

Derleme Makalesi

ÇİZGE SİNİR AĞLARI: GÖREVLER, BİLGİ GÜVENLİĞİ, SİBER GÜVENLİK VE ADLİ BİLİŞİM

Hamza Talha GÜMÜŞ[†], Can EYÜPOĞLU^{††}

[†] Milli Savunma Üniversitesi, Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul, Türkiye

^{††} Milli Savunma Üniversitesi, Hava Harp Okulu, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

hamzatalhagumus@gmail.com, caneyupoglu@gmail.com



0000-0001-7360-8138, 0000-0002-6133-8617

Atıf/Citation : Gümüş H. T., Eyüpoğlu C. , ÇİZGE SİNİR AĞLARI: GÖREVLER, BİLGİ GÜVENLİĞİ, SİBER GÜVENLİK VE ADLİ BİLİŞİM, İstanbul Ticaret Üniversitesi Teknoloji ve Uygulamalı Bilimler Dergisi, Vol (8) No 1 sayfa 59-101 DOI: 10.56809/icujtas.1562430

ÖZET

Çizge Sinir Ağları (Graph Neural Networks-GNNs), Yapay Sinir Ağları (Artificial Neural Networks-ANNs) ailesine mensup ve çizgeler üzerinden bilgi çıkarımı işlemi gerçekleştiren derin öğrenme yöntemleridir. Bilgi güvenliği teknikleri ise sistem ve insan olarak adlandırabileceğimiz varlığın, tehdit ve tehlike oluşturmaya karşı bilginin gizliliği, bütünlüğü ve erişimine yönelik korumayı amaçlamaktadır. Siber güvenlik açısından ise, GNN'ler kritik altyapılara yönelik saldırıları tespit etmek ve önlemek için kullanılır. GNN'lerin kullanımı kritik altyapıların ve sistemlerin saldırganların ilgi odağı haline gelmesi ve maddi-manevi kayıp kazancı nedeniyle önem kazanmaktadır. Bu çalışmada GNN'lerin görevleri ve temel kullanım alanları ile birlikte bilgi güvenliği, siber güvenlik ve adli bilişim konularına yönelik gelişmeleri açıklanmaktadır.

Anahtar Kelimeler: Çizge Sinir Ağları, Yapay Sinir Ağları, Bilgi Güvenliği, Siber Güvenlik, Adli Bilişim

GRAPH NEURAL NETWORKS: TASKS, INFORMATION SECURITY, CYBER SECURITY, AND DIGITAL FORENSICS

ABSTRACT

Graph Neural Networks (GNNs) are deep learning methods that belong to the Artificial Neural Networks (ANNs) family and perform information extraction over graphs. Information security techniques aim to protect the privacy, integrity, and access of information against threats and dangers posed by systems and human beings. In terms of cyber security, GNNs are used to detect and prevent attacks on critical infrastructures. The use of GNNs gains importance due to the fact that critical infrastructures and systems become the center of attention of attackers and gain material and moral losses. In this study, the tasks and main usage areas of GNNs and their developments in information security, cyber security, and digital forensics are explained.

Keywords: Graph Neural Networks, Artificial Neural Networks, Information Security, Cyber Security, Digital Forensics

1. GİRİŞ

Teknolojinin gelişmesi ve sistemlerin dijital ortamlara aktarılması ile internet güvenliği kavramı ortaya çıkmıştır. Her geçen gün artan veriler ile bilgiye erişmek kolaylaşmış, kişisel bilgiler ise güvenlik bakımından önemli bir hale gelmiştir. Kişisel güvenlik açısından suç teşkil eden durumlarda mağduriyet yaşanmaması için geliştirilen analiz yöntemlerinin sayısı da artış göstermektedir.

Çizge öğrenme ve alt alanı olan Çizge Sinir Ağları (Graph Neural Networks-GNNs) da bilgi güvenliği sistemlerinde kullanılmaya başlanmıştır. Çizge öğrenme farklı alanlarda yaygın olarak kullanılmaktadır (Gümüş ve Eyüpoğlu, 2023). Çizgeler üzerinde gerçekleşen öğrenme olarak tanımlanan çizge öğrenme GNN'ler ile görüntü ve video üzerinde de analiz yapabilmektedir. Ayrıca GNN'ler siber güvenlik ve yazılım alanlarında da yaygınlaşmaktadır. Bu çalışmada GNN'lerin görevleri ile birlikte bilgi güvenliği, siber güvenlik ve adli bilişim konuları ile ilişkisine yer verilecektir.

Çalışmanın diğer bölümleri şu şekilde organize edilmiştir: Bölüm 2'de GNN'lerin görevlerine, modellerine ve literatürde hangi çalışmalarda kullanıldığı bilgilerine değinilmiştir. Bölüm 3-5'te sırasıyla GNN'lerin bilgi güvenliği, siber güvenlik ve adli bilişim konuları ile ilişkisine yer verilecektir. Son olarak Bölüm 6'da ise çalışmanın genel sonuçlarından ve yapılabilecek gelecek çalışmalardan bahsedilmiştir.

2. ÇİZGE SİNİR AĞI MODELLERİ VE GÖREVLERİ

GNN'ler çizge yapılı verilerle çalışmak üzere tasarlanmış özel sinirsel modellerdir. Çizgelerdeki bağımlılıkları yakalamak için düğümler arasında mesaj geçişinden yararlanılmaktadır. GNN'ler, CNN (Convolutional Neural Networks-Evrişimsel Sinir Ağları) ve diğer çizge tekniklerinden etkilenmiştir (Gümüş ve Eyüpoğlu, 2024). Bu bölümde yaygın olarak kullanılan modellerden olan GCN (Graph Convolutional Networks-Çizge Evrişim Ağları), DCNN (Diffusion-Convolutional Neural Networks-Difüzyon-Evrişimli Sinir Ağları), GT (Graph Transformator), GraphSAGE, GAT (Graph Attention Networks-Çizge Dikkat Ağları), MoNet (Mixture Model Network-Karışım Modeli Ağı), MPNN (Message Passing Neural Network-Mesaj Aktarma Sinir Ağı) ve SSE (Stochastic Steady-state Embedding-Stokastik Kararlı Durum Gömme) gibi modellerden bahsedilecektir.

GCN ve GAT modelleri literatürde sıklıkla kullanılan GNN modelleridir. GCN'ler CNN'lerin görüntüler üzerinde çalışmasına benzer şekilde, çizgeler üzerinde konvolüsyonel işlemler gerçekleştirir. GAT'lar ise mesaj geçişi sırasında komşu düğümlerin önemini tartmak için dikkat mekanizmalarını kullanmaktadırlar.

GNN'ler düğüm sınıflandırması, çizge sınıflandırma, bağlantı tahmini ve çizge oluşturma gibi bir çok görevde kullanılmaktadır. Düğüm sınıflandırma, bireysel düğümler için etiketlerin tahmin edilmesidir. Bir sosyal ağdaki kullanıcıların sınıflandırılması düğüm sınıflandırma için örnek olarak verilebilir. Çizge sınıflandırma, tüm çizgelere etiket atamasıdır. Moleküler yapıları kategorize etme işlemi çizge sınıflandırmaya örnek olarak gösterilebilir. Bağlantı tahmini, bir çizgedeki eksik veya gelecekteki kenarları tahmin etme işlemidir. Örneğin bir sosyal ağda arkadaş önerilmesi. Çizge oluşturma ise yeni makul çizgeler oluşturulmasıdır. Moleküler yapılar oluşturma örnek olarak verilebilir. Tablo 1'de GNN'lerin görevleri ve bu görevlerin açıklanmasına yer verilmektedir.

Tablo 1. GNN'lerin görevleri.

Görev	Açıklama
3 Boyutlu Nesne Algılama	Nesneleri sınıflandırarak üç boyutlu tahminleme.
3 Boyutlu Şekil Sınıflandırma	Nesnelerini biçimlerine göre sınıflandırarak grup oluşturma.
3 Boyutlu Şekil Yeniden İnşası	Modellerin farklı sınıflandırmalar kullanılarak yeniden modellenmesi.
Açıklama Üretimi	Açıklama üretimi.
Aktif Öğrenme	Tahmin modelini tekrarlamalı eğiterek verimi ve doğruluğu artırma.
Anahtar Nokta Tespiti	İnsan algılamasını eşzamanlı olarak yaparken anahtar noktaları yerelleştirme.
Anomali Tespiti	Normal-anormal arası yapılan sınıflandırma.
Bağımlılık Ayrıştırma	Metinsel bilgileri dilbisi ile tanımlayarak ilişkisel çözümleme yapabilme.
Bağlantı Tahmini	Düğüm arası bağlantı ihtimali tahmin etme.
Bant Boşluğu	Malzeme özelliği tahminleme.
Belge Sınıflandırma	Bir etiket kümesi yardımı ile tanımsız nesnelere etiket verme.
Bilgi Çizgeleri	Nesne-olay-kavram açıklaması için anlamsal ilişkilerde ve tanımlamalarda kullanma.
Bilgi Damıtma	Büyük bir modelden alınan bilgilerin daha küçük modellerde işlenmesi.
Bilgisayarlı Tomografi	X-ışınları ile hazırlanan çizgelerin analizi.

Borsa Tahmini	Finansal çizgelerde tahmin.
Çizge Bölümleme	Dağıtılmış çizgelerde hesaplamayı kolaylaştırma.
Çizge Dikkat	Dikkat katmanı ile verim artırma.
Çizge Evrimsel Ağ	Evrimsel sinir ağlarının çizgelere uygulanması.
Çizge Gömme	Düğüm özelliklerinin korunmasıyla çizgelerin eşlenmesi.
Çizge Kümeleme	Kenar yapısına odaklanarak, çizge düğümlerinin küme halinde gruplanması.
Çizge Oluşturma	Malzeme ve ilaç tasarımı.
Çizge Öğrenme	Çizgelerden anlam ve bilgi çıkarımı.
Çizge Özellik Tahmini	Çizgelerin türlerine ve işlemlerine göre özelliklerini öğrenme.
Çizge Regresyon	Performans ölçütü ve kayıp fonksiyonu kullanarak çizge sınıflandırma.
Çizge Sınıflandırması	Çizgelerin eşlenerek sınıflandırılması.
Çizge Temsili Öğrenme	Çizgelerin yapısı ve çizge üzerindeki verilerin temsili için özellik oluşturma.
Çizge Yapısı	Çizge öğrenme için tür etiketleme.
Çok Aracılı Güçlendirme Öğrenimi	Alt görevlerin çözümünde birden fazla kullanıcıyı sağlayarak karmaşık çözümleri gerçekleştirme.
Çok Değişkenli Zaman Serileri Tahmini	Değişken durumları hesaba katarak geçmişten çıkarım ile farklı yolların gösterilmesi.
Çok Etiketli Sınıflandırma	Bir nesnenin birden fazla etiket ile etiketlenmesi sorunu için kullanılması.
Çok Görevli Öğrenme	Yüksek performans ile birden fazla görevi aynı anda yapılabilme.
Denetimsiz Görüntü Segmentasyonu	Görüntü bölme ve etiketleme.
Denetimsiz Nesne Segmentasyonu	Nesne bölme ve etiketleme.
Denetimsiz Semantik Segmentasyonu	Görüntüleri ve nesneleri bölerek etiketleme.
Derin Kümeleme	Temsillerin derinleştirilmesi ve açık amaç ile yan ürün çıktısı alınması.
Duygu Analizi	Metin tabanında olumlu ve olumsuz gibi kutup belirleme.
Düğüm Özelliği Tahmini	Etiketlenmiş düğümlerin özellik tahmininin gerçekleştirilmesi.
Düğüm Sınıflandırması	Komşu etiketler yardımıyla düğümün etiketinin belirlenmesi.
Düşman Saldırısı	Karışıklığı bulmak için tahmin değiştirme.
Eylem Tanıma	Görüntü ve video gibi çizgesel nesnelerde insani eylemlerin tanımlanarak çizgelere aktarılması.
Geçici Eylem Yerleştirme	Video süreçlerinde eylemlerin tanımlanması ve başlangıç-bitiş süre çıkarımının yapılması.
Genel Sınıflandırma	Belirli bir durum için etiketleme.
Genelleme Sınırları	Genelleştirme ve yerelleştirme için aralık belirleme.
Gizli Değişken Modeller	Kuantum modeller için tahmin.
Görüntü Kümeleme	Görüntü kümelerinin anlamsal biçimde alt kümelere bölünmesi.
Görüntü Oluşturma	Hali hazırda bulunan bir verikümesi kullanılarak yeni görüntü oluşturma.
Görüntü Sınıflandırma	Belirli bir görüntünün tüm hatlarıyla kavranarak etiketlenmesi.
Gauss Süreci Regresyonu	Gauss süreç regresyonunun uygulanması.
Genel Sınıflandırma	Belirli bir durum için etiketleme yapılması.
Hisse Fiyat Tahmini	Finansal çizgelerden çıkarım yaparak tahmin etme.
İlaç Keşfi	Yeni ilaçların üretimi ve modellenmesi.
İlişki Çıkarma	Metinsel belgelerde nesneler için nitelik tahmini.
İlişkisel Akıl Yürütme	Farklı nesnelerin arasındaki anlamsal ilişkilerin çıkarımı.
İskelet Tabanlı Eylem Tanıma	Görüntüler üzerinde hareket ve varlıkları çizgelere aktararak tanıma ve tahmin.
İzinsiz Giriş Tespiti	Bilişim sistemlerinde analiz, tespit ve engelleme.
Kalabalık Sayma	Görüntüdeki varlıkların matematiksel olarak sayılması.
Karar Verme	Veri analizi yöntemleri ile bilgiyi işleyerek birleştirme.
Karşı Olgusal Çıkarım	Karşı deneyler ile ilgili tahmin gerçekleştirme.
Kelime Gömme	Doğal dil işleme için kullanılan özellik öğrenme.
Kendi Kendine Denetimli Öğrenme	Etiketlenmemiş verilerin kullanılması ile etiketlenmiş veri oluşturma.
Konuşma Tahmini	Sesler içerisindeki diyalogların algılanarak metin haline dönüştürülmesi.
Malzeme Eleme	Etiketleme yardımıyla sağlık ve kuantum gibi alanlarda kullanım amaçlı eleme.
Matris Tanımlama	Kayıp verilerin kurtarılması.
Meta Öğrenme	Öğrenmeyi öğrenme olarak bilinen algoritmalar yardımıyla işleme.
Metin Sınıflandırma	Seçilen veri kümelerine bağlı olarak metin ve dökümanları kategorisel olarak ayırma.
Metrik Öğrenme	Nesnelerin eşlenmesi ile temsil öğrenme gerçekleştirilmesi.
Moleküler Özellik Tahmini	Biyoloji ve kimya gibi alanlarda çizgeler üzerinden özellik tahmin etme.
Nesne Algılama	Görüntü içerisinde bulunan nesnelerin benzer sınıf nesneler ile örnek algılama.
Nesne Sınıflandırma	Görüntü içerisinde bulunan ve daha önceden bilinmeyen nesnelerin tanımlanması.

Nesne Keşfi	Bilinmeyen nesnelerin tanımlanması.
Nokta Bulutu Sınıflandırması	Çizgesel nokta kümelerinin sınıflandırılması.
Nesne Tanıma	Görüntü içerisinde bulunan nesnelerin algılama ve tanımlamaya yönelik sınıflandırılması.
Niceleme	Yüksek hesaplamalı çizgeleri düşük hesaplama seviyesine getirme.
Oluşum Enerjisi	Moleküler çizgeler için kullanılma.
Optik Akış Tahmini	Ardışık görüntüler kullanılarak hareket bulma.
Ortak Filtreleme	Modelin önceki bilgileri ile girdi ve çıktı tahmin etme.
Ortak Sıralama	Önceki bilgilerin kullanılması ile nesnelerin sınıflandırılması.
Otomatik Teorem Kanıtı	Bilinen ve algılanan durumları bir veritabanı ile otomatik şekilde ispatlama.
Otonom Sürüş	Bir aracın kendi kendisini sürme görevidir. Sürüş için gereken algılama ve tahminin yapılması GNN ile bağlantısıdır.
Öneri Sistemleri	Elde edilen bilgiler ile öneri oluşturma.
Özellik Mühendisliği	Tahmin problemi eğitimi ile özellik tahmini gerçekleştirebilecek sistem tasarımı.
Parametre Tahmini	Parametrelerin tahmin edilmesi.
Program Onarımı	Model tabanında denetim ile onarım işlemini gerçekleştirme.
Program Sentezi	Model tabanında denetim ile program analizi gerçekleştirme.
Protein Fonksiyonu Tahmini	Moleküler çizgeler üzerinde işlem tahmini.
Rakip Dayanıklılık	Güvenlik açığı değerlendirme.
Sahte Haber Tespiti	Sahte haberlerin tespit edilmesi.
Sayısal Entegrasyon	İntegral ve diferansiyel denklem çözme.
Semantik Segmentasyon	Bir görüntünün farklı parçalarını eş olarak bir araya getirme.
Sistematik Genelleme	Bilinen nesneleri yeni anlamlar ile birleştirme.
Soru Cevaplama	Anlamsal olarak değerlendirme ve yanıt verme.
Soru Üretimi	Belirlenen bir cevaba ve amaca göre soru üretme.
SQL Metin Dönüşümü	SQL çıktısını metne dönüştürme.
Stil Aktarımı	Bir alan içerisinde bulunan görüntünün stilini başka bir alandaki görüntü stiline göre değiştirme.
Süperpiksel Görüntü Sınıflandırması	Piksel odak alarak piksel grubuna göre sınıflandırma ya da ortak piksel değeri ile aynı grupta bölme yapma.
Sürekli Öğrenme	Eski görev bilgilerinin depolandığı ve yeni görevler ile birlikte birden fazla görevi aynı anda yapabilme.
Temsil Öğrenme	Gizli özellikler ve aktarım eğitimi için yorumlanabilirlik.
Tıklama Oranı Öğrenme	Web sitesi içerisinde bulunan bir nesnenin etkileşimini öğrenme.
Toplam Miknastıslanma	Çizgelerin etkileşimlerini tahmin etme.
Topluluk Algılama	Benzer düğümlerin gruplandırılması.
Trafik Sınıflandırması	Sohbet ve akış gibi durumların sınıflandırılması.
Unsur Bazlı Duygu Analizi	Bir hedefe karşı kutuplaşma belirleme.
Ürün Tavsiyesi	Belirli bir veri içerisinde kullanıcıya ürünlerden bir ya da birkaçının tavsiye edilmesi.
Varlık Bağlantısı	Metin içerisinde ismi geçen varlıklar benzeri olmayan isimler ile değiştirilmesi.
Varlık Belirsizliği	Belirsiz olarak tanımlanan varlıkların belirli varlıklara bağlanması.
Veri Büyütme	Elde olan veri kümesinin ihtiyaçlar dahilinde büyütülmesi.
Video Tahmini	Video karelerinden geçmişte olanlar işlenerek gelecek için tahmin gerçekleştirme.
Yanlış Bilgi	Metinsel bilgiler içerisinde yanlış bilginin verilerden kontrol edilerek tespit edilmesi.
Yürütmeyi Öğrenme	Öğrenme işleminin süreklilik sağlaması.
Yüz Tanıma	Veritabanı içerisinde var olan yüzlerin görüntü ya da video analizi sonrası tespiti.
Zaman Serisi Tahmini	Gelecek durumları tahmin etmek için geçmişte gerçekleşen durumların incelenmesi.

