başvurulmaktadır. Bir önceki yığın (N_k) için algoritmanın ürettiği skor çıktısı ağı güncelleme işleminde kullanılarak gerçek değere ihtiyaç ortadan kaldırılmıştır. Çünkü Hoeffding Sınır Teoremi' ne göre iki yığın arasında içerik farklılaşması olmadığı durumda yığınların aynı olasılık dağılımına sahip olduğu varsayımı kullanılmaktadır. Böylelikle iki yığın arasında büyük bir derecede bir farklılık bulunmadığından N_k yığını ile ağ (49) eşitliğindeki gibi güncellenebilmektedir ve gerçek etiket değerlerine ihtiyaç duyulmamaktadır.

İçerik farklılaşması algılandığı durumda ise ağ modeli bu yığın için yeniden oluşturulmaktadır. Bu durumda aktif öğrenme stratejisinde yer alan etiket değerlerini bir uzmandan istemeye başvurulmaktadır. Yani içerik farklılaşması tespit edildiğinde yığındaki veriler için gerçek etiket değerleri kullanılarak İlkendirme Aşamasındaki gibi ağ modeli tekrar bu yığın için inşa edilmektedir. Bu durum dışında gerçek etiket değerleri yaklaşımda kullanılmamaktadır.

2.6.3. Deneysel Sonuçlar

Aktif öğrenmeye dayalı akan veri tabanlı video anomali tespiti çalışmasının değerlendirilmesi bu bölümde gerçekleştirilmiştir. Çalışma yine aynı şekilde UCF-Crimes veri seti ile UCSD Yaya veri seti üzerinde analiz edilmiştir.

Performans analizi tüm öznetelik seti kullanıldığında yani HPSO olmadan ve HPSO ile öznetelik indirgemesi yapıldığı durumlarda gerçekleştirilmiştir. Önce sınıflandırma performansı analiz edilmiştir. Daha sonra HPSO' nun varlığı ve yokluğu durumlarındaki performans incelenmiştir. Son olarak anomali eşik değerinin etkisi araştırılarak optimum değeri belirlenmiştir.

Tablo 41. UCF-Crimes veri seti için HPSO ile AKD' ye dayalı AÖTDÖTÇA-AÖM anomali tespit yaklaşımının EAA metriğinin diğer yaklaşımlarla karşılaştırılması

	Sunulan Çalışma	Sultani vd. [120]	Hasan vd. [143]	Lu vd. [204]	Zhong vd. [142]
EAA	0,9260/ 34557	0,7541	0,506	0,6551	0,8212

Tablo 42. UCSD veri seti için HPSO ile AKD' ye dayalı TAÖDÖTÇA-AÖM anomali tespit yaklaşımının EAA, YSVS ve EHO metriklerinin diğer yaklaşımlarla karşılaştırılması

	Ped1		Ped2	
	EAA/YSVS	EHO (%)	EAA/YSVS	EHO (%)
Sunulan Çalışma	0,8976 / 737	11,76	0,9333 / 134	10,71
AOE [123]	0,946/--	--	0,959/--	--
SCG-SF [119]	0,909/--	16,2	0,902/--	17,3
AnomalyNet [145]	0,835/--	25,2	0,949/--	10,3
MGFC-AAE [136]	0,850/--	20	0,902/--	16
GMFC-VAE [149]	0,949/--	11,3	0,922/--	12,6
AMDN [144]	0,921/--	16	0,908/--	17

2.6.3.1. Sınıflandırma Performansı

Önerilen yaklaşımın sınıflandırma performansı son teknoloji video anomali tespiti çalışmaları ile karşılaştırılmalı olarak incelenmiştir. UCF-Crimes ve UCSD yaya veri setleri için ayrı tablolar halinde sınıflandırma sonuçları sunulmuştur. Veri setlerinden UCF-Crimes

465985, UCSD Ped1 7200 ve UCSD Ped2 210 çerçeveden oluşmaktadır. Bu analizde topluluk sınıflandırıcı sayısı 7, içerik farklılaşması için hesaplanan minimum eşik değeri 0.1 ve anomali eşik değeri 1,2 olarak kullanılmıştır. Gizli katman nöron sayısı ve ilk yığındaki veri sayısı UCF-Crimes veri setindeki videoların çerçeve sayıları fazla olması nedeniyle 100 olarak belirlenmiştir. UCSD yaya veri seti için ise veri setlerinin videolarının uzunluğu sabit 200 olması nedeniyle 50 olarak seçilmiştir. Ardışıl yığınlardaki veri sayıları ise UCF-Crimes için 25, UCSD yaya veri seti için ise 5 olarak belirlenerek analiz gerçekleştirilmiştir. Bu analize ait sonuçlar Tablo 41 ve Tablo 42’ de verilmektedir. Her iki tablodaki sonuçlar HPSO varken elde edilmiştir. Sonuçlar 2500 öznitelik içerisinden UCF-Crimes için 1000, Ped1 veri seti için 1000 ve Ped2 veri seti için 1500 tanesinin otomatik olarak HPSO ile seçildiği durumlara aittir. Bu sonuçlar incelendiğinde önerilen aktif öğrenmeye dayalı etiket verisinin minimum derecede kullanan yaklaşımın UCF-Crimes veri setinde diğer yaklaşımlardan daha başarılı olduğu görülmektedir. Ped1 ve Ped2 için elde edilen sonuçlar ise diğer yaklaşımlar ile rekabet edecek şekilde umut vericidir. Her iki veri setinde en iyi ikinci EHO değerleri elde edilmiştir.

Sınıflandırma performansı analizinde bir diğer deney gerçekte anomali olan çerçevelerin ne kadar doğru bir şekilde tespit edildiğinin incelenmesidir. Bu deneye ait sonuçlar Tablo 43’ de verilmektedir. Tablo 43’ de tüm çerçeveler için elde edilen sonuçlarla birlikte anomali çerçeveleri için elde edilen EAA ve Doğru Sınıflandırılmış Anomali Çerçeveleri Sayısı (DSAÇS) verilmektedir. Tablo 44 ise veri setleri için elde edilen karmaşıklık matrislerini göstermektedir. Tablolardaki sonuçlara göre aktif öğrenmeye dayalı yaklaşım anomali çerçevelerini yüksek bir oranda tespit edebildiği görülmektedir.

Tablo 43. Ped1, Ped2 ve UCF-Crimes için HPSO ile otomatik öznitelik seçimi sonucu elde edilen anomali ve tüm çerçeveler için sonuçlar

	Tüm Çerçeveler İçin		Anomali Çerçeveleri için	
	EAA	YSVS	EAA	DSAÇS
Ped1	0,8976	737	0,9127	3692
Ped2	0,9333	134	0,9435	1555
UCF-Crimes	0,9260	34557	0,8484	109000

Tablo 44. Sırasıyla Ped1, Ped2 ve UCF-Crimes için HPSO ile otomatik öznitelik seçimi sonucu elde edilen karmaşıklık matrisi

Ped1			Ped2			UCF-Crimes		
	TN	TA		TN	TA		TN	TA
GN	2771	384	GN	321	41	GN	323428	15080
GA	353	3692	GA	93	1555	GA	19477	109000

Tablo 45. Veri setlerinin HPSO varken ve HPSO yokken elde edilen sonuçları

		Tüm Çerçeveler İçin		Anomali Çerçeveleri için	
		EAA	YSVS	EAA	DSAÇS
Ped1	HPSO varken	0,8976	737	0,9127	3692
	HPSO yokken	0,8795	867	0,9043	3658
Ped2	HPSO varken	0,9333	134	0,9435	1555
	HPSO yokken	0,9308	139	0,9466	1560
UCF-Crimes	HPSO varken	0,9260	34557	0,8484	109000
	HPSO yokken	0,9108	41645	0,7753	99621


2.6.3.2. Otomatik Öznitelik Seçiminin Etkisi

Bu bölümde üç veri seti için HPSO uygulanmadığı tüm özniteliklerin yer aldığı durumun analizi incelenmektedir. Tablo 45 bu analize ait sonuçları içermektedir. Elde edilen sonuçlar HPSO ile en iyi ve tutarlı öznitelik setinin seçilmesi yaklaşımının daha başarılı olduğunu kanıtlamaktadır.

2.6.3.3. Anomali Eşiğinin Etkisi


Bu bölümde anomaliye karar verme sürecindeki anomali eşiği olan $\varepsilon_{anomali}$ değerinin yaklaşıma olan etkisi incelenmektedir. Bu analizde kullanılan parametreler sınıflandırma performansındakiler ile aynıdır. Sadece anomali eşiği 1.1, 1.2, 1.3, 1.4 ve 1.5 olarak değiştirilerek yaklaşımın EAA sonuçları elde edilmiştir. 1.1' in altının sadece normal olayları ifade edecek olması nedeniyle alt sınır 1.1 olarak belirlenmiştir. Şekil 43' te bu analize dair sonuçlar yer almaktadır.

