

Derleme Makalesi

ÇİZGE ÖĞRENMEDE ÇİZGE SINIR AĞLARI

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., (2024). Çizge Öğrenmede Çizge Sinir Ağları, Journal of Technology and Applied Sciences 7(2) s.17-56, DOI: 10.56809/icujtas.1442504

ÖZET

Sinir ağları, alt alanlarında geniş bir aileyi sahiptir. Sinir ağlarının kendi içerisinde karşılaştığı kısıtlar ve limitler gelişimini olumlu yönde etkilemiş ve yeni sinir ağı modellerinin oluşmasını sağlamıştır. Bunun en büyük örneği bazı üç boyutlu verilerde yüksek başarı sergilemeyen evrişimli sinir ağı (Convolutional Neural Network-CNN) modellerine ek olarak çizge sinir ağı (Graph Neural Network-GNN) modellerinin geliştirilmesi olmuştur. Bir derin öğrenme modeli olan GNN, temelde çizge öğrenmeyi kullanmaktadır. GNN'ler bir nevi çizge derin öğrenmedir. Ancak bilinmelidir ki GNN'ler sinir ağları ailesinin bir üyesi olduğu gibi çizge öğrenmenin de alt modellerinden birisidir. Bu çalışmada çizge öğrenme ve GNN'ler ile ilgili temel kavramlar, ortak özellikler, farklılıklar, avantajlar, dezavantajlar ve uygulama alanlarından bahsedilmektedir.

Anahtar Kelimeler: Çizge Sinir Ağları, Çizge Öğrenme, Yapay Sinir Ağları, Derin Öğrenme

GRAPH NEURAL NETWORKS IN GRAPH LEARNING

ABSTRACT

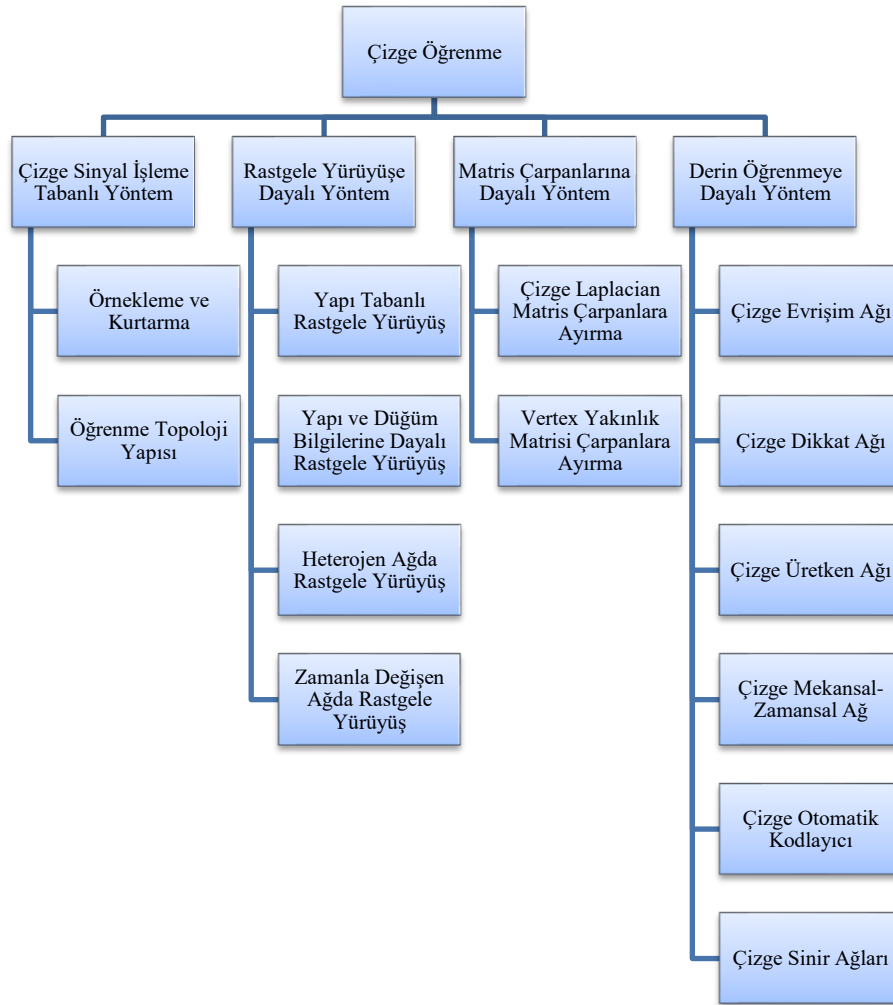
Neural networks have a large family of sub-fields. The constraints and limitations that neural networks face within themselves have positively affected their development and led to the creation of new neural network models. The biggest example of this is the development of graph neural network (GNN) models in addition to convolutional neural network (CNN) models, which do not perform well in some three-dimensional data. GNN, a deep learning model, basically uses graph learning. GNNs are a kind of graph deep learning. However, it should be noted that GNNs are a member of the neural network family and a sub-model of graph learning. In this study, the basic concepts, common features, differences, advantages, disadvantages and application areas of graph learning and GNNs are discussed.

Keywords: Graph Neural Networks, Graph Learning, Artificial Neural Networks, Deep Learning

Geliş/Received	:	24.02.2024
Gözden Geçirme/Revised	:	01.04.2024
Kabul/Accepted	:	06.05.2024

1. GİRİŞ

Çizgeler, günümüzde sosyal sistem, biyolojik ağ, bilgi çizgesi ve bilgi sistemleri, ilişkilendirme ile ekosistemler gibi farklı alanlarda yaygın olarak kullanılmaktadır. Makine öğrenmesi ve yapay zeka içerisinde ağ olarak da adlandırılan “graph” kavramı, iki farklı küme ile tanımlanmaktadır. Bu kümelerden birincisi olan köşe kümesi varlık temsili, kenar kümesi ise varlıklar arası ilişki temsili gerçekleştirilmektedir (Zia ve ark., 2021). Çizge öğrenme kavramı her geçen gün gelişerek derin öğrenme, güçlü öğrenme, temsil öğrenme ve öğrenme verimliliği gibi konuların da önemini artırmasını sağlamaktadır. Bir tanım ve anlam olarak ifade edilirse çizge öğrenme, çizgesel sistemlerin odağında makine öğrenmesi gerçekleştirme işlemidir. Öğrenme gerçekleştirilmesi için farklı modeller geliştirilmiştir. Bu modellerden birisi GNN (Graph Neural Networks – Çizge Sinir Ağları) modelidir. GNN’ler çizge öğrenmenin alt dalı olarak tanımlanabilmektedir. Çizge öğrenme yöntemlerinin çoğu derin öğrenme teknikleri ile gerçekleştirilmektedir. Amaç olarak çizgelerden istenilen veya ihtiyaç duyulan özelliklerin çıkarılmasını sağlayan çizge öğrenme, çizge analizi için geliştirilen güçlü, aynı zamanda da anlamlı bir yöntem olmaktadır. Çizgeleri odak noktası olarak gerçekleştirilen yöntemlerin sınıflandırılması Şekil 1’de görülmektedir (Zia ve ark., 2021).