Literatürde; GCN, SSE, GAT, DCNN, MoNet, GT, GSAGE, MPNN ve GraphSAGE gibi modellere dayanan ve farklı görevler için kullanılan bir çok çalışma vardır. Bu çalışmalarda modeller üç boyutlu insan pozu tahmini, aktif öğrenme, anomali tespiti, bağlantı tahmini, çizge sınıflandırma, duygu analizi, duygu tanıma, poz tahmini ve yüz tanıma gibi farklı görevler için kullanılmıştır. Tablo 2’de GNN görevlerinin temel modeller ve literatürdeki çalışmalar ile eşleştirilmesine yer verilmektedir.

Tablo 2. GNN görevlerinin temel modeller ve literatürdeki çalışmalar ile eşleştirilmesi.

GNN Görevleri	Modeller	Çalışma
3 Boyutlu İnsan Pozu Tahmini	GCN	(Zou ve Tang, 2021)
3 Boyutlu Rekonstrüksiyon	GCN	(Qian ve diğ., 2021; Masoumian ve diğ., 2023)
3 Boyutlu Semantik Segmentasyon	GCN	(Li ve diğ., 2019a)
Açıklama Üretimi	SSE	(Yang ve diğ., 2022)

Adlandırılmış Varlık Tanıma	GCN	(Cetoli ve diğ., 2017; Theodoropoulos ve diğ., 2021)
Ağ Gömme	GCN	(Ghorbani ve diğ., 2018)
	GAT	(Huang ve diğ., 2019)
Akciğer Hastalığı Sınıflandırması	DCNN	(Kumar ve diğ., 2018)
Aktif Öğrenme	GCN	(Caramalau ve diğ., 2021)
	SSE	(Wagner ve diğ., 2022)
Amodal Örnek Segmentasyon	GCN	(Ke ve diğ., 2021)
Anahtar Nokta Tespiti	MoNet	(Yao ve diğ., 2019)
Android Kötü Amaçlı Yazılım Algılama	GT	(Fan ve diğ., 2021)
Anomali Tespiti	GAT	(Zhao ve diğ., 2020)
	GT	(Liu ve diğ., 2021c)
Atama	GCN	(Taguchi ve diğ., 2021)
	SSE	(Wu ve diğ., 2024)
Az Çekimli Nesne Algılama	GCN	(Wang ve diğ., 2021a)
Bağlantı Tahmini	GNN	(Chaiang ve diğ., 2019)
	GCN	(Vashishth ve diğ., 2020; Chami ve diğ., 2019; Sahla ve diğ., 2020; Zeng ve diğ., 2021; Sahla ve diğ., 2019; Shang ve diğ., 2018; Vashishth, 2019; Ma ve diğ., 2019; Ghorbani ve diğ., 2018; Anwaar ve diğ., 2020; Taguchi ve diğ., 2021)
	GAT	(Veličković ve diğ., 2017; Zeng ve diğ., 2021)
	GSAGE	(Hamilton ve diğ., 2017; Zeng ve diğ., 2021)
	GT	(Dwivedi ve Bresson, 2021; Hussain ve diğ., 2021)
Bant Boşluğu	MPNN	(Yamamoto, 2019)
Bayes Çıkarımı	GCN	(Elinas ve diğ., 2020)
Belirginlik Tahmini	DCNN	(Yang ve diğ., 2019)
Belge Sınıflandırma	GCN	(Kipf ve Welling, 2017)
	GAT	(Veličković ve diğ., 2017)
	MoNet	(Monti ve diğ., 2017)
Beyin Tümörü Segmentasyonu	DCNN	(Hussain ve diğ., 2018)
Bilgi Bankası Tamamlama	GCN	(Shang ve diğ., 2018)
Bilgi Çizgeleri	GCN	(Wang ve Daniels, 2018; Shang ve diğ., 2018; Vashishth, 2019; Tai ve diğ., 2020; Wu ve diğ., 2019a; Yu ve diğ., 2020b; Chen ve diğ., 2020a; Ashraf ve diğ., 2019; Berrendorf ve diğ., 2020)
	GAT	(Yasunaga ve diğ., 2021; Sinha ve diğ., 2020; Li ve diğ., 2019b)
	GT	(Dwivedi ve Bresson, 2021)
	SSE	(Wu ve diğ., 2019b)
Bilgi Damıtma	GCN	(Yang ve diğ., 2021; Yang ve diğ., 2020)
	GAT	(Yang ve diğ., 2021)
Bilgi Grafiği Gömme	GCN	(Vashishth ve diğ., 2020; Shang ve diğ., 2018; Yu ve diğ., 2020b)
Bilgilendiricilik	GCN	(Li ve diğ., 2019c)
Bilgisayarlı Tomografi	DCNN	(Ding ve diğ., 2017)
Binarizasyon	SSE	(Mironov ve Khuziev, 2022)
Birkaç Adımda Öğrenme	GCN	(Iscen ve diğ., 2020; Zhang ve diğ., 2019a)
Birleşik Öğrenim	GCN	(Sajadmanesh ve Gatica-Perez, 2021)
Borsa Tahmini	SSE	(Liu ve diğ., 2022b)
Boyutsal Küçülme	GCN	(Jiang ve Lin, 2018a)
Cilt Lezyonu Segmentasyonu	DCNN	(Jafari ve diğ., 2020; Yao ve diğ., 2021; Li ve diğ., 2020b)
Cümle Gömmeleri	GCN	(Theodoropoulos ve diğ., 2021)
Çizge Bölümleme	GSAGE	(Mondal ve diğ., 2022)

Çizge Dikkat	GCN	(Yu ve diğ., 2020d; Zhang ve diğ., 2019a; Min ve diğ., 2020)
	GAT	(Veličković ve diğ., 2017; Broccatelli ve diğ., 2022; Zhao ve diğ., 2020; Louis ve diğ., 2020; Huang ve diğ., 2019; Li ve diğ., 2019b; Leng ve diğ., 2020; Min ve diğ., 2020; Lin ve diğ., 2021; Dasoulas ve diğ., 2021; Zhou ve Wang, 2020a; Mandya ve diğ., 2020; Aykas ve Mehrkanon, 2021; Huang ve diğ., 2023)
	GSAGE	(Chang ve Branco, 2021; Mondal ve diğ., 2022)
	GT	(Xia ve diğ., 2021)
Çizge Gömme	GCN	(Vashishth ve diğ., 2020; Lu ve diğ., 2020; Shang ve diğ., 2018; Vashishth, 2019; Ghorbani ve diğ., 2018; Yu ve diğ., 2020b)
	GAT	(Veličković ve diğ., 2017)
	GSAGE	(Tam ve diğ., 2019)
Çizge Kümeleme	GCN	(Chaiang ve diğ., 2019; Liu ve diğ., 2021b)
Çizge Madenciliği	GSAGE	(Tam ve diğ., 2019)
	GT	(Zhao ve diğ., 2021)
Çizge Oluşturma	GCN	(Dehmamy ve diğ., 2019; Zhang ve diğ., 2019a)
Çizge Öğrenme	GCN	(Chen ve diğ., 2019b; Taguchi ve diğ., 2021; Wang ve diğ., 2021b; Zang ve diğ., 2020)
	GAT	(Yasunaga ve Liang, 2020)
	GSAGE	(Wang ve diğ., 2021c)
	GT	(Cai ve Lam, 2020)
Çizge Örnekleme	GSAGE	(Jangda ve diğ., 2020)
	GT	(Zhao ve diğ., 2021)
Çizge Özellik Tahmini	GT	(Rampásek ve diğ., 2022)
Çizge Regresyon	GCN	(Kipf ve Welling, 2017)
	GAT	(Veličković ve diğ., 2017)
	GSAGE	(Hamilton ve diğ., 2017; Xu ve diğ., 2019)
	GT	(Dwivedi ve Bresson, 2021; Rampásek ve diğ., 2022; Hussain ve diğ., 2021; Rampásek ve diğ., 2022)
	MPNN	(Gilmer ve diğ., 2017)
	MoNet	(Monti ve diğ., 2017)
Çizge Sınıflandırma	GNN	(Kipf ve Welling, 2017)
	GCN	(Li ve diğ., 2019a; Vashishth ve diğ., 2020; Ma ve diğ., 2019; Wang ve diğ., 2021b)
	GAT	(Veličković ve diğ., 2017; Dou ve diğ., 2021)
	GSAGE	(Hamilton ve diğ., 2017; Xu ve diğ., 2019; Dou ve diğ., 2021; Kooverjee ve diğ., 2022; Nt ve diğ., 2019; Zhang, 2019b)
	GT	(Rampásek ve diğ., 2022; Hussain ve diğ., 2021; Zhang ve diğ., 2022)
	MPNN	(Loukas, 2020)
	MoNet	(Monti ve diğ., 2017)
Çizge Temsili Öğrenme	GCN	(Ma ve diğ., 2019)
	GAT	(Yasunaga ve diğ., 2021; Thakoor ve diğ., 2022)
	GSAGE	(Xu ve diğ., 2019; Tam ve diğ., 2019)
	GT	(Rampásek ve diğ., 2022; Wang ve diğ., 2021d)
	MPNN	(Vrcek ve diğ., 2020)
Çizge Yapısı	GCN	(Shi ve diğ., 2019b; Shi ve diğ., 2019a; Yu ve diğ., 2020d)
	GT	(Jia ve diğ., 2023)
Çok Aracılı Güçlendirme Öğrenimi	GCN	(Kim ve Kim, 2021)
	GAT	(Kim ve Kim, 2021)
	SSE	(Sengupta ve Kambhampati, 2020)

Çok Atlamalı Soru Cevaplama	GAT	(Yasunaga ve diğ., 2021)
Çok Etiketli Sınıflandırma	GCN	(Chen ve diğ., 2019d; Wang ve diğ., 2019a)
Çok Görevli Öğrenme	GCN	(Sinha ve diğ., 2020)
	GAT	(Sinha ve diğ., 2020)
	MoNet	(Tallec ve diğ., 2022)
Çok Görüntülü Yürüyüş Tanıma	GCN	(Teepe ve diğ., 2021)
Çok Modlu Derin Öğrenme	GCN	(Chen ve diğ., 2020a)
Çözülme	GCN	(Degardin ve diğ., 2021)
Dağıtılmış Bilgi İşlem	SSE	(Chen ve diğ., 2019a)
Denetimsiz Görüntü Segmentasyonu	MoNet	(Engelcke ve diğ., 2020)
Denetimsiz Nesne Segmentasyonu	MoNet	(Engelcke ve diğ., 2020; Wang ve diğ., 2020b)
Derecelendirmeyi Öğrenme	SSE	(Mironov ve Khuziev, 2022)
Derinlik Tahmini	GCN	(Masoumian ve diğ., 2023)
	DCNN	(Liu ve diğ., 2021a)
Dil Modelleme	GCN	(Theodoropoulos ve diğ., 2021)
	GAT	(Yasunaga ve diğ., 2021)
Doğruluk Kontrolü	GAT	(Dou ve diğ., 2021)
	GSAGE	(Dou ve diğ., 2021)
Doku Sentezi	DCNN	(Li ve diğ., 2016)
Duygu Analizi	GCN	(Yao ve diğ., 2018; Zhao ve diğ., 2020; Liang ve diğ., 2020)
	SSE	(Rajput ve diğ., 2020)
Duygu Tanıma	DCNN	(Zhang ve diğ., 2021c)
	GT	(Jia ve diğ., 2021)
Düğüm Kümeleme	GCN	(Sahla ve diğ., 2020; Sahla ve diğ., 2019)
Düğüm Özelliği Tahmini	GCN	(Kipf ve Welling, 2017; Shi ve diğ., 2020; Peng ve diğ., 2019; Zeng ve diğ., 2021)
	GAT	(Veličković ve diğ., 2017; Zeng ve diğ., 2021)
	GSAGE	(Zeng ve diğ., 2021)
Düğüm Sınıflandırma	GCN	(Chaiang ve diğ., 2019; Kipf ve Welling, 2017; Chen ve diğ., 2019d; Li ve diğ., 2019a; Vashishth ve diğ., 2020; Chami ve diğ., 2019; Zeng ve diğ., 2021; Wang ve Leskovec, 2020d; Li ve diğ., 2018; Ma ve diğ., 2019; Yang ve diğ., 2021; Oono ve Suzuki, 2020; Ghorbani ve diğ., 2018; Sajadmanesh ve Gatica-Perez, 2021; Zhu ve diğ., 2020b; Taguchi ve diğ., 2021; Wang ve diğ., 2021b; Dong ve Li, 2020; Feng ve diğ., 2018; Zhang ve Meng, 2019c; Min ve diğ., 2020; Wan ve diğ., 2022)
	DCNN	(Atwood ve Towsley, 2016)
	GAT	(Veličković ve diğ., 2017; Zeng ve diğ., 2021; Yang ve diğ., 2021; Huang ve diğ., 2019; Zhu ve diğ., 2020b; Min ve diğ., 2020; Zhang ve Meng, 2019c; Dasoulas ve diğ., 2021; Zhou ve diğ., 2019)
	GSAGE	(Hamilton ve diğ., 2017; Xu ve diğ., 2019; Abu-El-Haija ve diğ., 2018; Zeng ve diğ., 2021; Oh ve diğ., 2019; Kooverjee ve diğ., 2022; Tam ve diğ., 2019; Li ve diğ., 2020a; Shi ve diğ., 2021a)
	GT	(Yun ve diğ., 2022; Dwivedi ve Bresson, 2021; Rampásek ve diğ., 2022; Hussain ve diğ., 2021; Zhang ve diğ., 2022; Zhao ve diğ., 2021; Rampásek ve diğ., 2022)
	MPNN	(Gilmer ve diğ., 2017; Craandijk ve Bex, 2020)
	MoNet	(Monti ve diğ., 2017)
Düşman Savunması	GSAGE	(Wang ve diğ., 2019b)
El Poz Tahmini	GCN	(Caramalau ve diğ., 2021)
Etki Alanı Uyarlaması	GCN	(Zhang ve diğ., 2021b)

Etkinlik Tanıma	DCNN	(Creagh ve diğ., 2021)
Eylem Anlayışı	GCN	(Wang ve diğ., 2020a)
Eylem Birimi Algılama	MoNet	(Tallec ve diğ., 2022)
Eylem Oluşturma	GCN	(Degardin ve diğ., 2021; Yu ve diğ., 2020d)
Eylem Segmentasyonu	GCN	(Wang ve diğ., 2020a)
Eylem Tanıma	GCN	(Shi ve diğ., 2019b; Shi ve diğ., 2019a; Wang ve diğ., 2020a)
Fiziksel Simülasyonlar	GCN	(Cachay ve diğ., 2021)
Geçici Eylem Yerleştirme	GCN	(Shi ve diğ., 2019b; Shi ve diğ., 2019a)
Genel Sınıflandırma	GCN	(Kipf ve Welling, 2017; Chen ve diğ., 2019d; Yao ve diğ., 2018; Vashishth ve diğ., 2020; Wang ve diğ., 2019a; Lu ve diğ., 2020; Wang ve Leskovec, 2020d; Wan ve diğ., 2019; Jiang ve Lin, 2018a; Zhang ve diğ., 2018b; Chen ve diğ., 2019c; Zhuo ve diğ., 2019; Ma ve diğ., 2019; Bhattacharya ve diğ., 2019; Oono ve Suzuki, 2020; Ghorbani ve diğ., 2018; Zhu ve diğ., 2020b; Iscen ve diğ., 2020; Feng ve diğ., 2019; Elinas ve diğ., 2020)
	DCNN	(Zhaou ve diğ., 2017; Kortylewski ve diğ., 2020; Kumar ve diğ., 2018; Li ve diğ., 2017; Atwood ve Towsley, 2016; Mardanisamani ve diğ., 2019; Yao ve diğ., 2021; Kassani ve diğ., 2019; Chen ve diğ., 2017b; Ge ve diğ., 2016; Harley ve diğ., 2015; Ma ve Xia, 2018)
	GAT	(Zhu ve diğ., 2020b)
	GraphSAGE	(Xu ve diğ., 2019; Abu-El-Haija ve diğ., 2018; Oh ve diğ., 2019; Zhang, 2019b)
	MoNet	(Tang ve diğ., 2019)
Gerçek Zamanlı Örnek Segmentasyon	GCN	(Ke ve diğ., 2021)
Gizli Değişken Modeller	MoNet	(Zurel ve diğ., 2021)
Go Oyunu	DCNN	(Tian ve diğ., 2015)
Görsel İzleme	GCN	(Gao ve diğ., 2019a)
Görsel Odyometri	GT	(Li ve Ling, 2021a)
Görüntü Alma	GCN	(Yuan ve diğ., 2022)
Görüntü Gürültüsü	DCNN	(Jia ve diğ., 2019)
Görüntü Kırpma	DCNN	(Zhang ve diğ., 2018a)
Görüntü Oluşturma	DCNN	(Li ve diğ., 2016)
	MoNet	(Engelcke ve diğ., 2020; Praramadhan ve Saputra, 2021)
Görüntü Sınıflandırma	GCN	(Wan ve diğ., 2019; Caramalau ve diğ., 2021; Zhang ve diğ., 2021b)
	DCNN	(Zhaou ve diğ., 2017; Li ve diğ., 2017; Schuler ve diğ., 2022; Schuler ve diğ., 2021; Ge ve diğ., 2016; Ma ve Xia, 2018)
Görüntüden Görüntüye Çeviri	MoNet	(Chang ve diğ., 2019)
Gürültü Arındırma	DCNN	(Jia ve diğ., 2019)
	GAT	(Ma ve diğ., 2021)
Hareket Sentezi	GCN	(Degardin ve diğ., 2021)
Hastalık Tahmini	GCN	(Parisot ve diğ., 2017)
Hiperspektral Görüntü Sınıflandırılması	GCN	(Wan ve diğ., 2019; Zhang ve diğ., 2021b)
İlaç Keşfi	GT	(Morehead ve diğ., 2022; Chen ve diğ., 2021)
	MPNN	(Gilmer ve diğ., 2017; Klicpera ve diğ., 2020; Zhang ve diğ., 2020b)
İlişki Çıkarımı	GCN	(Vashishth, 2019)
	GAT	(Mandya ve diğ., 2020)
	GT	(Lai ve Lu, 2021)
İlişkisel Akıl Yürütme	GCN	(Sinha ve diğ., 2020)
	GAT	(Sinha ve diğ., 2020)
İnci Taneli Görüntü Sınıflandırma	DCNN	(Ge ve diğ., 2016)

