



Fault detection in pipelines with graph convolutional networks (GCN) method

Ersin Şahin^{1,*}, Hüseyin Yüce²

¹Beykoz Vocational School, Computer Programming, Beykoz University, 34820, Istanbul, Türkiye

²Mechatronics Engineering, Faculty of Technology, Marmara University, 34722, Istanbul, Türkiye

Highlights:

- Five scenarios have been developed for the detection of faults in pipelines.
- Two data sets were created for the detection of faults in pipelines.
- Fault detection estimation has been made in pipelines with graph convolutional networks algorithm.

Keywords:

- Machine learning
- Graph convolutional networks
- Fault detection
- Pipelines

Article Info:

Research Article

Received: 30.05.2023

Accepted: 14.06.2024

DOI:

10.17341/gazimmfd.1306916

Acknowledgement:

This study was supported by Marmara University with the scientific research project numbered FDK-2023-10459 within the scope of the doctoral thesis. In the experimental stages of the study, the experimental set in Marmara University, Faculty of Technology, Mechatronics Engineering Fault Diagnosis Laboratory was used. The authors would like to express their gratitude to Marmara University for providing these opportunities.

Correspondence:

Author: Ersin Şahin
e-mail:
ersinsahin@beykoz.edu.tr
phone: +90 536 498 0004

Graphical/Tabular Abstract

Fault situations in pipelines result in significant economic losses and environmental pollution. Consequently, the detection of fault conditions in pipelines is of critical importance. In this study, graph-based machine learning algorithms, namely GCN, RGCN, GraphSAGE, and HinSAGE, were applied for fault detection in pipelines. The fault prediction accuracies for GCN, GraphSAGE, HinSAGE, and RGCN were identified as 0.91%, 0.90%, 0.87%, and 0.89%, respectively (Figure A).

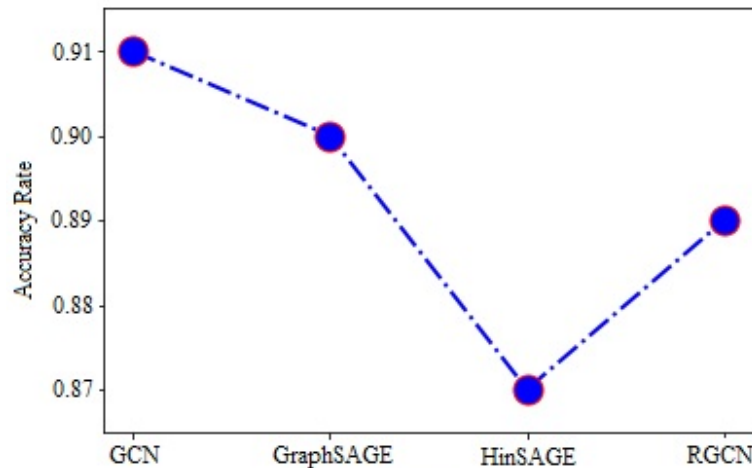


Figure A. Performance values of graph-based machine learning algorithms

Purpose:

The aim of this study is to detect the faults (leakage and blockage) occurring in pipelines by graph convolutional networks algorithm.

Theory and Methods:

Graph-based machine learning algorithms GCN, RGCN, GraphSAGE and HinSAGE were used to make predictions for the detection of faults in pipelines. An experimental study was conducted with the aim of applying these algorithms. Five scenarios were created, including three leaks and two blockages, and data were collected via pressure sensors. Two sets of data were created with the collected data progress. During the implementation of GCN, RGCN, GraphSAGE and HinSAGE algorithms, Python programming language and StellarGraph, Pandas, Numpy, Sklearn, Tensorflow, IPython, Matplotlib and pyvis libraries were used. The contrast matrix, accuracy, precision, sensitivity, f1 scoring methods were used in the performance evaluation of the algorithms.

Results:

In this study, GCN, GraphSAGE, HinSAGE and RGCN algorithms are used respectively 0.91%, 0.90%, 0.87%, 0.89% it has been found that they perform fault detection in pipelines with accuracy rates.

Conclusion:

In this study, the GCN model demonstrated superior performance compared to the other algorithms, despite their closely aligned performance metrics. The findings are consistent with existing literature when comparing the performances of GCN, GraphSAGE, HinSAGE, and RGCN algorithms.



Boru hatlarında çizge evrişimsel ağlar yöntemi (GCN) ile arıza tespiti

Ersin Şahin^{1,*}, Hüseyin Yüce²

¹Beykoz Üniversitesi, Beykoz MYO, Bilgisayar Programcılığı, 34820, İstanbul, Türkiye

²Marmara Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği, 34722, İstanbul, Türkiye

Ö N E Ç I K A N L A R

- Boru hatlarında arızaların tespitine yönelik beş adet senaryo geliştirilmiştir
- Boru hatlarında arızaların tespitine yönelik iki adet veri seti oluşturulmuştur
- Boru hatlarında çizge evrişimsel ağlar algoritması ile arıza tespit tahmini yapılmıştır

Makale Bilgileri

Araştırma Makalesi

Geliş: 30.05.2023

Kabul: 14.06.2024

DOI:

10.17341/gazimmfd.1306916

Anahtar Kelimeler:

Makine Öğrenme,
çizge evrişimli ağlar,
arıza tespiti,
boru hatları

ÖZ

Boru hatları petrol ve doğalgaz gibi enerji kaynaklarının taşınmasından, su kaynaklarının iletilmesi ve dağıtılmasına kadar çok geniş bir alanda kullanım alanına sahiptir. Boru hatlarından sızan petrol ve gaz akışkanları çevreye ciddi zararlar vermektedir. Boru hatlarındaki arızaların doğru bir şekilde tespit edilmesi, ekonomik kayıpların etkilerinden kaçınmak ve çevreyi korumak için önemlidir. Bu çalışmada su akışkanına sahip boru hatları çizgeler (graf) ile temsil edilmiştir. Boru hatlarında sızıntı ve tıkanma durumlarının tespiti için çizge temelli makine öğrenmesi algoritması GCN kullanılmıştır. Deneysel yöntemler kullanılarak GCN algoritması için gerekli olan veriler (basınç verileri), beş farklı senaryo oluşturularak toplanmış ve iki adet veri seti oluşturulmuştur. GCN algoritmasından elde edilen arıza tespit performans değeri diğer çizge makine öğrenmesi algoritmaları; RGCN, HinSAGE ve GraphSAGE 'nin performansları ile karşılaştırılmıştır. Bu çalışmada GCN modelinin performansı diğer algoritmalara göre daha yüksek bulunmuştur. Literatür incelendiğinde makine öğrenmesi algoritmaları kullanılarak boru hatlarında arıza tespiti için doğruluk oranları %78,51 ile %99 değerleri arasında tespit edilmiştir. Bu çalışmada, GCN, GraphSAGE, HinSAGE ve RGCN algoritmalarının sırasıyla %0,91, %0,90, %0,87, %0,89 doğruluk oranları ile boru hatlarında arıza tespiti yaptıkları bulgusuna varılmıştır. Çizge temelli algoritmaların performanslarının kıyaslanması için klasik makine öğrenmesi SVM modeli kullanılmıştır. Algoritmaların performansları literatür ile karşılaştırıldığında sonuçların literatür ortalamasının üstünde olduğu görülmektedir.