Sonuçlara göre anomali eşik değeri arttıkça yaklaşımın anomaliyi tespit etmesi ve normal olaylar ile ayırması gücü azalmaktadır. Eşik değeri düştükçe ise yaklaşım daha doğru bir şekilde anomali tespitini yapabilmektedir. Bu duruma göre en uygun eşik değerin 1.1 olduğu söylenebilmektedir.



(a)

(b)



(c)

Şekil 43. Anomali eşik değerinin (a) UCSD Ped1 (b) UCSD Ped2 ve (c) UCF - Crimes veri setlerinin üzerindeki etkisi

3. SONUÇLAR

Tez çalışmaları kapsamında, akan veri analizi için öznitelik çıkartma ve öğrenme yaklaşımları geliştirilmiş, geliştirilen yaklaşımlar literatürde yer alan popüler gerçek ve yapay akan veri setleri üzerinde analiz edilerek, sayısal ve görsel sonuçlar elde edilmiştir. Ayrıca gerçek dünya problemi olan akan veri uygulama alanına giren video anomali tespiti üzerinde geliştirilen yaklaşımların yer aldığı yeni yaklaşımlar geliştirilmiş ve bu uygulamaya ait sonuçlar elde edilmiştir. Tüm çalışmalarda sonuçlar literatürdeki son teknoloji yaklaşımlar ile karşılaştırılarak performans analizi yapılmıştır. Bu bölümde, çalışma kapsamında elde edilen sonuçlar özet şeklinde sıralanacaktır.

- AKD ve HPSO tabanlı otomatik akan veri öznitelik çıkarma yaklaşımı ile elde edilen sonuçlar literatürdeki ATBA yaklaşımlarına göre bu yaklaşımın daha avantajlı olduğunu kanıtlamaktadır. Sunulan yaklaşım daha az hesaplama maliyetine ve zaman karmaşıklığına sahiptir ve bu nedenle ATBA algoritmalarından daha az ek iş yükü gerektirmektedir. Ayrıca otomatik öznitelik seçimi ile elde edilen sonuçlar, otomatik öznitelik seçiminin akan veri öznitelik çıkarımı üzerindeki olumlu etkisini doğrulamaktadır. Bu nedenle, veri setlerinin yapısını dikkate alan öznitelik seçimi, daha yüksek sınıflandırma doğruluğu elde etmek için önemli bir rol oynamaktadır.

- Akan verilerin içerik farklılaşması sorunuyla ilgilenen yeni, daha basit ve etkili bir sınıflandırma yaklaşımı sunulmuş ve ayrıntılı olarak analizi gerçekleştirilmiştir. Sunulan sınıflandırma modelinde kullanılan AÖM yaklaşımı esasen giriş katmanla gizli katman arasındaki başlangıç ağırlık değerlerinin rassal olarak atandığı yaklaşımdır. AÖM' den türetilen bütün algoritmalar bu rastgeleliğe dayanmaktadır. Sunulan yaklaşım ile bu durumdan kaynaklanan bazı durumlarda girdi verilerinin en iyi şekilde temsil edilememesi, ağ modelinin tutarsız davranıp kararlı sonuçlar elde edilememesi, kötü koşullu matris oluşması nedeniyle oluşan hesaplama sorunları gibi sorunların önüne geçilmektedir. Yaklaşımda AÖM' nin giriş katmanı ağırlık değerlerinin rastgele atanması yerine bir algoritmik yaklaşım ile belirleme fikri ortaya atılmıştır ve verinin kendisinden ağ parametresinin bulunmasını sağlayan AÖM-OK yaklaşımı entegre edilmiştir. Bu yaklaşımın başarısı ve sağladığı tutarlı bir ağ yapısı elde edilen sonuçlar üzerinden kanıtlanmaktadır.

- Bir önceki çalışma olan ÇA-AÖM ve AÖM-OK' ya dayanan yaklaşım her ne kadar tutarlılık sağlamış olsa da akan verinin en önemli karakteristiği olan içerik farklılaşmasına

cevap verememektedir. Bu nedenle geliştirilen DÖTÇA-AÖM akan veri öğrenme yaklaşımı Hoeffding Sınır Teoremine dayanan içerik farklılaşmasını tespit etme ve AÖM-OK' ya dayanan yeni içeriğe uyum sağlama mekanizmalarına sahiptir. Elde edilen sonuçlar DÖTÇA-AÖM' nin hem bir önceki çalışmaya göre hem de literatürdeki akan veri için önemli olan çalışmalara göre daha başarılı bir yaklaşım olduğunu göstermektedir. Ayrıca DÖTÇA-AÖM ile geliştirilen birden çok sınıflandırıcıya sahip TDÖTÇA-AÖM, içerik farklılaşmasına karşı sağlamlığı geliştirmektedir ve akan veri sınıflandırmasını tek bir DÖTÇA-AÖM sınıflandırıcısından daha başarılı hale getirmektedir.

- Tez kapsamında gözetleme videolarındaki anormal olayların tespiti ve anomali türünün belirlenmesi akan veri problemi olarak ele alındığı bir yaklaşım sunulmuştur. Anomali tespiti akan veri uygulama alanlarından en popüler olanlarından biridir. Fakat akan veri problemi olarak gözetleme videolarındaki anomalinin tespiti ve anomali türünün belirlenmesi literatürde çalışılmamış bir problemidir ve bu çalışma ile ilk kez sunulmaktadır. Sunulan çalışma TDÖTÇA-AÖM ve zayıf etiketleme tekniğinden oluşan bir önileme aşamasını içermektedir. Çalışma en son teknoloji olan derin öğrenme tabanlı video anomali tespiti yaklaşımları ile karşılaştırılmış olup, bu yaklaşımlara göre birçok açıdan avantaj sağlamıştır. Görevi bir akan veri sorunu olarak ele almak, modeli sıfırdan eğitmeyi ortadan kaldırmak için oldukça etkilidir. Bu, dinamik yapının inşa edilmesini sağlar. Dinamizmle birlikte önerilen yaklaşım, normal olayların gelişen doğasına uyum sağlama potansiyeline sahiptir. Önerilen yaklaşım, akış sırasında gözetim video konseptinde herhangi bir değişiklik olup olmadığını araştırır. Kavramda önemli bir değişiklik varsa bu anormal bir olay anlamına gelen bir içerik farklılaşması olarak değerlendirilmektedir. Ayrıca önerilen yaklaşım derin öğrenme tabanlı yaklaşımlara göre daha basit bir yapıya sahiptir. Önerilen yaklaşımda, TKİBA sınıflandırıcısının yalnızca bir gizli katmanı vardır. AÖM-OK ise, TKİBA sınıflandırıcısına ek olarak bir gizli katmana sahiptir ve gerektiğinde çalışmaktadır. Bu nedenle, yaklaşım derin öğrenme tabanlı anomali algılama yaklaşımlarına kıyasla çok fazla hesaplama ve zaman maliyeti gerektirmemektedir. Deneysel sonuçlar, önerilen yaklaşımın son teknoloji derin öğrenme yaklaşımlarından daha iyi bir video anormalliği algılama ve anormal olay türü belirleme performansına sahip olduğunu kanıtlar niteliktedir.

- Geliştirilen akan veri tabanlı anomali tespiti yaklaşımına frekans uzayında otomatik olarak özniteliklerin belirlendiği AKD ve HPSO akan veri öznitelik çıkartma yaklaşımı eklenerek iki çalışma birleştirilmiştir. Eklenen öznitelik çıkartma yaklaşımı ile en etkili ve tutarlı öznitelik setinin bulunması sağlanarak performans artışı sağlanmıştır. Bu performans

artışı literatürdeki çalışmalar ve bir önceki çalışma ile kıyaslanarak elde edilen deneysel sonuçlar ile göz önüne serilmektedir.

- Video anomali tespiti için sunulan iki çalışma zayıf etiketlemeye dayalı olmalarına rağmen verilerin etiket değerlerinin bilinmesini gerektiren çalışmalardır. Bu nedenle gerçek dünya uygulamalarına cevap verebilecek bir şekilde önerilen video anomali tespiti yaklaşımı düzenlenmiştir. Sunulan çalışma etiket değerine daha az gereksinimi gerektiren bir yaklaşım olarak aktif öğrenme stratejisine göre geliştirilmiştir. Yaklaşım anomali tespiti işleminde kendi ürettiği etiket değerlerini kullanarak artımlı bir şekilde ağı güncellemektedir. Yaklaşımın performansı literatürdeki popüler derin öğrenme tabanlı video anomali tespiti çalışmaları ile kıyaslamalı olarak ölçülmüştür. Sonuçlar aktif öğrenmeye dayalı yaklaşımın bu çalışmalardan UCF-Crimes veri setinde daha başarılı olduğunu ve UCSD yaya veri seti içinde rekabetçi bir performansla umut verici olduğunu göstermektedir.