İnsan Eylemi Üretimi	GCN	(Degardin ve diğ., 2021; Yu ve diğ., 2020d)
İnsan Poz Tahmini	GCN	(Sofianos ve diğ., 2021)
İskelet Tabanlı Çizge Tanıma	GCN	(Shi ve diğ., 2019b; Shi ve diğ., 2019a)
İskelet Tabanlı Eylem Tanıma	GCN	(Kipf ve Welling, 2017; Shi ve diğ., 2019b; Shi ve diğ., 2019a; Peng ve diğ., 2019; Jiang ve diğ., 2021)
	GAT	(Veličković ve diğ., 2017)
İşaret Dili Tanıma	GCN	(Jiang ve diğ., 2021)
İzinsiz Giriş Tespiti	GSAGE	(Chang ve Branco, 2021; Wang ve diğ., 2021c)
Kalabalık Sayma	MoNet	(Bai ve Chan, 2021)
Kalan Faydalı Ömür Tahmini	DCNN	(Martin ve diğ., 2021)
Kamera Yer Değiştirme	GT	(Li ve Ling, 2021a)
Karar Verme	GAT	(Murugesan ve diğ., 2021; Leng ve diğ., 2020)
Kelime Gömmme	GCN	(Shi ve diğ., 2020; Vashishth, 2019)
Kelime Gömmelerini Öğrenmek	GCN	(Vashishth, 2019)
Kenar Sınıflandırma	GT	(Hussain ve diğ., 2021)
Kendi Kendine Denetimli Öğrenme	GCN	(Zhu ve diğ., 2020a)
	GAT	(Yasunaga ve Liang, 2020; Thakoor ve diğ., 2022)
Kişi Yeniden Tanımlama	GCN	(Yu ve diğ., 2020a)
	DCNN	(Su ve diğ., 2016)
Kod Oluşturma	GAT	(Yasunaga ve Liang, 2020)
Kontrastlı Öğrenme	GCN	(Theodoropoulos ve diğ., 2021; Wang ve diğ., 2020c)
	GAT	(Thakoor ve diğ., 2022)
	GSAGE	(Wang ve diğ., 2019b)
Konuşma Duygu Tanıma	DCNN	(Zhang ve diğ., 2021c)
Konuşma Tahmini	MoNet	(Monti ve diğ., 2017)
Konuşma Tanıma	MoNet	(Monti ve diğ., 2017)
Kötü Amaçlı Yazılım Algılama	GCN	(Zhang ve diğ., 2020a)
	GT	(Fan ve diğ., 2021)
Lezyon Segmentasyonu	DCNN	(Jafari ve diğ., 2020; Yao ve diğ., 2021; Li ve diğ., 2020b)
Makine Çevirisi	GT	(Gokden, 2021)
Malzeme Eleme	MPNN	(Yamamoto, 2019)
Mekânsal Zamansal Tahmin	GCN	(Choi ve diğ., 2021)
	GAT	(Zhao ve diğ., 2020)
Meta-Öğrenme	GCN	(Mou ve diğ., 2021; Wang ve diğ., 2021a; Zhang ve diğ., 2019a)
Metin Eşleştirme	GT	(Lyu ve diğ., 2021)
Metin-Görüntü Alma	GCN	(Yuan ve diğ., 2022)
Metin Kategorizasyonu	GCN	(Gao ve diğ., 2019b)
Metin Sınıflandırma	GCN	(Yao ve diğ., 2018; Lu ve diğ., 2020)
Metin Stil Aktarımı	GT	(Shi ve diğ., 2021b)
Metin Tabanlı Okuyucular	GAT	(Murugesan ve diğ., 2021)
Metrik Öğrenme	GCN	(Cucurull ve diğ., 2019)
	DCNN	(Su ve diğ., 2016)
Mobil Güvenlik	GT	(Fan ve diğ., 2021)
Model Seçimi	GCN	(Li ve diğ., 2018)
	DCNN	(Martin ve diğ., 2021)
	GAT	(Zhou ve diğ., 2019)
Moleküler Özellik Tahmini	GCN	(Chen ve diğ., 2019c)
	GT	(Bratholm ve diğ., 2021)


	MPNN	(Gilmer ve diğ., 2017; Lamb ve Paige, 2020; Jiang ve Balaprakash, 2020)
Monoküler Derinlik Tahmini	GCN	(Masoumian ve diğ., 2023)
	DCNN	(Liu ve diğ., 2021a)
Müzik Otomatik Etiketleme	DCNN	(Lee ve diğ., 2017)
Müzik Sınıflandırma	DCNN	(Lee ve diğ., 2017)
Nesne Algılama	GCN	(Ke ve diğ., 2021; Wang ve diğ., 2021a)
	DCNN	(Kemker ve diğ., 2018)
	GAT	(Kumar ve diğ., 2022)
	MoNet	(Monti ve diğ., 2017)
Nesne Keşfi	MoNet	(Engelcke ve diğ., 2020; Wang ve diğ., 2020b)
Nesne Sınıflandırma	DCNN	(Kanezaki ve diğ., 2018)
Nesne Tanıma	DCNN	(Kemker ve diğ., 2018; Alom ve diğ., 2015; Sun ve diğ., 2017; Alom ve diğ., 2017)
Nispetleme	GCN	(Yu ve Qin, 2020c)
	GT	(Gokden, 2021)
Nokta Bulutu Süper Çözünürlük	GCN	(Qian ve diğ., 2021)
Oklüzyon İşleme	GCN	(Ke ve diğ., 2021)
Olay Algılama	GCN	(Cui ve diğ., 2020)
	GT	(Dutta ve diğ., 2021)
Oluşum Enerjisi	MPNN	(Gilmer ve diğ., 2017; Klicpera ve diğ., 2020; Yamamoto, 2019; Zhang ve diğ., 2020b)
Optik Akış Tahmini	MoNet	(Tang ve diğ., 2019; Kim ve diğ., 2021; Xiao ve diğ., 2018)
Organ Tespiti	DCNN	(Li ve diğ., 2020b)
Ortak Filtreleme	GCN	(Chen ve diğ., 2020b; Zheng ve diğ., 2021)
	SSE	(Wu, 2020)
Ortak Sıralama	SSE	(Wu, 2020)
Otonom Sürüş	GT	(Jia ve diğ., 2023)
	MoNet	(Lu ve diğ., 2021)
Öneri Sistemleri	GCN	(Chen ve diğ., 2020b; Cucurull ve diğ., 2019; Tai ve diğ., 2020; Anwaar ve diğ., 2020; Min ve diğ., 2021)
	GAT	(Han, 2020; Leng ve diğ., 2020)
	GSAGE	(Pande ve diğ., 2019)
	GT	(Xia ve diğ., 2021)
	SSE	(Wu ve diğ., 2019b)
	MoNet	(Palowitch ve Perozzi, 2019)
Örnek Segmentasyon	GCN	(Ke ve diğ., 2021)
	DCNN	(Ragi ve diğ., 2021)
Özellik Mühendisliği	GCN	(Cetoli ve diğ., 2017)
Öznitelik Seçimi	DCNN	(Panda, 2016)
Pekiştirme-Öğrenme	GCN	(Chen ve diğ., 2019b; Zhang ve diğ., 2020a; Kim ve Kim, 2021)
	DCNN	(Erharter ve diğ., 2021)
	GAT	(Kim ve Kim, 2021)
	SSE	(Liu ve diğ., 2022a; Sengupta ve Kambhampati, 2020)
Poz Tahmini	GCN	(Qiu ve diğ., 2020; Teepe ve diğ., 2021; Caramalau ve diğ., 2021; Zou ve Tang, 2021)
	GT	(Li ve Ling, 2021a)
Program Onarımı	GAT	(Yasunaga ve Liang, 2020)
Program Sentezi	GAT	(Yasunaga ve Liang, 2020)
Protein Katlanması	GT	(Gao ve diğ., 2022)

Q-Öğrenme	SSE	(Sengupta ve Kambhampati, 2020; Sengupta ve Kambhampati, 2021)
Resim Altyazısı	GAT	(Wang ve diğ., 2022)
RL için Sağduyulu Akıl Yürütme	GAT	(Murugesan ve diğ., 2021)
Sağduyulu Akıl Yürütme	GAT	(Yasunaga ve diğ., 2021; Murugesan ve diğ., 2021)
Sahne Tanıma	DCNN	(Chen ve diğ., 2017b)
Sahne Üretimi	MoNet	(Engelcke ve diğ., 2020)
Sahte Haber Tespiti	GAT	(Dou ve diğ., 2021)
	GSAGE	(Dou ve diğ., 2021)
Semantik Segmentasyon	GCN	(Li ve diğ., 2019a; Ke ve diğ., 2021)
	DCNN	(Chen ve diğ., 2017a; Kemker ve diğ., 2017; Huo ve diğ., 2018b; Dewan ve Burgard, 2020; Zhang ve diğ., 2018a; Jafari ve diğ., 2020; Jafari ve diğ., 2019; He ve diğ., 2020; Huo ve diğ., 2018a; Li ve diğ., 2020b; Zhang ve diğ., 2020c; Ragi ve diğ., 2021; Panda, 2016; Harley ve diğ., 2015)
	MoNet	(Xiao ve diğ., 2018; Wang ve diğ., 2020b)
Ses İçi Boyama	DCNN	(Marafioti ve diğ., 2018)
Ses Üretimi	DCNN	(Marafioti ve diğ., 2018)
Sıfır Atışta Öğrenme	GCN	(Wang ve Daniels, 2018)
Sınır Tespiti	GCN	(Ke ve diğ., 2021)
Sıralı Öneri	SSE	(Wu, 2020)
Sinir Mimarisi Arama	GCN	(Peng ve diğ., 2019)
	MPNN	(Jiang ve Balaprakash, 2020)
Soru Cevaplama	GAT	(Veličković ve diğ., 2017; Yasunaga ve diğ., 2021)
Soyut Tartışma	MPNN	(Craandijk ve Bex, 2020)
Stil Aktarımı	GT	(Shi ve diğ., 2021b)
	MoNet	(Praramadhan ve Saputra, 2021)
Stok Tahmini	GCN	(Ye ve diğ., 2020)
Süper Çözünürlük	DCNN	(Zhu ve diğ., 2017)
Süperpiksel Görüntü Sınıflandırması	MoNet	(Monti ve diğ., 2017)
Sürekli Öğrenme	GCN	(Sinha ve diğ., 2020)
	GAT	(Sinha ve diğ., 2020)
Tablo Arama	GT	(Wang ve diğ., 2021d)
Temsil Öğrenme	GCN	(Wang ve diğ., 2019a; Chen ve diğ., 2020b; Li ve diğ., 2021b; Ma ve diğ., 2019; Yu ve diğ., 2020b; Dong ve Li, 2020; Wang ve diğ., 2020c; Zeng ve Prasanna, 2020)
	GAT	(Thakoor ve diğ., 2022)
	GSAGE	(Hamilton ve diğ., 2017; Xu ve diğ., 2019; Luo ve Zhuo, 2018; Wang ve diğ., 2019b; Tam ve diğ., 2019; Zhang, 2019b; Li ve diğ., 2020a; Jangda ve diğ., 2020; Arya ve diğ., 2020)
	GT	(Rampásek ve diğ., 2022; Wang ve diğ., 2021d; Fan ve diğ., 2021; Gokden, 2021; Rampásek ve diğ., 2022)
	MPNN	(Vrcek ve diğ., 2020)
	MoNet	(Engelcke ve diğ., 2020; Xiao ve diğ., 2018)
Tercüme	DCNN	(Zhu ve diğ., 2017; Alom ve diğ., 2017)
	GT	(Morehead ve diğ., 2022; Rampásek ve diğ., 2022)
	MoNet	(Chang ve diğ., 2019)
Tıbbi Görüntü Segmentasyonu	DCNN	(Jafari ve diğ., 2020; He ve diğ., 2020; Li ve diğ., 2020b)
Tokenizasyon	SSE	(Jiang ve Lin, 2018b)
Toplam Miknatıslanma	MPNN	(Yamamoto, 2019)
Topluluk Öğrenimi	GSAGE	(Shi ve diğ., 2021a)

Trafik Sınıflandırma	MPNN	(Dong ve Li, 2019)
Trafik Tahmini	GCN	(Zhao ve diğ., 2019; Choi ve diğ., 2021)
Transfer Öğrenimi	GCN	(Yang ve diğ., 2020; Zhang ve diğ., 2019a)
	DCNN	(Creagh ve diğ., 2021; Han, 2017; Mardanisamani ve diğ., 2019; Kassani ve diğ., 2019)
	GSAGE	(Kooverjee ve diğ., 2022; Luo ve Zhuo, 2018; Shi ve diğ., 2021a)
Tümör Segmentasyonu	DCNN	(Hussain ve diğ., 2018)
Unsur Bazlı Duygu Analizi	GCN	(Zhao ve diğ., 2020)
Uzaktan Algılama Görüntü Sınıflandırma	DCNN	(Li ve diğ., 2017)
Varlık Gömmeleri	GCN	(Wu ve diğ., 2019a)
Varlık Hizalamaları	GCN	(Wu ve diğ., 2019a; Chen ve diğ., 2020a; Berrendorf ve diğ., 2020)
	GAT	(Li ve diğ., 2019b)
Varyasyon Çıkarımı	GCN	(Elinas ve diğ., 2020)
Veri Büyütme	GCN	(Wang ve diğ., 2021b; Zhu ve diğ., 2020a)
	DCNN	(Yao ve diğ., 2021; Kassani ve diğ., 2019; Machiraju ve diğ., 2022)
	GT	(Zhao ve diğ., 2021)
	MoNet	(Yao ve diğ., 2019)
Veri Depolama	GSAGE	(Lee ve diğ., 2022)
Video İşlemci	DCNN	(Zhu ve diğ., 2017)
Video Nesnesi Segmentasyonu	MoNet	(Xiao ve diğ., 2018)
Video Semantik Segmentasyonu	MoNet	(Xiao ve diğ., 2018)
Video Sınıflandırması	MoNet	(Tang ve diğ., 2019)
Video Üretimi	GCN	(Degardin ve diğ., 2021; Yu ve diğ., 2020d)
Web Sayfası Nesne Algılama	GAT	(Kumar ve diğ., 2022)
Yanlış Bilgi	GAT	(Dou ve diğ., 2021)
	GSAGE	(Dou ve diğ., 2021)
Yarı Denetimli Tıbbi Görüntü Segmentasyonu	DCNN	(Li ve diğ., 2020b)
Yaşa Göre Değişmeyen Yüz Tanıma	DCNN	(Bianco, 2017)
Yönlendirme İfadesi	MoNet	(Wang ve diğ., 2020b)
Yönlendirme İfadesi Anlama	MoNet	(Wang ve diğ., 2020b)
Yörünge Planlama	GCN	(Mou ve diğ., 2021)
Yörünge Tahmini	GT	(Jia ve diğ., 2023)
Yuva Doldurma	GCN	(Cucurull ve diğ., 2019)
Yürüyüş Tanıma	GCN	(Teepe ve diğ., 2021)
Yüz Doğrulama	DCNN	(Bianco, 2017)
Yüz Hareketi Birim Algılama	MoNet	(Tallec ve diğ., 2022)
Yüz İfadesi Tanıma	GCN	(Antoniadis ve diğ., 2021)
Yüz Tanıma	DCNN	(Kortylewski ve diğ., 2018; Bianco, 2017)
Zaman Serisi	GCN	(Sofianos ve diğ., 2021; Weber ve diğ., 2019)
	DCNN	(Hejazi ve diğ., 2021)
	GAT	(Zhao ve diğ., 2020)
	GSAGE	(Li ve diğ., 2020a)
	SSE	(Xu ve Zhou, 2018)
Zaman Serisi Tahmini	GCN	(Choi ve diğ., 2021)
Zayıf Denetimli Semantik Segmentasyon	GCN	(Pan ve diğ., 2021)

3. ÇİZGE SİNİR AĞLARI VE BİLGİ GÜVENLİĞİ


Bilgi, iki farklı anlam ile genelleştirilebilmektedir. Birincisi, insan aklının sezgisel ve anlamsal olarak kavrayabildiği olgular bütünü olarak tanımlanırken diğeri ise öğrenme, araştırma yapma ya da gözlemsel neticeler sonucu elde edilen gerçeklikler olarak tanımlanabilmektedir (TDK Sözlük). İnternetin gelişimi ve bu gelişimin hayatımızın her alanında olması bilgiye erişmeyi kolaylaştırdığı gibi şahıs bilgilerinin de güvenlik sorununu ortaya çıkarmıştır. Bu durum sonucunda bilgi güvenliği kavramı ortaya çıkmış, şahıslar, kurumlar ve ülkeler bilgi koruma gerekliliği karşısında bilgi güvenliğinin gerekliliklerini kullanmaya başlamışlardır. Bilgi güvenliği kavramı üç ana unsur üzerinde durmaktadır. Bu üç unsur; bilgiye yetki bakımından ihtiyaç olmamasına rağmen ikinci veya üçüncü şahısların erişememesi gerekliliğini sağlayan gizlilik, doğruluk ve eksiksizlik gerekliliklerini sağlayan bütünlük ve yetki bakımından elde edilmesinin sağlanması gerekliliğini sağlayan erişilebilirlik olarak ifade edilmektedir (ISO27001, 2017). Bilgi güvenliği aynı zamanda ISO (International Organization for Standardization-Uluslararası Standardizasyon Kuruluşu) tarafından da dokümanlaştırılarak ISO 27001 Bilgi Güvenliği standartlarını oluşturmuştur. Bu durum hem şahıslar hem de kuruluşlar için bilgi güvenliğinin önemini göstermektedir. Bilgi güvenliği farklı alt alanlara ayrılmaktadır. Bunun en bilinen örneği Securisis firması tarafından yapılmıştır (Securisis, 2022). Firma bilgi güvenliğini yedi alt alana ayırarak incelemektedir. Bilgi güvenliği alt alanları Şekil 1’de gösterilmektedir.




Şekil 1. Bilgi güvenliği alt alanları.

Birçok kaynak tarafından da kullanılan bu sıralama genel olarak kabul edilmiştir (Önaçan ve Atan, 2016). Securisis firması bu yedi alanı da ayrıntılandırarak alt alanlar ile ilişkilendirmiştir. Şekil 2’de ağ güvenliği ve uç/son nokta/kullanıcı güvenliği, Şekil 3’te veri güvenliği, Şekil 4’te erişim yönetimi ve uygulama güvenliği, Şekil 5’de güvenlik yönetimi ve Şekil 6’da kimlik ve erişim yönetimi ile sanallaştırma ve bulut alt alanları gösterilmektedir.