Şekil 1. Çizge öğrenme yöntemlerinin sınıflandırılması.

Çalışmanın diğer bölümleri şu şekilde organize edilmiştir: Bölüm 2’de GNN ve çizge öğrenme kavramları ile ilgili ayrıntılı bilgilere yer verilmiştir. Bölüm 3’te çizge modellerin uygulama alanları açıklanmıştır. Bölüm 4’te GNN’lerin avantajları, dezavantajları ve kısıtları ele alınmıştır. Son olarak Bölüm 5’te ise çalışmanın genel sonuçlarından bahsedilmiştir.

2. ÇİZGE SİNİR AĞLARI VE ÇİZGE ÖĞRENME


Çizge öğrenmede öznelik vektörleri girdi olarak kullanıldığında çıktı, tahmin sonuçları olmaktadır. Derin öğrenme yöntemleri hem yapay zekanın hem de çizge öğrenmenin en başarılı yöntemlerinden olduğundan iki alanda da yaygın olarak kullanılmaktadır. En bilinen teknikleri GNN, GCN (Graph Convolutional Network – Çizge Evrişimli Ağ) ve GAE (Graph Auto-Encoders – Çizge Otomatik Kodlayıcılar) modelleri olmaktadır. Bu çalışmada ilk incelenecek yöntem olan GSP (Graph Signal Processing – Çizge Sinyal İşleme) tepe noktası bulabilmekte ve bu noktaları birbirine bağlayabilmektedir. Bu sayede GSP sinir ağlarında başarı yakalamıştır (Zia ve ark., 2021).

Sinyal işleme, Fourier dönüşümü ve filtre gibi klasik sinyal işleme teknikleri ile kullanılmaya başlanmıştır ve tanımlı sinyalleri işleyebilen geleneksel bir konudur. İşleme, çizge analizi için önerilmesi ile çizge öğrenme de önem kazanmıştır. İşlenmesi zor ve düzensiz veri olarak adlandırılan çizgeler spektral analize bir bakış getirmiştir. Bağlanabilirlik ve benzetme ile özellik açıklaması elde edilebilmektedir. Çizge sinyal işleme çizgelerde temsil, örnekleme-kurtarma ve öğrenme topolojisinin yapısı olarak üç başlık altında incelenmektedir. Çizgelerde temsil, anlamlı bir niteleme olarak tanımlanmaktadır. Burada temsil, komşuluk matrisi tabanlı ve Laplacian tabanlı olacak şekilde iki farklı GSP modeli üzerinden tanıtılacaktır. Komşuluk matrisi tabanlı GSP'ler ASP (Algebraic Signal Processing – Cebirsel Sinyal İşleme) yönteminden elde edilmektedir. Bu yöntem, cebirsel teorilerin yorumlanarak lineer sinyal oluşturulması ile elde edilmektedir. Laplacian tabanlı GSP'ler ise, spektral teoriden yararlanmaktadır. Temelde yüksek boyutlu verilerin düşük boyuta aktarılması ile gerçekleştirilen yöntem, yönsüz çizgeleri de analiz edebilmektedir. Örnekleme yöntemi, geleneksel sinyal işlemede olduğundan biraz daha farklıdır. Geleneksel sinyal işlemede tüm bilgiler saklanırken çizgelerde ise yüksek boyut sebebiyle örnekleme teorilerinin çizgelere uyarlanması ile elde edilmektedir. Bu sayede az sayıda örnekleme ile daha iyi kurtarma gerçekleştirilmektedir. Kurtarma ise orijinal çizgeden bilgi kaybı olmadan bilgi çıkarımı yapılması ve verimin düşmemesi olarak adlandırılabilir. Çizge sinyal işlemede verilerden topoloji yapısını öğrenme, bağlantılar yardımıyla gerçekleştirilen analiz işlemidir (Zia ve ark., 2021).

Matris çarpanlarına dayalı yöntemler, matrislerin bileşenlerine ayrılarak basitleştirme yöntemidir. Basitleştirme işlemiyle bileşenler daha düşük boyuta gelir ve orijinal bilgilerde kayıp olmamasıyla temsil işleminde kullanılır. Laplacian matris çarpanlarına ayırma ve köşe yakınlık matris çarpanlarına ayırma olarak iki farklı türü bulunmaktadır. Laplacian matris çarpanlarına ayırma, çizge özelliklerinin korunması ile ikili tepe benzerliği olarak adlandırılır. Laplacian matris çarpanlarına ayırma, dönüştürücü ile endüktif olmak üzere iki gruba ayrılmaktadır. Dönüştürücü işlemlerde sadece eğitim kümesinde köşelerde gömme kullanırken endüktifte ise eğitim kümesinde olmayan köşelere gömme işlemi uygulanmaktadır. Köşe yakınlık matrisinde ise ilişkisel olmayan çizgeler ve homojen çizgelerde öğrenme için kullanılmaktadır. Köşe yakınlığı korunarak en az hata alınmakta ayrıca köşe yakınlığı da tahmin edilebilmektedir. Yaygın olarak kullanılsa da Gauss matris çarpanlarına ayırma ve düşük sıralı matris çarpanlarına ayırma yöntemleri de vardır (Zia ve ark., 2021). Büyük ölçekli ayrışma ve çıkarım için kullanılan Gauss matris çarpanlarına ayırma yöntemi, kenar yerine komşu köşelerde sayıları en aza indirerek çizge bölümlenmesi yapmaktadır (Ahmed ve ark., 2013). Düşük sıralı matris çarpanlarına ayırma yöntemi ise köşe metin özelliklerini ağ öğrenimine dâhil etmektedir. Modelin işlenmesi için DeepWalk modeli geliştirilmiştir. Modelin sorunlarından birisi ise eğitim süreci ile denetimli veya yarı denetimli görevlere uygulanamamasıdır (Zia ve ark., 2021).