Fault detection in pipelines with graph convolutional networks (GCN) method

H I G H L I G H T S

- Five scenarios have been developed for the detection of faults in pipelines
- Two data sets were created for the detection of faults in pipelines
- Fault detection estimation has been made in pipelines with graph convolutional networks algorithm

Article Info

Research Article

Received: 30.05.2023

Accepted: 14.06.2024

DOI:

10.17341/gazimmfd.1306916

Keywords:

Machine learning,
graph convolutional
networks,
fault detection,
pipelines

ABSTRACT

Pipeline networks have a wide range of applications, from the transportation of energy sources such as oil and natural gas to the conveyance and distribution of water resources. However, leaks and ruptures in pipelines can cause significant harm to the environment. Therefore, it is crucial to accurately detect pipeline faults in order to avoid economic losses and protect the environment. In this study, pipeline networks carrying water fluid are represented using graph structures. The graph convolutional network (GCN) algorithm is employed for the detection of leaks and blockages in pipeline networks. Experimental methods are employed to collect the necessary data (pressure data) for the GCN algorithm, creating two datasets by considering five different scenarios. The fault detection performance of the GCN algorithm is compared with other graph machine learning algorithms, namely, RGCN, HinSAGE, and GraphSAGE. The results of this study indicate that the performance of the GCN model surpasses that of the other algorithms. Reviewing the literature, accuracy rates for fault diagnosis in pipeline networks using machine learning algorithms range from 78.51% to 99%. In this study, it is found that the GCN, GraphSAGE, HinSAGE, and RGCN algorithms achieve fault detection accuracies of 91%, 90%, 87%, and 89%, respectively, in pipeline networks. Classical machine learning SVM model was used to compare the performance of graph-based algorithms. It is seen that the performances of the algorithms face the literature and the results are above the literature average.

1. Giriş (Introduction)

Boru hatları; petrol, doğalgaz gibi enerji kaynaklarının taşınmasından, su kaynaklarının iletilmesi ve dağıtılmasına kadar çok geniş bir alanda kullanım alanına sahiptir. Boru hatlarındaki arıza durumları sızıntı ve tıkanma olmak üzere iki farklı şekilde ortaya çıkmaktadır. Boru hatlarındaki arızalar yaygın ve önemli olup küresel bir problemdir. Basınç veya sıcaklık değişikliklerinin neden olduğu katı ve hidrokarbon birikiminden kaynaklanan boru hattı tıkanmaları [1] ile korozyon, yıpranma ve üçüncü taraf hasarlarından kaynaklanan boru hattı sızıntıları [2] boru hattı taşıma sistemlerinde kritik sorunlara yol açmaktadır. Boru hatlarındaki arızaların doğru bir şekilde tespit edilmesi, ekonomik kayıpların etkilerinden kaçınmak ve çevreyi korumak için önemlidir [3]. Boru hatlarından sızan petrol ve gaz akışkanları çevreye ciddi zararlar vermektedir [4]. Bu nedenle, boru hatlarında meydana gelen arıza durumlarının hızla tespit edilmesi ve onarılması gerekmektedir. Boru hatlarında meydana gelen arızalara zamanında ve doğru müdahale edilmesi önemli bir karar alma problemidir. Bir boru hattındaki arızayı tespit etmek için fiziksel inceleme ve matematiksel model simülasyonu olmak üzere iki tür yaklaşım kullanılmaktadır. Fiziksel yöntemler, arızanın yerini ve boyutunu doğru bir şekilde saptanmasına rağmen üretimin durdurulması sebebiyle yüksek maliyete sahiptir. Matematiksel yaklaşım teorik olarak arızaları tespit eder bu yüzden çok daha düşük maliyete sahiptir [5]. Boru hatlarındaki arızaları tespit etmek için çeşitli yöntemler kullanılmaktadır. Bu yöntemlerden bazıları; akustik yöntemler [6, 7], negatif basınç dalgası ölçümü [8-10], basınç ve akışkan hızının giriş ve çıkış değerlerinin ölçümü [11-13], titreşim analizi, dağıtılmış fiber optik algılama, kızılötesi kameralar ve lidar sistemleridir [14]. Arıza tespiti ve sınıflandırması için, evrişimli sinir ağı ve yapay sinir ağını temel alan birçok makine öğrenmesi algoritması kullanılmaktadır [15]. Boru hatlarında arızanın tespiti ve yerinin belirlenmesi için çok sayıda araştırma yapılmıştır [16, 17]. Boru hatlarında arıza tespiti için uygulanan makine öğrenmesi uygulamaları için literatür bulunmaktadır [18, 19]. Boru hatlarında çizge tabanlı yöntemler ile sızıntı arızalarının tespiti ve arıza yerinin belirlenmesi üzerine çalışmalar mevcuttur. Bu çalışmalar su dağıtım şebekelerinde [20-23] ve doğal gaz dağıtım şebekeleri [24] üzerine odaklanmaktadır. Fakat boru hatlarında arıza tespiti için makine öğrenmesi yöntemi kullanımı çok sınırlıdır [25]. Literatürde boru hatlarında arıza tespitine yönelik; SVM (Support Vector Machines) [26, 27], CNN (Convolutional Neural Network) [28, 29], ANN (Artificial Neural Network) [30, 31], DCNN (Deep Convolutional Neural Network)-LSTM (Long-Short-Term Memory) [32], CatBoost [33], k-NN (K-Nearest Neighbors) [34], RVM (Relevance Vector Machine) [35], INN (Immune Neural Network) [36], SSA-CNN (Sparrow Search Algorithm and Convolutional Neural Network) [37] ve GCN (Graph Convolutional Network) [38] makine öğrenmesi algoritmaları kullanılmaktadır. Makine öğrenmesi algoritmaları kullanılarak boru hatlarında arıza teşhisi için doğruluk oranları %78,51 ile %99 değerleri arasında tespit edilmiştir. Gerçek hayatta karşılaşılan birçok kompleks sistemi teorik olarak temsil etmek zordur. Bu tür kompleks sistemler çizgeler ile temsil edilebilmektedir. Havayolu ağları, banka ağları, sosyal ağlar, medikal ağlar, tedarik zinciri ağları gibi birçok yapı çizge yapısı ile ifade edilmektedir. Özellikle birden fazla boru hattının birleştiği veya ayrıldığı dağıtım şebekeleri gibi kompleks bir sistemi çizgelerle temsil etmek mümkündür. Bu çalışmada su akışkanına sahip boru hatları çizgeler ile temsil edilmiştir. Boru hatlarında sızıntı ve tıkanma durumlarının tespiti için çizge temelli makine öğrenmesi algoritması GCN kullanılmıştır. Literatürde GCN üzerine yapılan çalışmalar genellikle nesne tanıma ve sınıflandırma üzerine yapılmıştır. GCN algoritması ile kentsel boru hatlarında %75 [38], görüntü işleme alanında %94 [39], müşteriye ürün önerisi verme konusunda %88 [40] ve buhar türbinleri üzerinde hata tespitinde %86 [41] doğruluk ile sonuçlar elde

edilmiştir. Bu çalışmada deneysel yöntemler kullanılarak GCN algoritması için gerekli olan veriler, beş farklı senaryo oluşturularak toplanmış ve iki adet veri seti oluşturulmuştur. GCN algoritmasından elde edilen arıza tespit performans değeri diğer çizge makine öğrenmesi algoritmaları; RGCN (Relational Graph Convolutional Network), HinSAGE (Heterogeneous GraphSAGE) ve GraphSAGE 'nin performansları ile karşılaştırılmıştır.