4. ÖNERİLER VE TARTIŞMA

Teknolojinin gelişmesiyle birlikte birçok uygulama yoğun bir şekilde akan veri üretmesine rağmen, akan verilerin öğrenmesi için makine öğrenmesine dayalı çalışmaların üretilmesi son yıllarda ortaya çıkmıştır. Geliştirilen ilk algoritmalar geleneksel veriler için üretilen yaklaşımların akan veri için adaptasyonu olacak şekilde tasarlanmıştır. Bu durum bazı yaklaşımların akan verilerin karakteristiklerine ve kısıtlamalarına cevap verme yeteneklerinden uzak olmalarına neden olmaktadır. Geliştirilen yaklaşımların akan verilere özgü olması ve kısıtlamalarını göz önüne alması akan veri öğrenmesi için elzem bir durum olarak gözükmektedir.

Akan veri öğrenmesi için öznitelik çıkartma ve boyut indirgeme çalışmaları literatürde fazla yer alan bir çalışma alanı değildir. Akan verilerin büyük-ölçekli doğası nedeniyle öznitelik çıkartma adımı, sınıflandırma ve kümeleme uygulamalarında daha doğru sonuçlar üretmeye yardım etmektedir. Akan verilerin için öznitelik çıkartma ve özellikle otomatik olarak boyut indirgeme çalışmaları daha çok çalışılması gereken bir konudur. Bunun dışında tez çalışmasında AKD ve HPSO' ya dayalı öznitelik çıkartma ve otomatik boyut indirgeme çalışmasında ilklendirme aşaması sabit sayıda akan veri örneği kullanmaktadır. Bu sayının verinin karakteristiğine göre dinamik olarak seçilmesini içeren bir yaklaşım çalışmanın iyileşmesi açısından pozitif bir katkı sağlayacağı düşünülmektedir.

Akan veriler için geliştirilen sınıflandırma yaklaşımlarında içerik farklılaşması dışında karşılaşılan bir diğer sorun dengesiz sınıf verisinin olmasıdır. Bu nedenle geliştirilen yaklaşımlar dengesiz sınıf problemini göz önüne alarak tasarlanması öneriler arasında yer almaktadır. Tez kapsamında geliştirilen topluluk öğrenmesine dayanan DÖTÇA-AÖM yaklaşımının bu problemi göz önüne alacak şekilde düzenlenmesi performans kalitesinin arttırabileceği düşünülmektedir.

Akan veri uygulama sahası ve akan veri üreten alanlar oldukça geniştir. Bu durum tez kapsamında akan veri için geliştirilen yaklaşımların bankacılık, finans, sağlık gibi farklı veri akan veri türleri üreten farklı alanlara da uygulanması gerçekleştirilebilir.

DÖTÇA-AÖM' nin danışmanlı bir çalışma olması nedeniyle geliştirilen AÖDÖTÇA-AÖM minimum sayıda etiket verisini gerektiği zaman kullanarak video anomali tespiti gerçekleştirmeye odaklanan bir çalışmadır. Bu çalışma tamamen danışmansız bir öğrenme mimarisine evrilmesi yapılabilecek yeni bir çalışma olarak söylenebilmektedir. Ayrıca bu

alıřma anomali skoru kullandığı iin sadece anomali tespitine zg gerekleřtirilmiřtir. Aė mimarisinde yapılacak iyileřtirmeler ile ok sınıflı bir yaklařım elde edilmesi mmkndr.

DTA-AM ve ADTA-AM tek gizli katman kullanan TKİBA yapılarıdır. Bu yaklařımlarda gizli katmandaki nron sayısı artmasının alıřmaların performanslarında olumlu bir etki gstereceėi dřnlmektedir. Akan verilere cevap verme zamanını ok fazla arttırmayacak řekilde aė mimarisindeki gizli katman nron sayısını otomatik ve dinamik olarak verinin karakteristiėine gre belirlenmesi yapılabilecek bir diėer alıřmalar arasında yer alabilmektedir. Bunun dıřında yığın yapılarındaki veri sayısının yine dinamik olarak belirlenmesi daha iyi bir řekilde ierik farklılařmasının tespit edilmesine ve adaptasyon saėlanması katkı saėlayacaėı dřnlmektedir.



5. KAYNAKLAR

1. Fogli, D. ve Guida, G., Knowledge-Centered Design of Decision Support Systems for Emergency Management, Decision Support Systems, 55, 1 (2013) 336–347.
2. Nguyen, H. L., Woon, Y. K. ve Ng, W. K., A Survey on Data Stream Clustering and Classification, Knowledge and Information Systems, 45, 3 (2015) 535-569.
3. Zeng, X.Q. ve Li, G.Z, Incremental Partial Least Squares Analysis of Big Streaming Data, Pattern Recognition, 47 11, (2014), 3726-3735.
4. Bifet, A., Adaptive Learning and Mining for Data Streams and Frequent Patterns, Doktora Tezi, Universitat Polit cnica de Catalunya, Barselona, 2009.
5. Gama, J., Knowledge Discovery from Data Streams, Chapman & Hall, CRC Press, Boca Raton, 2010.
6. Stefanowski, J., Adaptive Ensembles for Evolving Data Streams – Combining Block-Based And Online Solutions, In International Workshop on New Frontiers in Mining Complex Patterns, Eyl l 2015, Porto, Bildiriler Kitabı, 3-16.
7. Őenol, A., K-Boyutlu Aęaę, Uyarlanabilir Yarıęap ve  znitelik Seęme (KD-ARFS Stream) Tabanlı Geręek Zamanlı Akan Veri K meleme, Doktora Tezi, Gazi  niversitesi, Fen Bilimleri Enstit s , Ankara, 2019.
8. Aggarwal, CC., Data Streams: An Overview and Scientific Applications, In: Gaber M. (eds) Scientific Data Mining and Knowledge Discovery, Springer, Berlin, 2009.
9. Bifet, A., Holmes, G. ve Kirkby, R., Moa: Massive Online Analysis, Journal of Machine Learning Research, 11 (2012) 1601–1604.
10. Guha, S., Meyerson, A., Mishra, N., Motwani, R. ve O’Callaghan, L., Clustering Data Streams: Theory and Practice, IEEE Transactions on Knowledge and Data Engineering, 15 (2003) 515–528.
11. Gama, J., Data stream mining: the bounded rationality, Informatica, 37 1, (2013), 21–25.
12. Gama, J. ve Rodrigues, P., An Overview on Mining Data Streams, Foundations of Computational, Intelligence, 6 (2009) 29-45
13. Kranen P, Assent I, Baldauf C ve Seidl T., The clustree: Indexing Micro-Clusters for Anytime Stream Mining. Knowledge and Information Systems, 29, 2 (2011) 249–272.
14. Zliobaite, I., Adaptive Training Set Formation, Doktora Tezi, Vilnius  niversitesi, Vinius, 2010.

15. Gama, J., Žliobaite, I., Bifet, A., Pechenizkiy, M. ve Bouchachia, A., A Survey on Concept Drift Adaptation, ACM Computing Surveys, 46, 4 (2014) 44:1–44:37.
16. Brzezinski, D., Block-Based and Online Ensembles for Concept-Drifting Data Streams, Doktora Tezi, Poznan University of Technology, 2015.
17. Webb, G., Hyde, R., Cao, H., Nguyen, H.L. ve Petitjean F., Characterizing Concept Drift, Data Mining and Knowledge Discovery, 30 (2016) 964–994.
18. Žliobaitė, I., Learning Under Concept Drift: An Overview, arXiv preprint arXiv:1010.4784, 2010.
19. Krawczyk, B., Minku, L. L., Gama, J., Stefanowski, J., ve Woźniak, M., Ensemble Learning for Data Stream Analysis: A Survey, Information Fusion, 37 (2017) 132-156.
20. Pesaranghader, A., Viktor, H. L., ve Paquet, E., McDiarmid drift detection methods for evolving data streams. In 2018 International Joint Conference on Neural Networks (IJCNN), Temmuz 2018, Rio de Janeiro, Bildiriler Kitabı, 1-9.
21. Aggarwal, CC., Han, J., Wang, J. ve Yu, PS., A framework for clustering evolving data streams, In: Proceedings of the 29th International Conference on Very Large Data Bases, Eylül 2003, Berlin, Bildiriler Kitabı, 81–92.
22. Aggarwal, CC., Han, J., Wang, J. ve Yu, PS., A framework for On-Demand Classification of Evolving Data Streams", IEEE Transactions on Knowledge and Data Engineering, 18, 5 (2006) 577–589.
23. Dang, X., Lee, V., Ng, W., Ciptadi, A. ve Ong, K., An EM-Based Algorithm for Clustering Data Streams in Sliding Windows, In International Conference on Database Systems for Advanced Applications, Nisan 2009, Brisbane, Bildiriler Kitabı, 230–235.
24. Guha, S., Kim, C. ve Shim, K., Xwave: Optimal and Approximate Extended Wavelets, In: Proceedings of the 30th International Conference on Very large Data Bases, Ağustos 2004, Toronto, Bildiriler Kitabı, 288–299.
25. Zeng, H-J., He Q-C., Chen Z., Ma, W-Y. ve Ma, J., Learning To Cluster Web Search Results, In: Proceedings of the 27th Annual International ACM SIGIR Conference on Research and Development in Informations Retrieval, Temmuz 2004, Sheffield, Bildiriler Kitabı, 210–217.
26. Chien S. ve Immorlica N., Semantic Similarity Between Search Engine Queries Using Temporal Correlation, In: Proceedings of the 14th International Conference on World Wide Web, Mayıs 2005, Chiba, Bildiriler Kitabı, 2–11.

