

Kapalı Mekân Ortamında 1D-CNN Kullanarak Yapılan Doluluk Tespiti Sınıflandırması

Erkan GÜLER^{1*} , Muhammet Talha KAKIZ² , Faruk Baturalp GÜNAY³ , Burcu ŞANAL⁴ ,
Tuğrul ÇAVDAR⁵ 

Öz

Derin Öğrenme modelleri kompleks deneyimlerden bilgi çıkarımına imkân sağlayan spesifik Makine Öğrenmesi yöntemleridir. Kapalı bir mekândaki bazı veri değerlerindeki değişiminin öğrenilmesi ile odada herhangi bir kişinin bulunup bulunmamasının tespit edilmesi bu deneyimlerden biridir. Bu çalışmanın amacı zaman serileri olarak oluşturulmuş ve zaman içinde ışık, sıcaklık, nem ve CO₂ değerlerindeki değişimler ile kapalı bir mekânda doluluk tespiti probleminin Bir Boyutlu Evrişimli Sinir Ağı (1D-CNN) ile gerçekleştirilmesidir. Bir adet eğitim ve iki adet test veri seti kullanılarak model eğitilmiş ve daha önce tecrübe edilmeyen test veri setleri ile modelin başarısı gözlenmiştir. Keras uygulama programlama arayüzünde 1D-CNN modeli ile gerçekleştirilen testlerde doluluk tespiti sınıflandırmasının RF (Random Forest), GBM (Gradient Boosting Machines), CART (Classification and Regression Trees), LDA (Linear Discriminant Analysis) yöntemlerinden daha başarılı sonuçlar verdiği gözlenmiştir.

Anahtar Kelimeler: Doluluk Tespiti, 1D-CNN, Zaman Serisi, Sınıflandırma, Derin Öğrenme.

Occupancy Detection Classification Using 1D-CNN in Indoor Environment

Abstract

Deep Learning models are specific Machine Learning methods that allow to extract knowledge from complex experiences. Learning the change in some data values in an indoor environment and detecting whether there is any person in the room is one of these experiences. The aim of this study is to realize the problem of determining the occupancy in an indoor space with changes in light, temperature, humidity and CO₂ values over time, using a One-Dimensional Convolutional Network (1D-CNN). The model has been trained using one training and two test datasets, and the success of the model has been observed with test datasets that the model has not been experienced before. In the tests performed with the 1D-CNN model in the Keras application programming interface, it has been observed that the occupancy detection classification has given more successful results than the RF (Random Forest), GBM (Gradient Boosting Machines), CART (Classification and Regression Trees), LDA (Linear Discriminant Analysis) methods.

Keywords: Occupancy Detection, 1D-CNN, Time Series, Classification, Deep Learning.

¹Giresun Üniversitesi, Bilgisayar Mühendisliği Bölümü, Giresun, Türkiye, erkan.guler@giresun.edu.tr

²Osmaniye Korkut Ata Üniversitesi, Bilgisayar Mühendisliği Bölümü, Osmaniye, Türkiye, mtalhakakiz@osmaniye.edu.tr

³Atatürk Üniversitesi, Bilgisayar Mühendisliği Bölümü, Erzurum, Türkiye, baturalp@atauni.edu.tr

⁴Recep Tayyip Erdoğan Üniversitesi, Elektronik ve Otomasyon Bölümü, Rize, Türkiye, burcu.sanal@erdogan.edu.tr

⁵Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Trabzon, Türkiye, ulduz@ktu.edu.tr

¹<https://orcid.org/0000-0001-7225-0859>

²<https://orcid.org/0000-0003-4928-6559>

³<https://orcid.org/0000-0001-5472-3608>

⁴<https://orcid.org/0000-0002-4541-7622>

⁵<https://orcid.org/0000-0003-3656-9592>

1. Giriş

Sabit kodlanmış sistemlerin aksine ham veriden bazı kalıplar çıkararak kendi bilgilerini edinme yeteneğine sahip olan sistemlerin bu yeteneği Makine Öğrenmesi (Machine Learning, ML) olarak adlandırılır. Derin Öğrenme (Deep Learning, DL) ise bir tür ML olmakla birlikte, hiyerarşik düzeyde basit konseptlerin bir araya gelerek daha derin bir yapıyı oluşturması sonucu bilgisayarların daha kompleks deneyimlerden bilgi çıkarımına imkân sağlar (Goodfellow, 2016).