2. Metot (Method)

Bu çalışmada çizge temelli makine öğrenmesi algoritmalarından GCN, RGCN, GraphSAGE ve HinSAGE kullanılmıştır. Bu algoritmaların uygulanması aşamasında Python temelinde StellarGraph, Pandas, Numpy, Sklearn, Tensorflow, IPython, Matplotlib ve pyvis kütüphaneleri kullanılmıştır. GCN, RGCN, GraphSAGE ve HinSAGE algoritmaların performans değerlendirilmesinde karşıtlık matrisi, doğruluk, kesinlik, duyarlılık, f₁ skorlama yöntemleri kullanılmıştır. Algoritmaların uygulanmasında model parametreleri literatür [42] dikkate alınarak seçilmiştir. Optimizasyon yöntemi olarak "ADAM", kayıp fonksiyonu olarak "Cross-Entropy" ve ezberlemeye karşı erken durdurma yöntemi kullanılmıştır. Bu çalışmada ele alınan modeller için kullanılan parametreler Tablo 1'de verilmektedir.

Tablo 1. Çizge temelli model parametreleri

Model Parametreleri	
Katman sayısı	[16,16]
Epochs değeri	70
Optimizasyon	lr=0,01
Aktivasyon Fonk.	Tanh, Softmax
Drop-out oranı	0,3
Test/ Eğitim Oranı	%30
Verbose	2

Bu çalışmada, boru hatlarında arızaların tespiti için Çizge Evrişimli Ağlar (Graph Convolutional Networks/GCN) gibi derin öğrenme tekniklerinin kullanılması önerilmektedir. GCN, grafik veri yapılarını işlemek için özel olarak tasarlanmış derin öğrenme yöntemlerinden biridir ve son zamanlarda sağlık ve finans gibi çeşitli alanlarda başarıyla uygulanmıştır [43].

2.1. Çizge evrişimli ağlar (Graph Convolutional Networks)

Çizge evrişimli ağlar (GCN), yapay sinir ağları araştırmalarında güncel bir konudur. GCN modeli, çizgeler ile temsil edilebilen verilerde makine öğrenmesi uygulayabilmek için çizge teorisi ve evrişim teoremlerini temel alarak türetilmiştir. Genel olarak bir düğüm, ilgili düğümün öznelikleri ve komşularının öznelikleri birleştirilerek temsil edilmektedir [39]. GCN algoritması

Kipf vd. [40] tarafından önerilmiş ve tek katmanlı çalışma prensibi aşağıda Eş. 1 ile ifade edilmektedir.

$$Z = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} X W \right) = \sigma (\tilde{A} X W) \quad (1)$$

$$\tilde{A} = A + I \quad (2)$$

Eş. 2'de verilmekte olan \tilde{A} ifadesi kendisine döngülü komşuluk matrisidir. \tilde{A} komşuluk matrisinin derecesi \tilde{D}_{ii} , Eş. 3 ile ifade edilmektedir.

$$\tilde{D}_{ii} = \sum_j \tilde{A}_{ij} \quad (3)$$

Eş. 1'deki σ ifadesi aktivasyon fonksiyonunu temsil etmektedir. Bu çalışmada aktivasyon fonksiyonu olarak tanh ve Softmax fonksiyonları kullanılmıştır. W ifadesi ise eğitilebilir ağırlık matrisidir. X , çizge yapısını oluşturan düğümlerin ve kenarların giriş özelliklerini göstermektedir. Z , tüm düğümlerin birinci dereceden komşuluk bilgisi içerdiği GCN katmanının çıktısıdır. GCN algoritmasında k adet katman kullanılırsa, Z çıktısı k -derece komşuluk (mekânsal) bilgisini içermektedir. Bu nedenle, GCN' nin gizli katman verileri, model eğitimi için daha fazla ön bilgi sağlayabilir, böylece eğitilmiş gizli katman nöronları daha derin bir öznitelik ifade etme yeteneğine sahip olmaktadır [41].

2.2. Diğer çizge temelli makine öğrenmesi algoritmaları (Other graph-based machine learning algorithms)

Çizge temelli makine öğrenmesi uygulamaları için RGCN, GAT (Graph Attention Networks), SGC (Simplifying Graph Convolutional Networks), PPNP (Personalised Propagation of Neural Predictions), APPNP (Approximate PPNP), GraphSAGE, Cluster-GCN, HinSAGE algoritmaları da kullanılmaktadır. Bu çalışmada GCN modeli ile arıza tespiti tahminlenmesi yapıldıktan sonra, GCN modelinin başarımı RGCN, GraphSAGE ve HinSAGE isimli diğer algoritmalar ile de karşılaştırılmıştır.

2.2.1. RGCN

Relational Graph Convolutional Networks (RGCN), ilişkisel veri yapılarını işlemek için tasarlanmış bir derin öğrenme modelidir. RGCN modeli, GCN modeli temel alınarak genişletilmiştir [47]. RGCN, özellikle ilişkisel veri tabanlarında veya sosyal ağlarda bulunan karmaşık ilişkisel yapıları modellemek için kullanılır. Bu yapılar, birbirleriyle ilişkili varlıklar arasındaki çeşitli ilişkileri temsil eder.

2.2.2. GraphSAGE

GraphSAGE (Graph Sample and Aggregation), çizge temelli öğrenimde kullanılan bir derin öğrenme yöntemidir. Genellikle

düğümlerin özelliklerini, çizge yapısını dikkate alarak öğrenmek ve görevler için temsil oluşturmak amacıyla kullanılmaktadır [48].

2.2.3. HinSAGE

HinSAGE, her düğüm türü için ayrı düğüm gömme (embedding) işlemleri gerçekleştirir ve bunları komşuluk bilgisi ile birleştirerek yeni düğüm gömüleri oluşturmaktadır. Bu yaklaşım, heterojen ağlarda daha iyi performans ve daha derin özellik öğrenme yeteneği sağlamaktadır.