27. Aggarwal, CC. ve Yu, P., Online Analysis Of Community Evolution in Data Streams, In: Proceedings of the SIAM International Conference on Data Mining, Nisan 2005, Philadelphia, Bildiriler Kitabı, 56–67.
28. Sun, J., Faloutsos, C., Papadimitriou, S. ve Yu, PS., Graphscope: Parameter-Free Mining Of Large Timeevolving Graphs, In: Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Ağustos 2007, San Jose, Bildiriler Kitabı, 687–696.
29. Cui, W., Liu, S., Tan, L., Shi, C., Song, Y., Gao, Z., Qu, H. ve Tong, X., (2011) Textflow: Towards Better Understanding of Evolving Topics in Text. IEEE Transactions Visualization and Computer Graphics, 17, 12 (2011) 2412–2421.
30. Aggarwal, CC. ve Subbian, K., Event Detection in Social Streams, In: Proceedings of the SIAM International Conference on Data Mining, Nisan-Mayıs 2015, Vancouver, Bildiriler Kitabı, 624–635.
31. Domingos, P. ve Hulten, G., Mining High-Speed Data Streams. In: Proceedings of the 6th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Ağustos 2000, Boston, Bildiriler Kitabı, 71–80.
32. O’Callaghan, L., Mishra, N., Meyerson, A., Guha, S. ve Motwani R, Streaming-Data Algorithms for High-Quality Clustering. In: Proceedings of the 18th International Conference on Data Engineering, Şubat 2002, San Jose, Bildiriler Kitabı, 685–694.
33. Babcock, B., Datar, M. ve O’Callaghan, L., Maintaining Variance and K-Medians Over Datastream Windows, In: Proceedings of the 22nd ACM Symposium on Principles of Database Systems, Haziran 2003, San Diego, Bildiriler Kitabı, 234–243.
34. Jain, A.K., Data clustering: 50 years beyond K-means, Pattern Recognition Letters, 31, 8 (2010) 651–666.
35. Ackermann, M. R., Mörtens, M., Raupach, C., Swierkot, K., Lammersen, C. ve Sohler, C., StreamKM++: A Clustering Algorithm for Data Streams, ACM Journal of Experimental Algorithmics, 17, 1 (2012) 173–187.
36. Aggarwal, CC., Han, J., Wang, J. ve Yu PS. A Framework for Projected Clustering Of High Dimensional Data Streams, In: Proceedings of the 30th International Conference on Very Large Data Bases, Ekim 2004, Toronto, Bildiriler Kitabı, 852–63.
37. Zhang, T., Ramakrishnan, R. ve Livny, M., Birch: an Efficient Data Clustering Method for Very Large Databases, In: Proceedings of the 1996 ACM SIGMOD International Conference on Management of Data, Haziran 1996, Montreal Quebec, Bildiriler Kitabı, 103–114.

38. Udommanetanakit, K., Rakthanmanon, T. ve Waiyamai, K., E-stream: evolution-based technique for stream clustering, International conference on advanced data mining and applications, Kasım 2007, Berlin, Bildiriler Kitabı, 605–615.
39. Lühr, S. ve Lazarescu, M., Incremental clustering of dynamic data streams using connectivity based representative points, Data and Knowledge Engineering, 68, 1 (2009) 1–27.
40. Karypis, G., Eui-Hong, H. ve Kumar, V., Chameleon: hierarchical clustering using dynamic modeling, Computer, 32, 8 (1999) 68–75.
41. Cao, F., Ester, M., Qian, W. ve Zhou, A., Density-based Clustering Over An Evolving Data Stream With Noise, In: Proceedings of the 2006 SIAM International Conference on Data Mining, Nisan 2006, Bethesda, Bildiriler Kitabı, 328–339.
42. Tasoulis, DK., Ross, G. ve Adams, N. M., "Visualising The Cluster Structure of Data Streams", In: Proceedings of the 7th International Conference On Intelligent Data Analysis, Eylül 2007, Berlin, Bildiriler Kitabı, 81–92.
43. Kriegel, H-P., Kröger, P., Ntoutsi, I. ve Zimek, A., Density based subspace clustering over dynamic data, International conference on scientific and statistical database management, Haziran 2011, Crete, Bildiriler Kitabı, 387–404.
44. Laohakiat, S., Phimoltares, S., ve Lursinsap, C., A Clustering Algorithm For Stream Data With LDA-Based Unsupervised Localized Dimension Reduction, Information Sciences, 381 (2017) 104-123.
45. Ding, S., Zhang, J., Jia, H., ve Qian, J., An adaptive density data stream clustering algorithm, Cognitive Computation, 8, 1 (2016) 30-38.
46. Laohakiat, S., Phimoltares, S., ve Lursinsap, C., Hyper-cylindrical micro-clustering for streaming data with unscheduled data removals, Knowledge-Based Systems, 99 (2016) 183-200.
47. Chen, Y. ve Tu, L., Density-based clustering for real-time stream data, In: Proceedings of the 13th ACM SIGKDD International Conference On Knowledge Discovery And Data Mining, Ağustos 2007, Chicago, Bildiriler Kitabı, 133–142.
48. Wan, L., Ng, W. K., Dang, X. H., Yu, P. S. ve Zhang, K., "Density-based clustering of data streams at multiple resolutions, ACM Transactions on Knowledge Discovery from Data, 3, 3 (2009) 1–28.
49. Park, N. H. ve Lee, W. S., Statistical grid-based clustering over data streams, ACM SIGMOD Record., 33, 1 (2004) 32–37.
50. Hyde, R., Angelov, P. ve MacKenzie, A. R., Fully online clustering of evolving data streams into arbitrarily shaped clusters, Information Sciences, 382 (2017) 96-114.

51. Smith, T. Ve Iahakoon, D., Growing self-organizing map for online continuous clustering, Foundations of Computational Intelligence, 4 (2009) 49–83.
52. Wang, H., Fan, W., Yu, V., ve Han, J., Mining concept-drifting data streams using ensemble classifiers, In: Proceedings of the 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Ağustos 2003, Washington, Bildiriler Kitabı, 226–235.
53. Bieft, A., Holmes, G., Pfahringer, B., Kirkby, R. ve Gavalda, R., New ensemble methods for evolving data streams, In: Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Haziran 2009, Paris, Bildiriler Kitabı, 139–148.
54. Attar, V., Sinha, P. Ve Wankhade, K., A fast and light classifier for data streams. Evolving Systems, 1, 3 (2010) 199–207.
55. Masud, M., Gao, J., Khan, L., Han, J., ve Thuraisingham, B., A multi-partition multi-chunk ensemble technique to classify concept drifting data streams, In: Proceedings of the 13th Pacific-Asia Conference on Knowledge Discovery and Data Mining, Nisan 2009, Berlin, Bildiriler Kitabı, 363–375.
56. Masud, M.M., Gao, J., Khan, L. Ve Bhavani, B., Classification and novel class detection in concept-drifting data streams under time constraints, IEEE Transactions on Knowledge and Data Engineering, 23, 6 (2011) 859–874.
57. Widmer, G. ve Kubat, M., Learning in the presence of concept drift and hidden contexts, Machine Learning, 23, 1 (1996) 69–101.
58. Bifet, A. ve Gavalda, R., Learning from time-changing data with adaptive windowing, In: Proceedings of the 2007 SIAM International Conference on Data Mining, Nisan 2007, Mineapolis, Bildiriler Kitabı, 443–448.
59. Wankhade, K.K., Snehlata, S.D ve Kalpana C.J., Data stream classification: a review, Iran Journal of Computer Science, 3 (2020) 239-260.
60. Yan, J., Zhang, B., Liu, N., Yan, S., Cheng, Q., Fan, W., Yang, Q., Xi, W. ve Chen, Z., Effective and efficient dimensionality reduction for large-scale and streaming data preprocessing. IEEE Transactions on Knowledge and Data Engineering, 18, 3 (2006) 320–333.
61. Ahmed, N., Natarajan, T. ve Rao, K.R., Discrete cosine transform, IEEE Transaction Computers, C-23 (1974) 90–93.
62. Jolliffe, I.T., Principal component analysis and factor analysis, In Principal Component Analysis, Springer, New York, 1986.
63. Zhao, H., Yuen, P.C. ve Kwok, J.T., A novel incremental principal component analysis and its application for face recognition. IEEE Transactions on Systems, Man, and Cybernetics, 36 (2006) 873–886.