Farklı ihtiyaçlar için geliştirilmiş birçok DL modeli bulunmaktadır. Tekrarlayan Sinir Ağı (Recursive Neural Network, RvNN) modeli ağaç yapısı şeklinde kelimeleri bölerek doğal dil cümlelerini sınıflandırma konusunda başarılı bir model iken, Yinelemeli Sinir Ağı (Recurrent Neural Network, RNN) konuşma işleme gibi sıralı bilgilerin öğrenilmesi konusunda başarılıdır. Bununla birlikte, Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) bilgisayarla görme ve görüntü tanıma alanlarında başarılı bir model iken Çekişmeli Üretici Ağ (Generative Adversarial Network, GAN) denetimsiz öğrenme ile orijinal veriye benzer yeni örnekler üretebilir (Pouyanfar ve ark., 2018).

Bu çalışmanın amacı zaman serileri ile oluşturulmuş bir veri setindeki örneklerin sınıflandırılmasıdır. (Candanedo ve ark., 2016) tarafından oluşturulan veri setinde bir ofis odasında ışık, sıcaklık, nem, CO₂ değerleri dikkate alınarak yapılan ölçüm zamanında odada herhangi bir kimsenin bulunup bulunmadığı etiketlenmiştir. Belirli zaman aralıklarında bu değerler periyodik olarak ölçülmüştür. Zaman serisi olarak paylaşılan bu veri setinin öğrenilmesi sürecinde doğru modelin kullanılması önem arz etmektedir. Biz bu çalışmada zaman serilerinin sınıflandırılması görevinde oldukça başarılı olan bir boyutlu CNN (1D-CNN) modelini kullandık.

Bu bölümün devamında zaman serisi sınıflandırma problemlerinin karakteristik özellikleri, zaman serisi problemleri için kullanılan DL modelleri, 1D-CNN modelinin mimarisi ve bu problem üzerine yapılmış çalışmalardan kısaca bahsedilecektir.

1.1. Zaman Serileri

Bir zaman serisi zaman içinde yapılan sıralı ölçümlerden elde edilen değerlerin toplamını ifade eder. Gerçek hayatta zaman serileri genellikle sensörler gibi sürekli fiziksel fenomenleri gözlemleyen cihazlardan elde edilir. Zaman serisi ile ilgili yapılan işlemlere örnek olarak anomali tespiti, kümeleme, sınıflandırma, segmentasyon verilebilir. Günümüzde hayatın birçok alanında zaman serisi analizi ile çözüm getirilen problemler vardır. Örneğin, ekonomik tahminler, izinsiz giriş tespiti, gen ekspresyon analizi, tıbbi gözetim ve hidroloji farklı alanlardaki zaman serisi analizleri ile çözüm getirilen problemlerden bazılarıdır (Esling ve ark., 2012).

1.3. İlgili Çalışmalar

Literatürde finanstan tarıma, sağlıktan jeolojiye kadar birçok alanda 1D-CNN modeli ile yapılmış zaman serisi sınıflandırma çalışmaları mevcuttur. Bu çalışmalardan bir kısmı zaman serilerinin sınıflandırılması ile ilgilenirken, zaman serileri ile ilgili anomali tespiti gibi tahminlerin yapıldığı çalışmalar da mevcuttur.

(Kuang, 2020) tarafından yapılan çalışmada bitki yapraklarının basit merkezi kontur mesafe eğrisi zaman serisi olarak değerlendirilmiş ve 1D-CNN modeli ile yaprakların sınıflandırılması gerçekleştirilmiştir. (Rizvi, 2022) tarafından yapılan çalışmada ise elektronik sistemlerin doğru voltaj kararlılığını değerlendirmek için zaman serisi olarak elde edilen sağlam veriye dayalı yük parametresi tahmini 1D-CNN modeli ile gerçekleştirilmiştir. Finans alanında yapılan bir sınıflandırma çalışmasında ise hisse senedi fiyat trendinde tekrar eden sinyaller zaman serisi olarak kullanılmış ve bu tekrar eden grafik şablonları 1D-CNN ağıyla amaca göre sınıflandırılmıştır (Liu ve Si, 2022).