Bir diğer yöntem olan rastgele yürüyüşe dayalı yöntemler, ağ örnekleme için kullanılan etkin yöntemlerdir. Ağ yapısı bağımlılığı ile NRL (Network Representation Learning – Ağ Temsil Öğrenimi) tepe noktası özellik vektörünü oluşturabilmektedir. Yapı tabanlı rastgele yürüyüşlerde, çizge yapısı ve köşe niteliklerine odaklanılmaktadır. Önem arz eden köşelere tahmin yapılmaktadır. Aynı şekilde öneme sahip olan ağ oluşum ve ağ evrimi modelleme işlemleri de yapılmaktadır. Yapı ve köşe bilgisine dayalı rastgele yürüyüşler, zengin köşe bilgilerini kullanarak analiz gerçekleştirmektedir. Köşe metin bilgileri, tepe noktası etiket bilgisi ve benzer düğümler dikkate alınarak ağ temsili öğrenmektedir. Heterojen ağlarda rastgele yürüyüşler ise farklı köşelerde ve köşeler arasında bulunan ilişkileri muhafaza ederek ağ temsil öğrenimi gerçekleştirmeyi amaçlamaktadır. Köşe ve bağlantı ilişkisi içerisinde bulunan anlamsal dikkatler gerçekleşmektedir. Bilgi çizgeleri ve sosyal ağlar heterojen çizgelere örnek olduğu gibi yaygın olarak da kullanılmaktadır. Bilgi çizgeleri ilişkisel çıkarım olarak adlandırılırken üç tür ilişkisel çıkarım bulunmaktadır. SRL (Statistical Relational Learning – İstatistiksel İlişkisel Öğrenme), LFM (Latent Factor Models – Gizli Faktör Modeller) ve RWM (Random Walk Models – Rastgele Yürüyüş Modelleri) ilişkisel çıkarım için kullanılan yöntemlerdir. SRL'de genelleme ve ölçekleme olmadığı için LFM ve RWD modelleri daha yaygın olarak kullanılmaktadır. Zamanla değişen ağlarda rastgele yürüyüşler ise bulunan ağın zamanla gelişmesi ve değişmesi sonucu köşe ve ilişkilerin ortaya çıkmasına karşı geliştirilmiş analiz yöntemidir. Bu yöntemde zamansal değişiklikler ve bu değişikliklerin yakalanması önem arz etmektedir (Zia ve ark., 2021).

Çizgelerde derin öğrenme ise RNN (Recurrent Neural Networks – Tekrarlayan Sinir Ağları) ve CNN (Convolutional Neural Networks – Konvolüsyonel Sinir Ağları) modellerinin çizgeler üzerinde geliştirilmeye çalışılması ile gerçekleşmektedir. Şekil 1’de görülen derin öğrenmeye dayalı yöntemlere ek olarak Şekil 2’de çizgelerde derin öğrenme metotları görülmektedir.



Şekil 2. Çizgelerde derin öğrenme metotları.

Şekil 1’e göre altı farklı yöntem bulunmaktadır. Bu yöntemler; çizge evrişim ağları, çizge dikkat ağı, çizge üretken ağı, çizge mekânsal-zamansal ağ, çizge otomatik kodlayıcı ve GNN şeklindedir. Çizge evrişim ağları, ızgara alanları ve çizge alanları üzerinde çalışmaktadır. Spektral çizge teorisinin zamansal olarak kullanıldığı zaman alanı ve spektral yöntemler ile birinci yöntemin geliştirilerek uzaysal geçerlilik ile analiz yapıldığı uzay alanı ve uzaysal yöntemler olmak üzere iki gruba ayrılmaktadır. Çizge dikkat ağları GCN’nin geliştirilmesiyle oluşturulmuş dikkat mekanizmaları gelişmiş çizge modellerdir. Çizge otomatik kodlayıcılar GNN yapısını kullanarak düşük boyutlu vektör gömme işlemlerinde kullanılmaktadır. Çizge üretken ağlar, elde olan çizge kümelerine göre yeni çizgeler elde etmektedir. Doğal dil işlemede kullanılan ağ modelleri, anlam ve bilgi çizgeleri elde etmektedir. Son yöntem olan çizge mekânsal-zamansal ağlar ise çizgelerde mekânsal ve zamansal bağımlılığı aynı anda yakalamaktadır. Trafik ağlarında yaygın olarak kullanılmaktadır (Zia ve ark., 2021). Şekil 2’de farklı olarak çizge tekrarlayan sinir ağları, çizge takviyeli öğrenme ve rakip yöntemlerin çizgeleri bulunmaktadır. Bu yöntemler arasında bulunan temel ayrımlar Tablo 1’de (Zhang ve ark., 2015a) gösterilmektedir.

Tekrarlayan sinir ağlarının çizgelere uyarlanması ile ortaya çıkan GRNN (Graph-based Recursive Neural Network – Çizge Tabanlı Özyinelemeli Sinir Ağı) modelleri genel olarak, düğüm düzeyinde tekrarlayan sinir ağları ve çizge düzeyinde tekrarlayan sinir ağları olmak üzere iki gruba ayrılmaktadır. Düğüm düzeyinde öğrenmenin çizgeler üzerinde kullanımı derin öğrenme öncesi zaman olarak adlandırılmaktadır. Çizge temsillerinde çizgenin tamamının temsili için düğüm ekleme önerisi ile ortaya çıkan model, düğüm durumlarının özyinelemeli bir tanımı olarak karşımıza çıkmaktadır. Çizge düzeyinde tekrarlayan sinir ağlarında ise düğüm düzeyinde olduğunun aksine bir düğüme uygulamak yerine tüm çizgeye bir RNN uygulanması ile gerçekleştirilmektedir. Tablo 2’de bu iki farklı grubun özellikleri görülmektedir.

Tablo 1. Yöntemler arasında bulunan temel ayrımlar.

Yöntem	Temel Amaç	Ana Fonksiyon
Çizge Yinelenen Sinir Ağları	Özyinelemeli ve sıralı çizge desenleri	Düğüm veya çizgeler için durum tanımları
Çizge Evrişimsel Ağlar	Çizgelerin ortak yerel ve küresel yapısal kalıpları	Çizge evrişim ve okuma işlemleri
Çizge Otomatik Kodlayıcılar	Çizgelerin düşük sıralı yapıları	Denetimsiz düğüm temsili öğrenimi
Çizge Pekiştirmeli Öğrenme	Çizge görevlerinin geri bildirimleri ve kısıtlamaları	Çizge tabanlı eylemler ve ödüller
Çizge Çekişmeli Yöntemler	Çizge tabanlı modellerin genelleme yeteneği ve sağlamlığı	Rakip eğitimlerin ve saldırıların çizgelerini çizin

Pekiştirmeli öğrenme, güçlendirme öğrenimi ya da takviye öğrenme olarak adlandırılan model, yapay zeka görevlerinde başarı elde etmektedir. Odak noktası kısıtlama ve ayırt edilmeyen hedefler olmasına rağmen geri bildirimlerden gerçekleşen öğrenmede de verimli olduğu bilinmektedir. Kısaca çizge pekiştirmeli öğrenme makine öğrenmesi yöntemlerinden olan pekiştirmeli öğrenmenin çizgelere uyarlanarak elde edilmesiyle oluşturulmaktadır. Tablo 3’te çizge pekiştirmeli öğrenme yöntemlerinin özellikleri gösterilmektedir.

Tablo 2. RNN model özellikleri.