HinSAGE 'nin, özellikle kenar özniteliklerine bağlı olarak sonuç tahminleri için daha verimlidir [49].

2.3. SVM modeli (Support Vector Machine model)

SVM modelinin temel amacı, veri noktalarını sınıflar arasında bir karar sınırı ile bölmektir. Bu karar sınırı, veri noktalarını iki sınıfa ayıran bir düzlem veya hiperdüzlem olabilmektedir. Yaygın olarak kullanılan çekirdek fonksiyonları arasında doğrusal çekirdek ve radial çekirdek fonksiyonları bulunmaktadır [50]. SVM yöntemi, uygun bir çekirdek işlevi ile karmaşık sorunları çözebilme, yerel optimumlara takılmama, yüksek boyutlu verilerle çalışabilme ve ezberleme sorununun az olması gibi avantajlara sahiptir. Bu avantajlar, SVM yöntemini geniş bir uygulama alanında çekici kılmaktadır [51]. Bu çalışmada SVM modeli için kernel olarak linear kullanılmıştır. Test/eğitim oranı 0,30 olarak rastgele seçilmiştir. SVM modeli, çizge temelli makine öğrenmesi yöntemlerinin etkinliğini ölçmek ve GCN modelinin klasik makine öğrenmesi modeli ile karşılaştırmak için kullanılmıştır. SVM modeli için doğruluk oranı %82.4 olarak tespit edilmiştir.

3. Veri Seti (Data Set)

Makine öğrenmesi algoritmalarının çalışması için ihtiyaç duyulan veri setlerinin oluşturulabilmesi için bir deney düzeneği tasarlanmış ve olası arıza durumlarını temsil etmesi için beş adet senaryo oluşturulmuştur. Oluşturulan senaryolar üzerinden basınç ve debi değişkenleri



Şekil 1. Boru hatlarında basınç ve debi ölçüm deney seti (Pressure and flow measurement test set in pipelines)

sensörler ve debimetre aracılığıyla zamana bağlı olarak ölçülmüştür. Verilerin toplanması yukarıda Şekil 1’de gösterilen deney seti ile gerçekleştirilmiştir.

Çizge temelli makine öğrenmesi algoritmalarının çalışabilmesi için elde edilen verilerin düğümler ve düğümleri birleştiren kenarlar ile ifade edilebilmesi gerekmektedir. Deney setinde bulunan basınç sensörleri, düğümleri ve bu sensörler arasındaki boru bağlantıları ise kenarları temsil etmektedir. Deney setinde 8 adet basınç sensörü kullanılmıştır. Veri setinde kullanılan değişkenlerin (debi ve basınç) ölçüm aralıkları farklı olduğu için Python programlama dili ve Sklearn, StandardScaler kütüphaneleri kullanılarak veri setinde standardizasyon işlemi gerçekleştirilmiştir. Yapay zekâ modelleri 0 ile 1 arasındaki değerlerde daha verimli çalıştığı için MinMaxScaler Kütüphanesi kullanılarak veri seti normalize edilmiştir. Makine öğrenmesi problemlerinde eğitim ve test verilerinin ayrılması noktasında, rastgele bölme, zaman tabanlı bölme, konum tabanlı bölme, grup tabanlı bölme gibi yöntemler kullanılmaktadır. Bu çalışmada eğitim/test veri bölünmesi aşamasında rastgele bölme yöntemi kullanılmıştır. Verilerin yaklaşık %30’u test için %70’i eğitim için ayrılarak kullanılmıştır. Literatürde, boru hatlarında sızıntı tahmini için basınç izleme verilerinden oluşturulan veri setleri üzerinde GCN (Graph Convolutional Network) modelinin kullanıldığı araştırmalar bulunmaktadır [43].

Tablo 2. Kenar listesi (List of Edge)

Kaynak	Hedef	Sistemin Durumu
s1n_A0_1	s1n_A3_1	Sızıntı-1 Normal
s2n_A0_1	s2n_A4_1	Sızıntı-2 Normal
t1n_A0_1	t1n_A3_1	Tıkanma-1 Normal
t2a_A9_9	t2a_A7_9	Tıkanma-2 Aksiyon

Tablo 2’de sistemin durumu, kaynak ve hedef olmak üzere üç sütun vardır. Sızıntı-1 Normal, Sızıntı-1 Aksiyon, Sızıntı-2 Normal, Sızıntı-2 Aksiyon, Sızıntı-3 Normal, Sızıntı-3 Aksiyon, Tıkanma-1 Normal, Tıkanma-1 Aksiyon, Tıkanma-2 Normal, Tıkanma-2 Aksiyon durumlarını ifade eden toplam 1656 satır bilgisi bulunmaktadır. Burada “Normal” ifadesi; sızıntı veya tıkanma yani arıza olmadığını aksiyon ifadesi ise arıza durumunu göstermektedir.

Tablo 3. Düğüm listesi (List of Nodes)

Düğüm	Özn-1	Özn-846	Sistemin Durumu
s1n_A0_1	1	0	Sızıntı-1 Normal
s1n_A2_1	0	0	Sızıntı-1 Normal
s1a_A2_1	0	0	Sızıntı-1 Aksiyon

Tablo 3’de düğümleri gösteren 720 satır bulunmaktadır. Düğüm listesinde her bir düğümün basınç ve debi gibi özniteliklerini (Özn) ifade eden 846 sütun bulunmaktadır. Düğüm adları şu şekilde kodlanmıştır: Sızıntı-1 durumu için (s1), Sızıntı-2 durumu için (s2), Sızıntı-3 durumu için (s3), Tıkanma-1 durumu için (t1), Tıkanma-2 durumu için (t2), normal koşullar için (n), aksiyon durumları (sızıntı veya tıkanma olma durumu) için (a) ve sıfırıncı düğüm için (A0_time) kullanılmıştır. Sızıntı-1 senaryosunda 1. saniyedeki Normal duruma ait olan A0 sensörünün düğümü s1n_A0_1 olarak ifade edilmiştir.

3.1. Senaryolar (Scenarios)

Boru hatlarında sızıntı ve tıkanma arıza durumlarını temsil etmesi için üç adet sızıntı ve iki adet tıkanma olmak üzere beş adet senaryo oluşturulmuştur. Senaryolar üzerinden veri toplama sürecinde deney setinde sıvı akışkan olarak su kullanılmıştır. Senaryolar oluşturulurken farklı durumları temsil etmesi için belirli senaryolarda

deney setindeki farklı hatlar ve farklı çaplardaki borular kullanılmıştır. Bu bölümde her bir senaryo deney setini temsil eden bir diyagram üzerinde gösterilmektedir.

3.1.1. Tıkanma-1 senaryosu (Scenario of blockage-1)

Şekil 2’de tıkanma-1 senaryosu için oluşturulan çizge ve tıkanma noktası verilmektedir. Çizgenin düğümleri, deney setindeki basınç ölçüm noktalarını göstermektedir. Sekiz adet noktada basınç ölçümü yapılmıştır. Tıkanma-1 senaryosunda Şekil 2’de yer alan deney seti üzerinde 5 hat kullanılmış ve bu hatlar yeşil renk ile gösterilmiştir.