Su kaynaklarının planlanması ve yönetilmesi amacıyla Pakistan'da bulunan Gilgit nehrinin su akış tahmini 1D-CNN ve ELM (Extreme Learning Machine) modelleri ile gerçekleştirilmiştir. Su akış verisi zaman serisi olarak elde edilmiştir (Hussain ve ark., 2020). Jeoloji alanında yapılan bir diğer çalışmada ise zaman serisi olarak kaydedilen rüzgâr hızı ölçüm verisi 1D-CNN ve LSTM modelleri ile eğitilerek geçmişe dönük veri dikkate alınarak gelecekteki rüzgâr hızı tahmin edilmeye çalışılmıştır (Fukuoka ve ark., 2018). Bu modellerin tam bağlı sinir ağı modelinden daha doğru sonuçlar verdiği gözlemlenmiştir. Ayrıca, (Barino ve ark., 2020) tarafından 1D-CNN modeli ile Amazon'un en büyük ve en önemli kolu olan Madeira Nehrinin korelasyonlu zaman serisi ile nehrin su akışı tahmini yapılmıştır.

Hata ve anomali tespiti ile ilgili de literatürde yapılmış çalışmalar mevcuttur. (Junior ve ark., 2022) bir elektrik motoruna ait iki farklı ivme ölçerden gelen titreşim sinyalini zaman serisi olarak kaydetmiş ve 1D-CNN modelini 7 farklı hata için eğitmiştir. Ayrıca, gaz türbinlerinde meydana gelecek ani hatanın tespiti için (Zhao ve Li, 2020) gaz türbinlerinden gelen zaman serisi verisini 1D-CNN ile eğitmiş ve hatalar tespit edilmiştir. Bilgisayar ağlarında anormal olan trafiği tespit için (Azizjon ve ark., 2020) anormal ağ verisi ile 1D-CNN modelini eğitmiştir.

(Wu ve Wang, 2021) çalışmasında hareket halinde ve sabit bulunan kişilerin odada bulunma durumları ve sıklığının tespiti PIR sensörü ile yapılmış ve oturma, yatma gibi günlük hareketler incelenmiştir. (Parzinger ve ark., 2022) tarafından yapılan oda içi doluluk tespiti çalışmasında gerçek ve yapay kullanıcı ile bir dizi test yapılarak, gerçek ve simüle edilmiş veri üzerinde çalışılmıştır. (Candanedo ve Feldheim, 2016) ve (Singaravel ve ark., 2021) çalışmalarında ise daha çok ortamda bulunan CO₂ seviyesi ve ışık, sıcaklık, nem verileri dikkate alınmıştır. Bununla birlikte, (Billah ve ark., 2021) ise RF (radio frequency)'ye bağlı doluluk dedektörü kullanmıştır.

2. Materyal ve Metot

Bu bölümde bir odada ölçülen bazı değerlerin kaydedilerek oluşturulduğu veri setinin özelliklerinden, veri setinin ön işleme sürecinden ve önerilen modelin mimarisinden bahsedilecektir. Doluluk tespiti (Occupancy Detection (OD)) probleminin çözümünde kullanılan 1D-CNN modelinin katman sayıları, filtre sayıları ve modele ait diğer parametrelerin değerleri bu bölümde anlatılacaktır. Bu çalışmanın aşamaları Şekil 2’de gösterilmiştir.



Şekil 2. Çalışmanın Aşamaları

2.1. Doluluk Tespiti Veri Seti

(Candanedo ve Feldheim, 2016) tarafından oluşturulan ve paylaşılan veri setinde bir odanın içerisinde ölçülen altı özellik paylaşılmaktadır. Bu özellikler tarih, sıcaklık, bağıl nem, ışık, ppm cinsinden CO₂ miktarı ve nem oranıdır. Bir adet eğitim seti ve iki adet test seti olmak üzere toplamda üç veri seti olarak paylaşılmıştır.

Bahsi geçen altı özellik her dakikada bir ölçülmekte ve bu değerler kaydedilmektedir. Her ölçümün sonunda ise kamera çekimi odada herhangi bir kimsenin olup olmadığı tespiti yapılarak 1 (odada kişi var) veya 0 (odada kimse yok) olarak her örnek için etiketlenmektedir. Eğitim setine ait üç kayıttan oluşan bir örnek Tablo 1’de gösterilmiştir.