Grup	Model	Özyinelemeli/Sıralı Çizge Desenleri	Uygulama
Düğüm Düzeyinde Tekrarlayan Sinir Ağları	GNN	Düğüm durumlarının özyinelemeli bir tanımı	(Scarselli ve ark., 2009)
	GGs-NNs		(Li ve ark., 2015)
	SSE		(Dai ve ark., 2018a)
Çizge Düzeyinde Tekrarlayan Sinir Ağları	GraphRNN	Otoregresif bir şekilde düğümler ve kenarlar oluşturma	(You ve ark., 2018a)
	DGNN	Düğümlerin ve kenarların oluşumunun zaman dinamiklerini yakalama	(Ma ve ark., 2018a)
	RMGCNN	Çizgeyi yinelemeli olarak yeniden oluşturma	(Monti ve ark., 2017)
	Dynamic GCN	Farklı zaman dilimlerinde düğüm temsillerini toplama	(Manessi ve ark., 2020)

Moleküler çizgeler oluşturmak için kullanılan GCPN (Graph Convolutional Policy Network – Çizge Evrimsel Politika Ağı) hedeflemeleri ve kısıtlamaları ele alarak modellenmede ve düğüm temsili için GCN kullanılmaktadır. MolGAN modeli de moleküler çizge oluşturmak için kullanılmaktadır. MolGAN, GCPN'den farklı olarak çizgeyi parça parça yerine tam bir şekilde oluşturulması gerektiğini savunmaktadır. GTPN (Graph Transformation Policy Network – Çizge Dönüşüm Politika Ağı), düğüm temsili öğrenmesinde GCN, tahmin verilerini ezberlemede ise RNN kullanarak kimyasal reaksiyon tahmini gerçekleştirmektedir. GAM (Graph Attention Model – Çizge Dikkat Modeli) modeli rastgele yürüyüşler için pekiştirmeli öğrenme gerçekleştiren modeldir. Bilgi çizgelerinde akıl yürütme ile birlikte yol bulma hedefleyen DeepPath ve soru yanıtlama görevine odaklanan MINERVA modeli ise akıl yürütme düğüm tahmini ile gerçekleştirmektedir (Zhang ve ark., 2015a).

Tablo 3. Çizge pekiştirmeli öğrenme yöntemlerinin özellikleri.

Model	Görev	Eylemler	Ödüller	Çalışma
GCPN	Çizge oluşturma	Bağlantı tahmini	GAN + Alan bilgisi	(You ve ark., 2018b)
MolGAN	Çizge oluşturma	Çizge oluşturma	GAN + Alan bilgisi	(Cao ve Kipf, 2018)
GTPN	Kimyasal reaksiyon tahmini	Düğüm çiftlerini ve yeni bağ türlerini tahmin etme	Tahmin sonuçları	(Do ve ark., 2019)
GAM	Çizge sınıflandırma	Çizge etiketlerini tahmin edin ve sonraki düğümü seçme	Sınıflandırma sonuçları	(Lee ve ark., 2018b)
DeepPath	Bilgi çizgesi akıl yürütme	Akıl yürütme yolunun bir sonraki düğümünü tahmin etme	Akıl yürütme sonuçları + Çeşitlilik	(Xiong ve ark., 2017)
MINERVA	Bilgi çizgesi akıl yürütme	Akıl yürütme yolunun bir sonraki düğümünü tahmin etme	Akıl yürütme sonuçları	(Das ve ark., 2018)

Çizge karşılaştırma yöntemlerinin temeli GAN (Generative Adversarial Nets – Üretici Hasım Ağları) modeline dayanmaktadır. Bu yöntemler hasım yani düşman eğitimi ve düşman saldırısı olarak iki farklı alt gruba ayrılmaktadır. Düşman eğitimi, GAN modellerinin ayrımcı ve üretici modellerinin üretici kısmının oluşturulması ile gerçekleştirilmektedir. Düşman saldırısı ise veriler içerisinde bozulmalar ekleme ile gerçekleştirilerek kandırma amacı taşıyan ayrımcı kısmını oluşturmaktadır. Bu yöntemlerin özellikleri Tablo 4'te görülmektedir (Zhang ve ark., 2015a).

Tablo 4. Çizge karşılaştırma yöntemlerinin özellikleri.

Grup	Model	Düşman Modeller	Çalışma
Düşman Eğitimi	ARGA/ARVGA	GAE için düzenleme	(Pan ve ark., 2018)
	NetRA	GAE için düzenleme	(Yu ve ark., 2018b)
	GCPN	Çizge RL için ödüller	(You ve ark., 2018b)
	MolGAN	Çizge RL için ödüller	(Cao ve Kipf, 2018)
	GraphGAN	Negatif örneklerin oluşturulması (düğüm çiftleri)	(Wang ve ark., 2018a)
	ANE	Ağ gömme için düzenleme	(Dai ve ark., 2019b)
	GraphSGAN	Çizgeler üzerinde yarı denetimli öğrenmeyi geliştirme	(Ding ve ark., 2018)
	NetGAN	Rastgele yürüyüşler yoluyla çizgelerin oluşturulması	(Shchur ve ark., 2018)
Düşman Saldırısı	Nettack	Çizge yapılarına ve düğüm özelliklerine yönelik hedefli saldırılar	(Zügner ve ark., 2018)
	AAGSD	Çizge yapılarının hedefli saldırıları	(Dai ve ark., 2018b)
	AAGNN	Çizge yapılarının hedeflenmemiş saldırıları	(Zügner ve Gunnemann, 2019a)


Bir diğer durum ise bu düşman saldırıları genelinde gerçekleştirilen görevlerdir. Bu görevler çizgelerde sağlam öğrenme olarak adlandırılmaktadır. Tablo 5'te çizgelerde sağlam öğrenme uygulamalar görülmektedir (Xu ve ark., 2021).

Tablo 5. Çizgelerde sağlam öğrenme uygulamaları.

Görev	Alt Görev	Uygulama
Anomali Tespiti	Statik Çizge	(Wang ve ark., 2020c) (Jiang ve ark., 2019)
	Dinamik Çizge	(Du ve ark., 2017)
Düşmanca Eğitim	Rakip Hedefler	(Jin ve ark., 2020) (Li ve ark., 2020b)
	Rakip Örnekler	(Deng ve ark., 2019) (Zhu ve ark., 2019) (Tang ve ark., 2020)
Dikkat Mekanizması	Dikkat Mekanizması	(Zhu ve ark., 2019) (Tang ve ark., 2020) (Entezari ve ark., 2020)
Sertifika Sağlamlığı	Sadece Özellikler	(Zügner ve Gunnemann, 2019b)
	Sadece Yapı	(Zügner ve Gunnemann, 2019b) (Bojhevski ve Gunneman, 2019a)
	Özellik + Yapı	(Zügner ve Gunnemann, 2020)
Ön İşleme	Ön İşleme	(Zügner ve ark., 2018) (Deng ve ark., 2019) (Entezari ve ark., 2020) (Xu ve ark., 2018) (Zhang ve ark., 2019e) (Ioannidis ve ark., 2019) (Xu ve ark., 2020) (Wu ve ark., 2019a) (Said ve ark., 2010)

Çizge öğrenmede bir diğer alan ise NRL (Network Representation Learning – Ağ Temsil Öğrenimi)'dir. Ağ öğrenimi, ağın topolojisini, tepe içeriklerini ve diğer bilgilerini koruyarak gömme işlemi gerçekleştirebilmektedir. Şekil 3'te ağ temsil öğrenme teknikleri görülmektedir (Zhang ve ark., 2018a).