64. Hall, P. ve Martin, R., Incremental Eigenanalysis for Classification, In Proceedings of the British Machine Vision Conference, Southampton, Eylül 1998, Southampton, Bildiriler Kitabı, 286–295.
65. Hall, P., Marshall, D. ve Martin, R., Merging and splitting eigenspace model, IEEE Transactions on Pattern Analysis and Machine Intelligence, 22 (2000) 1042–1049.
66. Liu, X. ve Chen, T., Shot boundary detection using temporal statistics modeling, In Proceedings of the 2002 IEEE International Conference on Acoustics, Speech, and Signal Processing, Mayıs 2002, Orlando, Bildiriler Kitabı, IV-3389.
67. Li, Y., On incremental and robust subspace learning, Pattern Recognition, 37 (2004) 1509–1518.
68. Ozawa, S., Pang, S. ve Kasabov, N., A modified incremental principal component analysis for online learning of feature space and classifier, In Proceedings of the Pacific Rim International Conference on Artificial Intelligence, Ağustos 2004, Auckland, Bildiriler Kitabı, 231–240.
69. Ozawa, S., Pang, S. ve Kasabov, N., Incremental learning of chunk data for online pattern classification systems, IEEE Transactions on Neural Networks, 19 (2008) 1061–1074.
70. Rosas-Arias, L., Portillo-Portillo, J., Hernandez-Suarez, A., Olivares-Mercado, J., Sanchez-Perez, G., Toscano-Medina, K., Perez-Meana, H., Orozco, A.L.S. ve García Villalba, L.J., Vehicle Counting in Video Sequences: An Incremental Subspace Learning Approach, Sensors, 19 (2019) 2848.
71. Fujiwara, T., Chou, J.K., Shilpika, S., Xu, P., Ren, L. ve Ma, K.L., An incremental dimensionality reduction method for visualizing streaming multidimensional data, IEEE Transactions on Visualization and Computer Graphics, 26 (2019) 418–428.
72. Wei, Y., Wang, H., Wang, S. ve Saporta, G., Incremental modelling for compositional data streams, Communications in Statistics-Simulation and Computation, 48 (2019) 2229–2243.
73. Weng, J., Zhang, Y. ve Hwang, W.S., Candid covariance-free incremental principal component analysis, IEEE Transactions on Pattern Analysis and Machine Intelligence, 25, 8 (2003) 1034–1040.
74. Tokumoto, T. ve Ozawa, S., A fast incremental kernel principal component analysis for learning stream of data chunks, In Proceedings of the 2011 International Joint Conference on Neural Networks, Ağustos 2011, San Jose, Bildiriler Kitabı, 2881–2888.
75. Ghashami, M., Perry, D.J. ve Phillips, J., Streaming kernel principal component analysis, In Proceedings of the 19th International Conference on Artificial Intelligence and Statistics, Mayıs 2016, Cadiz, Bildiriler Kitabı, 1365–1374.

76. Joseph, A.A., Tokumoto, T. ve Ozawa, S., Online feature extraction based on accelerated kernel principal component analysis for data stream, Evolving Systems, 7 (2016) 15–27.
77. Yan, F., Hou, W.C., Jiang, Z., Huan, Y. ve Che, D., Selectivity estimation of range queries over data streams using cosine transform, International Journal of Computational Science, 1, 4 (2007) 422–439.
78. Yu, F., Oyana, D., Hou, W.C. ve Wainer, M., Approximate Clustering on Data Streams Using Discrete Cosine Transform, Journal of Information Processing Systems, 6, 1 (2010) 67–78.
79. Hayat, M.Z. ve Hashemi, M.R., A dct based approach for detecting novelty and concept drift in data streams, In Proceedings of the 2010 International Conference of Soft Computing and Pattern Recognition, Aralık 2010, Paris, Bildiriler Kitabı, 373–378.
80. Jiang, Z., Luo, C., Hou, W. C., Yan, F. ve Zhu, Q., Estimating aggregate join queries over data streams using discrete cosine transform. In International Conference on Database and Expert Systems Applications, Eylül 2006, Berlin, Bildiriler Kitabı, 182-192.
81. Huang, G.B., Zhu, Q.Y. ve Siew, C.K., Extreme learning machine: theory and applications, Neurocomputing, 70, 1-3 (2006) 489–501.
82. Huang, G.B., Chen, L. ve Siew, C.K., Universal approximation using incremental constructive feedforward networks with random hidden nodes, IEEE Transactions on Neural Networks, 17 (2006a) 879–892.
83. Huang, G.B., Wang, D.H. ve Lan, Y., Extreme learning machines: a survey, International Journal of Machine Learning and Cybernetics, 2, 2 (2011) 107-122.
84. Albadra, M.A.A. ve Tiuna, S., Extreme Learning Machine: A Review, International Journal of Applied Engineering Research, 12, 14 (2017) 4610-4623.
85. Huang, G., Huang, G.B., Song, S.ve You, K., Trends in extreme learning machines: A review, Neural Networks, 61 (2015) 32-48.
86. Liang, N.Y., Huang, G.B., Saratchandran, P. ve Sundararajan, N., A fast and accurate online sequential learning algorithm for feedforward networks, IEEE Transactions on Neural Networks, 17 (2006) 1411–1423.
87. Lan, Y., Soh, Y.C. ve Huang, G.B., Ensemble of online sequential extreme learning machine, Neurocomputing, 72, 13-15 (2009) 3391–3395.
88. Pan, S., Wu, K., Zhang, Y. ve Li, X., Classifier Ensemble for Uncertain Data Stream Classification, In Pacific-Asia Conference on Knowledge Discovery and Data Mining, Haziran 2010, Berlin, Bildiriler Kitabı, 488-495.

89. Zhao, J., Wang, Z. ve Park, D.S., Online Sequential Extreme Learning Machine With Forgetting Mechanism, Neurocomputing, 87 (2012) 79–89.
90. Mirza, B., Lin, Z., Toh, K.A., Weighted Online Sequential Extreme Learning Machine For Class Imbalance Learning, Neural Processing Letters, 38, 3 (2013) 465–486.
91. Cao, J., Lin, Z. ve Huang, G.B., Voting Base Online Sequential Extreme Learning Machine for Multi-Class Classification, In 2013 IEEE International Symposium on Circuits and Systems, Mayıs 2013, Pekin, Bildiriler Kitabı, 2327-2330.
92. Gu, Y., Liu, J., Chen, Y. ve Yu, H., TOSELM: Timeliness Online Sequential Extreme Learning Machine, Neurocomputing 128 (2014) 119–127.
93. Cao, K., Wang, G., Han, D. ve Zhang, X., Classification of Uncertain Data Streams Based on Extreme Learning Machine, Cognitive Computation, 7, 1 (2014) 150–160.
94. Mirza, B., Lin, Z. ve Liu, N., Ensemble of Subset Online Sequential Extreme Learning Machine for Class İmbalance and Concept Drift, Neurocomputing, 149 (2015) 316–329.
95. Singh, R., Kumar, H. ve Singla, R.K., An Intrusion Detection System Using Network Traffic Profiling and Online Sequential Extreme Learning Machine, Expert Systems With Applications, 42, 22 (2015) 8609–8624.
96. Mao, W., Wang, J. ve Wang, L., Online Sequential Classification of Imbalanced Data by Combining Extreme Learning Machine and improved SMOTE Algorithm, In 2015 International Joint Conference on Neural Networks, Temmuz 2015, Killarney, Bildiriler Kitabı, 1-8.
97. Han, D.H., Zhang, X. ve Wang, G.R., Classifying Uncertain and Evolving Data Streams With Distributed Extreme Learning Machine, Journal of Computer Science and Technology, 30, 4 (2015a) 874–887.
98. Cavalcante, R.C., Oliveira, A.L., An Approach to Handle Concept Drift in Financial Time Series Based on Extreme Learning Machines and Explicit Drift Detection. In 2015 International Joint Conference on Neural Networks, Temmuz 2015, Killarney, Bildiriler Kitabı, 1-8.
99. Scardapane, S., Comminiello, D., Scarpiniti, M. ve Uncini, A., Online sequential extreme learning machine with kernels, IEEE transactions on neural networks and learning systems, 26, 9 (2015) 2214–2220.
100. Mirza, B., Lin, Z., Cao, J. ve Lai, X., Voting based weighted online sequential extreme learning machine for imbalance multi-class classification, IEEE International Symposium on Circuits & Systems, Mayıs 2015, Lizbon, Bildiriler Kitabı, 565–568.