Bilgi güvenliği kavramı ülkemizde de önem kazanmış ve Türkiye Cumhuriyeti Cumhurbaşkanlığı Dijital Dönüşüm Ofisi Temmuz 2020’de Bilgi ve İletişim Güvenliği Rehberi yayımlayarak farklı güvenlik tedbirlerini yaşamımıza dâhil etmiştir. Rehber tedbirleri üç ana alan altında toplamıştır. Bu üç ana tedbir alanı Şekil 7’de varlık gruplarına yönelik güvenlik tedbirleri, Şekil 8’de uygulama ve teknoloji alanlarına yönelik güvenlik tedbirleri ve son olarak Şekil 9’da sıkılaştırma tedbirleri olarak sınıflandırılmıştır (CBDDO, 2020).




Şekil 2. Ağ güvenliği ve uç/son nokta/kullanıcı güvenliği alt alanları.




Şekil 3. Veri güvenliği alt alanları.




Şekil 4. Erişim yönetimi ve uygulama güvenliği alt alanları.




Şekil 5. Güvenlik yönetimi alt alanları.




Şekil 6. Kimlik ve erişim yönetimi ile sanallaştırma ve bulut alt alanları.



Şekil 7. Varlık gruplarına yönelik güvenlik tedbirleri.



Şekil 8. Uygulama ve teknoloji alanlarına yönelik güvenlik tedbirleri.



Şekil 9. Sıkılaştırma tedbirleri.

4. ÇİZGE SİNİR AĞLARI VE SİBER GÜVENLİK

Mahremiyet kavramı her geçen gün önem kazanmaktadır. İnternet tabanlı teknolojilerin artması, cihazların boyutlarının küçülmesi ile sürekli taşınması ve ihlal ile maddi kazanç sağlanması durumları sebepleriyle güvenlik gereklilikleri daha da önemli hale gelmektedir. Güvenlik, her anlamda insan yaşamının sağlıklı bir şekilde geçirilmesi için önem arz etmektedir. İnternetin de bu duruma dâhil olması ile siber güvenlik kavramı şekillenmeye başlamıştır.


Siber güvenlik kavramının anlaşılabilmesi için öncelikle tanımlanması gereken kavramlar bulunmaktadır. İlk olarak 1984 yılında Gibson tarafından yazılan Neuromancer adlı kitap ile siber uzay kavramı hayatımıza girmiştir. Sonraki yıllarda yayımlanan eserler ile kavram bilgisayar bilimi ile ilişkilendirilmeye başlanmıştır. Kavram, alan ve dünya ile eş anlamlı kabul edilerek siber uzayın tanımı şekillenmeye başlamıştır. Siber uzay kavramı siber dünya ve siber alan olarak da adlandırılmaya başlanmıştır. Uluslararası alanda ise dünya ve uzaya yayılmış bilişim sistemleri ile bağlantılı ağlardan oluşan sayısal ortam olarak adlandırılmaktadır. Siber varlık, siber dünya içerisinde bulunan tüm nesneler olarak tanımlanmaktadır. Önek olarak doküman, plan, veri, sunucu ve bilgisayar verilebilir. Siber olay ise siber varlıkların etkileşim halinde olduğu durumlarda gerçekleşen olaylardır. Bu olaylar suç, zarar ve mağduriyet oluşturulabilmektedir. Bu durum karşısında siber savaş, siber tehdit, siber silah, siber terör ve siber casusluk kavramları da ortaya çıkmıştır. Kişisel ya da ulusal çıkarların korunması sebebiyle ancak ulusal menfaatlerin ön planda olduğu sistemlere zarar vermek için gerçekleştirilen siber savaş, casusluğun sanal ortamlarda gerçekleşmesi ile gerçekleştirilen siber casusluk, dijital saldırı ve savunma araçları olarak kullanılan siber silahlar, dijital ortamda terör faaliyetlerine destek verme ya da bu faaliyetleri dijital ortamı taşıyarak gerçekleştirilen siber terör kavramları hayatımıza siber güvenlik kavramı ile dahil olmuştur (Sağiroğlu ve Alkan, 2018). Ayrıca kavram günümüzde gelişerek siber istihbarat kavramını da oluşturmuştur. İstihbarat faaliyetlerinin dijital ortamlarda yapılması, sistemlere sızılarak bilgi edinilmesi ile siber istihbarat kavramı da gelişmektedir. Tanımsal olarak siber güvenlik kavramının dijital ve sanal ortamlarda güvenlik ve mahremiyet tanımına yaklaştığı

görülmektedir. Uluslararası düzeyde siber güvenlik teknolojiler bütünü olarak, ulusal stratejide ise siber uzay içerisinde gizlilik, güvenlik ve bütünlük sağlanması olarak tanımlanmıştır (Sağıroğlu ve Alkan, 2018). Dünya genelinde kavram derinleştirilerek yeni faaliyet alanları oluşturulmaktadır. Ulusal ve uluslararası kuruluşlarda dahil olmak üzere bir çok kişi kurumları ve şahıs firmaları siber güvenlik konusuna önem vermektedir. Ülkemizde Ulaştırma, Denizcilik ve Haberleşme Bakanlığı (UDHB), Bilgi Teknolojileri ve İletişim Kurumu (BTK), Telekomünikasyon İletişim Başkanlığı (TİB), Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK), Ulusal Siber Olaylara Müdahale Merkezi (USOM), Afet ve Acil Durum Yönetim Başkanlığı (AFAD), Türk Silahlı Kuvvetleri (TSK), Emniyet Genel Müdürlüğü, Jandarma Genel Komutanlığı ve birçok kuruluş kendi içerisinde siber güvenlik birimi kurarak kavramın önemini göstermiştir. Ayrıca siber tehdit gibi durumların suç olması sebebiyle Emniyet Genel Müdürlüğü bünyesinde Siber Suçlarla Mücadele Daire Başkanlığı, Jandarma Genel Komutanlığı bünyesinde Siber Suçlarla Mücadele Daire Başkanlığı kurulmuş ayrıca Türk Silahlı Kuvvetleri bünyesinde Siber Savunma Komutanlığı kurularak kavramın önemi vurgulanmıştır. Sadece suç olarak değil aynı zamanda artık bir cephe görevi görmekte olan siber güvenlik, anonimlik sebebiyle son zamanlarda Rusya – Ukrayna arasında tırmanan gerginlikte de önemini göstermiştir (Bıçakçı ve diğ., 2016). Ülkemiz siber güvenliğe son derece önem vermektedir. Geçmiş yıllardan başlanarak her geçen gün konu takip edilerek yeni çalışmalar yayımlanmaktadır. Tablo 3’te Türkiye’de siber güvenliğin gelişimi görülmektedir (Önaçan ve Atan, 2016; Aslay, 2017).

Tablo 3. Türkiye’de siber güvenliğin gelişimi.

Yıl	Durum
2012	Siber suçlarla mücadele BTK tarafından yapılmaktadır.
2012	Ulusal Siber Güvenlik Stratejisi ve 2013-2014 Eylem Planı yürürlüğe girdi.
2012	TSK Siber Savunma Merkezi Başkanlığı kuruldu.
2012	TUBİTAK Siber Güvenlik Enstitüsü kuruldu.
2012	Siber güvenlik yüksek lisans programı açıldı.
2013	UDHB tatbikat önerisinde bulundu.
2013	UDHB eğitim için gelişme gerekliliğini vurguladı.
2013	UDHB Siber Güvenlik Kurulu oluşturdu.
2013	USOM kuruldu.
2014	İlk siber güvenlik tatbikatı düzenlendi.
2016	Ulusal Siber Güvenlik Stratejisi ve 2016-2019 Eylem Planı yürürlüğe girdi.
2021	Siber güvenlik lisesi açıldı.
2023	Siber güvenlik meslek yüksekokulları açıldı.

Siber güvenlik alanı her sektör içerisinde yer edinirken bu durum eğitim sürecini de etkilemiştir. Yüksek lisans programları ve liseler açılırken, ACM (Association for Computing Machinery-Bilgisayar Makineleri Derneği) ve IEEE (Institute of Electrical and Electronics Engineers-Elektrik ve Elektronik Mühendisleri Enstitüsü) gibi uluslararası kuruluşlar da eğitim programları oluşturmaktadır. ACM 2013 yılında hazırladığı ve 2016 yılında yayımladığı Siber Güvenlik Eğitim ve Öğretimi için Müfredat Kılavuzu ile siber güvenliği altı farklı alana ayırmıştır (ACM, 2017; ACM, 2020). Şekil 10’da bu alanlar görülmektedir.



Şekil 10. ACM siber güvenlik alanları.

Farklı bir eğitim yaklaşımı ise siber güvenliği yine altı alan altında incelemiş ve hukuk ile strateji konularına daha fazla önem vererek milli güvenlik programını oluşturmuştur (Kessler ve Ramsay, 2014). Şekil 11’de milli güvenlik programının alt alanları görülmektedir.



Şekil 11. Milli güvenlik programı siber güvenlik alanları.

Çizge öğrenme ve GNN'ler siber güvenlik alanında farklı uygulamalarda kullanılmaktadır. Yaygın kullanım alanları; kötü amaçlı yazılım tespiti, kötü amaçlı yazılım analizi, dolandırıcılık tespiti, anormallik tespiti, istenmeyen posta tespiti, sahte inceleme/haber tespiti ve ağ trafiği analizidir. ResGCN ve GraphSAGE modelleri izinsiz giriş tespiti yapabilen modellere örnek olarak verilebilir.

Güvenlik açıkları sistemler için son derece tehlikeli zafiyet sorunları ortaya çıkarabilmektedir. Sistemlerin saldırılardan korunması ve güvenliğinin sağlanması gerekmektedir. Bu gereklilik için öncelik uzmanlardır. Uzman, kodu ve sistemi tarayarak zafiyet bulabilir fakat bu durum zaman isteyen ve zorlu bir süreçtir. ReGVD modeli, GNN ve doğal dil işleme için geliştirilmiş programlama dili olan CodeBERT kullanarak güvenlik açıkları tespiti yapabilmektedir. Dönüşüm tabanlı nöral mimari kullanan CodeBERT, hem programlama hem de doğal diller için eğitilmiştir. Düşüm özellikleri programlama diline girdi olarak işlenmesiyle izin ve belirteçten yararlanan bir çizge oluşturmaktadır. GNN modelinde katmanlar arası bağlantı oluşturarak çizge gömme gerçekleştirmektedir (Nguyen ve diğ., 2022).

Botnetler internet ortamlarında sıklıkla karşımıza çıkmaktadır. Botnet kullanım amaçlarından birisi de DDoS (Distributed Denial of Service-Dağıtılmış Hizmet Reddi) atakları ve spam saldırılarıdır. Geleneksel yöntemler zamansal zorluklar yarattığından otomatik tespit ihtiyacı doğmuştur. Hiyerarşik yapı ve merkeziyetsiz botnet için yapı yakalamada GNN kullanılmaktadır. Deneyler sonucu ağ güvenliği ile çizge öğrenmede başarı yakalayan modeller verimini kanıtlamıştır (Zhou ve diğ., 2020b).

Bilgi çizgeleri siber güvenlikte bilgi toplanmasına yardımcı olmaktadır. CKG (Cybersecurity Knowledge Graph-Siber Güvenlik Bilgi Çizgesi), akıl yürütme ile sorgulama sistemi olan SPARQL ile birleştirilerek gelecek tahmini ve geçmişten bilgi çıkarımı yapılmaktadır. CKG'ler arasında konu-nesne ilişkisi bulunmaktadır. Grafiğe gelen bilgiler veri kaynağı ile eşdeğerdir. Doğruluk durumunu veri belirlemekte ve öne sürülen bilgilerin doğruluğu tartışmaya açıktır. Dasgupta ve diğ. (2021) tarafından yapılan çalışmadaki işlemde denetimli öğrenme kullanılarak GCN'den yardım alınmıştır. Model başarılı olsa da gelecekteki yeni saldırılar ve sıfır gün açıklıkları için belirsizlik göstermektedir.


İzinsiz giriş algılama siber güvenlik için önemli konulardan birisi olmaktadır. Bilgi çizgeleri yardımı ile veri entegre etme yeteneği kullanan modeller, bağlantı tahmini görevini kullanarak giriş tespiti işlemini gerçekleştirmek istemektedir. İlgili model ilk denemesini denetimsiz öğrenme ile gerçekleştirmiş ve verimli bir sonuç ortaya çıkarmıştır (Garrido ve diğ., 2021). Bir benzer durum da Oracle veri tabanında çizge sunucusunun Python istemcisi olan OPG4Py ve Oracle makine öğrenme ara yüzü olan OML4Py arasında gerçekleşmektedir. İşlem ile izinsiz giriş algılama gerçekleştirilebilmektedir (Yamanaka, 2021).

Sadece GNN modelleri değil genelleştirilmiş derin öğrenme modelleri de siber güvenlik alanında kullanılmaktadır. Genellikle kötü amaçlı yazılım tespiti, kimlik avı, spam tespiti, izinsiz giriş tespiti ve web sitesi tahrip tespiti için geliştirilen modeller popülerleşmektedir (MahdaviFar ve Ghorbani, 2019). Klasik makine öğrenmesine karşı derin öğrenme modelleri klasik yapay zekadan daha başarılı olmuşlardır. Derin öğrenmenin gelişmesiyle siber güvenlik yöntemleri de gelişim göstermiştir. Vinayakumar ve diğ. (2020) tarafından geliştirilen çalışmada saldırı tespiti, kötü amaçlı yazılım ve botnet tespiti, istenmeyen posta ve kimlik avı tespiti, ağ trafiği analizi, ikili analiz, içeriden gelen tehdit tespiti, CAPTCHA analizi, steganografi, kriptografi, bulut güvenliği, biyometrik güvenlik, nesnelerin interneti tabanlı akıllı şehirler, sis hesaplama, sinyal ve görüntü işleme, blok zinciri teknolojisi, büyük veri ve doğal dil işleme alanları arasında kapsamlı bir inceleme yapılmıştır. İnceleme sonucu modellerin geliştirilmesinde sınır bulunmadığı fakat hala bu konular üzerinde çalışmalar yapılması gerektiği belirtilmiştir.

IoT (Internet of Things-Nesnelerin İnterneti) etrafımızda bulunan ve dijital bağlantısı bulunarak internet erişimi gerçekleştiren cihazlar olarak tanımlanabilmektedir. IoT teknoloji her geçen gün gelişirken siber güvenlik açıkları da bir o kadar artmaktadır. Bir çok IoT cihazının güvenlik açıkları sebebiyle saldırılara karşı dayanıklılığı zayıftır. DDoS saldırıları sadece bilgisayarlar üzerinde değil IoT cihazları üzerinde de etkili olmaktadır. Bu sebeple Roopak ve diğ. (2019) tarafından yapılan çalışmada IoT cihazları için DDoS atak tespit yapabilen bir model geliştirilmiştir. Diğer bir çalışmada (Protogerou ve diğ., 2021), IoT cihazların açıklıkları sebebiyle bu cihazlara güvenin azaldığı belirtilmiş ve anomali tespiti için bir model önerilmiştir. Model akıllı ajanlar için GNN modelleri ile zenginleştirilerek DDoS saldırılarına karşı verimli bir performans sergilemiştir. GNN modellerinin IoT üzerinde kullanılmasının bir başka amacı da anomali tespitidir. IoT veri toplama ile veri analizi ve otomatikleştirme sorunlarını basitleştirmektedir. Bu sayede üretkenlik ve verimlilik artmaktadır. Wu ve diğ. (2021) tarafından geliştirilen model, dinamik biçimde gelişen ağlar dışında endüstri, enerji, ulaşım ve akıllı sistemlerde de anomali tespiti gerçekleştirmektedir. Modelin GNN kullandığı ve verimli bir performans gösterdiği görülmüştür.

5. ÇİZGE SİNİR AĞLARI VE ADLİ BİLİŞİM

Günümüzde internet teknolojilerinin gelişimi olumlu katkılarıyla birlikte olumsuz durumları da beraberinde getirmektedir. Bu olumsuz yönlerden biriside bilişim suçlarıdır. Bilişim suçları, dijital ortamlarda yetki dışında gerçekleşen ahlak ve etik dışı eylemler olarak tanımlanabilir. Dünya genelinde polis birlikleri bu suça karşı mücadele etmekte, bireyler ise eğitimler ile farkındalık kazanmaktadır. Bilişim suçları farklı gruplara göre sınıflandırılabilir. Genel anlamda bozma, silme, yok etme gibi zarara uğraticı durumlar ele alınmaktadır. Bu durum karşısında ise suç kapsamında delil analizi ihtiyacı doğmuştur. Bu ihtiyaç adli bilişim adı ile anılan çok disiplinli bir bilim alanı sayesinde gerçekleştirilmektedir. Kelime anlamı olarak adli bilişim; dijital, elektronik, elektromanyetik ve optik ortamlarda saklanan ve yine bu ortamlar tarafından iletilen bilişim nesnelerinin hukuk karşısında sayısal delil niteliği taşıması ile tanımlama, elde edilme, saklanma, inceleme sonucu mahkeme huzuruna sunulması sürecinin tamamı olarak tanımlanabilmektedir. Adli bilişim analizi bir nevi tersine mühendislik ve beyaz şapkalı hackerlik ile aynı durumdadır. İşlenecek suçun çözülebilmesi için öncelikle suçun nasıl oluşturulduğu bilinmelidir. Analiz yapacak olan kişiler ise suçu işleyecek teknik bilgiye sahip olmalarına rağmen bu suçu işlememektedir. Bilişim sistemlerinin gelişmesi ile dijital suçlardaki artışa karşı geliştirilen adli bilişim kavramı, hukukun sağlanabilmesi ve suç-masumiyet kavramlarının insan özneline gerçekleştirebilmesi için önem arz etmektedir. Dijital delil kavramı adli bilimler kapsamında suç ispat edecek kanıt niteliği taşıyan objedir. Dijital ortamda iz silmek kolay gibi görünse de bu durum aslında siber güvenlikte bulunan anonimlik durumundan farklıdır. Adli bilişimde en önemli etmenlerden birisi de hukuk bilgisidir. Kişisel cihaza erişmek her ne kadar suç olsa da analiz için gerekli hukuksal düzenlemeler Ceza Muhakemesi Kanunu 134. Maddesinde yasal olarak uzmana izin verecek şekilde düzenlenmiştir. Bu izin karşısında uzman hukuksal çerçevede içerisinde mesleğinin gereğini yapabilmektedir. Adli bilişim; disk analizi, cep telefonu analizi, GSM analizi, ağ analizi ve bellek analizi olarak ayrılabilir (BGA Security, 2011; Ahi, 2009; Dülger, 2017). Şekil 12’de adli bilişim süreci gösterilmektedir.



Şekil 12. Adli bilişim süreci.