Denetimsiz ağ temsili öğrenme Şekil 3'ten de anlaşıldığı gibi iki alt gruptan oluşmaktadır. İlk bölüm olan denetimsiz yapıyı koruyan NRL, ağ yapısı korunarak birbirlerine yakı olan köşelerin yeniden yerleştirme sağlayarak benzer şekilde temsil edileceğini savunmaktadır. Yapısal olarak üç farklı tipte ortaya çıkmaktadır. NRL'yi koruyan mikroskobik yapıda derecesel olarak yakınlık ile birlikte köşeler arasındaki yapı bilgileri korunması amaçlanmaktadır. Bu işlemde köşeler arasındaki benzerlik yakalanmaktadır. DeepWalk, LINE (Large-scale Information Network Embedding – Büyük Ölçekli Bilgi Ağı Gömme), GraRep (Graph Representations – Çizge Temsilleri), DNNGR (Deep Neural Networks for Graph Representations – Çizge Temsilleri için Derin Sınır Ağları), SDNE (Structural Deep Network Embedding – Yapısal Derin Ağ Gömme), HOPE (High-Order Proximity Preserved Embedding – Yüksek Dereceli Yakınlık Korunmalı Gömme), APP (Asymmetric Proximity Preserving Graph Embedding – Asimetrik Yakınlık Koruma Çizgeyi Gömme) ve GraphGAN modellerinden oluşmaktadır. NRL'yi koruyan yapısal rol yakınlığında ise birbirleri arasında uzaklık bulunan sadece yapısal rolleri birbirine benzeyen köşelerde yerleştirme yapmaktadır. Bu işlem ile aşağıdaki görevleri basitleştirirken, mikroskobik yapı da geliştirilmektedir. NRL'yi koruyan yapısal rol yakınlığı, struct2vec, GraphWave ve SNS (Structural and Neighborhood Similarity Preserving Network Embedding – Ağ Yerleştirmeyi Koruyan Yapısal ve Komşuluk Benzerliği) modellerinden oluşmaktadır. Gerçek dünyada ağlar tepe noktaları aynı gruplar içinde birbirlerine bağlıdır fakat başka bir gruptan gelen ağlarda tepe noktalarının seyrek bağlı olduğu topluluk içi yakınlık koruma, temelinde köşe özellikleri ile karakterizasyon gerçekleştirmektedir. Bu yöntemde LLSD (Learning Latent Social Dimensions – Gizli Sosyal Boyutları Öğrenmek) ve M-NMF (Modularized Nonnegative Matrix Factorization – Modülerleştirilmiş Negatif Olmayan Matris Çarpanlara Ayırma) modelleri bulunmaktadır. Makroskobik yapı korumada ise makroskobik görünüm ile koruma amaçlanmaktadır. Hedef küresel ağ özellikleridir. Bu yöntemde DP (Degree Penalty Principle – Derece Ceza İlkesi) ve HARP (Hierarchical Representation Learning for Networks – Ağlar için Hiyerarşik Temsil Öğrenimi) modelleri bulunmaktadır. Denetimsiz içerikler için artırılmış ağ temsili öğrenmede ağ yapısı ile birlikte web ağları, alıntı ağlar ve sosyal ağlarda bulunan köşe niteliklerde zenginlik sağlanmaktadır. Bu nitelikler köşe arası için benzerlik ölçmede bir ölçüt sayılmaktadır. Öğrenme köşe öznelik bilgisi ile doğru orantılıdır. DeepWalk modelinin metin ile ilişkilmesi ile gerçekleştirilen TADW (Text-Associated DeepWalk – Metinle İlişkili DeepWalk), köşe içerik ve yapısal bağlam içeriklerini eş zamanlı entegre etmeyi gerçekleştiren HSCA (Homophily, Structure, and Content Augmented Network Representation Learning – Homofil, Yapı ve İçerikle Artırılmış Ağ Temsili Öğrenme), köşe niteliği ile bağlantı bilgisini birleştirmede kısıtlı Boltzmann makinesi kullanarak köşe temsili öğrenmede kullanılan pRBM (Paired Restricted Boltzmann Machine – Eşleştirilmiş Kısıtlı Boltzmann Makinesi), gürültü filtrelemenin yanında kullanıcı profillerinden bilgi çıkarmayı gömülü öğrenme ile gerçekleştiren, bu işlemi de kullanıcıların profil bilgileri ile yapan UPP-SEN (User Profile Preserving Social Network Embedding – Sosyal Ağ Gömmesini Koruyan Kullanıcı Profili) ve öznelik güdümlü amaç ile yapı güdümlü amacı optimize ederek içerik ile artırılmış köşe temsil öğrenimi gerçekleştiren PPNE (Property Preserving Network Embedding – Mülkiyet Koruma Ağı Gömme) modellerinden oluşmaktadır (Zhang ve ark., 2018a).



Şekil 3. Ağ temsil öğrenme teknikleri.

Yarı denetimli öğrenmede köşelere iliştilmiş etiket bilgileri kullanılmaktadır. Ağın yapısı ve nitelikler hakkında bilgi vermesi ile temsillerde kolaylık sağlayan bu etiketler için yarı denetimli algoritmalar da kullanılmaktadır. Bu algoritmalar NRL'yi koruyan yarı denetimli yapı ve yarı denetimli içerik artırılmış NRL olmak üzere iki gruba ayrılmaktadır. NRL'yi koruyan yarı denetimli yapı, ağ yapısı ile ayırt edici öğrenme eş zamanlı olarak optimize edilmesi sonucunda köşe etiketler sayesinde elde edilen bilgiler köşe temsili ve ayırt etme gücünde verimi artırmaktadır. DDRW (Discriminative Deep Random Walk – Ayrımcı Derin Rastgele Yürüyüş), MMDW (Max-Margin DeepWalk – Maksimum Marj DeepWalk), TLINE (Transductive LINE – İletken LINE), GENE (Group Enhanced Network Embedding – Grup Gelişmiş Ağ Gömme) ve SemiNE (Semi-supervised Network Embedding – Yarı denetimli Ağ Gömme) modellerinden oluşmaktadır. Yarı denetimli içerik artırılmış ağ temsili öğrenmede ise içerik bilgisi dahil edilerek köşe temsili verimi artmaktadır. Etiketleme bilgilerinin de dikkate alınmasıyla sınıflandırma görevleri gerçekleştirilmektedir. TriDNR (Tri-Party Deep Network Representation – Üç Taraflı Derin Ağ Temsili), LDE (Linked Document Embedding – Bağlantılı Belge Gömme), DMF (Discriminative Matrix Factorization – Ayrımcı Matris Çarpanlara Ayırma), Planetoid (Predictive Labels and Neighbors with Embeddings Transductively or Inductively from Data – Verilerden Dönüştürücü veya Tümevarımsal Olarak Gömülü Öngörücü Etiketler ve Komşular) ve LANE (Label Informed Attribute Network Embedding – Etiket Bilgili Nitelik Ağ Gömme) modellerinden oluşmaktadır. Ayrıca Tablo 6'da ağ temsili öğrenme model-çalışma tablosu görülmektedir.