Tablo 1. Doluluk Tespiti Veri Seti Örneği

Tarih	Sıcaklık	Nem	Işık	Karbondioksit	Nem Oranı	Doluluk
2/4/2015 17:51	23.180	27.272	426.0	721.25	0.0047929881	1
2/4/2015 18:08	22.945	27.290	0.0	685.00	0.0047279513	0
2/7/2015 00:03	20.000	18.700	0.0	434.00	0.0026962878	0

2.2. OD Veri Seti Ön İşleme

OD veri seti bir dakikalık zaman aralıklarında ölçülen değerlerden oluşur. Bu haliyle zaman serisi olarak isimlendirilmiş olsa da tam bir zaman serisine benzememektedir. Bundan dolayı, öncelikle kronolojik zaman dikkate alınarak etikete göre kayıtlar ayrılmış ve her 32 kayıttan oluşan seri bir örneklem olarak dikkate alınmıştır. Böylece, 32 satırlık ölçümlerden oluşan zaman serileri

hem 0 etiketine sahip kayıtlar için hem de 1 etiketine sahip kayıtlar için oluşturulmuştur. Ayrıca, yapılan bu işlem hem eğitim seti için hem de paylaşılan iki adet test seti için de gerçekleştirilmiştir.

Tablo 2. Ön İşleme Sonundaki Doluluk Tespiti Veri Seti Örneği

Zaman Damgası (NS)	Sıcaklık (T)	Nem (ϕ)	Işık (Light)	Karbondioksit (CO_2)	Nem Oranı (W)	Hafta İçi / Hafta Sonu (WS)	Doluluk
0.0	1.0	0.4676576576	0.6481551920	0.1889164855	0.5592566358	1	1
0.0019749240	0.9493827160	0.4695417182	0.0	0.1666407585	0.5433896308	1	0
0.3959723251	0.2439024390	0.0815315315	0.0	0.0096603303	0.0014448939	0	0

Veri setinde değerleri girilen altı özelliğin her biri 0 ve 1 aralığında normalize edilmiştir. Bu işlem için sklearn modülünün MinMaxScaler fonksiyonu kullanılmıştır. Altı özelliğin sonuca olan etkisini de görmek açısından her özelliğin farklı kombinasyonları ile model eğitilmiş ve her farklı senaryo için sonuçlar alınmıştır. Veri setinin ön işlem sürecinin sonucunda elde edilen yeni veriler Tablo 2’de gösterilmiştir. Tablo 2’de gösterilen üç satırlık veri Tablo 1’de gösterilen orijinal verilere karşılık gelen yeni verilerdir.

2.3. OD Veri Seti için Kullanılan 1D-CNN Modeli

1D-CNN modeline ait detaylar Tablo 3’te gösterilmiştir. OD veri setinin eğitiminde ve test veri setinin değerlendirilmesinde Python programlama dili ile yazılmış Keras DL Uygulama Programlama Arayüzü (Application Programming Interface, API) kullanılmıştır. 1D-CNN modeli oluşturulurken Keras sıralı (Sequential) modeli kullanılmıştır. Sıralı modelin amacı Keras katmanlarının sıralı bir düzen ile oluşturulmasıdır. Sıralı model yapılandırıcısına add() metodunu kullanarak Keras katmanlarını bir liste şeklinde ileterek bir sıralı model oluşturabiliriz.

Tablo 3. 1D-CNN Model Detayları

Model Parametresi	Değer/Açıklama
API	Keras
Katman Yığılı Modeli	Sequential
Katmanlar	Conv1D, MaxPooling1D, Flatten, Dense
Aktivasyon Fonksiyonları	ReLU, SoftMax
pool_size	2
Kayıp Fonksiyonu	Binary Cross Entropy
Optimizasyon Aracı	Adam

1D-CNN modelinin ilk katmanı zaman serisi olarak düzenlenen girdi verisidir. İkinci katmanı ise Conv1D katmanıdır. Bu katman, bir çıktı tensörü üretmek için tek bir uzaysal (veya zamansal) boyut üzerinden katman girişiyle evrişen bir evrişim çekirdeği (convolution kernel) oluşturur. Bu

katmandaki filtre sayısı bölüm 2.2’de anlatılan farklı özellik kombinasyonlarına bağlı olmak üzere 64 veya 256 olarak belirlenmiştir. Filtrelere ait çekirdek boyutu ise yine özellik kombinasyonlarına bağlı olmak üzere 3×3 veya 16×16 olarak belirlenmiştir. Bu katmana ait aktivasyon fonksiyonu olan Relu (Rectified Linear Units) fonksiyonuna ait eşitlik aşağıda verilmiştir.