Adli bilişim bilgi sistemlerinde dijital delil elde etme amacıyla varlığını sürdüren bir bilim dalıdır. GNN'ler analiz görevlerini başarı ile yerine getirmektedir. Bu iki alan incelendiğinde ortak noktalarının bulunduğu ve bu kavramların siber güvenlik alanı için de son derece önemli olduğu görülmektedir. GNN'lerde yeni gelişen görevler bulunmaktadır. Çekirdek algılama, adli bilişimde bellek analizi ve bellek dökümü bu görevlerdendir. Song ve diğ. (2018) tarafından bu görevler temelinde geliştirilen DeepMEM modelinin amacı art niyet ile suç belirten davranışlarda delil toplamaktır. İmza ve çapraz liste yaklaşımı zorluklarını aşan DeepMEM, topoloji bilgisi ile yeniden yapılandırma, bellek grafiğine düğüm gömme ve farklı kısımlardan toplanmış nesneleri çapraz doğrulama ile analiz edebilmektedir. Ayrıca etiket manipülasyonu ve işlem gizleme saldırılarına karşı direnç göstermektedir.

Spam mailler insanlar için güvenlik sorunu teşkil etmektedir. GNN modelleri ile zenginleştirilen DeG-Spam modeli, spam gönderenin tespitini gerçekleştirebilmektedir. Bu tespiti ara ve içsel ilişkileri ayrı ayrı modelleyerek gerçekleştirmektedir (Guo ve diğ., 2021).

Adli bilişim ham bellekte bulunan verileri delil olarak kullanabilmektedir. Bellek dökümü görevi bu sebeple önem arz etmektedir. NoSyms modeli sinir ağı kullanarak veri yapısı tespiti gerçekleştirmektedir. Eğitim için hata ayıklama kullanan NoSyms, Linux tabanlı sistemlerde çekirdek bellek içerisinde veri yapısı tespiti işlemini gerçekleştirmektedir (Beierl, 2018).

Adli bilişim uzmanları, dijital eser eşleştirme ve olay sırası algılama için veri gösterimi ve veri normalleştirme yöntemlerini boyut azaltmak için kullanabilmektedir. Varlık işlemede büyük disklerden kaynaklanan hesaplama sorunu oluşmaktadır. Bu soruna karşı olarak PGER (Property Graph Event Reconstruction-Özellik Grafiği Yeniden Olay İnşası) modeli geliştirilmiştir (Schelkoph ve diğ., 2019).

Adli bilişimde görselleştirme işlemi ağlar üzerinde analizi kolaylaştırabilmektedir. Jiang ve diğ. (2018c) tarafından elde bulunan yöntemlerin yetersiz olması sebebiyle AOI-FIM (Attribute-Oriented Induction-based Frequent-Item Mining-Öznitelik Yönelimli Tümevarım Tabanlı Sık Madde Madenciligi) algoritması ile görselleştirme çerçevesi önerilmiştir. Bu algoritmaya ek olarak hiper çizgeleri kullanan model başarılı olmuş ve kolaylık sağlamıştır.

Adli bilişim aynı zamanda kötü amaçlı yazılım konusu ile de ilgilenmektedir. Karamitsos ve diğ. (2020) tarafından geliştirilen model temelinde DRNN (Deep Recurrent Neural Network-Derin Tekrarlayan Sinir Ağı) ve LSTM (Long Short Term Memory-Uzun Kısa Süreli Bellek) ile geliştirilmiştir. LSTM modeline ek olarak dikkat katmanı ve çift yönlülük eklenmiştir. Bu sayede verim artmış ve model başarıya ulaşmıştır.

Ağ analizi, adli bilişim için önemli görevlerden birisi olmuştur. Wang ve diğ. (2008) tarafından geliştirilen modelde ağ analizi yaklaşımında delil sunma ve otomatik akıl yürütmeye dayalı kanıt grafiği bulunmaktadır. Grafiğe dayanarak iki seviye hiyerarşik akıl yürütme kullanılmaktadır. Küresel akıl yürütme saldırı senaryosu ve varlık tanımlama yaparken, bölgesel akıl yürütme çıkarımı yapmaktadır. Çalışma saldırgan tarafından kapalı saldırı gerçekleştirilmede diğer deliller ile anlamlandırma sağlayarak saldırgan tespiti için kullanılan hipotez testine odaklanmaktadır.

Saldırı tahmini GNN modelleri için önemli bir konu olmuştur. Zhang ve diğ. (2021a) tarafından yapılan çalışmada GNN modellerine arka kapı saldırısı yapılarak tahmin özelliği test edilmiştir. Tahminler sonucu GNN modelleri yarı etkili durumda kalmış bu sebeple arka kapı saldırılarına karşı başarısız olunmuştur.

Yapısal öğrenim adli bilişim için önemli konulardan biridir. Çizge öğrenmede geçerli olan zorluklar adli bilişimde de aynı modellerin kullanılması ile sorun teşkil etmektedir ve verim düşmektedir. Delil niteliği taşıması sebebiyle adli bilişim doğruluğa yüksek önem vermektedir. Beishuizen (2018) tarafından gerçekleştirilen çalışmada pratikte kullanılan verilerin deneyler esnasında teoride kullanılması savunulmaktadır. Temsil öğrenme ile bu sorunları çözen bir model geliştirilmiş ve verim artırılmıştır.

Teknolojinin gelişmesi verilerin sadece USB, SD, CD ya da SSD vb. ile saklanması ortadan kaldırmış ve internet depolama olarak bilinen bulut depolama kavramını da yaşamımıza sokmuştur. Adli bilişim analizinde bulut bilişimden delil elde etmek önemli bir hale gelmiştir. Bu nedenle bulut bilişim üzerine çok sayıda çalışma yapılmaktadır. Simou ve diğ. (2016) tarafından yapılan araştırmada bu çalışmalar karşılaştırılarak gelecek çalışmalara yol gösterilmiştir. Bulut bilişimde adli bilişim analizi esnasında karşılaşılan zorluklara değinilmiş ve bu zorlukların çözümleri anlatılarak yeni geliştirilecek olan modeller için yol göstermek hedeflenmiştir.

6. SONUÇ VE GELECEK ÇALIŞMALAR

GNN'lerin keşfi, çizge yapılı verilerle ilişkili karmaşık sorunlara yaklaşım ve çözüm şeklimizi dönüştürmüştür. Bu çalışmada, GNN'lerin düğüm sınıflandırması, bağlantı tahmini, çizge sınıflandırması ve topluluk tespiti gibi görevlerdeki çok yönlülüğüne ışık tutularak çeşitli görev tanımlarına değinilmiştir. GNN'lerin çeşitli alanlara uyarlanabilirliği açıktır ve bu da onları makine öğrenimi uygulayıcılarının ve araştırmacılarının odağı haline getirmiştir. Bu çalışmada ele alınan görev tanımları, GNN'lerin çizge veriler içindeki karmaşık ilişkileri ve bağımlılıkları yakalama yeteneğini göstermekte ve altta yatan yapıların bütünsel bir anlayışını sunmaktadır. Bu sadece tahmin yeteneklerini geliştirmekle kalmamakta, aynı zamanda birbirine bağlı sistemlerin karmaşık dinamikleri hakkında değerli bilgiler sağlamaktadır. Ayrıca bu çalışmada incelenen eşleştirmeler, GNN'lerin gerçek dünya sorunlarına uygulanabileceği yolları vurgulamaktadır. GNN'lerin potansiyel uygulamaları sosyal ağ analizinden tavsiye sistemlerine kadar çok geniş bir alana yayılmaktadır ve genişlemeye devam etmektedir.

Geleneksel GNN uygulamaları alanının ötesinde, GNN'lerin bilgi güvenliği, siber güvenlik ve adli bilişim ile beraber kullanılması, birbirine bağlı sistemlerin güvenliğini sağlama anlayışımıza yeni bir boyut getirmektedir. GNN'lerin bu alanlara dahil edilmesi yalnızca anomali tespiti ve tehdit analizini geliştirmekle kalmaz, aynı zamanda dijital adli bilişim soruşturmalarındaki karmaşık modellerin çözülmesinde de önemli bir rol oynamaktadır. GNN'ler birbirine bağlı sistemlerdeki güvenlik açıklıklarının belirlenmesi ve azaltılması için bilgi güvenliği alanında sağlam bir çerçeve ortaya koymaktadır. Karmaşık ağlardaki ilişkileri modelleme ve analiz etme yetenekleri, potansiyel güvenlik tehditlerini tahmin etmeye yardımcı olmakta ve böylece siber saldırılara karşı savunma mekanizmalarını güçlendirmektedir. GNN'ler hassas bilgileri ve kritik altyapıları korumak için devam eden siber savaşta zorlu bir destekçi olarak durmaktadır. GNN'lerin adli bilişim ile birlikteliği, dijital soruşturmalarda bir paradigma değişikliğine yol açmaktadır. GNN'lerin çizge yapılı verileri anlama ve yorumlama konusundaki doğal yeteneklerinden yararlanan adli bilişim uzmanları, dijital ayak izlerini takip etmek, olayları yeniden yapılandırmak ve farklı kanıt parçalarını birbirine bağlamak için güçlü bir araç kazanmaktadır. Bu sinerji, soruşturma sürecini hızlandırarak daha verimli ve etkili adli analizlere katkıda bulunmaktadır. GNN'ler sadece teknolojik bir dönüm noktası olarak değil, aynı zamanda farklı disiplinlerdeki yenilikler için bir katalizör olarak ortaya çıkmaktadır. GNN'lerin bilgi güvenliği, siber güvenlik ve adli bilişim ile birleşmesi, bu alanın disiplinler arası doğasını örneklendirmekte ve birbirine bağlı sistemleri anlama, analiz etme ve güvence altına alma şeklimizin geleceğini şekillendirme potansiyelini vurgulamaktadır.

Sonuç olarak, bu makale GNN'lerin dönüştürücü etkisinin altını çizmektedir. Ayrıca çizge ile ilgili temel görevlerin ele alınmasından dijital ekosistemlerimizin korunmasına kadar, GNN'lerin çok yönlü ve vazgeçilmez bir araç olduğu vurgulanmaktadır. İleriye bakıldığında, GNN'lerin çeşitli alanlara entegrasyonunun; yapay zeka, veri bilimi ve güvenlik alanlarında yeni sınırların aşılmasına yol açacağı düşünülmektedir. GNN'lerin bilgi güvenliği, siber güvenlik ve adli bilişim alanlarındaki mevcut durumu kayda değer ilerlemeler sergilemiş olsa da gelecek çalışmalar şu konulara odaklanabilir: güvenlik uygulamalarında GNN sağlamlığının artırılması, dinamik ve gelişen çizgeler, gizliliği koruyan GNN'ler, disiplinlerarası işbirliği, açıklanabilirlik ve yorumlanabilirlik, gerçek zamanlı ve ölçeklenebilir uygulamalar, etik hususlar ve önyargı azaltma, gelişen teknolojilerle entegrasyon.

KAYNAKLAR

- Abu-El-Haija, S., Kapoor, A., Perozzi, B., Lee, J. (2018). N-GCN: Multi-scale Graph Convolution for Semi-supervised Node Classification. In Proceedings of the 32nd International Conference on Neural Information Processing System, December, pp. 9198-9208.
- ACM. (2017). Cybersecurity Curricula 2017: Curriculum Guidelines for Post-Secondary Degree Programs in Cybersecurity. Association for Computing Machinery, New York, NY, United States, ISBN: 978-1-4503-8919-8.
- ACM. (2020). Cybersecurity Curricular Guidance for Associate-Degree Programs. Association for Computing Machinery, New York, NY, United States, ISBN: 978-1-4503-7555-9.
- Ahi, M.G. (2009). Adli Bilişim Nedir?. Güncel Hukuk Dergisi, Mart 2009.
- Alom, Z., Hasan, M., Yakopcic, C., Taha, T.M. (2015). Inception Recurrent Convolutional Neural Network for Object Recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June.

Alom M.Z., Sidike P., Hasan M., Taha T.M., Asari V.K. (2017). Handwritten Bangla Character Recognition Using the State-of-the-Art Deep Convolutional Neural Networks. *Computational Intelligence and Neuroscience*, vol. 2018, no. 1, p. 6747098.

Antoniadis, P., Filntisis, P.P., Maragos, P. (2021). Exploiting Emotional Dependencies with Graph Convolutional Networks for Facial Expression Recognition. In *Proceedings of the 2021 16th IEEE International Conference on Automatic Face and Gesture Recognition*.

Anwaar, M.U., Han, Z., Arumugaswamy, S., Khan, R.A., Weber, T., Qiu, T., Shen, H., Liu, Y., Kleinstaub, M. (2020). Metapath- and Entity-aware Graph Neural Network for Recommendation. In *Proceedings of the 1st Workshop on Multimedia Computing towards Fashion Recommendation*, October, pp. 3-10.

Arya, D., Gupta, D.K., Rudinac, S., Worring, M. (2020). HyperSAGE: Generalizing Inductive Representation Learning on Hypergraphs. *arXiv:2010.04558*.

Ashraf, A.W.U., Budka, M., Musial, K. (2019). Simulation and Augmentation of Social Networks for Building Deep Learning Models. *Future Internet*, vol. 14, no. 3, p. 93.

Aslay, F. (2017). Siber Saldırı Yöntemleri ve Türkiye'nin Siber Güvenlik Mevcut Durum Analizi. *International Journal of Multidisciplinary Studies and Innovative Technologies*, vol. 1, no. 1, pp. 24-28.

Atwood, J., Towsley, D. (2016). Diffusion-Convolutional Neural Networks. In *Proceedings of the 29th Conference on Neural Information Processing Systems*, Barcelona, Spain, pp. 1993-2001.

Aykas, D., Mehrkanon, S. (2021). Multistream Graph Attention Networks for Wind Speed Forecasting. In *Proceedings of the 2021 IEEE Symposium Series on Computational Intelligence*, pp. 1-8.

Bai, H., Chan, S.H.G. (2021). Motion-guided Non-local Spatial-Temporal Network for Video Crowd Counting. *arXiv:2104.13946*.

Beierl, N. (2021). NoSyms: A neural network approach to detecting data structures in raw memory. *OpenAIRE*, doi: 10.5281/zenodo.4977243.

Beishuizen, M. (2018). Structural graph learning in real-world digital forensics. Master's Thesis, Artificial Intelligence, University of Groningen, Netherlands.

Berrendorf, M., Faerman, E., Melnychuk, V., Tresp, V., Seidl, T. (2020). Knowledge Graph Entity Alignment with Graph Convolutional Networks: Lessons Learned. In *Proceedings of the Advances in Information Retrieval: 42nd European Conference on IR Research*, Lisbon, Portugal, April 14-17, pp. 3-11.

BGA Security (2011). Bilişim Sistemlerinde Adli Bilişim Analizi ve Bilgisayar Olayları İnceleme. <https://www.bgasecurity.com/makale/bilisim-sistemlerinde-adli-bilisim-analizi-ve-bilgisayar-olaylari-inceleme/>

Bhattacharya, U., Mittal, T., Chandra, R., Randhavane, T., Bera, B., Manocha, D. (2019). STEP: Spatial Temporal Graph Convolutional Networks for Emotion Perception from Gaits. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 2, pp. 1342-1350.

Bıçakçı, S., Ergun, F.D., Çelikpala, M. (2016). Türkiye'de Siber Güvenlik. *Türkiye'de Siber Güvenlik ve Nükleer Enerji*, pp. 28-73.

Bianco, S. (2017). Large age-gap face verification by feature injection in deep networks. *Pattern Recognition Letters*, vol. 90, pp. 36-42.

Bratholm, L.A., Gerrard, W., Anderson, B., Bai, S., Choi, S., Dang, L., ... Glowacki, D.R. (2021). A community-powered search of machine learning strategy space to find NMR property prediction models. *PLOS ONE*, vol. 16, no. 7, p. e0253612.

Broccatelli, F., Trager, R., Reutlinger, M., Karypis, G., Li, M. (2022). Benchmarking Accuracy and Generalizability of Four Graph Neural Networks Using Large In Vitro ADME Datasets from Different Chemical Spaces. *Molecular Informatics*, vol. 41, no. 8, p. 2100321.

- Cachay, S.R., Ramesh, V., Cole, J.N.S., Barker, H., Rolnick, D. (2021). ClimART: A Benchmark Dataset for Emulating Atmospheric Radiative Transfer in Weather and Climate Models. *NeurIPS Datasets and Benchmarks*. arXiv:2111.14671.
- Cai, D., Lam, W. (2020). Graph Transformer for Graph-to-Sequence Learning. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 5, pp. 7464-7471.
- Caramalau, R., Bhattarai, B., Kim, T.K. (2021). Sequential Graph Convolutional Network for Active Learning. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 9583-9592.
- CBDDO. (2020). Bilgi ve İletişim Güvenliği Rehberi. Türkiye Cumhuriyeti Cumhurbaşkanlığı Dijital Dönüşüm Ofisi.
- Cetoli, A., Bragaglia, S., O'Harney, A.D., Sloan M. (2017). Graph Convolutional Networks for Named Entity Recognition. In *Proceedings of the 16th International Workshop on Treebanks and Linguistic Theories*, Prague, Czech Republic, pp. 37-45.
- Chaiaing, W.L., Liu, X., Si, S., Li, Y., Bengio, S., Hsieh, C.J. (2019). Cluster-GCN: An Efficient Algorithm for Training Deep and Large Graph Convolutional Networks. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, July 2019, pp. 257-266.
- Chami, I., Ying, R., Re, C., Leskovec, J. (2019). Hyperbolic Graph Convolutional Neural Networks. In *Proceedings of the 33rd Conference on Neural Information Processing Systems*, Vancouver, Canada, pp. 1-12.
- Chang, S., Park, S.U., Yang, J., Kwak, N. (2019). Sym-Parameterized Dynamic Inference for Mixed-Domain Image Translation. In *Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision*, pp. 4802-4810.
- Chang, L., Branco, P. (2021). Graph-based Solutions with Residuals for Intrusion Detection: the Modified E-GraphSAGE and E-ResGAT Algorithms. arXiv:2111.13597.
- Chen, L.C., Papandreou, G., Kokkinos, K., Murphy, K., Yuille, A.L. (2017a). DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, no. 4, pp. 834-848.
- Chen, J., Yuan, C., Deng, M., Tao, C., Peng, J., Li, H. (2017b). On the Selective and Invariant Representation of DCNN for High-Resolution Remote Sensing Image Recognition. arXiv:1708.01420.
- Chen, K., Lin, Z., Wan, J., Xu, L., Xu, C. (2019a). Multi-owner Secure Encrypted Search Using Searching Adversarial Networks. In *Proceedings of the International Conference on Cryptology and Network Security*, pp. 184-195.
- Chen, C., Hu, S., Nikdel, P., Mori, G., Sava, M. (2019b). Relational Graph Learning for Crowd Navigation. In *Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 10007-10013.
- Chen, B., Barzilay, R., Jaakkola, T. (2019c). Path-Augmented Graph Transformer Network. arXiv:1905.12712.
- Chen, Z., Wei, X., Wang, P., Guo, Y. (2019d). Multi-Label Image Recognition with Graph Convolutional Networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 5177-5186.
- Chen, L., Li, Z., Wang, Y., Xu, T., Wang, Z., Chen, E. (2020a). MMEA: Entity Alignment for Multi-Modal Knowledge Graphs. In *Proceedings of the 13th International Conference on Knowledge Science, Engineering and Management*, Hangzhou, China, August 28-30, pp. 134-147.
- Chen, L., Wu, L., Hong, R., Zhang, K., Wang, M. (2020b). Revisiting Graph based Collaborative Filtering: A Linear Residual Graph Convolutional Network Approach. In *Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence*, pp. 27-35.