Tablo 6. Ağ temsili öğrenme model-çalışma tablosu.

Denetim	Yapı	Altyapı	Model	Çalışma	
Denetimsiz Ağ Temsili Eğitimi	Denetimsiz Yapı Koruma Ağı Temsili Öğrenme	NRL'yi Koruyan Mikroskopik Yapı	DeepWalk	(Perozzi ve ark., 2014)	
			LINE	(Tang ve ark., 2015)	
			GraRep	(Cao ve ark., 2015)	
			DNGR	(Cao ve ark., 2016)	
			SDNE	(Wang ve ark., 2016)	
			node2vec	(Grover ve Leskovec, 2016)	
			HOPE	(Ou ve ark., 2016)	
			APP	(Zhou ve ark., 2017a)	
			GraphGAN	(Zhou ve ark., 2017a)	
			Struct2vec	(Ribeiro ve ark., 2017)	
	Denetimsiz İçerik Artırılmış Ağ Temsili Öğrenme	NRL'yi Koruyan Yapısal Rol Yakınlığında	GraphWawe	(Donnat ve ark., 2017)	
			SNS	(Lyu ve ark., 2017)	
			NRL Topluluk İçi Yakınlık Koruma	LLSD	(Tang ve ark., 2009a) (Tang ve ark., 2011) (Tang ve ark., 2009b)
				M-NMF	(Wang ve ark., 2017)
				DP	(Feng ve ark., 2018a)
			Makroskobik Yapı Koruma	HARP	(Chen ve ark., 2018a)
Köşe Nitelikleri	TADW	(Yang ve ark., 2015a)			
	HSCA	(Zhang ve ark., 2016a)			
	pRBM	(Wang ve ark., 2016)			
	PPNE	(Li ve ark., 2017b)			
Ağ Yapısı	UPP-SEN	(Zhang ve ark., 2017b)			
Yarı Denetimli Ağ Temsili Eğitimi	NRL'yi Koruyan Yarı Denetimli Yapı	Ağ Yapısı	DDRW	(Zhu ve ark., 2012)	
			MMDW	(Tu ve ark., 2016)	
			TLINE	(Chen ve ark., 2016)	
			GENE	(Pan ve ark., 2016)	
			SemiNE	(Li ve ark., 2017a)	
	Yarı Denetimli İçerik Artırılmış NRL	Ağ Yapısı Köşe İçeriği Köşe Etiketleri	TriDNR	(Pan ve ark., 2016)	
			LDE	(Pan ve ark., 2016)	
			DMF	(Zhang ve ark., 2016c)	
			Planetoid	(Yang ve ark., 2016)	
			LANE	(Huang ve ark., 2017)	

Çizge öğrenmedeki incelenen son konu ise çizgelerde temsil öğrenme konusudur. Çizge gömme, çizge temsili için kullanılan yöntemlerden birisidir. Çizge gömme için sekiz farklı yöntem mevcuttur. Bu yöntemlerden ilki boyut küçültme yöntemleridir. Temel amaç veri boyutunu küçültürken bilgileri koruyarak temsil indirgemesi gerçekleştirmektir. Doğrusal ve doğrusal olmayan olarak iki farklı gruba ayrılmaktadır. Doğrusal yöntemler PCA (Principal Component Analysis – Temel Bileşen Analizi), LDA (Linear Discriminant Analysis – Doğrusal Diskriminant Analizi) ve MDS (Multidimensional Scaling – Çok Boyutlu Ölçekleme) olarak ayrılmaktadır. Doğrusal olmayan yöntemler ise Isomap (Isometric Feature Mapping – İzometrik Özellik Eşleme), LLE (Locally Linear Embedding – Yerel Olarak Doğrusal Gömme) ve Kernel Metodu şeklindedir. Rastgele yürüyüşe dayalı yöntemler, başlangıç noktasını rastgele belirleyerek çok sayıda ve farklı yolları içererek örnekleme gerçekleştirir. Bu yöntem ayrıca keşif ve küresel-yerel bilgi yakalama yeteneği vermektedir. DeepWalk ve node2vec gibi farklı modelleri bulunmaktadır. Matris çarpanlarına ayırma tabanlı yöntemler, zaman çizge gömme gerçekleştiren yöntemlerdendir. Düğüm gömme görevleri için yaygın bir şekilde kullanılmaktadır. Gömme elde edilmesi çizgesi de komşuluk matrisinin çarpanlarına ayrılması ile gerçekleşmektedir ve çizge yapısı korunmaktadır. GLE (Graph Laplacian Eigenmaps – Laplacian Öz Haritalarının Çizgesini Çizme), NPMF (Node Proximity Matrix Factorization – Düğüm Yakınlık Matrisi Çarpanlarına Ayırma), TADW (Text-Associated DeepWalk – Metinle İlişkili DeepWalk), HSCA (Homophily, Structure, and Content Augmented Network Representation Learning – Homofil, Yapı ve İçerikle Artırılmış Ağ Temsili Öğrenme), GraRep (Graph Representations – Çizge Temsilleri) ve HOPE (High-Order Proximity Preserved Embedding – Yüksek Dereceli Yakınlık Korunmalı Gömme) modelleri matris çarpanlara ayırma yöntemlerindedir. Sınır ağı tabanlı yöntemler, RNN ve CNN modellerinin genelleştirilmesi ve çizgelere uyarlanması ile gerçekleştirilmektedir. GCN, SGCN (Signed Graph Convolutional Network – İmzalı Çizge Evrişim Ağı), VGAE (Variational Graph Auto-encoders – Varyasyon Çizgesi Otomatik Kodlayıcılar), GraphSAGE ve SDNE (Structural Deep Network Embedding – Yapısal Derin Ağ Gömme) modellerinden oluşmaktadır. Büyük çizge gömme yöntemleri, daha önce bahsedilen yöntemler ile boyut sorununun çözülmemesi ile ortaya çıkmıştır. Yakınlık yakalayamama ve temsil verimsizliği sebebiyle geliştirilmiştir. LGCL (Learnable Graph Convolutional Layer – Öğrenilebilir Çizge Evrişimli Katmanını), GPNN

