



SOM ve K-Ortalama Kümeleme Algoritmaları Kullanarak Vagon Tamire Tutma Verilerinin İncelenmesi

Ender GÜNHER^{ORCID}, Mehmet FİDAN*^{ORCID}, Ömür AKBAYIR^{ORCID}

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Raylı Sistemler Mühendisliği Anabilim Dalı,
Eskişehir, Türkiye

*mfidan@eskisehir.edu.tr

(Alınış/Received: 06.08.2024, Kabul/Accepted: 24.01.2025, Yayınlama/Published: 31.01.2025)

Öz: Bu çalışma, Türkiye demiryolu bakım süreçlerinin optimizasyonu için Kendini Organize Eden Haritalar (SOM) ve K-Ortalama algoritmalarının karşılaştırmalı performanslarını incelemeyi amaçlamaktadır. Bu amaçla vagon tamire tutulma yeri (TTY) tespitinde kullanılan SOM ve K-Ortalama kümeleme algoritmalarının performansları incelenmiştir. Çalışmada kullanılan veri seti, Türkiye'deki vagon arıza kayıtlarından elde edilmiş olup, Tamire Tutulma Nedeni (TTN), Komponent Adı (KA) ve Vagon Tipi (VT) gibi öznitelikleri içermektedir. SOM ve K-Ortalama algoritmaları, Tamire Tutulma Nedeni (TTN), Komponent Adı (KA) ve Vagon Tipi (VT) özniteliklerinin kullanıldığı veri seti üzerinde uygulanmıştır. SOM, yüksek boyutlu verilerin iki boyutlu bir harita üzerinde görselleştirilmesini sağlayarak benzer özelliklere sahip verilerin aynı kümede toplanmasına imkân tanır. K-Ortalama algoritması ise veri noktalarını belirli sayıda küme merkezine atayarak bu merkezlere en yakın veri noktalarını aynı kümede toplar. Analiz sonuçları, SOM ve K-Ortalama algoritmalarının vagon bakım süreçlerini optimize etme açısından etkili olduğunu göstermektedir. Bu yöntemlerin birlikte kullanılması, vagon bakım süreçlerinin daha verimli ve sistematik bir şekilde yönetilmesine olanak tanıyacaktır. Doğru arıza tespiti ve uygun atölyelere yönlendirme, bakım süreçlerinin hızlanmasına ve maliyetlerin düşürülmesine katkı sağlayacaktır.

Anahtar kelimeler: Vagon Arızaları, Veri Analizi, Kümeleme Yöntemleri, Kendini Organize Eden Haritalar, K-Ortalama

Analysis of Wagon Repair Data Using SOM and K-Means Clustering Algorithms

Abstract: This study aims to investigate the comparative performances of Self Organizing Maps (SOM) and K-Means algorithms for the optimization of railway maintenance processes in Turkey. For this purpose, the performances of SOM and K-Means clustering algorithms used in the determination of the railcar repair location (TTY) were investigated. The dataset used in the study was obtained from railcar failure records in Turkey and includes attributes such as Reason for Repair (TTN), Component Name (KA) and Railcar Type (VT). SOM and K-Means algorithms were applied on the dataset where the attributes of Reason for Repair (TTN), Component Name (KA) and Wagon Type (VT) were used. SOM enables the visualization of high-dimensional data on a two-dimensional map and enables the collection of data with similar characteristics in the same cluster. The K-Means algorithm assigns data points to a certain number of cluster centers and collects the data points closest to these centers in the same cluster. The analysis results show that SOM and K-Means algorithms are effective in optimizing the wagon maintenance processes. Using these methods together will allow the management of wagon maintenance processes in a more efficient and systematic way. Correct fault detection and directing to the appropriate workshops will contribute to the acceleration of maintenance processes and the reduction of costs.

Keywords: Wagon Failures, Data Analysis, Clustering Methods, Self-Organizing Maps, K-Means

1. Giriş

Kümeleme, veri madenciliği, makine öğrenimi, örüntü tanıma ve biyoinformatik gibi birçok alanda kullanılan önemli bir veri analiz yöntemidir [1]. Bu çalışmanın amacı, vagon arıza

Atıf için/Cite as: E. Günher, M. Fidan, Ö. Akbayır, "SOM ve K-ortalama kümeleme algoritmaları kullanarak vagon tamire tutma verilerinin incelenmesi," *Demiryolu Mühendisliği*, sy. 21, ss. 168-177, Ocak 2025. doi: 10.47072/demiryolu.1529040

verilerini kullanarak tamire tutulma yerlerini (TTY) tespit etmektir. Bu amaçla, Kendini Organize Eden Haritalar (SOM) ve K-Ortalama kümeleme algoritmaları kullanılarak çeşitli özniteliklere göre vagonların hangi atölyelerde tamir edilmesi gerektiği belirlenmeye çalışılacaktır [2].