$$f(x) = \max(0, x) \quad (1)$$

Oluşturulan modelin üçüncü katmanı ise bir havuzlama katmanı (Pooling Layer) MaxPooling1D katmanıdır. Bu katmanın amacı, pool_size parametresi boyutundaki bir uzamsal pencere üzerinden maksimum değeri alarak girdi temsilini alt örneklemeektir. Böylece, pencere adım adım kaydırılır. pool_size parametresinin değeri iki olarak belirlenmiştir. “Valid” dolgu seçeneği kullanıldığında çıktı aşağıdaki gibi olur.

$$output_shape = (input_shape - pool_size + 1) / strides \quad (2)$$

Bir sonraki katman olan Flatten katmanına girdi olarak gelen veri düzleştirilir ve tek boyutlu bir dizi haline çevrilir. Bu katmandan sonra ise iki adet Dense katmanı bulunur. Bu katmanlarda bir önceki katmanın çıktıları Dense katmanına girdi olarak gelir ve her çıktı Dense katmanındaki bir düğüm ile bağlantı kurar. Böylece bir önceki katmanın bütün düğümleri (veya çıktıları) ile yeni katmanın bütün düğümleri bağlantılı duruma gelir. Birinci Dense katmanının aktivasyon fonksiyonu Denklem (1)’de gösterildiği gibi Relu fonksiyonudur. İkinci Dense katmanının aktivasyon fonksiyonu ise aşağıda Denklem (3)’de gösterilen Softmax fonksiyonudur.

$$f(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(y_j)} \quad (3)$$

Oluşturulan modelin kayıp fonksiyonu (loss function) ise Binary Cross Entropy olarak belirlenmiştir. Bu fonksiyonun denklemi aşağıdaki gibidir. y_i ve $p(y_i)$ parametreleri sırasıyla sınıfların etiket değerini ve bu sınıfların olasılık tahminlerini ifade etmektedir. Optimizasyon aracı olarak ise “adam” optimize edici aracı kullanılmıştır.

$$Loss = -\frac{1}{N} \sum_{i=1}^N y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i)) \quad (4)$$

Her bir özellik kombinasyonu için model on defa eğitilmiş ve test verisi ile sonuçlar alınmıştır. Her bir modelin on defa çalıştırılması sonucunda bir ortalama ve standart sapma hesabı yapılması amaçlanmıştır.

3. Bulgular ve Tartışma

Bu bölümde 1D-CNN modelinin eğitilmesi sonucunda hem eğitim hem de Test 1 ve Test 2 veri setlerinin sonuçları paylaşılacak ve değerlendirilecektir. Elde edilen sonuçlar RF (Random Forest), GBM (Gradient Boosting Machines), CART (Classification and Regression Trees), LDA (Linear Discriminant Analysis) yöntemleri ile karşılaştırılmıştır.