(Graph Partition Neural Networks – Çizge Bölümü Sinir Ağları) ve LINE (Large-scale Information Network Embedding – Büyük Ölçekli Bilgi Ağı Gömme) modellerinden oluşmaktadır. Hiper çizge gömme, çizgelerin kenar derecelerinin iki ve üstü olduğu durumlarda süper düğüm oluşturma amacıyla hiper kenarların bağlanması ile elde edilmektedir. SHGE (Spectral Hyper-Graph Embedding – Spektral Hiper Çizge Gömme), HGNN (Hyper-Graph Neural Network – Hiper Çizge Sinir Ağı) ve DHNE (Deep Hyper-Network Embedding – Derin Hiper Ağ Gömme) modellerinden oluşmaktadır. Dikkat çizgesi gömme, farklı görevlerde odaklanma için kullanılmaktadır. Ayrıca bu gömme yöntemi ile sinyal-gürültü oranı dengelenerek verim artırılırken gürültüden de kaçılabilir. GAT (Graph Attention Networks – Çizge Dikkat Ağı), AW (Attention Walks – Dikkat Yürüyüşleri) ve AGRNN (Attentive Graph-based Recursive Neural Network – Özenli Çizge Tabanlı Özyinelemeli Sinir Ağı) modellerinden oluşmaktadır. Bu yöntemlerin dışında çizge temsil öğreniminde üretken ve ayırt edici yerel modellerden GraphGAN ve üretken model olan GenVector modelleri de çizge temsili öğrenmede çizge gömme kullanılmaktadır. Tablo 7’de (Wang ve ark., 2019e) çizge temsili öğrenme modelleri ve uygulama tablosu görülmektedir. Tablo 8’de (Wang ve ark., 2019e) bu bölümde görülen farklı gömme yöntemlerinin karşılaştırma tablosu görülmektedir. Tablo 9-11’de ise çizge öğrenme uygulama alanları görülmektedir.

Tablo 7. Çizge temsili öğrenme modelleri ve uygulamaları.

Yöntem	Alt Yöntem	Model	Çalışma
Boyut Küçültme Yöntemleri	Doğrusal Boyut Küçültme Yöntemleri	PCA	(Jolliffe ve ark., 2016)
		LDA	(Jolliffe ve ark., 2016)
		MDS	(Robinson ve ark., 1995)
	Doğrusal Olmayan Boyut Küçültme Yöntemleri	Isomap	(Samko ve ark., 2006)
		LLE	(Roweis ve ark., 2000)
		Kernel	(Harandi ve ark., 2011)
Rastgele Yürüyüşe Dayalı Yöntemler		DeepWalk	(Perozzi ve ark., 2014)
		node2vec	(Grover ve Leskovec, 2016)
Matris Çarpınlarına Ayırma Tabanlı Yöntemler		GLE	(Belkin ve Niyogi, 2003)
		NPMF	(Singh ve Gordon, 2008)
		TADW	(Yang ve ark., 2015a)
		HSCA	(Zhang ve ark., 2016a)
		GraRep	(Cao ve ark., 2015)
		HOPE	(Ou ve ark., 2016)
Sinir Ağı Tabanlı Yöntemler		GCN	(Kipf ve ark., 2017)
		SGCN	(Derr ve ark., 2018)
		VGAE	(Kingma ve Welling, 2013)
		GraphSAGE	(Hamilton ve ark., 2017b)
		SDNE	(Wang ve ark., 2016)
Büyük Çizge Gömme Yöntemleri		LGCL	(Gao ve ark., 2018)
		GPNN	(Motsinger ve ark., 2006)
		LINE	(Tang ve ark., 2015)
Hiper Çizge Gömme		SHGE	(Zhou ve ark., 2007)
		HGNN	(Feng ve ark., 2018b)
		DHNE	(Tu ve ark., 2017)
Dikkat Çizgesi Gömme		GAT	(Velickovic ve ark., 2018)
		AW	(Abu-El-Haija ve ark., 2018) (Abu-El-Haija ve ark., 2018)
		AGRNN	(Xu ve ark., 2017)
Diğer		GrpGAN	(Wang ve ark., 2018a)
		GenVector	(Yang ve ark., 2015b)

Tablo 8. Farklı gömme yöntemlerinin karşılaştırması.

Yöntem	Avantaj	Dezavantaj
Boyut Küçültme Tabanlı	Anlaşılabilir ve uygulanması kolay	Daha yüksek dereceli yakınlığı iyi yakalayamaz
Rastgele Yürüyüşe Dayalı	Tüm çizgeyi bir kerede almaz	Bazen küresel bilgileri çok iyi yakalayamaz
Matris Çarpanlarına Ayırma Tabanlı	Küresel yapıyı yakalayabilir	Yüksek zaman karmaşıklığı
Sınır Ağı Tabanlı	Son teknoloji performans	Donanım gerektiren, BP ile eğitim zaman alıcıdır
Büyük Çizge Yerleştirme	İyi ölçeklenebilirlik	Yüksek zaman karmaşıklığı
Hiper Çizge Gömme	Daha karmaşık verileri modeller	Uygulanması daha zor
Dikkat Çizgesi Yerleştirme	Daha iyi uzun mesafe düğüm modelleme	Yüksek zaman karmaşıklığı
Diğerleri	Daha fazla alternatif sağlama	Kavram kanıtı aşaması

Tablo 9. Çizge öğrenme uygulama alanları (1).