- Chen, X., Morehead, M., Liu, J., Cheng, J. (2021). DProQ: A Gated-Graph Transformer for Protein Complex Structure Assessment. arXiv:2205.10627.
- Choi, J., Choi, H., Hwang, J., Park, N. (2021). Graph Neural Controlled Differential Equations for Traffic Forecasting. arXiv:2112.03558.
- Craandijk, D., Bex, F. (2020). Deep Learning for Abstract Argumentation Semantics. Craandijk, D., Bex, F. (2020). Deep Learning for Abstract Argumentation Semantics. In Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence, pp. 1667-1673.
- Creagh, A.P., Lipsmeier, F., Lindemann, M., Vos, M.D. (2021). Interpretable Deep Learning for the Remote Characterisation of Ambulation in Multiple Sclerosis using Smartphones. Scientific Reports, vol. 11, no. 1, p. 14301.
- Cucurull, G., Taslakian, P., Vazquez, D. (2019). Context-Aware Visual Compatibility Prediction. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 12617-12626.
- Cui, S., Yu, B., Liu, T., Zhang, Z.Y., Wang, X., Shi, J. (2020). Edge-Enhanced Graph Convolution Networks for Event Detection with Syntactic Relation. arXiv:2002.10757.
- Dasgupta, S., Piplai, A., Ranade, P., Joshi, A. (2021). Cybersecurity Knowledge Graph Improvement with Graph Neural Networks. In Proceedings of the 2021 IEEE International Conference on Big Data, pp. 3290-3297.
- Dasoulas, G., Scaman, K., Virmaux, A. (2021). Lipschitz Normalization for Self-Attention Layers with Application to Graph Neural Networks. In Proceedings of the International Conference on Machine Learning, pp. 2456-2466.
- Degardin, B., Neves, J., Lopes, V., Brito, J., Yaghoubi, E., Proença, H. (2021). Generative Adversarial Graph Convolutional Networks for Human Action Synthesis. In Proceedings of the 2022 IEEE/CVF Winter Conference on Applications of Computer Vision, pp. 2753-2762.
- Dehmamy, N., Barabasi, A.L., Yu, R. (2019). Understanding the Representation Power of Graph Neural Networks in Learning Graph Topology. In Proceedings of the 33rd Conference on Neural Information Processing Systems, Vancouver, Canada, pp. 1-11.
- Dewan, A., Burgard, W. (2020). DeepTemporalSeg: Temporally Consistent Semantic Segmentation of 3D LiDAR Scans. In Proceedings of the 2020 IEEE International Conference on Robotics and Automation, pp. 2624-2630.
- Ding, J., Li, A., Hu, Z., Wang, L. (2017). Accurate Pulmonary Nodule Detection in Computed Tomography Images Using Deep Convolutional Neural Networks. arXiv:1706.04303.
- Dong, S., Li, R. (2019). Traffic identification method based on multiple probabilistic neural network model. Neural Computing and Applications, vol. 31, pp. 473-487.
- Dong, H., Chen, J., Feng, F., He, X., Bi, S., Ding, Z., Cui, P. (2020). On the Equivalence of Decoupled Graph Convolution Network and Label Propagation. In Proceedings of the Web Conference 2021, New York, NY, USA, pp. 3651-3662.
- Dou, Y., Shu, K., Xia, C., Yu, P.S., Sun, L. (2021). User Preference-aware Fake News Detection. In Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 2051-2055.
- Dutta, S., Ma, L., Saha, T.K., Lu, D., Tetreault, J., Jaimes, A. (2021). GTN-ED: Event Detection Using Graph Transformer Networks. arXiv:2104.15104.
- Dülger, M.V. (2017). Adli Bilişim & Ülkemizde Uygulaması. H+ Dergi, Haziran 2017, pp. 20-25.
- Dwivedi, V.P., Bresson, X. (2021). A Generalization of Transformer Networks to Graphs. arXiv:2012.09699.

- Elinas, P., Bonilla, E.V., Tiao, L. (2020). Variational Inference for Graph Convolutional Networks in the Absence of Graph Data and Adversarial Settings. *Advances in Neural Information Processing Systems*, vol. 33, pp. 18648-18660.
- Engelcke, M., Kosiorek, A.R., Parker Jones, O., Posner, I. (2020). GENESIS: Generative Scene Inference and Sampling with Object-Centric Latent Representations. *arXiv:1907.13052*.
- Erharter, G.H., Hansen, T.F., Liu, Z., Marcher, T. (2021). Reinforcement learning based process optimization and strategy development in conventional tunneling. *Automation in Construction*, vol. 127, p. 103701.
- Fan, Y., Ju, M., Hou, S., Ye, Y., Wan, W., Wang, K., Mei, Y., Xiong, Q. (2021). Heterogeneous Temporal Graph Transformer: An Intelligent System For Evolving Android Malware Detection. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, August, pp. 2831-2839.
- Feng, Y., You, H., Zhang, Z., Ji, R., Gao, Y. (2018). Hypergraph neural networks. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, no. 1, pp. 3558-3565.
- Feng, F., He, X., Tang, J., Chua, T.S. (2019). Graph Adversarial Training: Dynamically Regularizing Based on Graph Structure. *IEEE Transactions on Knowledge and Data Engineering* vol. 33, pp. 2493-2504.
- Gao, J., Zhang, T., Xu, C. (2019a). Graph Convolutional Tracking. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 4649-4659.
- Gao, H., Chen, Y., Ji, S. (2019b). Learning Graph Pooling and Hybrid Convolutional Operations for Text Representations. In *Proceedings of the World Wide Web Conference*, pp. 2743-2749.
- Gao, Z., Tan, C., Li, S.Z. (2022). AlphaDesign: A graph protein design method and benchmark on AlphaFoldDB. *arXiv:2202.01079*.
- Garrido, J.S., Dold, D., Frank, J. (2021). Machine learning on knowledge graphs for context-aware security monitoring. In *Proceedings of the 2021 IEEE International Conference on Cyber Security and Resilience*, pp. 55-60.
- Ge, Z.Y., Bewlwy, A., Mccool, C., Upcroft, B., Corke, P., Sanderson, C. (2016). Fine-Grained Classification via Mixture of Deep Convolutional Neural Networks. In *Proceedings of the 2016 IEEE Winter Conference on Applications of Computer Vision*, pp. 1-6.
- Ghorbani, M., Baghshah, M.S., Rabiee, H.R. (2018). MGCN: Semi-supervised Classification in Multi-layer Graphs with Graph Convolutional Networks. In *Proceedings of the 2019 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, pp. 208-211.
- Gilmer, J., Schoenholz, S.S., Riley, P.F., Vinyals, O., Dahl, G.E. (2017). Neural Message Passing for Quantum Chemistry. In *Proceedings of the International Conference on Machine Learning*, pp. 1263-1272.
- Gokden, B. (2021). Power Law Graph Transformer for Machine Translation and Representation Learning. *arXiv:2107.02039*.
- Guo, Z., Tang, L., Guo, T., Yu, K., Alazab, M., Shalaginov, A. (2021). Deep Graph neural network-based spammer detection under the perspective of heterogeneous cyberspace. *Future Generation Computer Systems*, vol. 117, pp. 205-218.
- Gümüş, H.T., Eyüpoğlu, C. (2023). Grafik Sinir Ağlarına Genel Bir Bakış. *EMO Bilimsel Dergi*, vol. 13, no. 2, pp. 39-56.
- Gümüş, H.T., Eyüpoğlu, C. (2024). Grafik Sinir Ağları Üzerine Bir İnceleme. *Savunma Bilimleri Dergisi*, vol. 20, no. 1, pp. 105-138.
- Hamilton, W.L., Ying, R., Leskovec, L. (2017). Inductive representation learning on large graphs. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, CA, USA, pp. 1-11.

- Han, Y., Karunasekera, S., Leckie, C. (2020) Graph Neural Networks with Continual Learning for Fake News Detection from Social Media. arXiv:2007.03316.
- Han, X. (2017). MR-based synthetic CT generation using a deep convolutional neural network method. *Medical Physics*, vol. 44, no. 4, pp. 1408-1419.
- Harley, A.W., Derpanis, K.G., Kokkinos, I. (2015). Learning Dense Convolutional Embeddings for Semantic Segmentation. arXiv:1511.04377.
- He, J., Erfani, S., Wijewickrema, S., O’Leary, S., Ramamohanarao, K. (2020). Learning Non-Unique Segmentation with Reward-Penalty Dice Loss. In *Proceedings of the 2020 International Joint Conference on Neural Networks*, pp. 1-8.
- Hejazi, F., Vuckovic, K., Rahnavard, N. (2021). DyLoc: Dynamic Localization for Massive MIMO Using Predictive Recurrent Neural Networks. In *Proceedings of the IEEE INFOCOM 2021 - IEEE Conference on Computer Communications*, pp. 1-9.
- Huang, J., Shen, H., Hou, L., Cheng, X. (2019). Signed Graph Attention Networks. In *Proceedings of the Artificial Neural Networks and Machine Learning–ICANN 2019: Workshop and Special Sessions: 28th International Conference on Artificial Neural Networks, Munich, Germany, September 17-19*, pp. 566-577.
- Huang, Z., Chen, X., Wang, B. (2023). DHSEGATs: Distance and Hop-wise Structures Encoding Enhanced Graph Attention Networks. *Journal of Systems Engineering and Electronics*, vol. 34, no. 2, pp. 350-359.
- Huo, Y., Xu, Z., Bao, S., Bermudez, C., Plassard, A.J., Liu, J., Yao, Y., Assad, A., Abramson, R.G., Landman, B.A. (2018a). Splenomegaly Segmentation using Global Convolutional Kernels and Conditional Generative Adversarial Networks. *Medical Imaging 2018: Image Processing*, vol. 10574, pp. 45-51.
- Huo, Y., Xu, Z., Moon, H., Bao, S., Assad, A., Moyo, T.K., Savona, M.R., Abramson, R.G., Landman, B.A. (2018b). SynSeg-Net: Synthetic Segmentation Without Target Modality Ground Truth. *IEEE Transactions on Medical Imaging*, vol. 38, no. 4, pp. 1016-1025.
- Hussain, S., Anwar, S.M., Majid, M. (2018). Segmentation of Glioma Tumors in Brain Using Deep Convolutional Neural Network. *Neurocomputing*, vol. 282, pp. 248-261.
- Hussain, S., Zaki, M.J., Subramanian, D. (2021). Edge-augmented Graph Transformers: Global Self-attention is Enough for Graphs. arXiv:2108.03348.
- Iscen, I., Tolia, G., Avrithis, Y., Chum, O., Schmid, C. (2020). Graph convolutional networks for learning with few clean and many noisy labels. In *Proceedings of the Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23-28*, pp. 286-302.
- ISO27001. (2017). TS ISO/IEC 27001:2017.
- Jafari, M., Auer, D., Francis, S., Garibaldi, J., Chen, X. (2020). DRU-net: An Efficient Deep Convolutional Neural Network for Medical Image Segmentation. In *Proceedings of the 2020 IEEE 17th International Symposium on Biomedical Imaging*, pp. 1144-1148.
- Jafari, M., Li, R., Xing, Y., Auer, D., Francis, S., Garibaldi, J., Chen, X. (2019). FU-net: Multi-class Image Segmentation Using Feedback Weighted U-net. In *Proceedings of the 10th International Conference on Image and Graphics, Beijing, China, August 23-25*, pp. 529-537.
- Jangda, A., Polisetty, S., Guha, A., Serafini, M. (2020). Accelerating graph sampling for graph machine learning using GPUs. In *Proceedings of the Sixteenth European Conference on Computer Systems*, pp. 311-32.
- Jia, X., Liu, S., Feng, X., Zhang, L. (2019). FOCNet: A Fractional Optimal Control Network for Image Denoising. In *Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 6047-6056.

- Jia, Z., Lin, Y., Wang, J., Feng, Z., Xie, X., Chen, C. (2021). HetEmotionNet: Two-Stream Heterogeneous Graph Recurrent Neural Network for Multi-modal Emotion Recognition. In Proceedings of the 29th ACM International Conference on Multimedia, pp. 1047-1056.
- Jia, X., Wu, P., Chen, L., Li, H., Liu, Y.S., Yan, J. (2023). HDGT: Heterogeneous Driving Graph Transformer for Multi-Agent Trajectory Prediction via Scene Encoding. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 45, no. 11, pp. 13860-13875.
- Jiang, B., Lin, D. (2018a). Graph Laplacian Regularized Graph Convolutional Networks for Semi-supervised Learning. arXiv:1809.09839.
- Jiang, J., Li, J. (2018b). Constructing Financial Sentimental Factors in Chinese Market Using Natural Language Processing. arXiv:1809.0839.
- Jiang, J., Chen, J., Choo, K.K.R., Liu, C., Liu, K., Yu, M. (2018c). A Visualization Scheme for Network Forensics Based on Attribute Oriented Induction Based Frequent Item Mining and Hyper Graph. In: Matoušek, P., Schmiedecker, M. (eds) Digital Forensics and Cyber Crime. ICDF2C 2017. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol. 216, pp. 130-143.
- Jiang, S., Balaprakash, P. (2020). Graph Neural Network Architecture Search for Molecular Property Prediction. In Proceedings of the 2020 IEEE International Conference on Big Data, pp. 1346-1353.
- Jiang, S., Sun, B., Wang, L., Bai, Y., Li, K., Fu, Y. (2021). Skeleton Aware Multi-modal Sign Language Recognition. In Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, pp. 3408-3418.
- Kanezaki, A., Matsushita, Y., Nishida, Y. (2018). RotationNet: Joint Object Categorization and Pose Estimation Using Multiviews from Unsupervised Viewpoints. In Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 5010-5019.
- Karamitsos, I., Afzulpurkar, A., Trafalis, T.B. (2020). Malware Detection for Forensic Memory Using Deep Recurrent Neural Networks. Journal of Information Security, vol. 11, no. 2, pp. 103-120.
- Kassani, S.H., Kassani, P.H., Wesolowski, M.J., Schneider, K.A., Deters, R. (2019). Breast Cancer Diagnosis with Transfer Learning and Global Pooling. In Proceedings of the 2019 International Conference on Information and Communication Technology Convergence, pp. 519-524.
- Ke, L., Tai, Y.W., Tang, C.K. (2021). Deep Occlusion-Aware Instance Segmentation with Overlapping BiLayers. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4019-4028.
- Kemker, R., Salvaggio, C., Kanan, C. (2018). Algorithms for Semantic Segmentation of Multispectral Remote Sensing Imagery using Deep Learning. ISPRS Journal of Photogrammetry and Remote Sensing, vol. 145, pp. 60-77.
- Kessler, G.C., Ramsay, J.D. (2014). A Proposed Curriculum in Cybersecurity Education Targeting Homeland Security Students. In Proceedings of the 47th Hawaii International Conference on System Science, pp. 4932-4937.
- Kim, H.H., Yu, S., Tomasi, C. (2021). Joint Detection of Motion Boundaries and Occlusions. arXiv:2111.01261.
- Kim, J., Kim, K. (2021). Optimizing Large-Scale Fleet Management on a Road Network using Multi-Agent Deep Reinforcement Learning with Graph Neural Network. In Proceedings of the 2021 IEEE International Intelligent Transportation Systems Conference, pp. 990-995.
- Kipf, T.N., Welling, M. (2017). Semi-supervised classification with graph convolutional networks. In Proceedings of the 5th International Conference on Learning Representations, Toulon, France, April 24-26, pp. 1-14.
- Klicpera, J., Groß, J., Günnemann, S. (2020). Directional Message Passing for Molecular Graphs. arXiv:2003.03123.

- Kooverjee, K., James, S., Zyl, T.V. (2022). Investigating Transfer Learning in Graph Neural Networks. *Electronics*, vol. 11, no. 8, p. 1202.
- Kortylewski, A., Egger, B., Schneider, A., Gerig, T., Forster, A.M., Vetter, T. (2018). Empirically Analyzing the Effect of Dataset Biases on Deep Face Recognition Systems. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pp. 2093-2102.
- Kortylewski, A., He, J., Liu, Q., Yuille, A. (2020). Compositional Convolutional Neural Networks: A Deep Architecture with Innate Robustness to Partial Occlusion. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 8940-8949.
- Kumar, P., Grewal, M., Srivastava, M.M. (2018). Boosted Cascaded Convnets for Multilabel Classification of Thoracic Diseases in Chest Radiographs. In *Proceedings of the International Conference on Image Analysis and Recognition*, pp. 546-552.
- Kumar, A., Morabia, K., Wang, J., Chang, K.C.C., Schwing, A. (2022). CoVA: Context-aware Visual Attention for Webpage Information Extraction. In *Proceedings of the Fifth Workshop on e-Commerce and NLP*, pp. 80-90.
- Lai, P., Lu, Z. (2021). BERT-GT: Cross-sentence n-ary relation extraction with BERT and Graph Transformer. *Bioinformatics*, vol. 36, no. 24, pp. 5678-5685.
- Lamb, G., Paige, B. (2020). Bayesian Graph Neural Networks for Molecular Property Prediction. *arXiv:2012.02089*
- Lee, J., Park, J., Kim, K.L., Nam, J. (2017). Sample-level Deep Convolutional Neural Networks for Music Auto-tagging Using Raw Waveforms. *arXiv:1703.01789*.
- Lee, Y., Chung, J., Rhu, M. (2022). SmartSAGE: training large-scale graph neural networks using in-storage processing architectures. In *Proceedings of the 49th Annual International Symposium on Computer Architecture*, New York, NY, USA, pp. 932-945.
- Leng, Y., Ruiz, R., Dong, X., Pentland, A. (2020). Interpretable Recommender System With Heterogeneous Information: A Geometric Deep Learning Perspective. *SSRN Electronic Journal*, vol. J, no. 10, pp. 2411-2430.
- Li, Y., Tarlow, D., Brockschmidt, M., Zemel, R. (2016). Gated graph sequence neural networks. In *Proceedings of the 5th International Conference on Learning Representations*.
- Li, H., Dou, X., Tao, C., Hou, Z., Chen, J., Peng, J., Deng, M., Zhao, L. (2017). RSI-CB: A Large Scale Remote Sensing Image Classification Benchmark via Crowdsourced Data. *arXiv:1705.10450*.
- Li, R., Wang, S., Zhu, F., Huang, J. (2018). Adaptive Graph Convolutional Neural Networks. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 32, no. 1, pp. 3546-3553.
- Li, G., Muller, M., Thabet, A., Ghanem, B. (2019a). DeepGCNs: Can GCNs Go as Deep as CNNs?. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 9267-9276.
- Li, C., Cao, Y., Hou, L., Shi, J., Li, J., Chua, T.S. (2019b). Semi-supervised Entity Alignment via Joint Knowledge Embedding Model and Cross-graph Model. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, Hong Kong, November 3-7, pp. 2723-2732.
- Li, Z., Zhang, L., Song, G. (2019c). GCN-LASE: Towards Adequately Incorporating Link Attributes in Graph Convolutional Networks. *arXiv:1902.09817*.
- Li, Y., Tam, D.S., Xie, S., Liu, X., Ying, Q., Lau, W., Chiu, D., Chen, S.Z. (2020a). GTEA: Representation Learning for Temporal Interaction Graphs via Edge Aggregation. *arXiv:2009.05266*.
- Li, R., Auer, D., Wagner, C., Chen, X. (2020b). A generic ensemble based deep convolutional neural network for semi-supervised medical image segmentation. In *Proceedings of the 2020 IEEE 17th International Symposium on Biomedical Imaging*, pp. 1168-1172.