3.1.2. Tıkanma-2 senaryosu (Scenario of blockage-2)

Şekil 3’de tıkanma-2 senaryosu için oluşturulan çizge ve tıkanma noktası verilmektedir. Çizgenin düğümleri, deney setindeki basınç ölçüm noktalarını göstermektedir. Sekiz adet noktada basınç ölçümü yapılmıştır. Tıkanma-2 senaryosunda Şekil 3’de yer alan deney seti üzerinde yeşil renk ile verilmekte olan 3 hat kullanılmıştır.

3.1.3. Sızıntı-1 senaryosu (Scenario of leakage-1)

Şekil 4’de sızıntı-1 senaryosu için oluşturulan çizge ve sızıntı noktası verilmektedir. Çizgenin düğümleri, deney setindeki basınç ölçüm noktalarını göstermektedir. Sekiz adet noktada basınç ölçümü yapılmıştır. Sızıntı-1 senaryosunda Şekil 4’de yer alan deney seti üzerinde yeşil renk ile verilmekte olan 3 hat kullanılmıştır.

3.2. Sızıntı-2 Senaryosu (Scenario of Leakage-2)

Şekil 5’de sızıntı-2 senaryosu için oluşturulan çizge ve sızıntı noktası verilmektedir. Çizgenin düğümleri, deney setindeki basınç ölçüm noktalarını göstermektedir. Sekiz adet noktada basınç ölçümü yapılmıştır. Sızıntı-2 senaryosunda Şekil 5’de yer alan deney seti üzerinde yeşil renk ile verilmekte olan 3 hat kullanılmıştır. Sızıntı-2 senaryosunda farklı iletim hattında olmak üzere iki farklı noktada sızıntı durumu bulunmaktadır.

3.3. Sızıntı-3 Senaryosu (Scenario of Leakage-3)

Şekil 6’da sızıntı-3 senaryosu için oluşturulan çizge ve sızıntı noktası verilmektedir. Çizgenin düğümleri, deney setindeki basınç ölçüm noktalarını göstermektedir. Sekiz adet noktada basınç ölçümü yapılmıştır. Sızıntı-3 senaryosunda Şekil 6’da yer alan deney seti üzerinde yeşil renk ile verilmekte olan 4 hat kullanılmıştır. Sızıntı-3 senaryosunda iletim hatlarında 1mm ve 3mm olmak üzere iki farklı çapta boru kullanılmıştır.

4. Bulgular (Results)


4.1. GCN algoritmasının sonuçları (Results of the GCN algorithm)

GCN algoritmasının performansına ilişkin parametreler; doğruluk puanı 0,9125, kayıp değeri 0,4493 ve f₁ puanı 0,91 olarak tespit edilmiştir. GCN algoritmasının senaryolara göre sınıflandırılmasının özeti Tablo 4’de yer almaktadır.


GCN algoritmasının; doğruluk, kayıp değerlerinin grafiği Şekil 7a’da, senaryolara göre tahmin değerlerinin sınıflandırılması Şekil 7b’de, gerçek ve tahmin değerlerin karşılaştırıldığı karşıtlık matrisi ise Şekil 7c’de gösterilmektedir.

4.1.1. RGCN algoritmasının sonuçları (Results of the RGCN algorithm)


RGCN algoritmasının performansına ilişkin parametreler; doğruluk puanı 0,8875, kayıp değeri 0,3554 ve f₁ puanı 0,8865 olarak tespit edilmiştir. RGCN algoritmasının senaryolara göre sınıflandırılmasının özeti Tablo 5’te yer almaktadır.




Şekil 2. Tıkanma-1 senaryosu temsili (Blockage-1 scenario representation)




Şekil 3. Tıkanma-2 Senaryosu temsili (Scenario-2: blockage representation)



Şekil 4. Sızıntı-1 senaryosu temsili (Leak-1 scenario representation)



Şekil 5. Sızıntı-2 Senaryosu temsili (Scenario-2: leakage representation)



Şekil 6. Sızıntı-3 Senaryosu temsili (Scenario-3: leakage representation)

Tablo 4. GCN algoritmasının senaryolara göre sınıflandırma özeti (Classification summary of the GCN algorithm by scenario)

Sistemin Durumu	Kesinlik	Duyarlılık	f1-Skoru	Örneklem
Sızıntı-1 Normal	1,00	0,89	0,94	72
Sızıntı-1 Aksiyon	0,90	1,00	0,95	72
Sızıntı-2 Normal	0,99	1,00	0,99	72
Sızıntı-2 Aksiyon	1,00	1,00	1,00	72
Sızıntı-3 Normal	0,89	0,89	0,89	72
Sızıntı-3 Aksiyon	0,89	0,88	0,88	72
Tıkanma-1 Normal	0,89	0,89	0,89	72
Tıkanma-1 Aksiyon	1,00	0,89	0,94	72
Tıkanma-2 Normal	0,86	0,69	0,77	72
Tıkanma-2 Aksiyon	0,77	1,00	0,87	72
Doğruluk			0,91	720
Makro Ortalama	0,92	0,91	0,91	720
Ağırlıklı Ortalama	0,92	0,91	0,91	720

RGCN algoritmasının; doğruluk, kayıp değerlerinin grafiği Şekil 8a'da, senaryolara göre tahmin değerlerinin sınıflandırılması Şekil 8b'de, gerçek ve tahmin değerlerin karşılaştırıldığı karşıtlık matrisi ise Şekil 8c'de yer almaktadır.

4.2. GraphSAGE algoritmasının sonuçları (Results of the GraphSAGE algorithm)

GraphSAGE algoritmasının performansına ilişkin parametreler; doğruluk puanı 0,9041, kayıp değeri 0,5275 ve f1 puanı 0,9043 olarak tespit edilmiştir. GraphSAGE algoritmasının senaryolara göre sınıflandırılmasının özeti ise Tablo 6'da yer almaktadır.


GraphSAGE algoritmasının; doğruluk, kayıp değerlerinin grafiği Şekil 9a'da, senaryolara göre tahmin değerlerinin sınıflandırılması

Şekil 9b'de, gerçek ve tahmin değerlerin karşılaştırıldığı karşıtlık matrisi ise Şekil 9c'de yer almaktadır.

4.3. HinSAGE algoritmasının sonuçları (Results of the HinSAGE algorithm)

HinSAGE algoritmasının performansına ilişkin parametreler; doğruluk puanı 0,865, kayıp değeri 1,2535 ve f1 puanı 0,865 olarak tespit edilmiştir. HinSAGE algoritmasının senaryolara göre sınıflandırılmasının özeti ise Tablo 7'de yer almaktadır.