Vagon tamir süreçleri, demiryolu taşımacılığında operasyonel verimliliği artırmak için kritik öneme sahiptir. Vagonların tamire tutulma yerlerinin doğru belirlenmesi, bakım süreçlerinin hızlanmasını ve maliyetlerin düşürülmesini sağlar. Bu çalışma, Tamire Tutulma Nedeni (TTN), Komponent Adı (KA) ve Vagon Tipi (VT) özniteliklerinin kullanıldığı veri seti üzerinde SOM ve K-Ortalama kümeleme algoritmalarının uygulanmasını ve sonuçlarının karşılaştırılmasını içermektedir [3]. Literatürde, SOM ve K-Ortalama algoritmalarının veri kümelemede etkin olduğu bilinmektedir ve bu çalışmada da bu iki yöntem arasındaki farklar ve benzerlikler incelenmiştir [4].

Demiryolu bakım süreçlerinin optimize edilmesi üzerine yapılan çalışmalar, taşımacılık sistemlerinde operasyonel verimliliğin artırılmasında önemli rol oynamaktadır [5], [6]. Benzer şekilde, SOM ve K-Ortalama algoritmaları, sağlık sektöründe hastane kaynaklarının yönetimi [7], veri madenciliği alanında müşteri segmentasyonu [8] ve endüstriyel süreçlerde bakım operasyonlarının optimizasyonu [9] gibi farklı uygulama alanlarında etkin bir şekilde kullanılmıştır. Bu çalışmalarda, özellikle yüksek boyutlu verilerin kümeleme ve görselleştirilmesinde SOM algoritmasının, veri merkezli tahminlerde ise K-Ortalama algoritmasının öne çıktığı görülmüştür. Örneğin, Zhang ve arkadaşları, EMU parçalarının BOM'una ve bakım sürecinin topolojisine dayalı optimizasyon modelleri geliştirerek bakım süreçlerini verimli hale getirmiştir [10]. Wang ve arkadaşları, bakım operasyonlarının ve iş yükü tahsisinin entegre planlamasıyla atölyelerdeki makinelerin kullanım sürelerini maksimize etmeye yönelik çalışmalar yapmıştır [11]. Ayrıca, Sivaraju ve Kumar, kablosuz sensör ağlarının performansını iyileştirmek için zamanlama algoritmaları geliştirmiştir [12].

Güvenlik kritik kablosuz sensör ağlarının performansını iyileştirmek için geliştirilen zamanlama algoritmaları da bakım süreçlerine benzer şekilde uygulanabilir [13]. Shadroo ve arkadaşları, derin öğrenme tabanlı iki aşamalı zamanlama yöntemleri kullanarak IoT ortamlarında etkinlik sağlamıştır [14]. Ayrıca, Ullah ve Youn, kenar hesaplama platformlarında görevlerin etkin sınıflandırılması ve dağıtımı için K-Ortalama kümeleme algoritması tabanlı bir zamanlama şeması önermiştir [15].

Çin'in yüksek hızlı demiryolu inşaatındaki dikkate değer başarıları ve artan EMU'lar mevcut revizyon üslerine büyük baskı getirmektedir [10]. EMU parçalarının BOM'una ve bakım sürecinin topolojisine dayalı optimizasyon modelleri, bakım süreçlerini verimli hale getirmektedir [10]. Ayrıca, bakım operasyonlarının ve iş yükü tahsisinin entegre planlaması, atölyelerdeki makinelerin kullanım sürelerini maksimize etmeye yardımcı olmaktadır [11]. Bunun yanında, taşımacılık sistemlerinde bakım süreçlerinin optimize edilmesi, filo kullanılabilirliğini artırmak için önemlidir [16]. Demiryolu bakım süreçlerinde SOM ve K-Ortalama algoritmalarının birlikte kullanıldığı kapsamlı bir analiz çalışmasına rastlanmamıştır.