- Li, X., Ling, H. (2021a). TransCamp: Graph Transformer for 6-DoF Camera Pose Estimation. arXiv:2105.14065.
- Li, Z., Jin, X., Li, W., Guan, S., Guo, J., Shen, H., Wang, Y., Cheng, X. (2021b). Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning. In Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 408-417.
- Liang, B., Yin, R., Gui, L., Du, J., Xu, R. (2020). Jointly Learning Aspect-Focused and Inter-Aspect Relations with Graph Convolutional Networks for Aspect Sentiment Analysis. In Proceedings of the 28th International Conference on Computational Linguistics, pp. 150-161.
- Lin, C., Su, H., Tung, S., Hsu, W.H. (2021). Multivariate and Propagation Graph Attention Network for Spatial-Temporal Prediction with Outdoor Cellular Traffic. In Proceedings of the 30th ACM International Conference on Information & Knowledge Management, pp. 3248-3252.
- Liu, L., Songi X., Wang, M., Liu, Y., Zhang, L. (2021a). Self-supervised Monocular Depth Estimation for All Day Images using Domain Separation. In Proceedings of the IEEE/CVF International Conference on Computer Vision, pp. 12737-12746.
- Liu, Y., Tu, W., Zhou, S., Liu, X., Song, L., Yang, X., Zhu, E. (2021b). Deep Graph Clustering via Dual Correlation Reduction. arXiv:2112.14772.
- Liu, Y., Pan, S., Wang, Y.G., Xiong, F., Wang, L., Chen, Q., Lee, V.C.S. (2021c). Anomaly Detection in Dynamic Graphs via Transformer. IEEE Transactions on Knowledge & Data Engineering, vol. 35, no. 12, pp. 12081-12094.
- Liu, X., Yang, H., Chen, Q., Zhang, R., Yang, L., Xiao, B., Wang, C. (2022a). FinRL: A Deep Reinforcement Learning Library for Automated Stock Trading in Quantitative Finance. Capital Markets: Market Microstructure eJournal.
- Liu, L., Tsai, W.T., Bhuiyan, Z.A., Peng, H., Liu, M. (2022b). Blockchain-enabled fraud discovery through abnormal smart contract detection on Ethereum. Future Generation Computer Systems, vol. 128, pp. 158-166.
- Louis, S.M., Zhao, Y., Nasiri, A., Wong, X., Song, Y., Liu, F., Hu, J. (2020). Global Attention based Graph Convolutional Neural Networks for Improved Materials Property Prediction. arXiv:2003.13379.
- Loukas, A. (2020). How hard is to distinguish graphs with graph neural networks?. Advances in Neural Information Processing Systems, vol. 33, pp. 3465-3476.
- Lu, F., Chen, G., Liu, Y., Li, Z., Qu, S., Zou, T. (2021). MoNet: Motion-based Point Cloud Prediction Network. IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 8, pp. 13794-13804.
- Lu, Z., Du, P., Nie, J.Y. (2020). VGCN-BERT: Augmenting BERT with Graph Embedding for Text Classification. In Proceedings of the 42nd European Conference on Advances in Information Retrieval Research, Lisbon, Portugal, April 14-17, 2020, pp. 369-382.
- Luo, X., Zhuo, H.H. (2018). BIGSAGE: unsupervised inductive representation learning of graph via bi-attended sampling and global-biased aggregating. ICLR 2019
- Lyu, B., Chen, L., Zhu, S., Yu, K. (2021). LET: Linguistic Knowledge Enhanced Graph Transformer for Chinese Short Text Matching. In Proceedings of the AAAI Conference on Artificial Intelligence, vol. 35, no. 15, pp. 13498-13506.
- Ma, B., Xia, Y. (2018). Autonomous Deep Learning: A Genetic DCNN Designer for Image Classification. Neurocomputing, vol. 379, pp. 152-161.
- Ma, Y., Wang, S., Aggarwal, C.C., Tang, J. (2019). Graph Convolutional Networks with EigenPooling. In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp. 723-731.

- Ma, Y., Liu, X., Zhao, T., Liu, Y., Tang, J., Shah, N. (2021). A Unified View on Graph Neural Networks as Graph Signal Denoising. In *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, New York, NY, USA, pp. 1202-1211.
- Machiraju, H., Choung, O.H., Herzog, M.H., Frossard, P. (2022). Empirical Advocacy of Bio-inspired Models for Robust Image Recognition. *arXiv:2205.09037*.
- MahdaviFar, S., Ghorbani, A.A. (2019). Application of deep learning to cybersecurity: A survey. *Neurocomputing*, vol. 347, pp. 149-176.
- Mandya, A., Bollegala, D., Coenen, F. (2020). Contextualised Graph Attention for Improved Relation Extraction. *arXiv:2004.10624*.
- Marafioti, A., Holighaus, N., Majdak, P., Perraudin, N. (2018). Audio inpainting of music by means of neural networks. *arXiv:1810.12138*.
- Mardanisamani, S., Maleki, F., Kassani, S.H., Rajapaksa, S., Duddu, H., Wang, M., Shirtliffe, S., Ryu, S., Josuttes, A., Zhang, T., Vail, S., Pozniak, C., Parkin, I., Stavness, I., Eramian, M. (2019). Crop Lodging Prediction From UAV-Acquired Images of Wheat and Canola Using a DCNN Augmented With Handcrafted Texture Features. In *Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, Long Beach, CA, USA, pp. 2657-2664.
- Martin, D.S., Paez, J.G., Diaz, J.B. (2021). A stacked deep convolutional neural network to predict the remaining useful life of a turbofan engine. *arXiv:2111.12689*.
- Masoumian, A., Rashwan, H.A., Abdulwahab, S., Cristiano, J., Puig, D. (2023). GCNDepth: Self-supervised Monocular Depth Estimation based on Graph Convolutional Network. *Neurocomputing*, vol. 517, pp. 81-92.
- Min, Y., Wenkel, F., Wolf, G. (2020). Scattering GCN: Overcoming Oversmoothness in Graph Convolutional Networks. *Advances in Neural Information Processing Systems*, vol. 33, pp. 14498-14508.
- Min, S.W., Wu, K., Huang, S., Hidayetoğlu, M., Xiong, J.J., Ebrahimi, E., Chen, D., Hwu, W.M. (2021). Large Graph Convolutional Network Training with GPU-Oriented Data Communication Architecture. *arXiv:2103.03330*.
- Mironov, A., Khuziev, I. (2022). Optimization of Decision Tree Evaluation Using SIMD Instructions. In *Proceedings of the VLDB Endowment*, vol. 14, no. 11, pp. 2087-2100.
- Mondal, S., Manasi, S.D., Kunal, K., Sapatnekar, S.S. (2022). GNNIE: GNN Inference Engine with Load-balancing and Graph-Specific Caching. In *Proceedings of the 59th ACM/IEEE Design Automation Conference*, pp. 565-570.
- Monti, F., Boscaini, D., Masci, J., Rodolà, E., Svoboda, J., Bronstein, M.M. (2017). Geometric Deep Learning on Graphs and Manifolds Using Mixture Model CNNs. In *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 5425-5434.
- Morehead, A., Chen, C., Cheng, J. (2022). Geometric Transformers for Protein Interface Contact Prediction. In *Proceedings of the International Conference on Learning Representation*, pp. 1-18.
- Mou, Z., Gao, F., Liu, J., Wu, Q. (2021). Resilient UAV Swarm Communications with Graph Convolutional Neural Network. *IEEE Journal on Selected Areas in Communications*. vol. 40, no. 1, pp. 393-411.
- Murugesan, K., Atzeni, M., Kapanipathi, P., Shukla, P., Kumaravel, S., Tesauro, G., Talamadupula, K., Sachan, M., Campbell, M. (2021). Text-based RL Agents with Commonsense Knowledge: New Challenges, Environments and Baselines. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 35, no. 10, pp. 9018-9027.
- Nguyen, V.A., Nguyen, D.Q., Nguyen, V., Le, T., Tran, Q.H., Phung, D. (2022). ReGVD: Revisiting Graph Neural Networks for Vulnerability Detection. In *Proceedings of the ACM/IEEE 44th International Conference on Software Engineering: Companion Proceedings*, pp. 178-182.

- Nt, H., Jin, C.J., Murata, T. (2019). Learning Graph Neural Networks with Noisy Labels. In Proceedings of the International Conference on Learning Representation, pp. 1-5.
- Oh, J., Cho, K., Bruna, J. (2019). Advancing GraphSAGE with A Data-Driven Node Sampling. In Proceedings of the International Conference on Learning Representation, pp. 1-6.
- Oono, K., Suzuki, T. (2020). Graph Neural Networks Exponentially Lose Expressive Power for Node Classification. In Proceedings of the International Conference on Learning Representation, pp. 1-37.
- Önaçan, M.B.K., Atan, H. (2016). Siber Güvenlikte Lisansüstü Eğitim: Deniz Harp Okulu Örneği. Trakya University Journal of Engineering Sciences, vol. 17, no. 1, pp. 13-21.
- Palowitch, J., Perozzi, B. (2019). MONET: Debiasing Graph Embeddings via the Metadata-Orthogonal Training Unit. arXiv:1909.11793.
- Pan, S.Y., Lu, C.Y., Lee, S.P., Peng, W.H. (2021). Weakly-Supervised Image Semantic Segmentation Using Graph Convolutional Networks. In Proceedings of the 2021 IEEE International Conference on Multimedia and Expo, pp. 1-6.
- Panda, M. (2016). Towards the effectiveness of Deep Convolutional Neural Network based Fast Random Forest Classifier. arXiv:1609.08864.
- Pande, A., Ni, K., Kini, V. (2019). SWAG: Item Recommendations using Convolutions on Weighted Graphs. In Proceedings of the 2019 IEEE International Conference on Big Data, pp. 2903-2912.
- Parisot, S., Ktena, S.I., Ferrante, E., Lee, M., Moreno, R.G., Glocker, B., Rueckert, D. (2017). Spectral Graph Convolutions for Population-based Disease Prediction. In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention.
- Peng, E., Hong, X., Chen, H., Zhao, G. (2019). Learning Graph Convolutional Network for Skeleton-based Human Action Recognition by Neural Searching. In Proceedings of the AAAI Conference on Artificial Intelligence, vol. 34, no. 03, pp. 2669-2676.
- Paramadhan, A.A., Saputra, G.E. (2021). Cycle Generative Adversarial Networks Algorithm With Style Transfer For Image Generation. arXiv:2101.03921.
- Protogerou, A., Papadopoulos, S., Drosou, A., Tzovaras, D., Refanidis, I. (2021). A Graph Neural Network Method for Distributed Anomaly Detection in IoT. Evolving Systems, vol. 12, no. 1, pp. 19-36.
- Qian, G., Abualshour, A., Li, G., Thabet, A., Ghanem, B. (2021). PU-GCN: Point Cloud Upsampling using Graph Convolutional Networks. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 11683-11692.
- Qiu, L., Zhang, X., Li, Y.R., Li, G., Wu, X.J., Xiong, Z., Han, X., Cui, S. (2020). Peeking into occluded joints: A novel framework for crowd pose estimation. In Proceedings of the 16th European Conference on Computer Vision, Glasgow, UK, August 23-28, pp. 488-504.
- Ragi, S., Rahman, H., Duckworth, J., Jawaharraj, K., Chundi, P., Gadhamshetty, V. (2021). Artificial Intelligence-driven Image Analysis of Bacterial Cells and Biofilms. IEEE/ACM Transactions on Computational Biology and Bioinformatics, vol. 20, no. 1, pp. 174-184.
- Rajput, N.K., Grover, B.A., Rathi, V.K. (2020). Word frequency and sentiment analysis of twitter messages during Coronavirus pandemic. arXiv:2004.03925.
- Rampášek, L., Galkin, M., Dwivedi, V.P., Luu, A.T., Wolf, G., Beaini, D. (2022). Recipe for a General, Powerful, Scalable Graph Transformer. Advances in Neural Information Processing Systems, vol. 35, pp. 14501-14515.
- Roopak, M., Tian, G.Y., Chambers, J. (2019). Deep Learning Models for Cyber Security in IoT Networks. In Proceedings of the IEEE 9th Annual Computing and Communication Workshop and Conference, pp. 0452-0457.

- Sağıroğlu, Ş., Alkan, M. (2018). Siber Güvenlik ve Savunma Farkındalık ve Caydırıcılık. Grafiker Yayınları, no. 287, Ankara, Türkiye.
- Sahla, G., Hennequin, R., Vazirgiannis, M. (2019). Keep It Simple: Graph Autoencoders Without Graph Convolutional Networks. In Proceedings of the 33rd Conference on Neural Information Processing Systems, Vancouver, Canada, pp. 1-8.
- Sahla, G., Hennequin, R., Vazirgiannis, M. (2020). Simple and Effective Graph Autoencoders with One-Hop Linear Models. In Proceedings of the European Conference on Machine Learning and Knowledge Discovery in Databases, Ghent, Belgium, September 14-18, pp. 319-334.
- Sajadmanesh, S., Gatica-Perez, D. (2021). Locally Private Graph Neural Networks. In Proceedings of the 2021 ACM SIGSAC Conference on Computer and Communications Security, November, pp. 2130-2145.
- Schelkoph, D.J., Peterson, G.L., Okolica, J.S. (2019). Digital Forensics Event Graph Reconstruction. In Proceedings of the 10th International EAI Conference on Digital Forensics and Cyber Crime, New Orleans, LA, USA, September 10-12, pp. 185-203.
- Schuler, J.P.S., Romani, S., Abdel-Nasser, M., Rashwan, H., Puig, D. (2021). Reliable Deep Learning Plant Leaf Disease Classification Based on Light-Chroma Separated Branches. Artificial Intelligence Research and Development, pp. 375-382.
- Schuler, J.P.S., Romani, S., Abdel-Nasser, M., Rashwan, H., Puig, D. (2022). Grouped Pointwise Convolutions Reduce Parameters in Convolutional Neural Networks. Mendel, vol. 28, no. 1, pp. 23-31.
- Securisis, 2022, securisis.com
- Sengupta, S., Kambhampati, S. (2020). Multi-agent Reinforcement Learning in Bayesian Stackelberg Markov Games for Adaptive Moving Target Defense. arXiv:2007.10457.
- Sengupta, S., Kambhampati, S. (2021). Learning Movement Strategies for Moving Target Defense. In Proceedings of the International Conference on Learning Representation, pp. 1-18.
- Shang, C., Tang, Y., Huang, J., Bi, J., He, X., Zhou, B.W. (2018). End-to-end Structure-Aware Convolutional Networks for Knowledge Base Completion. In Proceedings of the AAAI Conference on Artificial Intelligence, vol. 33, no. 1, pp. 3060-3067.
- Shi, L., Zhang, Y., Cheng, J., Lu, H. (2019a). Skeleton-Based Action Recognition with Multi-Stream Adaptive Graph Convolutional Networks. IEEE Transactions on Image Processing, vol. 29, pp. 9532-9545.
- Shi, L., Zhang, Y., Cheng, J., Lu, H. (2019b). Two-Stream Adaptive Graph Convolutional Networks for Skeleton-Based Action Recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 12026-12035.
- Shi, Y., Huang, Z., Feng, S., Zhong, H., Wang, W., Sun, Y. (2020). Masked Label Prediction: Unified Message Passing Model for Semi-Supervised Classification. arXiv:2009.03509.
- Shi, Y., Huang, Z., Feng, S., Zhong, H., Wang, W., Sun, Y. (2021a). Masked Label Prediction: Unified Message Passing Model for Semi-Supervised Classification. arXiv:2009.03509.
- Shi, Y., Zhang, S., Zhou, C., Liang, X., Yang, X., Lin, L. (2021b). GTAE: Graph-Transformer based Auto-Encoders for Linguistic-Constrained Text Style Transfer. ACM Transactions on Intelligent Systems and Technology, vol. 12, no. 3, pp. 1-16.
- Simou, S., Kallinias, C., Gritzalis, S., Mouratidis, H. (2016). A survey on cloud forensics challenges and solutions. Security and Communication Networks, vol. 9, no. 18, p. 6285-6314.
- Sinha, K., Sodhani, S., Pineau, J., Hamilton, W.L. (2020). Evaluating Logical Generalization in Graph Neural Networks. arXiv:2003.06560.