HinSAGE algoritmasının; doğruluk, kayıp değerlerinin grafiği Şekil 10a'da, senaryolara göre tahmin değerlerinin sınıflandırılması Şekil 10b'de, gerçek ve tahmin değerlerin karşılaştırıldığı karşıtlık matrisi ise Şekil 10c'de yer almaktadır.



Şekil 7. (a) Doğruluk ve kayıp grafiği (b) GCN ile senaryoların sınıflandırılması (c) Karşıtlık matrisi
(a) Accuracy and loss plot (b) Classification of scenarios with GCN (c) Contrast matrix

Tablo 5. RGCN algoritmasının senaryolara göre sınıflandırma özeti (Classification summary of the RGCN algorithm by scenario)


Sistemin Durumu	Kesinlik	Duyarlılık	f1-Skoru	Örneklem
Sızıntı-1 Normal	0,90	0,89	0,90	72
Sızıntı-1 Aksiyon	0,86	0,90	0,88	72
Sızıntı-2 Normal	0,86	0,67	0,75	72
Sızıntı-2 Aksiyon	0,75	0,89	0,82	72
Sızıntı-3 Normal	0,90	0,97	0,93	72
Sızıntı-3 Aksiyon	0,97	0,89	0,93	72
Tıkanma-1 Normal	1,00	1,00	1,00	72
Tıkanma-1 Aksiyon	1,00	1,00	1,00	72
Tıkanma-2 Normal	0,88	0,78	0,82	72
Tıkanma-2 Aksiyon	0,80	0,89	0,84	72
Doğruluk			0,89	720
Makro Ortalama	0,89	0,89	0,89	720
Ağırlıklı Ortalama	0,89	0,89	0,89	720



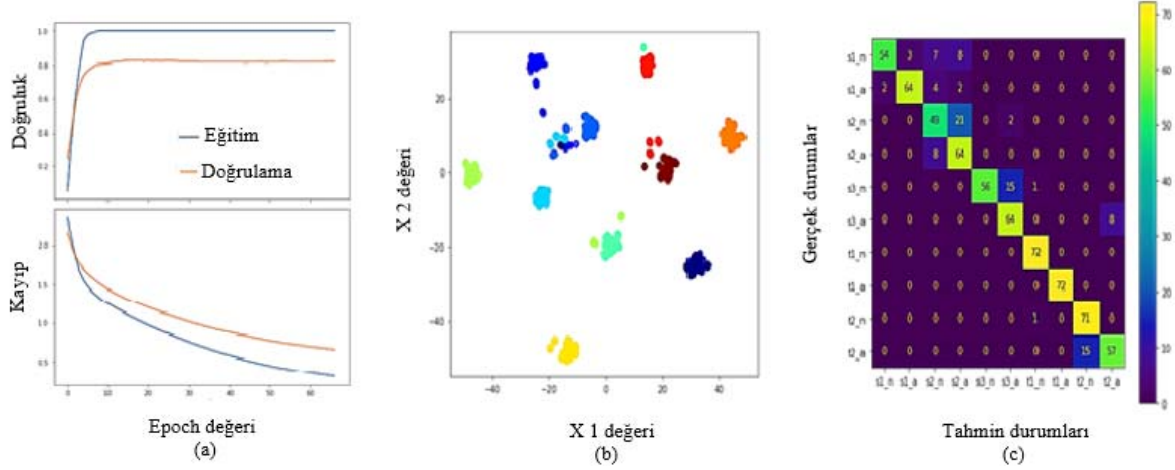
Şekil 8. (a) Doğruluk ve kayıp grafiği (b) RGCN ile senaryoların sınıflandırılması (c) Karşıtlık matrisi
(a) Accuracy and loss plot (b) Classification of scenarios with RGCN (c) Contrast matrix

Tablo 6. GraphSAGE algoritmasının senaryolara göre sınıflandırma özeti
(Classification summary of the GraphSAGE algorithm by scenario)

Sistemin Durumu	Kesinlik	Duyarlılık	f1-Skoru	Örneklem
Sızıntı-1 Normal	0,84	0,67	0,74	72
Sızıntı-1 Aksiyon	0,71	1,00	0,83	72
Sızıntı-2 Normal	1,00	0,93	0,96	72
Sızıntı-2 Aksiyon	1,00	0,89	0,94	72
Sızıntı-3 Normal	0,88	0,89	0,88	72
Sızıntı-3 Aksiyon	0,93	0,89	0,91	72
Tıkanma-1 Normal	1,00	0,89	0,94	72
Tıkanma-1 Aksiyon	0,89	1,00	0,94	72
Tıkanma-2 Normal	1,00	0,89	0,94	72
Tıkanma-2 Aksiyon	0,90	1,00	0,95	72
Doğruluk			0,90	720
Makro Ortalama	0,91	0,90	0,90	720
Ağırlıklı Ortalama	0,91	0,90	0,90	720

**Şekil 9.** (a) Doğruluk ve kayıp grafiği (b) GraphSAGE ile senaryoların sınıflandırılması (c) Karşıtlık matrisi
(a)Accuracy and loss plot (b) Classification of scenarios with GraphSAGE (c) Contrast matrix**Tablo 7.** HinSAGE 'nin senaryolara göre sınıflandırma özeti (Classification summary of the HinSAGE algorithm by scenario)

Sistemin Durumu	Kesinlik	Duyarlılık	f1-Skoru	Örneklem
Sızıntı-1 Normal	0,96	0,89	0,92	72
Sızıntı-1 Aksiyon	0,96	0,75	0,84	72
Sızıntı-2 Normal	0,67	0,89	0,77	72
Sızıntı-2 Aksiyon	0,72	0,68	0,70	72
Sızıntı-3 Normal	0,79	0,89	0,84	72
Sızıntı-3 Aksiyon	1,00	0,78	0,88	72
Tıkanma-1 Normal	1,00	1,00	1,00	72
Tıkanma-1 Aksiyon	0,97	1,00	0,99	72
Tıkanma-2 Normal	0,88	0,79	0,83	72
Tıkanma-2 Aksiyon	0,83	0,99	0,90	72
Doğruluk			0,87	720
Makro Ortalama	0,88	0,87	0,87	720
Ağırlıklı Ortalama	0,88	0,87	0,87	720



Şekil 10. (a) Doğruluk ve kayıp grafiği (b) HinSAGE ile senaryoların sınıflandırılması (c) Karşıtlık matrisi
(a)Accuracy and loss plot (b) Classification of scenarios with HinSAGE (c) Contrast matrix

5. Sonuçlar (Conclusions)

Günümüzde veri odaklı endüstriyel sistemlerin teknolojik gelişimi, potansiyel arızaların tespit edilmesini önemli hale getirmiştir [52]. Bu çalışmada boru hatlarındaki arızaların tespiti için Çizge temelli makine öğrenmesi algoritmaları kullanılmıştır. Çizge temelli algoritmaların performansı, SVM modeli ile karşılaştırılmıştır. Çizge temelli makine öğrenmesi algoritmalarının performansları ile ilgili parametrelerin özeti Tablo 8'de yer almaktadır.