Girişte vagonların tamire tutulma yerlerinin belirlenmesi probleminin çözümünde SOM ve K-Ortalama algoritmalarının kullanılmasının önemine değinilmiştir. Bu iki yöntemin farklı veri setleri üzerindeki performansları ve etkinlikleri literatürde geniş bir şekilde incelenmiştir. Bu çalışma, Türkiye'deki vagon bakım verilerini kullanarak bu iki yöntemin performansını karşılaştırmayı ve optimal tamire tutulma yerlerini belirlemeyi amaçlamaktadır.

2. Metot

Çalışmada kullanılan veriler, Türkiye'deki vagon arıza kayıtlarından elde edilmiştir. Bu verilerde, her bir vagonun arıza nedeni, komponent adı ve vagon tipi bilgileri yer almaktadır. Veriler, vagonların hangi atölyelerde tamir edilmesi gerektiğini belirlemek amacıyla kullanılmıştır.

Tablo 1, tamire tuttukları vagon adetine göre en çok vagon tamire tutan 20 yeri göstermektedir. Bu tablo, tamire en çok ihtiyaç duyulan yerleri belirlemekte ve bakım planlaması için önemli bilgiler sunmaktadır. Verilerin analizi sonucunda Demirbağ ve Kayseri gibi yerlerin en çok tamire tutulan vagonlara sahip olduğu görülmüştür. Bu yerler, demiryolu ağının kritik noktalarında bulunmakta ve yoğun trafik nedeniyle daha fazla bakım gerektirmektedir.

Tablo 1. Tamire tuttukları vagon adetine göre en çok vagon tamire tutan 20 yer

Yer	Tamire Tutulma Sayısı
Kayseri	11060
Demirbağ	8645
Eskişehir	6638
Çatalağzı	3952
Malatya	3811
Afyon	3792
İskenderun	3426
Halkalı	2918
Alsancak	2664
Mersin	2657
Balıkesir	2528
Sivas	2472
Soma	2431
Yakacık	2320
Arifiye	1845
Van	1724
Ülkü	1192
Tavşanlı	1137
Konya	1067
Kapıkule	973

Tablo 2, tamire tutulan vagon adetine göre en çok tamire tutulma nedenlerini göstermektedir. Bu tablo, en yaygın arıza nedenlerini ve bu nedenlerin tamir sıklığını ortaya koymaktadır. Fren Pnömatik Kısım ve Tekerleğin Bandaj Kısım gibi nedenlerin en yaygın tamire tutulma nedenleri olduğu belirlenmiştir. Bu bilgiler, bakım ekiplerinin hangi arızalara öncelik vermesi gerektiği konusunda rehberlik edebilir.

Tablo 2. Tamire tutulan vagon adetine göre en çok tamire tutulma nedenleri

Tamire Tutulma Nedeni	Tamire Tutulma Sayısı
Boden Kalınlığı 22mm Altında	6616
Tekerlek Apleti	5711
Dikme/Dikme Desteği Hasarlı/Noksan	5146
Kapı Açık/Hasarlı	4574
Kompozit Sabo İnce/Noksan/Çatlak	4381
Yan Duvar Açık/Hasarlı(Açık Vagon)	3956
Fren Hava Hortumu Hasarlı/Noksan/Sarkıyor	3116
Vagon Gövdesi Yan Duvar Hasarlı	2542

Tablo 3, vagonların tip bazında adetlerini göstermektedir. Bu tablo, demiryolu ağında hangi tip vagonların daha yaygın olduğunu ve bu vagonların bakım ihtiyaçlarını anlamaya yardımcı olur. Fals tipi vagonların en yaygın olan vagon tipi olduğu ve diğer vagon tiplerine göre daha sık tamire tutulduğu görülmüştür. Bu bilgi, bakım kaynaklarının etkili bir şekilde dağıtılmasına yardımcı olabilir.

Tablo 3. Vagonların tip bazında adedi

Vagon Tipi	Tamire Tutulma Sayısı
Fals (665 0 331/2708)	2188
Ks (330 1 001/2650)	1206
Hbbillnss (246 1 001/999)	975
Eanoss (TSI) (537 9 192/80066)	871
Sgss (456 8 923/9772)	828

Tablo 4, tip bazında tamire tutulan vagon adedini göstermektedir. Fals ve Ks tipleri en çok tamire tutulan vagon tipleri olarak öne çıkmaktadır. Bu tablo, hangi vagon tiplerinin daha fazla bakım gerektirdiğini ve bu bakım ihtiyaçlarının nasıl karşılanabileceğini belirlemek için kullanılabilir.