101. Huang, Y., Dynamic cost-sensitive ensemble classification based on extreme learning machine for mining imbalanced massive data streams, International Journal of u- and e-Service, Science and Technology, 8, 1 (2015) 333–346.
102. Mirza, B. ve Lin Z., Meta-cognitive online sequential extreme learning machine for imbalanced and concept-drifting data classification, Neural Networks, 80 (2016) 79–94.
103. Shao, Z. ve Er, M.J., An online sequential learning algorithm for regularized extreme learning machine, Neurocomputing, 173 (2016) 778–788.
104. Deng, W-Y., Ong, Y-S., Tan, P.S. ve Zeng, Q. H., Online sequential reduced kernel extreme learning machine, Neurocomputing, 174 (2016) 72–84.
105. Venkatesan, R., Er, M.J., Wu, S. ve Pratama, M., A novel online real-time classifier for multi-label data streams, In: Proceedings International Joint Conference on Neural Network (IJCNN), Temmuz 2016, Vancouver, Bildiriler Kitabı, 1833–1840.
106. Venkatesan, R., Er, M.J., Dave, M., Pratama, M. ve Wu, S., A novel online multi-label classifier for highspeed streaming data applications, Evolving Systems, 8, 4 (2017) 303–315
107. Xiao, W., Zhang, J., Li, Y., Zang, S., ve Yang, W., Class-specific cost regulation extreme learning machine for imbalanced classification, Neurocomputing, 261 (2017) 70–82.
108. Zhang Y, Liu W, Ren X. ve Ren, Y., Dual weighted extreme learning machine for imbalanced data stream classification, Journal of Intelligent & Fuzzy Systems, 33, 2 (2017) 1143–1154.
109. Yang, R., Xu, S. ve Feng, L., An ensemble extreme learning machine for data stream classification, Algorithms, 11, 7 (2018) 107.
110. Xu, S., Wang, J., A fast incremental extreme learning machine algorithm for data streams classification, Expert Systems With Applications, 65 (2016) 332–344.
111. Xu, S. ve Wang, J., Dynamic extreme learning machine for data stream classification. Neurocomputing, 238 (2017) 433–449.
112. Li, L., Sun, R., Cai, S., Zhao, K. ve Zhang, Q., A review of improved extreme learning machine methods for data stream classification, Multimedia Tools and Applications, (2019) 1–26.
113. Ding, S., Mirza, B., Lin, Z., Cao, J., Lai, X., Nyugen, T.V. ve Sepulveda, J., Kernel based online learning for imbalance multiclass classification, Neurocomputing, 277 (2018) 139–148.
114. Liu, Z., Loo, C.K. ve Seera, M., Meta-cognitive recurrent recursive kernel OS-ELM for concept drift handling, Applied Soft Computing, 75 (2019) 494–507.

115. Yu, H., Webb, G.I., Adaptive online extreme learning machine by regulating forgetting factor by concept drift map. Neurocomputing, 343 (2019) 141–153.
116. Xiao, D., Li, B. ve Zhang, S., An online sequential multiple hidden layers extreme learning machine method with forgetting mechanism, Chemometrics and Intelligent Laboratory Systems, 176 (2018) 126–133.
117. Fanaee, T.H. ve Gama, J., Tensor-based anomaly detection: An interdisciplinary survey, Knowledge-Based Systems, 98 (2016) 130-147.
118. Munir, M., Siddiqui, S.A., Chattha, M.A., Dengel, A. ve Ahmed, S., FuseAD: unsupervised anomaly detection in streaming sensors data by fusing statistical and deep learning models, Sensors, 19, 11 (2019) 2451.
119. Wang, S., Zhu, E., Yin, J. ve Porikli, F., Video anomaly detection and localization by local motion based joint video representation and OCELM, Neurocomputing, 277 (2018) 161-175.
120. Sultani, W., Chen, C. ve Shah, M., Real-world anomaly detection in surveillance videos, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2018, Salt Lake City, Bildiriler Kitabı, 6479-6488.
121. Chaker, R., Al Aghbari, Z., ve Junejo, I.N., Social network model for crowd anomaly detection and localization, Pattern Recognition, 61 (2017) 266-281.
122. Xu, D., Ricci, E., Yan, Y., Song, J., ve Sebe, N., Learning deep representations of appearance and motion for anomalous event detection, arXiv preprint arXiv:1510.01553, 2015.
123. Singh, K., Rajora, S., Vishwakarma, D.K., Tripathi, G., Kumar, S., ve Walia, G.S., Crowd anomaly detection using Aggregation of Ensembles of fine-tuned ConvNets, Neurocomputing, 371 (2020) 188-198.
124. Fang, Z., Fei, F., Fang, Y., Lee, C., Xiong, N., Shu, L., ve Chen, S., Abnormal event detection in crowded scenes based on deep learning, Multimedia Tools and Applications, 75, 22 (2016) 14617-14639.
125. Li, N., Wu, X, Xu, D, Guo, H., Feng W., Spatio-temporal context analysis within video volumes for anomalous-event detection and localization, Neurocomputing, 155 (2015) 309–319.
126. Kaltsa, V., Briassouli, A., Kompatsiaris, I., Hadjileontiadis, L.J., ve Strintzis, M. G., Swarm intelligence for detecting interesting events in crowded environments, IEEE transactions on image processing, 24, 7 (2015) 2153-2166.
127. Johnson, N. Ve Hogg, D, Learning the distribution of object trajectories for event recognition, Image and Vision Computing, 14, 8 (1996) 609-615.

- 128.Hu, W., Xiao, X., Fu, Z., Xie, D., Tan T. ve Maybank, S., A system for learning statistical motion patterns, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28, 9 (2006) 1450-1464.
- 129.Jiang, F., Wu, Y. ve Katsaggelos, A. K., A dynamic hierarchical clustering method for trajectory-based unusual video event detection, IEEE Transactions on Image Processing, 18, 4 (2009) 907-913.
- 130.Jiang, F., Yuan, J., Tsaftaris, S.A., Katsaggelos, A.K., Anomalous video event detection using spatiotemporal context, Computer Vision and Image Understanding, 115, 3 (2011) 323–333.
- 131.Coşar, S., Donatiello, G., Bogorny V., Garate C., Alvares L. O. Ve Brémond F., Toward abnormal trajectory and event detection in video surveillance, IEEE Transactions on Circuits and Systems for Video Technology, 27, 3 (2017) 683-695.
- 132.Yuan, Y., Feng, Y. ve Lu, X., Statistical hypothesis detector for anomalous event detection in crowded scenes, IEEE Transactions on Cybernetics, 99 (2016) 1–12.
- 133.Bera, A., Kim, S. ve Manocha, D., Real-time anomaly detection using trajectory level crowd behavior learning, In Proceedings 29th IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Haziran 2016, Las Vegas, Bildiriler Kitabı, 1289–1296.
- 134.Colque, R.M., Caetano, C., Toledo, M. ve Schwartz, W.R., Histograms of optical flow orientation and magnitude and entropy to detect anomalous events in videos, IEEE Transactions on Circuits and Systems for Video Technology, 27, 3 (2017) 673–682.
- 135.Fang, Z., Fei, F., Fang, Y., Lee, C., Xiong, N., Shu, L. ve Chen, S., Abnormal event detection in crowded scenes based on deep learning, Multimedia Tools and Applications, 75, 22 (2016) 14617-14639.
- 136.Li, N. ve Chang, F. Video anomaly detection and localization via multivariate gaussian fully convolution adversarial autoencoder, Neurocomputing, 369 (2019) 92–105.
- 137.Sabokrou, M., Fayyaz, M., Fathy, M., Klette, R., Deep-cascade: Cascading 3d deep neural networks for fast anomaly detection and localization in crowded scenes, IEEE Transactions on Image Processing, 26, 4 (2017) 1992-2004.
- 138.Sabokrou, M., Fayyaz, M., Fathy, M., Moayed, Z. ve Klette, R, Deep-anomaly: Fully convolutional neural network for fast anomaly detection in crowded scenes, Computer Vision and Image Understanding, 172 (2018) 88-97.
- 139.Feng, Y., Yuan, Y. ve Lu, X., Learning deep event models for crowd anomaly detection, Neurocomputing, 219 (2017) 548-556.