Tablo 4. Diğer Modellerin ve 1D-CNN Modelinin Sonuçları

	Parametreler	Filtre Sayısı Çekirdek Boyutu	Model	Eğitim	Test 1	Test 2
0	T, ϕ , Light, CO ₂ , W, NS, WS	64 3x3	RF	100,00	95,53	98,06
			GBM	100,00	95,76	96,10
			CART	99,39	94,52	96,52
			LDA	98,85	97,90	99,33
			1D-CNN	99,61	100,00	100,00
1	T, ϕ , Light, CO ₂ , W	64 3x3	RF	100,00	95,05	97,16
			GBM	99,98	93,06	95,14
			CART	99,30	95,57	96,47
			LDA	98,78	97,90	98,76
			1D-CNN	99,61	100,00	100,00
2	T, ϕ , CO ₂ , W, NS, WS	64 3x3	RF	100,00	94,63	64,86
			GBM	100,00	91,86	51,14
			CART	96,55	94,71	69,76
			LDA	93,12	84,88	72,32
			1D-CNN	100,00	96,34	77,30
3	T, ϕ , CO ₂ , W	64 3x3	RF	99,98	68,63	32,68
			GBM	99,56	69,53	38,81
			CART	93,05	84,65	78,96
			LDA	91,91	85,33	73,77
			1D-CNN	100,00	97,56	75,00
4	T, ϕ , Light, W, NS, WS	64 3x3	RF	100,00	95,65	97,21
			GBM	100,00	95,98	97,51
			CART	99,28	96,25	99,00
			LDA	98,77	97,90	98,96
			1D-CNN	99,61	100,00	100,00
5	T, ϕ , Light, W	64 3x3	RF	99,95	94,00	96,73
			GBM	99,96	92,42	95,27
			CART	99,23	93,70	96,29
			LDA	98,55	97,90	98,24
			1D-CNN	99,61	100,00	100,00
6	T, ϕ , W, NS, WS	256 16x16	RF	100,00	94,86	91,66
			GBM	99,98	95,50	92,49
			CART	88,97	90,81	89,36
			LDA	85,78	85,93	86,70
			1D-CNN	92,52	85,37	90,13
7	T, ϕ , W	64 3x3	RF	99,36	75,68	62,59
			GBM	97,85	76,10	63,75
			CART	88,28	84,02	86,30
			LDA	85,46	85,44	85,36
			1D-CNN	99,21	89,02	87,17
8	T, Light, NS, WS	64 3x3	RF	100,00	95,50	97,28
			GBM	99,88	96,36	98,81
			CART	99,28	96,25	99,00

			LDA	98,75	97,90	99,31
			ID-CNN	99,61	100,00	100,00
9	T, Light	64 3x3	RF	99,86	93,10	95,93
			GBM	99,45	95,50	98,33
			CART	99,08	85,10	95,43
			LDA	96,56	97,90	98,62
			ID-CNN	99,61	95,12	99,67
10	ϕ, Light, NS, WS	64 3x3	RF	100,00	96,92	98,31
			GBM	99,99	96,59	98,63
			CART	98,86	97,86	99,31
			LDA	98,12	97,86	97,86
			ID-CNN	99,61	100,00	100,00
11	ϕ, Light	64 3x3	RF	99,96	92,35	94,36
			GBM	99,75	94,52	98,71
			CART	98,86	97,86	99,31
			LDA	96,78	97,86	97,79
			ID-CNN	99,61	100,00	100,00
12	Light, CO₂, NS, WS	64 3x3	RF	100,00	96,06	97,42
			GBM	100,00	96,06	98,57
			CART	98,89	97,82	99,31
			LDA	98,33	97,86	98,05
			ID-CNN	99,61	100,00	100,00
13	Light, CO₂	64 3x3	RF	99,95	92,61	97,41
			GBM	99,26	93,70	98,34
			CART	98,89	97,82	99,31
			LDA	97,53	97,86	97,86
			ID-CNN	99,61	98,78	99,34
14	CO₂, T, NS, WS	64 3x3	RF	100,00	95,65	57,85
			GBM	99,98	96,14	77,71
			CART	96,55	94,71	69,76
			LDA	91,01	88,37	80,42
			ID-CNN	100,00	96,34	83,22
15	CO₂, T	64 3x3	RF	99,88	75,31	36,93
			GBM	97,76	72,98	46,46
			CART	93,05	84,65	78,96
			LDA	90,26	87,62	80,40
			ID-CNN	99,61	92,68	84,54
16	Light, W, NS, WS	64 3x3	RF	100,00	96,47	98,58
			GBM	99,99	96,74	99,03
			CART	99,37	96,89	98,89
			LDA	97,79	97,86	97,55
			ID-CNN	99,61	100,00	100,00
17	Light, W	64 3x3	RF	99,98	95,76	97,68
			GBM	99,52	96,10	98,98
			CART	98,94	96,66	98,90
			LDA	96,81	97,86	97,39
			ID-CNN	99,61	100,00	100,00
18	T, ϕ, NS, WS	256 16x16	RF	100,00	94,67	91,91
			GBM	99,95	95,61	92,85
			CART	88,97	90,81	89,36
			LDA	85,45	85,93	88,50
			ID-CNN	92,91	85,37	91,12
19	T, ϕ	64 3x3	RF	99,36	75,65	67,30
			GBM	97,85	77,49	65,34
			CART	88,24	84,02	86,30
			LDA	83,67	85,67	84,70
			ID-CNN	98,03	85,37	83,22
20	T, NS, WS	256 16x16	RF	99,88	95,08	92,52
			GBM	99,75	95,91	92,57
			CART	88,97	90,81	89,36