Tablo 4. Tip Bazında Tamire Tutulan Vagon Adedi

Vagon Tipi	Tamire Tutulma Sayısı
Fals (665 0 331/2708)	19973
Ks (330 1 001/2650)	6370
Hbbillnss (246 1 001/999)	4470
Eanoss (TSI) (537 9 192/80066)	3364
Sgss (456 8 923/9772)	3167

Bu çalışmada iki farklı kümeleme algoritması kullanılmıştır: Kendini Organize Eden Haritalar (SOM) ve K-Ortalama kümeleme.

2.1. Kendini organize eden haritalar (SOM)

SOM, yüksek boyutlu verilerin iki boyutlu bir harita üzerinde görselleştirilmesini sağlayan bir yapay sinir ağı algoritmasıdır. SOM, benzer özelliklere sahip verilerin aynı kümede toplanmasına olanak tanır ve veri setlerini görselleştirerek analiz edilmesini kolaylaştırır [11].

SOM algoritmasının temel adımları şunlardır:

1. Ağın Başlatılması: Rastgele ağırlık değerleri ile ağ başlatılır.
2. Veri Noktasının Seçilmesi: Eğitim veri setinden rastgele bir veri noktası seçilir.
3. En Yakın Düğümün Bulunması: Seçilen veri noktasına en yakın düğüm (kazanan düğüm) belirlenir.
4. Ağırlıkların Güncellenmesi: Kazanan düğüm ve komşularının ağırlıkları güncellenir.
5. Tekrarlama: Adım 2'den 4'e kadar olan işlemler belirli bir iterasyon sayısına kadar tekrarlanır [12].

2.2. K-ortalama kümeleme metodu

K-Ortalama kümeleme, veri noktalarını belirli sayıda (K) küme merkezine atayan bir algoritmadır. Her bir veri noktası, en yakın küme merkezine atanarak aynı kümede toplanır. K-Ortalama kümeleme algoritması, veri noktalarını belirli sayıda küme merkezine atar ve bu merkezlere en yakın veri noktalarını aynı kümede toplar. Bu yöntem, yük dengelemesi ve görev zamanlaması gibi çeşitli uygulamalarda etkin bir şekilde kullanılmaktadır [15].

K-Ortalama algoritmasının temel adımları şunlardır:

1. Küme Merkezlerinin Başlatılması: K adet küme merkezi rastgele seçilir.
2. Veri Noktalarının Atanması: Her bir veri noktası en yakın küme merkezine atanır.
3. Küme Merkezlerinin Güncellenmesi: Her bir küme merkezi, kümesine atanan veri noktalarının ortalaması alınarak güncellenir.
4. Tekrarlama: Adım 2 ve 3 belirli bir iterasyon sayısına kadar veya küme merkezleri sabitlenene kadar tekrarlanır [14].

3. Bulgular

Bu bölümde, SOM ve K-Ortalama algoritmaları kullanılarak elde edilen bulgular sunulmaktadır.

3.1. SOM bulguları

Tablo 5 ve Tablo 6'da SOM ile elde edilen küme istatistikleri verilmiştir. SOM algoritması ile elde edilen kümelerde, VT, KA ve TTN öznitelikleri arasında belirgin farklar gözlemlenmiştir. Özellikle VT özneliğinde Fals tipi vagonların diğer özniteliklere göre daha yaygın olduğu görülmüştür.

Tablo 5. SOM ile elde edilen küme istatistikleri

Küme No	VT Ortalama	VT Std	VT Mod	KA Ortalama	KA Std	KA Mod	TTN Ortalama	TTN Std	TTN Mod
1	9,86	0,83	10	4,98	0,35	5	27,96	1,46	28
2	9,90	0,60	10	48,98	0,16	49	104,96	0,30	105
3	20,47	0,86	20	10,99	0,22	11	51,07	0,49	51
4	10,06	0,40	10	21,51	0,50	22	66,49	2,84	68
5	11,64	1,20	12	24,35	2,18	23	55,84	3,17	56
6	14,55	1,35	15	39,62	1,14	38	85,71	4,15	88
7	10,23	0,95	10	17,78	1,19	18	42,34	2,37	41
8	13,45	1,05	14	35,22	1,56	34	76,84	3,89	77
9	9,96	0,60	10	24,56	0,85	25	57,28	1,78	56
10	10,03	0,85	10	29,12	1,35	28	67,34	2,75	66

Tablo 6, SOM ile elde edilen küme içi korelasyonları göstermektedir. Bu korelasyonlar, her küme için VT, KA, ve TTN özniteliklerinin birbirleriyle olan ilişkilerini ortaya koymaktadır.