Tablo 8. Algoritmaların performans parametreleri
(Parameters of algorithms performance)

Algoritmalar	Doğruluk	Kayıp	f1 Skoru
GCN	0,91	0,45	0,91
GraphSAGE	0,90	0,53	0,90
HinSAGE	0,87	1,25	0,87
RGCN	0,89	0,36	0,89

Bu çalışmada algoritmaların performans değerlerinin birbirine yakın olmasına rağmen GCN modelinin performansı diğer algoritmalara göre daha yüksek tespit edilmiştir. Literatür incelendiğinde makine öğrenmesi algoritmaları kullanılarak boru hatlarında arıza tespiti için doğruluk oranları %78,51 ile %99 değerleri arasında tespit edilmiştir. Bu çalışmada oluşturulan veri setine uygulanan GCN, GraphSAGE, HinSAGE ve RGCN algoritmalarının performansları literatür ile karşılaştırıldığında sonuçların literatür ile paralel olduğu görülmektedir [42]. Çalışma kapsamında su akışkanına sahip boru hatlarında sızıntı ve tıkanma koşullarının arıza tahmini yapılmıştır. Bu çalışmada çizge temelli makine öğrenmesi modellerinin doğruluk oranları 0,87 ile 0,91 arasında tespit edilmiştir. Çizge temelli modellerin etkinliğinin ortaya konulabilmesi için sonuçlar çizge tabanlı olmayan klasik makine öğrenmesi modeli SVM ile karşılaştırılmıştır. SVM modelinin doğruluk oranı 0,82 olarak tespit edilmiştir. Literatürde GCN ve SVM modellerinin birlikte kullanıldığı çalışmalar mevcuttur. Fakat GCN modeli daha çok ağ topolojisinin özelliklerinin çıkarılmasında, SVM modeli ise sınıflandırma yapmakta kullanılmıştır [53]. Elde edilen sonuçlar, ağ yapısına sahip karmaşık gerçek dünya problemlerini (sosyal ağlar, moleküler yapılar) çizge olarak temsil etmenin ve bu şekilde kenar ilişkilerini kullanmanın önemli bir fark yaratabileceğini göstermektedir. Bu çalışma, boru hatlarında çizge temelli makine öğrenmesi yöntemi (GCN) ile arıza (sızıntı ve tıkanma) tespit sistemlerinin geliştirilmesine yönelik önemli bir katkı sunmaktadır. Yapılan araştırmalar ve elde edilen sonuçlar, çizge tabanlı yapay zekâ

algoritmalarının boru hattı arızalarını tespit etme sürecinde etkili bir şekilde kullanılabileceğini göstermektedir. Bu teknolojinin kullanımı, boru hatlarının güvenliğini artırmak, arızaların erken tespiti ve önlenmesi için önemli bir fırsat sunmaktadır. Yapay zekâ tabanlı arıza tespit sistemlerinin boru hatlarında kullanımını, geleneksel yöntemlere göre daha hızlı ve hassas sonuçlar elde etmemizi sağlayacaktır. Ayrıca, bu sistemlerin operasyonel maliyetleri azaltması ve bakım süreçlerini optimize etmesi beklenmektedir. Çalışmadan edinilen deneyimin ileriki çalışmalarda diğer çizge temelli makine öğrenmesi algoritmaları GAT, SGC, PPNP, APPNP ve Cluster-GCN ile tekrarlanması ve gaz halindeki akışkana sahip boru hatlarındaki arızaların tahmini için uygulanması hedeflenmektedir.

Teşekkür (Acknowledgement)

Bu çalışma, doktora tez çalışması kapsamında Marmara Üniversitesi tarafından FDK-2023-10459 numaralı bilimsel araştırma projesi ile desteklenmiştir. Çalışmanın deneysel aşamalarında Marmara Üniversitesi, Teknoloji Fakültesi Mekatronik Mühendisliği Arıza Teşhis Laboratuvarında bulunan deney seti kullanılmıştır. Yazarlar bu imkânları sağlayan Marmara Üniversitesine teşekkürü bir borç bilir.

Kaynaklar (References)

1. Yang, L., et al., Detection of pipeline blockage using lab experiment and computational fluid dynamic simulation, *Journal of Petroleum Science and Engineering* 183, 106421, 2019.
2. Wang, W., et al., Experimental study on water pipeline leak using In Pipe acoustic signal analysis and artificial neural network prediction, *Measurement* 186, 110094, 2021.
3. Anfinsen, H., & Aamo, O. M., Leak detection, size estimation and localization in branched pipe flows, *Automatica* 140, 110213, 2022.
4. Shivananju, B. N., et al., Real time monitoring of petroleum leakage detection using etched fiber Bragg grating, *International Conference on Optics in Precision Engineering and Nanotechnology (icOPEN2013)* 8769, SPIE, 2013.
5. Meng, S., Li, Y., & Wang, X., A Simulation Study on the Dynamic Stability of a Fluid Conveying Pipe With a Constant Velocity Leakage, *Journal of Pressure Vessel Technology* 139 (4), 2017.
6. Zeng, W., et al., Linear phase detector for detecting multiple leaks in water pipes, *Applied Acoustics* 202, 109152, 2023.
7. Datta, S., & Sarkar, S., A review on different pipeline fault detection methods, *Journal of Loss Prevention in the Process Industries* 41, 97-106, 2016.
8. Liang, L., et al., Pipeline leakage test based on FBG pressure sensor, *IOP Conference Series: Earth and Environmental Science* 170 (2), 2018.