- 140.Nawaratne, R., Alahakoon, D., De Silva, D., Yu, X., Spatiotemporal anomaly detection using deep learning for real-time video surveillance, IEEE Transactions on Industrial Informatics, 16, 1 (2019) 393-402.
- 141.Medel, J.R. ve Savakis, A., Anomaly detection in video using predictive convolutional long short-term memory networks. arXiv preprint arXiv:1612.00390.
- 142.Zhong, J.X., Li, N., Kong, W., Liu, S., Li, T.H. ve Li, G., Graph convolutional label noise cleaner: Train a plug-and-play action classifier for anomaly detection, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2019, Long Beach, Bildiriler Kitabı, 1237-1246.
- 143.Hasan, M., Choi, J., Neumann, J., Roy-Chowdhury, A.K. ve Davis, L.S., Learning temporal regularity in video sequences. In Proceedings of the IEEE conference on computer vision and pattern recognition, Haziran 2016, Las Vegas, Bildiriler Kitabı, 733-742.
- 144.Xu, D., Yan, Y., Ricci, E., Sebe, N., Detecting anomalous events in videos by learning deep representations of appearance and motion, Computer Vision and Image Understanding, 156 (2017) 117-127.
- 145.Zhou, J.T., Du, J., Zhu, H., Peng, X., Liu, Y. ve Goh, R.S.M., AnomalyNet: An anomaly detection network for video surveillance, IEEE Transactions on Information Forensics and Security, 14, 10 (2019) 2537-2550.
- 146.Duman, E., Erdem, O.A., Anomaly detection in videos using optical flow and convolutional autoencoder, IEEE Access, 7 (2019) 183914-183923.
- 147.Murugan, B.S., Elhoseny, M., Shankar, K. ve Uthayakumar, J., Region-based scalable smart system for anomaly detection in pedestrian walkways, Computers & Electrical Engineering, 75 (2019) 146-160.
- 148.Li, Y., Cai, Y., Liu, J., Lang, S. ve Zhang, X., Spatio-temporal unity networking for video anomaly detection, IEEE Access, 7 (2019) 172425-172432.
- 149.Fan, Y., Wen, G., Li, D., Qiu, S., Levine, M.D. ve Xiao, F., Video anomaly detection and localization via Gaussian mixture fully convolutional variational autoencoder, Computer Vision and Image Understanding, 195 (2020) 102920.
- 150.Dong, F., Zhang, Y. ve Nie, X., Dual discriminator generative adversarial network for video anomaly detection, IEEE Access, 8 (2020) 88170-88176.
- 151.Majhi, S., Dash, R. ve Sa P.K., Two-Stream CNN Architecture for Anomalous Event Detection in Real World Scenarios, In International Conference on Computer Vision and Image Processing, Aralık 2019, Prayagraj, Bildiriler Kitabı, 343-353.
- 152.Hao, W., Zhang, R., Li, S., Li, J., Li, F., Zhao, S. ve Zhang, W., Anomaly Event Detection in Security Surveillance Using Two-Stream Based Model, Security and Communication Networks, 2020.

153. Chu, W., Xue, H., Yao, C. ve Cai, D., Sparse coding guided spatiotemporal feature learning for abnormal event detection in large videos, IEEE Transactions on Multimedia, 21, 1 (2018) 246-255.
154. Tang, Y., Zhao, L., Zhang, S., Gong, C., Li, G. ve Yang, J., Integrating prediction and reconstruction for anomaly detection, Pattern Recognition Letters, 129 (2020) 123-130.
155. Chen, D., Wang, P., Yue, L., Zhang, Y. ve Jia, T., Anomaly detection in surveillance video based on bidirectional prediction, Image and Vision Computing, 98 (2020) 103915.
156. Žliobaitė, I., Bifet, A., Pfahringer, B. ve Holmes, G., Active learning with evolving streaming data, In Joint European Conference on Machine Learning and Knowledge Discovery in Databases, Eylül 2011, Berlin, Bildiriler Kitabı, 597-612.
157. Zhu, J., Wang, H., Hovy E. Ve Ma, M., Confidence-based stopping criteria for active learning for data annotation, ACM Transactions on Speech and Language Processing, 6, 3 (2010) 3.
158. Yu, H., Sun, C., Yang, W., Yang, X. ve Zuo, X., AL-ELM: One uncertainty-based active learning algorithm using extreme learning machine, Neurocomputing, 166 (2015) 140-150.
159. Zhu, X., Zhang, P., Lin, X. ve Shi, Y., Active learning from data streams, In Seventh IEEE International Conference on Data Mining, Ekim 2007, Omaha, Bildiriler Kitabı, 757-762.
160. Zhu, X., Zhang, P., Lin, X., ve Shi, Y., Active learning from stream data using optimal weight classifier ensemble, IEEE Transactions on Systems, Man, and Cybernetics, 40, 6 (2010) 1607-1621.
161. Kurlej, B. ve Wozniak, M., Active learning approach to concept drift problem, Logic Journal of IGPL, 20, 3 (2012) 550-559.
162. Kurlej, B. ve Wozniak, M., Impact of window size in active learning of evolving data streams, In Proceedings of the 45th International Conference on Modelling and Simulation of Systems, 2011, 56-62.
163. Kurlej, B. ve Woźniak, M., Learning curve in concept drift while using active learning paradigm, In International Conference on Adaptive and Intelligent Systems, Eylül 2011, Berlin, Bildiriler Kitabı, 98-106.
164. Nguyen, H. L., Ng, W.K. ve Woon, Y. K., Concurrent semi-supervised learning with active learning of data streams, Transactions on Large-Scale Data-and Knowledge-Centered Systems VIII, (2013) 113-136.

- 165.Mohamad, S., Bouchachia, A. ve Sayed-Mouchaweh, M., A bi-criteria active learning algorithm for dynamic data streams, IEEE transactions on neural networks and learning systems, 29, 1 (2016) 74-86.
- 166.Korycki, Ł. ve Krawczyk, B., Combining active learning and self-labeling for data stream mining, In International Conference on Computer Recognition Systems, Mayıs 2017, Polanica-Zdrój, Bildiriler Kitabı, 481-490.
- 167.Yu, H., Yang, X., Zheng, S. ve Sun, C., Active learning from imbalanced data: A solution of online weighted extreme learning machine, IEEE Transactions on Neural Networks and Learning Systems, 30, 4 (2018) 1088-1103.
- 168.Abdallah, Z. S., Gaber, M.M., Srinivasan, B. ve Krishnaswamy, S., Adaptive mobile activity recognition system with evolving data streams, *Neurocomputing*, 150 (2015) 304-317.
- 169.Dua, D. ve Graff, C., UCI Machine Learning Repository <http://archive.ics.uci.edu/ml>, 14 Mayıs 2021.
- 170.Mahadevan, V., Li, W., Bhalodia, V. ve Vasconcelos, N., Anomaly detection in crowded scenes. In: The twenty-third IEEE conference on computer vision and pattern recognition, Haziran 2010, San Francisco, 1975–1981.
- 171.Loizou, C.P., Pantziaris, M., Pattichis, C.S. ve Seimenis, I., Brain MR Image Normalization in Texture Analysis of Multiple Sclerosis, In 2009 9th International Conference on Information Technology and Applications in Biomedicine, Kasım 2009, Larnaka, Bildiriler Kitabı, 1-5.
- 172.Fong, S., Wong, R. ve Vasilakos, A.V., Accelerated PSO swarm search feature selection for data stream mining big data, IEEE Transactions on Services Computing, 9 (2015) 33–45.
- 173.Cheng, X., Ciuonzo, D. ve Rossi, P.S., Multi-bit decentralized detection through fusing smart & dumb sensors based on rao test, IEEE Transactions on Aerospace and Electronic Systems, 56, 2 (2019) 1391-1405.
- 174.Cheng, X., Ciuonzo, D. ve Rossi, P.S., Multi-bit decentralized detection of a weak signal in wireless sensor networks with a rao test, In Proceedings of the 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP), Kasım 2018, Shanghai, Bildiriler Kitabı, 1–5.
- 175.Fong, S., Liang, J., Fister, I. ve Mohammed, S., Gesture recognition from data streams of human motion sensor using accelerated PSO swarm search feature selection algorithm, *Journal of Sensors*, 2015.
- 176.Kennedy, J. ve Eberhart, R., Particle swarm optimization, In Proceedings of the International Conference on Neural Networks, Kasım–Aralık 1995, Perth, Bildiriler Kitabı, 1942–1948.