Tablo 6. SOM ile elde edilen küme içi korelasyonlar

Küme No	VT-KA	KA-TTN	VT-TTN
1	-0,1426	0,8283	-0,2182
2	0,3364	0,9084	0,3687
3	0,4837	0,9146	0,6186
4	0,1154	0,5288	0,0151
5	0,3269	0,5525	-0,2096
6	-0,0222	-0,1781	0,05
7	-0,0661	0,2007	0,0092
8	-0,0917	0,0644	-0,1892
9	0,0204	0,9813	0,055
10	0,9766	0,9822	0,3878

Bu tablolar, SOM algoritması ile elde edilen kümelerde öznitelikler arasındaki korelasyonların analiz edilmesini sağlamaktadır. Örneğin, birinci kümede VT ile KA arasında negatif bir

korelasyon varken, KA ile TTN arasında pozitif bir korelasyon bulunmaktadır. Bu, KA ve TTN özneliklerinin birlikte hareket etme eğiliminde olduğunu göstermektedir.

Tablo 7’de Tablo 5’teki modların açıklamaları verilmiştir.

Tablo 7. SOM ile elde edilen modların tanımları

Küme No	VT Mod	KA Mod	TTN Mod
1	Fals (665 0 331/2708)	Boden	Boden Kalınlığı 22mm Altında
2	Fals (665 0 331/2708)	Yan veya Alın Duvar (Açık Vagon)	Yan veya Alın Duvarlar Hasarlı (Açık Vagon)
3	Ks (330 1 001/2650)	Dikme (Platform Vagon)	Dikme - Muhtelif Arızalar (Platform Vagon)
4	Fals (665 0 331/2708)	Fren Pnömatik Kısım	Fren Hava Hortumu Hasarlı/Noksan
5	Sgss (456 8 923/9772)	Tekerleğin Bandaj Kısım	Tekerlek Apleti
6	Ks (330 1 001/2650)	Yan Duvar Kapağı (Platform Vagon)	Yan Duvar Kapağı - Muhtelif (Platform Vagon)
7	Ks (330 1 001/2650)	Fren Pnömatik Kısım	Fren Mekanik Parçası Sarkık veya Kırık
8	Fals (665 0 331/2708)	Kapı ve Sürme Duvar	Kapı Çerçevesi, Menteşe, Kilit, Mandal Kancası, Tutamak vb Noksan/Kırık/Hasarlı
9	Fals (665 0 331/2708)	Duvar	Duvar Hasarlı
10	Falns (644/664 1 001/531)	Tekerleğin Bandaj Kısım	Tekerlek Apleti

3.2. K-ortalama bulguları

Tablo 8, 9 ve 10’da K-Ortalama yöntemi ile elde edilen küme istatistikleri verilmiştir. K-Ortalama yöntemi ile elde edilen kümelerde, VT, KA ve TTN öznelikleri arasında belirgin farklar gözlemlenmiştir. VT özneliğinde en yaygın vagon tipi yine Fals tipi vagonlardır ve KA özneliğinde en yaygın komponentler fren ve tekerlek bileşenleridir.

Tablo 8. K-ortalama ile elde edilen küme istatistikleri

Küme No	VT Ortalama	VT Std	VT Mod	KA Ortalama	KA Std	KA Mod	TTN Ortalama	TTN Std	TTN Mod
1	12,53	5,32	10	29,53	3,29	27	77,50	5,19	81
2	13,74	5,87	10	48,36	1,66	49	104,12	1,87	105
3	32,34	6,05	39	7,84	7,73	5	32,92	20,51	28
4	31,32	5,86	34	35,47	6,34	38	86,67	13,81	91
5	9,90	1,98	10	5,16	1,13	5	32,43	8,04	28
6	13,02	7,27	10	21,05	4,44	19	9,66	2,34	9
7	23,97	5,93	20	11,13	4,63	11	53,88	11,03	51
8	14,51	9,71	10	20,26	4,84	22	71,29	6,84	70
9	14,58	9,49	10	46,05	5,86	51	28,17	4,64	32
10	7,73	4,64	7	37,07	1,73	38	89,31	6,81	91

Tablo 9, VT, KA ve TTN öznelikleri için K-Ortalama yöntemi sayısal sonuçlarını açıklamaktadır. Bu sonuçlar, her küme için en yaygın öznelik değerlerini (mod) göstermektedir.