- Sofianos, T., Sampieri, A., Franco, L., Galasso, F. (2021). Space-Time-Separable Graph Convolutional Network for Pose Forecasting. In Proceedings of the IEEE/CVF International Conference on Computer Vision, pp. 11209-11218.
- Song, W., Yin, H., Liu, C., Song, D. (2018). DeepMem: Learning Graph Neural Network Models for Fast and Robust Memory Forensic Analysis. In Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security, pp. 606-618.
- Su, C., Zhang, S., Xing, J., Gao, W., Tian, Q. (2016). Deep Attributes Driven Multi-Camera Person Re-identification. In Proceedings of the 14th European Conference on Computer Vision, October 11-14, pp. 475-491.
- Sun, L., Zhao, C., Stolkin, R. (2017). Weakly-supervised DCNN for RGB-D Object Recognition in Real-World Applications Which Lack Large-scale Annotated Training Data. arXiv:1703.06370.
- Taguchi, H., Liu, X., Murata, T. (2021). Graph Convolutional Networks for Graphs Containing Missing Features. Future Generation Computer Systems, vol. 117, pp. 155-168.
- Tai, C.Y., Wu, M.R., Chu, Y.W., Chu, S.Y., Ku, L.W. (2020). MVIN: Learning Multiview Items for Recommendation. In Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, July, pp. 99-108.
- Tallec, G., Dapogny, A., Bailly, K. (2022). Multi-Order Networks for Action Unit Detection. IEEE Transactions on Affective Computing, vol. 14, no. 4, pp. 2876-2888.
- Tam, D.S., Lau, W., Hu, B., Ying, Q., Chiu, D., Liu, H. (2019). Identifying Illicit Accounts in Large Scale E-payment Networks - A Graph Representation Learning Approach. arXiv:1906.05546.
- Tang, Y., Ma, L., Zhou, L. (2019). Hallucinating Optical Flow Features for Video Classification. arXiv:1905.11799.
- TDK Sözlük, <https://sozluk.gov.tr/>
- Teepe, T., Khan, A., Gilg, J., Herzog, F., Hörmann, S., Rigoll, G. (2021). GaitGraph: Graph Convolutional Network for Skeleton-Based Gait Recognition. In Proceedings of the 2021 IEEE International Conference on Image Processing, pp. 2314-2318.
- Thakoor, S., Tallec, C., Azar, M.G., Azabou, M., Dyer, E.L., Munos, R., Veličković, P., Valko, M. (2022). Large-Scale Representation Learning on Graphs via Bootstrapping. In Proceedings of the International Conference on Learning Representation, pp. 1-21.
- Theodoropoulos, C., Henderson, J., Coman, A.C., Moens, M.F. (2021). Imposing Relation Structure in Language-Model Embeddings Using Contrastive Learning. arXiv:2109.00840.
- Vashishth, S. (2019). Neural Graph Embedding Methods for Natural Language Processing. arXiv:1911.03042.
- Vashishth, S., Sanyal, S., Nitin, V., Talukdar, P. (2020). Composition-Based Multi-Relational Graph Convolutional Networks. In Proceedings of the International Conference on Learning Representation, pp. 1-15.
- Veličković, P., Cucurull G., Casanova A., Romero A., Lio P., Bengio Y. (2017). Graph attention networks. arXiv:1710.10903.
- Vinayakumar, R., Soman, K.P., Alazab, M., Sriram, S., Simran, K. (2020). A Comprehensive Tutorial and Survey of Applications of Deep Learning for Cyber Security. IEEE Communications Surveys & Tutorial, vol. 23, no. 3, pp. 1920-1955.
- Vrcek, L., Velickovic, P., Šikić, M. (2020). A step towards neural genome assembly. arXiv:2011.05013.
- Wagner, P., Marelli, S., Papaioannou, I., Starub, D., Sudret, B. (2022). Rare event estimation using stochastic spectral embedding. Structural safety, vol. 96, p. 102179.

- Wan, S., Gong, C., Zhong, P., Du, B., Zhang, L., Yang, J. (2019). Multi-scale Dynamic Graph Convolutional Network for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 5, pp. 3162-3177.
- Wan, C., Li, Y., Li, A., Kim, N.S., Lin, Y. (2022). BNS-GCN: Efficient Full-Graph Training of Graph Convolutional Networks with Partition-Parallelism and Random Boundary Node Sampling. *Proceedings of Machine Learning and Systems*, vol. 4, pp. 673-693.
- Wang, W., Daniels, T.E. (2008). A Graph Based Approach Toward Network Forensics Analysis. *ACM Transactions on Information and System Security*, vol. 12, no. 1, pp. 1-33.
- Wang, X., Ye, Y., Gupta, A. (2018). Zero-shot Recognition via Semantic Embeddings and Knowledge Graphs. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 6857-6866.
- Wang, Y., He, D., Li, F., Long, X., Zhou, Z., Ma, J., Wen, S. (2019a). Multi-Label Classification with Label Graph Superimposing. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 7, pp. 12265-12272.
- Wang, S., Chen, Z., Ni, J., Yu, X., Li, Z., Chen, H., Yu, P.S. (2019b). Adversarial Defense Framework for Graph Neural Network. *arXiv:1905.03679*.
- Wang, D., Hu, D., Li, X., Dou, D. (2020a). Temporal Relational Modeling with Self-Supervision for Action Segmentation. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 35, no. 4, pp. 2729-2737.
- Wang, R., Mao, J., Gershman, S.J., Wu, J. (2020b). Language-Mediated, Object-Centric Representation Learning. *arXiv:2012.15814*.
- Wang, Y., Min, Y., Chen, X., Wu, J. (2020c). Multi-view Graph Contrastive Representation Learning for Drug-Drug Interaction Prediction. In *Proceedings of the Web Conference 2021*, April, pp. 2921-2933.
- Wang, H., Leskovec, J. (2020d). Unifying Graph Convolutional Neural Networks and Label Propagation. *arXiv:2002.06755*.
- Wang, C., Liu, W., Li, H., Yu, S., Chen, S., Ye, X., Wu, J. (2021a). Dynamic Relevance Learning for Few-Shot Object Detection. *IEEE Transactions on Neural Networks and Learning Systems*. *arXiv:2108.02235*.
- Wang, Y., Wang, W., Liang, Y., Cai, Y., Hooi, B. (2021b). Mixup for Node and Graph Classification. In *Proceedings of the Web Conference 2021*, pp. 3663-3674.
- Wang, S., Wang, Z., Zhou, T., Yin, X., Han, D., Zhang, H., Sun, H., Shi, X., Yang, J. (2021c). ThreaTrace: Detecting and Tracing Host-based Threats in Node Level Through Provenance Graph Learning. *IEEE Transactions on Information Forensics and Security*, vol. 17, pp. 3972-3987.
- Wang, F., Sun, K., Chen, M., Pujara, J., Szekely, P.A. (2021d). Retrieving Complex Tables with Multi-Granular Graph Representation Learning. In *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 1472-1482.
- Wang, C., Shen, Y., Ji, L. (2022). Geometry Attention Transformer with position-aware LSTMs for image captioning. *Expert Systems with Applications*, vol. 201, p. 117174.
- Weber, M., Domeniconi, G., Chen, J., Weidele, D.K.I., Bellei, C., Robinson, T., Leiserson, C.E. (2019). Anti-Money Laundering in Bitcoin: Experimenting with Graph Convolutional Networks for Financial Forensics. In *Proceedings of the 25th SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 1-7.
- Wu, Y., Liu, X., Feng, Y., Wang, Z., Zhao, D. (2019a). Jointly Learning Entity and Relation Representations for Entity Alignment, *arXiv:1909.09317*.
- Wu, L., Li, S., Hsieh, C., Sharpnack, J. (2019b). Stochastic Shared Embeddings: Data-driven Regularization of Embedding Layers. In *Proceedings of the 33rd Conference on Neural Information Processing Systems*, Vancouver, Canada, pp. 1-11.

- Wu, L. (2020). Advances in Collaborative Filtering and Ranking. arXiv:2002.12312.
- Wu, Y., Dai, H.N., Tang, H. (2021). Graph Neural Networks for Anomaly Detection in Industrial Internet of Things. *IEEE Internet of Things Journal*, vol. 9, no. 12, pp. 9214-9231.
- Wu, Y., Wang, J., Miao, X., Wang, W., Yin, J. (2024). Differentiable and Scalable Generative Adversarial Models for Data Imputation. *IEEE Transactions on Knowledge and Data Engineering*, vol. 36, no. 2, pp. 490-503.
- Xia, L., Huang, C., Xu, Y., Dai, P., Zhang, X., Yang, H., Pei, J., Bo, L. (2021). Knowledge-Enhanced Hierarchical Graph Transformer Network for Multi-Behavior Recommendation. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 35, no. 5, pp. 4486-4493.
- Xiao, H., Feng, J., Lin, G., Liu, Y., Zhang, M. (2018). MoNet: Deep Motion Exploitation for Video Object Segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1140-1148.
- Xu, H.C., Zhou, W.X. (2018). Modeling aggressive market order placements with Hawkes factor models. *Plos One*, vol. 15, no. 1, e0226667.
- Xu, K., Hu, W., Leskovec, J., Jegelka, S. (2019). How Powerful Are Graph Neural Networks?. arXiv:1810.00826.
- Yamamoto, T. (2019). Crystal Graph Neural Networks for Data Mining in Materials Science. Research Institute for Mathematical and Computational Sciences, LLC.
- Yamanaka, R. (2021). Graphs and Machine Learning for Cybersecurity. *Graphs and Machine Learning for Cybersecurity*, Medium.
- Yang, S., Lin, G., Jiang, Q., Lin, W. (2019). A Dilated Inception Network for Visual Saliency Prediction. *IEEE Transactions on Multimedia*, vol. 22, pp. 2163-2176.
- Yang, Y., Qui, J., Song, M., Tao, D.C., Wang, X. (2020). Distilling Knowledge from Graph Convolutional Networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 7074-7083.
- Yang, C., Liu, J., Shi, C. (2021). Extract the Knowledge of Graph Neural Networks and Go Beyond it: An Effective Knowledge Distillation Framework. In *Proceedings of the Web Conference 2021*, New York, NY, USA, pp. 1227-1237.
- Yang, K., Liu, D., Lei, W., Yang, B., Zhang, H., Zhao, X., Yao, W., Chen, B. (2022). GCPG: A General Framework for Controllable Paraphrase Generation. In *Findings of the Association for Computational Linguistics: ACL 2022*, pp. 4035-4047.
- Yao, L., Mao, C., Luo, Y. (2018). Graph Convolutional Networks for Text Classification. In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, no. 1, pp. 7370-7377.
- Yao, Y., Jafarian, Y., Park, H.S. (2019). MONET: Multiview Semi-supervised Keypoint Detection via Epipolar Divergence. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 753-762.
- Yao, P., Shen, S., Xu, M., Liu, P., Zhang, F., Xing, J., Shao, P., Kaffenberger, B., Xu, R.X. (2021). Single Model Deep Learning on Imbalanced Small Datasets for Skin Lesion Classification. *IEEE Transactions on Medical Imaging*, vol. 41, no. 5, pp. 1242-1254.
- Yasunaga, M., Liang, P. (2020). Graph-based, Self-Supervised Program Repair from Diagnostic Feedback. In *Proceedings of the International Conference on Machine Learning*, pp. 10799-10808.
- Yasunaga, M., Ren, H., Bosselut, A., Liang, P., Leskovec, J. (2021). QA-GNN: Reasoning with Language Models and Knowledge Graphs for Question Answering. arXiv:2104.06378.
- Ye, J., Zhao, J., Ye, K., Xu, C.Z. (2020). Multi-Graph Convolutional Network for Relationship-Driven Stock Movement Prediction. In *Proceedings of the 25th International Conference on Pattern Recognition*, pp. 6702-6709.

- Yu, F., Jiang, X., Gong, Y., Zhao, S., Guo, X., Zheng, W.S., Zheng, F., Sun, X. (2020a). Devil's in the Details: Aligning Visual Clues for Conditional Embedding in Person Re-Identification. arXiv:2009.05250.
- Yu, D., Yang, Y., Zhang, R., Wu, Y. (2020b). Knowledge Embedding Based Graph Convolutional Network. In Proceedings of the Web Conference 2021, April 19-23, Ljubljana, Slovenia, pp. 1619-1628.
- Yu, W., Qin, Z. (2020c). Graph Convolutional Network for Recommendation with Low-pass Collaborative Filters. In Proceedings of the International Conference on Machine Learning, pp. 10936-10945.
- Yu, P., Zhao, Y., Li, C., Yuan, J., Chn, C. (2020d). Structure-Aware Human-Action Generation. In Proceedings of the 16th European Conference on Computer Vision, Glasgow, UK, August 23-28, pp. 18-34.
- Yuan, Z., Zhang, W., Tian, C., Rong, X., Zhang, Z., Wang, H., fu, K., Sun, X. (2022). Remote Sensing Cross-Modal Text-Image Retrieval Based on Global and Local Information. IEEE Transactions on Geoscience and Remote Sensing. vol. 60, p. 5620616, pp. 1-16.
- Yun, S., Jeong, M., Yoo, S., Lee, S., Yi, S.S., Kim, R., Kang, J., Kim, H.J. (2022). Graph Transformer Networks: Learning Meta-path Graphs to Improve GNNs. Neural Networks, vol. 153, pp. 104-119.
- Zang, X., Xie, Y., Chen, J., Yuan, B. (2020). Graph Universal Adversarial Attacks: A Few Bad Actors Ruin Graph Learning Models. arXiv:2002.04784.
- Zeng, H., Prasanna, V. (2020). GraphACT: Accelerating GCN Training on CPU-FPGA Heterogeneous Platforms. In Proceedings of the 2020 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays, February pp. 255-265.
- Zeng, H., Zhang, M., Xia, Y., Srivastava, A., Malevichh, A., Kanan, R., Prasanna, V., Jin, L., Chen, R. (2021). Decoupling the Depth and Scope of Graph Neural Networks. Advances in Neural Information Processing Systems, vol. 34, pp. 19665-19679.
- Zhang, C., Loken, K., Chen, Z., Xiao, Z., Kunkel, G. (2018a). Mask Editor: an Image Annotation Tool for Image Segmentation Tasks. arXiv:1809.06461.
- Zhang, X.S., Chou, J., Wang, F. (2018b). Integrative Analysis of Patient Health Records and Neuroimages via Memory-based Graph Convolutional Network. In Proceedings of the 2018 IEEE International Conference on Data Mining, pp. 767-776.
- Zhang, C., Lyu, X., Tang, Z. (2019a). TGG: Transferable Graph Generation for Zero-shot and Few-shot Learning. In Proceedings of the 27th ACM International Conference on Multimedia, pp. 1641-1649.
- Zhang, J. (2019b). Graph Neural Networks for Small Graph and Giant Network Representation Learning: An Overview. arXiv:1908.00187.
- Zhang, J., Meng, L. (2019c). GResNet: Graph Residual Network for Reviving Deep GNNs from Suspended Animation. arXiv:1909.05729.
- Zhang, L., Liu, P., Choi, Y.H., Chen, P. (2020a). Semantic-preserving Reinforcement Learning Attack Against Graph Neural Networks for Malware Detection. arXiv:2009.05602.
- Zhang, S., Liu, Y., Xie, L. (2020b). Molecular Mechanics-Driven Graph Neural Network with Multiplex Graph for Molecular Structures. arXiv:2011.07457.
- Zhang, N., Francis, S., Malik, R., Chen, X. (2020c). A Spatially Constrained Deep Convolutional Neural Network for Nerve Fiber Segmentation in Corneal Confocal Microscopic Images using Inaccurate Annotations. In Proceedings of the 2020 IEEE 17th International Symposium on Biomedical Imaging, pp. 456-460.
- Zhang, Z., Jia, J., Wang, B., Gong, N.Z. (2021a). Backdoor Attacks to Graph Neural Networks. In Proceedings of the 26th ACM Symposium on Access Control Models and Technologies, June, pp. 15-26.

- Zhang, Y., Li, W., Zhang, M., Qu, Y., Tao R., Qi, H. (2021b). Topological Structure and Semantic Information Transfer Network for Cross-Scene Hyperspectral Image Classification. *IEEE Transactions on Neural Networks and Learning Systems*, vol. 34, no. 6, pp. 2817-2830.
- Zhang, H., Gou, R., Shang, J., Shen, F., Wu, Y., Dai, G. (2021c). Pre-trained Deep Convolution Neural Network Model With Attention for Speech Emotion Recognition. *Frontiers in Physiology*, vol. 12, p. 643202.
- Zhang, S., Chen, H., Yang, H., Sun, X., Yu, P.S., Xu, G. (2022). Graph Masked Autoencoders with Transformers. *arXiv:2202.08391*.
- Zhao, L., Song, Y., Zhang, C., Liu, Y., Wang, P., Deng, M., Li, H. (2019). T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. *IEEE Transactions on Intelligent Transportation Systems*. vol. 21, no. 9, pp. 3848-3858.
- Zhao, H., Wang, Y., Duan, J., Huang, C., Cao, D., Tong, Y., Xu, B., Bai, J., Tong, J., Zhang, Q. (2020). Multivariate Time-series Anomaly Detection via Graph Attention Network. In *Proceedings of the 2020 IEEE International Conference on Data Mining*, pp. 841-850.
- Zhao, J., Li, C., Wen, Q., Wang, Y., Liu, Y., Sun, H., Xie, X., Ye, X. (2021). Gophormer: Ego-Graph Transformer for Node Classification. *arXiv:2110.13094*.
- Zhaao, P., Houb, L., Wua, O. (2020). Modeling Sentiment Dependencies with Graph Convolutional Networks for Aspect-level Sentiment Classification. *Knowledge-Based Systems*, vol. 193, p. 105443.
- Zhaou, Y., Ye, Q., Qui, Q., Jiao, J. (2017). Oriented Response Networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 519-528.
- Zheng, Y., Gao, C., Chen, L., Jin, D., Li, Y. (2021). DGCN: Diversified Recommendation with Graph Convolutional Networks. In *Proceedings of the Web Conference 2021*, April, pp. 401-412.
- Zhou, Z., Zhang, S., Huang, Z. (2019). Dynamic Self-training Framework for Graph Convolutional Networks. *arXiv:1910.02684*.
- Zhou, X., Wang, H. (2020a). RoGAT: a robust GNN combined revised GAT with adjusted graphs. *arXiv:2009.13038*.
- Zhou, J., Xu, Z., Rush, A.M., Yu, M. (2020b). Automating Botnet Detection with Graph Neural Networks. *arXiv:2003.06344*.
- Zhu, H., Liu, X., Mao, X., Wong, T.T. (2017). Real-time Deep Video Deinterlacing. *arXiv:1708.00187*.
- Zhu, Q., Du, B., Yan, P. (2020a). Self-supervised Training of Graph Convolutional Networks. *arXiv:2006.02380*.
- Zhu, H., Feng, F., He, X., Wang, X., Li, Y., Zheng, K., Zhang, Y. (2020b). Bilinear Graph Neural Network with Neighbor Interactions. *arXiv:2002.03575*.
- Zhuo, J., Wang, S., Cui, S., Huang, Q. (2019). Unsupervised Open Domain Recognition by Semantic Discrepancy Minimization. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 750-759.
- Zou, Z., Tang, W. (2021). Modulated Graph Convolutional Network for 3D Human Pose Estimation. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 11477-11487.
- Zurel, M., Okay, C., Raussendorf, R., Heimendahl, A. (2021). Hidden Variable Model for Quantum Computation with Magic States on Any Number of Qudits of Any Dimension. *arXiv:2110.12318*.

TEŞEKKÜR ve BEYANLAR

Yazarlar çalışmaya eşit oranda katkı sağlamıştır. Bu çalışmada herhangi bir potansiyel çıkar çatışması bulunmamaktadır. Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

***Not:** Bu çalışma, Milli Savunma Üniversitesi, Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Siber Güvenlik Tezsiz Yüksek Lisans Programına bağlı olarak yürütülen “Siber Güvenlikte Grafik Sinir Ağları” adlı dönem projesinin bir bölümüdür.*