21	T	256 16x16	LDA	86,09	86,23	87,18
			1D-CNN	93,31	85,37	90,13
			RF	87,87	70,73	85,33
			GBM	87,44	64,69	85,63
			CART	85,88	66,53	86,51
			LDA	83,38	85,33	83,64
22	Light, NS, WS	64 3x3	1D-CNN	88,98	85,37	80,92
			RF	99,98	97,00	97,81
			GBM	99,74	95,95	98,47
			CART	98,93	97,22	99,26
			LDA	97,53	97,86	97,84
			1D-CNN	99,61	100,00	100,00
23	Light	64 3x3	RF	99,20	95,68	97,91
			GBM	98,77	97,86	99,32
			CART	98,78	97,86	99,31
			LDA	96,38	97,86	97,70
			1D-CNN	99,21	100,00	100,00
			RF	100,00	96,36	65,20
24	CO ₂ , NS, WS	64 3x3	GBM	99,99	96,21	74,51
			CART	96,55	94,71	69,76
			LDA	88,90	87,02	78,36
			1D-CNN	99,61	93,90	80,59
			RF	97,53	78,76	64,21
			GBM	92,15	87,13	74,62
25	CO ₂	64 3x3	CART	92,18	87,13	74,62
			LDA	88,38	86,19	79,93
			1D-CNN	98,82	93,90	72,70

Tabloda kısaltmaları verilen T, ϕ , W, NS, WS terimleri sırasıyla sıcaklık (temperature), nem (humidity), nem oranı (humidity ratio), saniye sayısı (number of seconds), hafta durumu (week status) değerleridir. Çalışmanın sonuçları ve karşılaştırmalar farklı özellik kombinasyonlarına göre gerçekleştirilmiştir. (Candanedo ve Feltheim, 2016) çalışması tarafından gösterilen özellikler arasındaki korelasyon grafiği dikkate alındığında sonuçların büyük çoğunluğunda özellikler arasındaki korelasyonun yüksek olduğu özellik kombinasyonlarında 1D-CNN modeli diğer modellerin sonuçlarından daha başarılıdır. Tablo 4'te verilen sonuçlar incelendiğinde 1D-CNN modeli ile eğitim sonucunda elde edilen eğitim ve test veri setlerinin başarı yüzdeleri neredeyse bütün özellik kombinasyonları için daha yüksektir.

Tablo 4'te gösterilen bazı kombinasyonlarının eğitim sütunundaki sonuç değerleri diğer modellerde daha yüksek çıkmış olsa da daha önce modelin tecrübe etmediği test veri setlerinde 1D-CNN modeli daha başarılı sonuçlar vermiştir. Tablodan da görüleceği üzere sonuçların büyük çoğunluğunda bu çalışmada uygulanan 1D-CNN modelinin test veri setleri için de doğruluk performansı diğer modellere kıyasla çok daha başarılıdır.

4. Sonular ve neriler

Zaman serisi olarak paylaşılan OD veri seti birçok farklı model ile sınıflandırma yapılmıştır. Bu çalışmada zaman serilerinin sınıflandırılması konusunda başarılı olan 1D-CNN modeli ile sınıflandırma işlemi yapılmıştır. Yapılan testlerin sonucunda literatürde bu problem için denenen birçok yöntemden daha başarılı sınıflandırma yapıldığı görülmüştür. Özellikler arasındaki korelasyon fazla olduğu takdirde birçok kombinasyonda 1D-CNN modelinin daha başarılı olduğu gözlemlenmiştir.