Tablo 9. K-ortalama ile elde edilen modların tanımları

Küme No	VT Mod	KA Mod	TTN Mod
1	Fals (665 0 331/2708)	Kapı ve Sürme Duvar	Kompozit Sabo İnce/Noksan/Çatlak
2	Fals (665 0 331/2708)	Yan veya Alın Duvar	Yan veya Alın Duvarlar Hasarlı
3	Talns (TSI)(066 5 001/300)	Boden	Boden Kalınlığı 22mm Altında
4	Sgss (456 8 923/9772)	Tekerleğin Bandaj Kısmı	Tekerlek Apleti
5	Fals (665 0 331/2708)	Boden	Boden Kalınlığı 22mm Altında
6	Fals (665 0 331/2708)	Duvar	Duvar Hasarlı
7	Ks (330 1 001/2650)	Dikme (Platform Vagon)	Dikme - Muhtelif Arızalar
8	Fals (665 0 331/2708)	Fren Pnömatik Kısım	Fren Mekanik Parçası Sarkık/Kırık
9	Fals (665 0 331/2708)	Yarı Otomatik Koşum Takımı	Yarı Otomatik Koşum Takımı Hasarlı
10	Falns (644/664 1 001/531)	Tekerleğin Bandaj Kısmı	Tekerlek Apleti

Tablo 10, K-Ortalama yöntemi ile elde edilen küme içi korelasyonları göstermektedir. Bu korelasyonlar, her küme için VT, KA ve TTN özniteliklerinin birbirleriyle olan ilişkilerini ortaya koymaktadır.

Tablo 10. K-ortalama ile elde edilen küme içi korelasyonlar

Küme No	VT-KA	KA-TTN	VT-TTN
1	0,1232	0,1818	0,1221
2	-0,3414	0,1637	-0,0198
3	0,2936	0,6391	0,2053
4	-0,3794	0,9887	-0,3698
5	-0,1801	-0,498	-0,1494
6	-0,0278	0,0092	-0,1792
7	0,008	-0,1867	0,0799
8	0,0716	0,3403	0,0052
9	0,0207	0,7897	0,0319
10	0,2796	0,5754	0,2797

Bu tablolar, K-Ortalama algoritması ile elde edilen kümelere öznitelikler arasındaki korelasyonların analiz edilmesini sağlamaktadır. Örneğin, dördüncü kümede KA ile TTN arasında güçlü bir pozitif korelasyon varken, VT ile TTN arasında negatif bir korelasyon bulunmaktadır. Bu, KA ve TTN özniteliklerinin birlikte hareket etme eğiliminde olduğunu göstermektedir.

Bu sonuçlar, SOM algoritmasının yüksek boyutlu verilerin görselleştirilmesi ve anlamlandırılmasında etkinliğini ortaya koyarken, K-Ortalama algoritmasının ise daha hızlı ve belirgin kümeleme sağladığını göstermektedir. Literatürde, Wang demiryolu bakım süreçlerindeki benzer çalışmaları ile karşılaştırıldığında[17], bu çalışma, SOM'un verilerin görselleştirilmesindeki katkısını vurgulaması açısından farklılık göstermektedir. Ayrıca, K-Ortalama algoritmasının literatürde diğer endüstriyel bakım süreçlerinde kullanılan uygulamaları

ile paralellik taşıdığı, ancak bu çalışmada demiryolu sektörüne özel verilerle test edilerek özgün bir yaklaşım sunduğu görülmektedir.

4. Sonuç

Bu çalışmada, vagon tamire tutulma yeri tespiti için SOM ve K-Ortalama kümeleme algoritmaları kullanılmıştır. Her iki yöntemin de vagon bakım süreçlerinin daha verimli yönetilmesine katkı sağladığı görülmüştür. SOM, veri setlerinin görselleştirilmesini sağlarken, K-Ortalama algoritması verileri belirli küme merkezlerine atayarak analiz edilmesini kolaylaştırmaktadır. Elde edilen sonuçlar, her iki yöntemin de vagonların tamire tutulma yerlerinin tespitinde etkin olduğunu göstermektedir.

Tablo analizleri, farklı vagon tipleri, tamire tutulma nedenleri ve komponent adları arasındaki ilişkileri anlamamıza yardımcı olmuştur. Özellikle, Fals tipi vagonların ve belirli komponent arızalarının daha yaygın olduğu tespit edilmiştir. Bu bilgiler, bakım kaynaklarının etkili bir şekilde dağıtılmasına ve arıza önleme stratejilerinin geliştirilmesine olanak tanır.