9. Sheltami, T. R., Bala, A., & Shakshuki, E. M., Wireless sensor networks for leak detection in pipelines: a survey, *Journal of Ambient Intelligence and Humanized Computing* 7 (3), 347-356, 2016.
10. Yu, D., et al., Projective Noise Reduction Algorithm for Negative Pressure Wave Signal Processing, *International Pipeline Conference* 48579, 2008.
11. Bai, L., Yue, Q., & Li, H., Sub-sea Pipelines Leak Detection and Location Based on Fluid Transient and FDI, *The Fourteenth International Offshore and Polar Engineering Conference One Petro*, 2004.
12. Ling, K., et al., A new method for leak detection in gas pipelines, *Oil and Gas Facilities* 4.02, 97-106, 2015.
13. Reddy, R. S., et al., Pressure and flow variation in gas distribution pipeline for leak detection, 2016 IEEE International Conference on Industrial Technology (ICIT), IEEE, 2016.
14. Korlapati, N. V. S., et al., Review and analysis of pipeline leak detection methods, *Journal of Pipeline Science and Engineering* 100074, 2022.
15. Goni, M. O. F., et al., Fast and Accurate Fault Detection and Classification in Transmission Lines using Extreme Learning Machine, *e-Prime Advances in Electrical Engineering, Electronics and Energy* 100107, 2023.
16. Mandal, S. K., Chan, F. T., & Tiwari, M. K., Leak detection of pipeline: An integrated approach of rough set theory and artificial bee colony trained SVM, *Expert Systems with Applications* 39 (3), 3071-3080, 2012.
17. Ayati, A. H., Haghghi, A., & Ghafouri, H. R., Machine Learning-Assisted Model for Leak Detection in Water Distribution Networks Using Hydraulic Transient Flows, *Journal of Water Resources Planning and Management* 148 (2), 04021104, 2022.
18. Eastvedt, D., Naterer, G., & Duan, X., Detection of faults in subsea pipelines by flow monitoring with regression supervised machine learning, *Process Safety and Environmental Protection* 161, 409-420, 2022.
19. Ahn, B., Kim, J., & Choi, B., Artificial intelligence-based machine learning considering flow and temperature of the pipeline for leak early detection using acoustic emission, *Engineering Fracture Mechanics* 210, 381-392, 2019.
20. Garðarsson, G. Ö., Boem, F., & Toni, L., Graph-based learning for leak detection and localization in water distribution networks, *IFAC Papers Online* 55 (6), 661-666, 2022.
21. Candelieri, A., Conti, D., & Archetti, F., A graph based analysis of leak localization in urban water networks, *Procedia Engineering* 70, 228-237, 2014.
22. Romero, L., et al., First results in leak localization in water distribution networks using graph-based clustering and deep learning, *IFAC Papers Online* 53 (2), 16691-16696, 2020.
23. Kang, J., et al., Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems, *IEEE Transactions on Industrial Electronics* 65 (5), 4279-4289, 2017.
24. Zhang, X., et al., Towards deep probabilistic graph neural network for natural gas leak detection and localization without labeled anomaly data, *Expert Systems with Applications* 231, 120542, 2023.
25. Miao, X., Zhao, H., & Xiang, Z., Leakage detection in natural gas pipeline based on unsupervised learning and stress perception, *Process Safety and Environmental Protection* 170, 76-88, 2023.
26. Rashid, S., Akram, U., Khan, S. A., WML: Wireless sensor network based machine learning for leakage detection and size estimation, *Procedia Computer Science* 63, 171-176, 2015.
27. Xu, T., et al., Pipeline leak detection based on variational mode decomposition and support vector machine using an interior spherical detector, *Process Safety and Environmental Protection* 153, 167-177, 2021.
28. De Kerf, T., et al., Oil spill detection using machine learning and infrared images, *Remote Sensing* 12 (24), 4090, 2020.
29. Zheng, J., et al., Deeppipe: A deep-learning method for anomaly detection of multi-product pipelines, *Energy* 259, 125025, 2022.
30. Baronti, L., et al., Neural network identification of water pipe blockage from smart embedded passive acoustic measurements, *The Canadian Journal of Chemical Engineering* 100 (3), 521-539, 2022.
31. Bohorquez, J., et al., Leak detection and topology identification in pipelines using fluid transients and artificial neural Networks, *Journal of Water Resources Planning and Management* 146 (6), 04020040, 2020.
32. Wang, B., et al., Prediction model of natural gas pipeline crack evolution based on optimized DCNN-LSTM, *Mechanical Systems and Signal Processing* 181, 109557, 2022.
33. Asghari, V., et al., Machine learning modeling for spectral transient based leak detection, *Automation in Construction* 146, 104686, 2023.
34. Xiao, R., & Li, J., Evaluation of acoustic techniques for leak detection in a complex low pressure gas pipeline network, *Engineering Failure Analysis* 143, 106897, 2023.
35. Banjar, N. K., Sasmal, S., & Voggu, S., Machine learning supported acoustic emission technique for leakage detection in pipelines, *International Journal of Pressure Vessels and Piping* 188, 104243, 2020.
36. Yu, X., & Tian, X., A fault detection algorithm for pipeline insulation layer based on immune neural network, *International Journal of Pressure Vessels and Piping* 196, 104611, 2022.
37. Li, Q., et al., A novel oil pipeline leakage detection method based on the sparrow search algorithm and CNN, *Measurement* 204, 112122, 2022.
38. Liao, Z., et al., A temporal and spatial prediction method for urban pipeline network based on deep learning, *Physical A: Statistical Mechanics and its Applications* 608, 128299, 2022.
39. Edwards, M., & Xie, X., Graph based convolutional neural network, *arXiv preprint arXiv: 1609.08965*, 2016.
40. Shafqat, W., & Byun, Y. C., Incorporating similarity measures to optimize graph Convolutional neural network for product recommendation, *Applied Sciences* 11 (4), 1366, 2021.
41. Zhang, Y. J., & Hu, L. S., Fault Propagation Inference Based on a Graph Neural Network for Steam Turbine Systems, *Energies* 14, 309, 2021.
42. Şahin, E & Yüce, H. "Prediction of Water Leakage in Pipeline Networks Using Graph Convolutional Network Method, *Applied Sciences*, 13, 1-16, 2023.
43. Peng, H., et al., Lingcn: Structural linearized graph convolutional network for homomorphically encrypted inference, *Advances in Neural Information Processing Systems* 36, 2024.
44. Wu, Z., et al., A comprehensive survey on graph neural networks, *IEEE Transactions on Neural Networks and Learning Systems* 32 (1), 4-24, 2020.
45. Kipf, T. N., & Welling, M., Semi-supervised classification with graph convolutional networks, *arXiv preprint arXiv: 1609.02907*, 2016.
46. Tong, H., et al., Detection and classification of transmission line transient faults based on graph convolutional neural Network, *CSEE Journal of Power and Energy Systems* 7 (3), 456-471, 2021.
47. Schlichtkrull, M., et al., Modeling relational data with graph convolutional networks, In *the Semantic Web: 15th International Conference, ESWC 2018, Heraklion, Crete, Greece, June 3-7, 2018, Proceedings* 15. Springer International Publishing, 2018.
48. Hamilton, W., Ying, Z., & Leskovec, J., Inductive representation learning on large graphs. *Advances in Neural Information Processing Systems* 30, 2017.
49. Cho, H. N., et al., Heterogeneous graph construction and HinSAGE learning from electronic medical records, *Scientific Reports* 12 (2), 1152, 2022.
50. Li, Q., et al., Predicting wheat gluten concentrations in potato starch using GPR and SVM models built by terahertz time-domain spectroscopy, *Food Chemistry* 432, 137235, 2024.
51. Aymaz, S., A novel hybrid approach to multi focus image fusion using CNN and SVM methods, *Gazi University Journal of the Faculty of Engineering and Architecture*, 39 (2), 1123-1136, 2023
52. Hatipoğlu, A., Güneri, Y., Yılmaz, E., A comparative predictive maintenance application based on machine and deep learning, *Gazi University Journal of the Faculty of Engineering and Architecture*, 39 (2), 1037-1048, 2024
53. Chen, J., et al., Prediction of ovarian cancer related metabolites based on graph neural network, *Frontiers in Cell and Developmental Biology* 9, 753221, 2021.