İlerideki çalışmalarda kapalı bir ortamda yapılan ölçümlerin çeşitliliği artırılabilir. Örneğin, zaman içinde ortamdaki ısı miktarındaki değişim veya ısının bölgesel olarak hareketi bir özellik olarak eklenebilir. Ayrıca, hareket algılayıcı cihazlar ile elde edilen anlık veriler de zaman serisi olarak eklenebilir ve tahminler yapılabilir. Bunun için bir dakikalık ölçümler sonucunda oluşturulan OD veri seti için daha kısa zaman dilimlerinde örneklemeler alınmalıdır.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Azizjon, M., Jumabek, A., & Kim, W. (2020, February). 1D CNN based network intrusion detection with normalization on imbalanced data. In *2020 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* (pp. 218-224). IEEE.
- Barino, F. O., Silva, V. N., López-Barbero, A. P., Honorio, L. D. M., & Dos Santos, A. B. (2020). Correlated time-series in multi-day-ahead streamflow forecasting using convolutional networks. *IEEE Access*, 8, 215748-215757.
- Billah, M. F. R. M., Saoda, N., Gao, J., & Campbell, B. (2021, May). BLE can see: a reinforcement learning approach for RF-based indoor occupancy detection. In *Proceedings of the 20th International Conference on Information Processing in Sensor Networks (co-located with CPS-IoT Week 2021)* (pp. 132-147).

- Candanedo, L. M., & Feldheim, V. (2016). Accurate occupancy detection of an office room from light, temperature, humidity and CO2 measurements using statistical learning models. *Energy and Buildings*, 112, 28-39.
- Esling, P., & Agon, C. (2012). Time-series data mining. *ACM Computing Surveys (CSUR)*, 45(1), 1-34.
- Fukuoka, R., Suzuki, H., Kitajima, T., Kuwahara, A., & Yasuno, T. (2018). Wind speed prediction model using LSTM and 1D-CNN. *Journal of Signal Processing*, 22(4), 207-210.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Hussain, D., Hussain, T., Khan, A. A., Naqvi, S. A. A., & Jamil, A. (2020). A deep learning approach for hydrological time-series prediction: A case study of Gilgit river basin. *Earth Science Informatics*, 13(3), 915-927.
- Junior, R. F. R., dos Santos Areias, I. A., Campos, M. M., Teixeira, C. E., da Silva, L. E. B., & Gomes, G. F. (2022). Fault detection and diagnosis in electric motors using 1d convolutional neural networks with multi-channel vibration signals. *Measurement*, 190, 110759.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151, 107398.
- Kuang, D. (2019). A 1d convolutional network for leaf and time series classification. *arXiv preprint arXiv:1907.00069*.
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200209.
- Liu, L., & Si, Y. W. (2022). 1D convolutional neural networks for chart pattern classification in financial time series. *The Journal of Supercomputing*, 1-24.
- Mahmoud, A., & Mohammed, A. (2021). A survey on deep learning for time-series forecasting. In *Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges* (pp. 365-392). Springer, Cham.
- Occupancy Detection Data Set*. (2016, February 29). <https://archive.ics.uci.edu/ml/datasets/Occupancy+Detection+>
- Parzinger, M., Hanfstaengel, L., Sigg, F., Spindler, U., Wellisch, U., & Wirnsberger, M. (2022). Comparison of different training data sets from simulation and experimental measurement with artificial users for occupancy detection-Using machine learning methods Random Forest and LASSO. *Building and Environment*, 109313.
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P., ... & Iyengar, S. S. (2018). A survey on deep learning: Algorithms, techniques, and applications. *ACM Computing Surveys (CSUR)*, 51(5), 1-36.
- Rizvi, S. M. H. (2022). Time series deep learning for robust steady-state load parameter estimation using 1D-CNN. *Arabian Journal for Science and Engineering*, 47(3), 2731-2744.
- Singaravel, S., Delrue, S., Pollet, I., & Vandekerckhove, S. (2022). Machine Learning for Occupancy Detection through Smart Home Sensor Data. In *ASHRAE Topical Conference Proceedings* (pp. 1-8). American Society of Heating, Refrigeration and Air Conditioning Engineers, Inc..
- Tang, W., Long, G., Liu, L., Zhou, T., Jiang, J., & Blumenstein, M. (2020). Rethinking 1d-cnn for time series classification: A stronger baseline. *arXiv preprint arXiv:2002.10061*.
- Wu, L., & Wang, Y. (2021). Stationary and moving occupancy detection using the SLEEPiR sensor module and machine learning. *IEEE Sensors Journal*, 21(13), 14701-14708.
- Zhao, J., & Li, Y. G. (2020). Abrupt Fault Detection and Isolation for Gas Turbine Components Based on a 1D Convolutional Neural Network Using Time Series Data. In *AIAA Propulsion and Energy 2020 Forum* (p. 3675).