Bu çalışma, Türkiye demiryolu bakım süreçlerinin sistematik bir şekilde optimize edilmesi için değerli bir model sunmaktadır. Gelecekteki çalışmalar, daha karmaşık veri setleri ve farklı kümeleme algoritmaları ile bu modellerin performansını değerlendirmelidir.

Bu çalışma, SOM ve K-Ortalama algoritmalarının demiryolu bakım süreçlerinde kullanımı açısından önemli sonuçlar sunmaktadır. Gelecekte, bu algoritmaların bakım önceliklendirmesi, arıza tahmini ve bakım kaynaklarının optimizasyonu gibi demiryolu sektöründe kritik öneme sahip farklı alanlarda da uygulanması önerilmektedir. Ayrıca, bu algoritmaların sağlık sektöründe hastane kaynaklarının yönetimi, veri madenciliği alanında müşteri segmentasyonu ve enerji sektöründe ekipman bakımının optimize edilmesi gibi diğer endüstriyel alanlarda test edilmesi, yöntemlerin genel uygulanabilirliği ve etkinliğini artırabilir. SOM'un yüksek boyutlu verilerin görselleştirilmesi avantajı, büyük veri setlerinin analizi için kullanılabilirken, K-Ortalama algoritmasının hızlı kümeleme yetenekleri, gerçek zamanlı uygulamalarda önemli faydalar sağlayabilir. Bu yöntemlerin farklı sektörlerdeki uygulamalarının karşılaştırmalı analizleri, algoritmaların sektörel avantajlarını ve sınırlamalarını daha iyi anlamak için önemli bir katkı sunacaktır.

Gelecekte, bu yöntemlerin daha büyük ve karmaşık veri setleri üzerinde test edilmesi ve diğer kümeleme algoritmaları ile karşılaştırılması önerilmektedir. Ayrıca, veri setine eklenebilecek yeni özniteliklerle algoritmaların performansı daha da artırılabilir. SOM ve K-Ortalama algoritmalarının birlikte kullanılması, vagon bakım süreçlerinin daha verimli ve sistematik bir şekilde yönetilmesine olanak tanıyacaktır. Bu sayede, demiryolu işletmelerinin operasyonel verimliliği artacak ve bakım planlaması daha etkili bir şekilde yapılacaktır.

Teşekkür

Bu çalışma TCDD Taşımacılık AŞ'nin 04.10.2021 tarih ve E-30614766-204.02.99-128179 sayılı onayı ile yapılmıştır.

Kaynakça

- [1] F. Feuillet, vd. "Psikotrop ilaçların tüketimi ve istatistiksel metodlar," *Journal of Health Studies*, vol. 45, no. 3, pp. 123-135, 2012
- [2] T.S. Madhulatha, "Kümeleme algoritmaları ve veri madenciliği," *Data Mining Journal*, vol. 34, no. 2, pp. 67-89, 2012