177. Yang, X.S., Nature-Inspired Metaheuristic Algorithms, Luniver Press, Frome, UK, 2010.
178. Deshpande, M. ve Karypis, G., Evaluation of techniques for classifying biological sequences, In Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining, Mayıs 2002, Taipei, Bildiriler Kitabı, 417–431.
179. Kong, X. ve Philip, S.Y., An ensemble-based approach to fast classification of multi-label data streams, In Proceedings of the 7th International Conference on Collaborative Computing: Networking Applications and Worksharing, Ekim 2011, Orlanda, Bildiriler Kitabı, 95–104.
180. Khan, M., Ding, Q. ve Perrizo, W., k-nearest neighbor classification on spatial data streams using P-trees, In Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining, Mayıs 2002, Taipei, Bildiriler Kitabı, 517–528.
181. Aggarwal, C.C., Data classification: algorithms and applications, CRC Press, Boca Raton, 2014.
182. Castaño, A., Fernández-Navarro, F. ve Hervás-Martínez, C., PCA-ELM: A robust and pruned extreme learning machine approach based on principal component analysis, Neural Processing Letters, 37, 3 (2013) 37–392.
183. Wang, Y., Cao, F. ve Yuan, Y., A study on effectiveness of extreme learning machine, Neurocomputing, 74, 16 (2011) 2483–2490.
184. Pacheco, A.G., Krohling, R.A. ve da Silva, C.A., Restricted Boltzmann machine to determine the input weights for extreme learning machines, Expert Systems With Applications, 96 (2018) 77–85.
185. Wang, D., Wang, P. ve Ji, Y., (2015) An oscillation bound of the generalization performance of extreme learning machine and corresponding analysis. Neurocomputing, 151 (2015) 883–890.
186. Webb, G.I., Hyde, R., Cao, H., Nguyen, H.L. ve Petitjean F., Characterizing concept drift, Data Mining and Knowledge Discovery, 30, 4 (2016) 964–994.
187. Zeng, Y., Qian, L. ve Ren, J., Evolutionary hierarchical sparse extreme learning autoencoder network for object recognition, Symmetry 10, 10 (2018) 474.
188. Han, M. ve Liu, X.X., An extreme learning machine algorithm based on mutual information variable selection, Control Decision, 29, 9 (2014) 1576–1580.
189. Han, F., Yao, H.F. ve Ling, Q.H., An improved evolutionary extreme learning machine based on particle swarm optimization, Neurocomputing, 116 (2013) 87–93.
190. Miche, Y., Sorjamaa, A., Bas, P., Simula, O., Jutten, C. ve Lendasse, A., OP-ELM: optimally pruned extreme learning machine, IEEE Transactions on Neural Networks and Learning Systems, 21, 1 (2019) 158–162.

- 191.Wang, W. ve Liu, X., The selection of input weights of extreme learning machine: a sample structure preserving point of view, Neurocomputing, 261 (2017) 28–36.
- 192.Ding, S., Zhang, N., Zhang, J., Xu, X. ve Shi, Z., Unsupervised extreme learning machine with representational features, International Journal of Machine Learning and Cybernetics, 8, 2 (2017) 587–595.
- 193.Zhao, G., Shen, Z. ve Man, Z., Robust input weight selection for well-conditioned extreme learning machine, International Journal of Information Technology, 17, 1 (2011) 1–13.
- 194.Baldi, P., Autoencoders, unsupervised learning, and deep architectures, In Proceedings of ICML workshop on unsupervised and transfer learning, Haziran 2012, Bellevue, Bildiriler Kitabı, 37-49.
- 195.Kasun, L.L.C., Zhou, H.M., Huang G.B.ve Vong, C.M, Representational learning with extreme learning machine for big data, IEEE Intelligent Systems, 28, 6 (2013) 31–34.
- 196.Rutkowski, L., Pietruczuk, L., Duda, P. ve Jaworski, M., Decision trees for mining data streams based on the mcDiarmid’s bound, IEEE Transactions on Knowledge and Data Engineering, 25 (2013) 1272–1279.
- 197.Sethi, T.S. ve Kantardzic, M., On the reliable detection of concept drift from streaming unlabeled data, Expert Systems With Applications, 82 (2017) 77–99.
- 198.Laohakiat, S., Phimoltares, S. ve Lursinsap, C., A clustering algorithm for stream data with LDA-based unsupervised localized dimension reduction, Information Sciences, 381 (2017) 104–123.
- 199.Carbonneau, M.A., Cheplygina, V., Granger, E. ve Gagnon, G., Multiple instance learning: A survey of problem characteristics and applications, Pattern Recognition, 77 (2018) 329-353.
- 200.Aydogdu, O. ve Ekinici, M., A new approach for data stream classification: unsupervised feature representational online sequential extreme learning machine, Multimedia Tools and Applications, 79, 37 (2020) 27205-27227.
- 201.Andrews, S., Tsochantaridis, I. ve Hofmann, T., Support vector machines for multiple-instance learning, In Advances in neural information processing systems, 2003, 577-584.
- 202.Dietterich, T.G., Lathrop, R.H. ve Lozano-Pérez, T., (1997) Solving the multiple instance problem with axis-parallel rectangles, Artificial intelligence, 89.1 (1997) 31-71.
- 203.Wei, X.S. ve Zhou, Z.H., An empirical study on image bag generators for multi-instance learning, Machine learning, 105, 2 (2016) 155-198.

- 204.Lu, C., Shi, J. ve Jia, J., Abnormal event detection at 150 fps in matlab. In Proceedings of the IEEE international conference on computer vision, Aralık 2013, Sidney, Bildiriler Kitabı, 2720-2727.
- 205.Tran, D., Bourdev, L., Fergus, R., L. Torresani, L. ve Paluri. M., Learning spatiotemporal features with 3d convolutional networks, In Proceedings of the IEEE international conference on computer vision, Aralık 2015, Santiago, Bildiriler Kitabı, 4489-4497.
- 206.Hou, R., Chen, C. ve Shah, M., Tube convolutional neural network (t-cnn) for action detection in videos, In Proceedings of the IEEE international conference on computer vision, Ekim 2017, Venice, Bildiriler Kitabı, 5822-5831.



ÖZGEÇMİŞ

2008 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde lisans programına başladı. 2012 yılında Bilgisayar Mühendisliği Bölümü'nden Bilgisayar Mühendisliği unvanı ile bölüm birincisi olarak mezun oldu. 2012 yılı güz döneminde Bilgisayar Mühendisliği Anabilim Dalı'nda Araştırma Görevlisi olarak göreve başladı. 2015 yılında yüksek lisans eğitimini tamamlayarak, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Halen Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'nde çalışmaya devam etmektedir. 2'si SCI/expanded indeksli dergilerde, 8' i uluslararası konferanslarda ve 1'i ulusal konferanslarda olmak üzere toplam 11 yayını mevcuttur. Yabancı dil olarak İngilizce bilmektedir. Yayınları aşağıda verilmiştir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Aydoğdu, O. ve Ekinci, M., A new approach for data stream classification: unsupervised feature representational online sequential extreme learning machine, Multimedia Tools and Applications, 79(37), 2020, 27205-27227.
2. Aydoğdu, Ö. ve Ekinci, M., An Approach for Streaming Data Feature Extraction Based on Discrete Cosine Transform and Particle Swarm Optimization, Symmetry, 12(2), 2020, 299.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

1. Aydoğdu, O. ve Ekinci, M., An Incremental Autoencoder Approach for Data Stream Feature Extraction, 2019 4th International Conference on Computer Science and Engineering (UBMK), Eylül 2019, Samsun, Bildiriler Kitabı, 261-264.
2. Aydoğdu, O. Zhaleh, S. ve Ekinci, M., A Study on Liveness Analysis for Palmprint Recognition System. 2018 41st International Conference on Telecommunications and Signal Processing, Ağustos 2018, Atina, Bildiriler Kitabı, 1-4.
3. Zhaleh, S., Aydoğdu, O., Günay, F.B. ve Çavdar, T., Performance Analysis of Licensed Shared Access Based Secondary Users Activity on Cognitive Radio Networks, EBBT 2018, 2018, İstanbul, Bildiriler Kitabı.
4. Aydoğdu, O., Ekinci, M., A Graph Form Data Stream Clustering Approach Based on Dimesion Reduction, 2017 25th Signal Processing and Communication Application Conference (SIU), Mayıs 2017, Antalya, Bildiriler Kitabı, 1-4.

5. Makul, Ö. ve Ekinici, M., Palm and palm finger joint surfaces based multibiometric approach. Telecommunications and Signal Processing (TSP), Haziran 2016, Viyana, Bildiriler Kitabı, 1619-1622.
6. Makul, Ö. Aydoğdu, M.C., Aykut, M. ve Ekinici M., Neighbourhood-Based Collaborative Filtering Approach Using K-means Clustering, Proceedings of 2016 International Conference on Image Processing, Production and Computer Science (ICIPCS'2016), Mart 2016, Londra, Bildiriler Kitabı.
7. Muzaffer, G., Makul, Ö., Üstübioğlu, B. ve Ulutaş G., Copy Move Forgery Detection Using Gabor Filter and ORB. Proceedings of 2016 International Conference on Image Processing, Production and Computer Science (ICIPCS'2016), Mart 2016, Londra, Bildiriler Kitabı.
8. Makul, Ö. ve Ekinici, M., Development and implementation of multibiometric on palm finger joint and palm pattern, 23. Signal Processing and Communications Applications Conference (SIU2015), Nisan 2015, Malatya, Bildiriler Kitabı.
9. Makul, Ö. ve Ekinici, M., Biometric identification based on knuckle prints, 2014 22nd Signal Processing and Communications Applications Conference (SIU2014), Nisan 2014, Trabzon, Bildiriler Kitabı.

Burslar

- Turkcell Akademi Teknoloji Liderleri Lisansüstü Burs Programı, 2012-2013.
- TÜBİTAK BİDEB 2228-B Yurt İçi Doktora Bursu, 2015-2018.