- [3] W. Zhang, Z. Wang, Z. Jia, H. Wang, "Optimization model for collaborative overhaul workshop scheduling problem of multiple EMUs," in *2021 IEEE 23rd Int Conf on High Performance Computing & Communications; 7th Int Conf on Data Science & Systems; 19th Int Conf on Smart City; 7th Int Conf on Dependability in Sensor Cloud & Big Data Systems & Application*, 2021, doi: 10.1109/HPCC-DSS-SmartCity-DependSys53884.2021.00181
- [4] Z. Wang, Q. Deng, L. Zhang, H. Li, F. Li, "Joint optimization of integrated mixed maintenance and distributed two-stage hybrid flow-shop production for multi-site maintenance requirements," *Expert Systems with Applications*, 215, 119422, 2023
- [5] M. Rodoplu, S. Dauzère-Pérès, P. Vialletelle, "Integrated planning of maintenance operations and workload allocation," *International Journal of Production Research*, vol. 61, no. 23, pp. 8291-8308, 2023
- [6] Y. Zhang, C. Li, X. Su, R. Cui, B. Wan, "A baseline-reactive scheduling method for carrier-based aircraft maintenance tasks," *Complex & Intelligent Systems*, vol. 9, no. 1, pp. 367-397, 2023
- [7] W. T. Lin, Y. C. Wu, J. S. Zheng, M. Y. Chen, "Analysis by data mining in the emergency medicine triage database at a Taiwanese regional hospital," *Expert Systems with Applications*, vol. 38, no. 9, pp. 11078-11084, 2011.
- [8] K. R. Kashwan, C. M. Velu, "Customer segmentation using clustering and data mining techniques," *International Journal of Computer Theory and Engineering*, vol. 5, no. 6, pp. 856, 2013.
- [9] L. Pinciroli, P. Baraldi, E. Zio, "Maintenance optimization in industry 4.0," *Reliability Engineering & System Safety*, vol. 234, pp. 109204, 2023.
- [10] I. Al-Nader, A. Lasebae, R. Raheem, "A novel scheduling algorithm for improved performance of multi-objective safety-critical WSN using spatial self-organizing feature map," *Electronics*, vol. 13, no. 1, 19, 2023
- [11] S. Sivaraju, C. Kumar, "Energy enhancement of WSN with deep learning based SOM scheduling algorithm," *Journal of Information Technology and Digital World*, vol. 4, no. 3, pp. 238-249, 2022
- [12] S. Shadroo, A.M. Rahmani, A. Rezaee, "The two-phase scheduling based on deep learning in the Internet of Things," *Computer Networks*, 185, 107684, 2021
- [13] A. Singh, G.S. Aujla, R.S. Bali, P.K. Chahal, M. Singh, "A self organised workload classification and scheduling approach in IoT-edge-cloud ecosystem," *2020 IEEE 92nd Vehicular Technology Conference (VTC2020-Fall)*, pp. 1-5, 2020
- [14] S.M. Mostafa, H. Amano, "Dynamic round robin CPU scheduling algorithm based on K-means clustering technique," *Applied Sciences*, vol. 10, no. 15, 5134, 2020
- [15] M. Belhor, A. El-Amraoui, A. Jemai, F. Delmotte, "Multi-objective evolutionary approach based on K-means clustering for home health care routing and scheduling problem," *Expert Systems with Applications*, 213, 119035, 2023
- [16] I. Ullah, H.Y. Youn, "Task classification and scheduling based on K-means clustering for edge computing," *Wireless Personal Communications*, vol. 113, no. 4, pp. 2611-2624, 2020
- [17] J. Wang, "Maintenance scheduling at high-speed train depots: An optimization approach," *Reliability Engineering & System Safety*, vol. 243, pp.109809, 2024.

Özgeçmiş



Ender GÜNER

Kocaeli Üniversitesi Mühendislik Fakültesi Makine Mühendisliği Bölümü'nden 2008 yılında mezun oldu. Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Raylı Sistemler Mühendisliği Anabilim Dalı'nda 2024 yılında yüksek lisansını tamamladı. 2018 yılından beridir Eskişehir Valiliği, Çevre ve Şehircilik İl Müdürlüğü'nde Makine Mühendisi olarak çalışmaktadır. E-Posta: endergunh@gmail.com

**Mehmet FİDAN**

Eskişehir Osmangazi Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden 2004 yılında mezun oldu. Yüksek lisans ve doktora eğitimini Anadolu Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde 2006 ve 2015 yıllarında tamamladı. Eskişehir Teknik Üniversitesi, Ulaştırma Meslek Yüksek Okulu Raylı Sistemler Elektrik-Elektronik Programında doktor öğretim üyesi olarak çalışmakta ve yine aynı alanda akademik çalışmalarına devam etmektedir.

E-Posta: mfidan@eskisehir.edu.tr

**Ömür AKBAYIR**

Lise eğitimini Demiryolu Meslek Lisesinde, lisans ve yüksek lisans eğitimini Eskişehir Osmangazi Üniversitesi'nde, doktora eğitimini Gazi Üniversitesi'nde tamamlamıştır. 1999-2015 yıllarında TCDD'den Teknisyen ve Mühendis olarak, 2015-2018 yıllarında Anadolu Üniversitesi'nde Dr. Öğr. Üyesi olarak çalışmıştır. 2018 yılından bu yana Eskişehir Teknik Üniversitesi'nde çalışmakta olup Doç. Dr. unvanını 2022 yılında almıştır.

E-Posta: omurakbayir@eskisehir.edu.tr

Beyanlar:

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Yazarların katkıları: Ender GÜNER: Metodoloji, Yazma, Yazılım. Mehmet FİDAN: Kavramsallaştırma, Metodoloji, Görselleştirme, Kaynaklar, Doğrulama, Yazma-orijinal taslak hazırlama. Ömür AKBAYIR: Kavramsallaştırma, İnceleme, Kontrol, Yazma-gözden geçirme ve düzenleme.