Uygulama	Çalışma
Topluluk Algılama	(Ding ve ark., 2001) (Chen, 2009) (Yuruk ve ark., 2009) (Zhang ve ark., 2015b) (Dourisboure ve ark., 2007) (Newman, 2004) (Girvan ve ark., 2002) (De Bacco ve ark., 2018) (Zheleva ve ark., 2008) (Fortunato, 2010) (Yang ve ark., 2009)
Öneri Sistemi	(Hamilton ve ark., 2017a) (Ying ve ark., 2018a) (Zhang ve ark., 2016b) (Kermarrec ve Leroy, 2011) (Zhang ve ark., 2017a)
Çizge Sıkıştırma ve Kabalaştırma	(Feder ve Motwani, 1995) (Liang ve ark., 2018) (Karypis ve ark., 1998)
Biyomedikal Uygulama	(Zhang ve ark., 2018a) (Yang ve ark., 2009) (Hamilton ve ark., 2017a) (Ying ve ark., 2018a) (Zhang ve ark., 2016b) (Kermarrec ve Leroy, 2011) (Zhang ve ark., 2017a) (Feder ve Motwani, 1995) (Liang ve ark., 2018) (Karypis ve ark., 1998) (Green ve Yang, 2009) (Hu ve ark., 2015) (Liu ve ark., 2018a)
Trafik Akışı Çıkarımı	(Thanou ve ark., 2017)
İnternet Haber Yayılım Çalışması	(Baingana ve Giannakis, 2016)
Bölgeler Arası Siyasi İlişki	(Dong ve ark., 2016)
İnsan Robotik Etkileşimi	(Li ve ark., 2018a)
Kavram Ontolojileri	(Lake ve Tenenbaum, 2010)
Sosyal Etkiyi Modelleme	(Qiu ve ark., 2018)
Kimya ve Biyoloji	(You ve ark., 2018b) (Duvenaud ve ark., 2015) (Gilmer ve ark., 2017) (Kearnes ve ark., 2016) (Cao ve Kipf, 2018)
Fizik	(Coley ve ark., 2017) (Xie ve Grossman, 2018)
Hastalık ve İlaç Tahmini	(Ktena ve ark., 2017) (Zitnik ve ark., 2018) (Parisot ve ark., 2017)
Gen İfadesi	(Dutil ve ark., 2018)
Doğal Dil İşleme	(Basting ve ark., 2017) (Marcheggiani ve ark., 2017)
Bilgisayarlı Görme	(Garcia ve Bruna, 2018) (Qi ve ark., 2018) (Marino ve ark., 2017) (Qi ve ark., 2017) (Jain ve ark., 2016)
Trafik Tahmini	(Yu ve ark., 2018a) (Li ve ark., 2018c)
Program Başlatma	(Allamanis ve ark., 2017)
Çizge Tabanlı Np Sorunları Çözme	(Li ve ark., 2018d) (Prates ve ark., 2019)
Çok Aracılı Yapay Zeka Sistemleri	(Sukhbaatar ve ark., 2016) (Battaglia ve ark., 2016) (Hoshen, 2017)

Tablo 10. Çizge öğrenme uygulama alanları (2).

Grup	Model	Bileşen	Görev	Çalışma
Zaman Alanı ve Spektral Yöntemler	SNLCN	GNN	Sınıflandırma	(Bruna ve ark., 2014)
	DCN	Spektral Ağ	Sınıflandırma	(Henaff ve ark., 2015)
	ChebNet	Evrişim Ağ	Sınıflandırma	(Defferrard ve ark., 2016)
	GCN	Spektral Ağ	Sınıflandırma	(Kipf ve ark., 2017)
	HA-GCN	GCN	Sınıflandırma	(Zhou ve ark., 2017b)
	D-GCN	GCN, LSTM	Sınıflandırma	(Manessi ve ark., 2020)
	DCRNN	DCN	Trafik Tahmini	(Li ve ark., 2018c)
Uzay Alanı ve Uzaysal Yöntemler	PATCHY-SAN	Evrişim Ağı	Çalışma Zamanı Analizi	(Niepert ve ark., 2016)
			Özellik Görselleştirme	
			Çizge Sınıflandırma	
	Neural FP	-	Alt Çizge Sınıflandırma	(Duvenaud ve ark., 2015)
	DCNN	DCNN	Sınıflandırma	(Atwood ve Towsley 2016)
	DGCN	GSBC, PPMI-BC	Sınıflandırma	(Zhuang ve ark., 2018)
	SSE	-	Köşe Sınıflandırması	(Dai ve ark., 2018a)
	LGCN	CNN	Köşe Sınıflandırması	(Gao ve ark., 2018)
	STGCN	GSC	Trafik Tahmini	(Yu ve ark., 2018a)

Tablo 11. Çizge öğrenme uygulama alanları (3).

Grup	Model	Bileşen	Görev	Çalışma
Derin Öğrenme Modeli Tabanlı Yöntemler	GATs	ANN	Sınıflandırma	(Velickovic ve ark., 2018)
	GAAN		Köşe Sınıflandırma	(Zhang ve ark., 2018b)
	GAM		Çizge Sınıflandırma	(Lee ve ark., 2018b)
	Aws	AENN	Bağlantı Tahmini	(Abu-El-Haija ve ark., 2018)
			Duyarlılık Analizi	
			Köşe Sınıflandırma	
	SDNE	AENN	Sınıflandırma	(Wang ve ark., 2016)
			Bağlantı Tahmini	
			Görselleştirme	
	DNGR	AENN	Kümeleme	(Cao ve ark., 2016)
			Görselleştirme	
	DRNE	AENN	Düzenli Denklik Tahmini	(Tu ve ark., 2018)
			Yapısal Rol Sınıflandırması	
			Ağ Görselleştirme	
	MoIGAN	GNN – Üretken Sinir Ağı	Üretici Model	(Schlichtkrull ve ark., 2018)
DGMG	Molekül Üretimi		(Li ve ark., 2018b)	
DCRNN	DCN	Trafik Tahmini	(Li ve ark., 2018c)	
STGCN	GSC	-	(Yu ve ark., 2018a)	
ST-GCN	GCNs	Eylem Tanıma	(Yan ve ark., 2018)	

Bu bölümde son olarak geliştirilme aşamasında olan iki farklı proje incelenecektir. Birleşik Devletler Ordusu, Ordu Araştırma Laboratuvarı ve Güney Kaliforniya Üniversitesi'nin geliştirdiği GraphSAINT modeli ile askeri çizge analizi gerçekleştirmek planlanmıştır. Model görüş ve görüntü işleme için geliştirilmesine rağmen GNN genelleştirilmesi ile hedef ve nesne tespiti yapabilmektedir. Bu sayede sadece siber istihbarat için değil, ajan kontrolü için de verimli olacaktır. Aynı zamanda GraphSAINT eylem tanıma ve hareket algılama gibi yetenekleri sayesinde durumsal farkındalık yaratacağı bilinmektedir. Daha sonra Birleşik Devletler Ordusu Savaş Yeteneği Geliştirme Komutanlığı (CCDC) Ordu Araştırma Laboratuvarı (ARL) Bağlama Duyarlı İşlem Şubesi tarafından GCN modelleri üzerinde çalışmalar gerçekleştirilmiştir. Ordu içerisindeki derin ve geniş veritabanları sayesinde nitelik ve özellik temsili gerçekleştirme verimi ile hızlı, doğru, ayrıca ölçeklenebilen bir model geliştirmeye odaklanılmıştır. Aynı şekilde GrapSAINT modelinin yaratıcılarından olan Kannan, çizge örnekleme tabanlı

endüktif öğrenme yöntemi olarak tanımlamış ve derin öğrenme ile yüksek hız sağladığını belirtmiştir. Modelin ordu içerisinde kullanılması düşüncesi ile bilinmeyen çizgelerde öğrenme gerçekleşirken ayrıca istihbarat konusunda da gelişmeler gösterecektir. Bu durum dünya ordularının siber istihbarat kavramı ve dijital ordu düşüncesine geçtiğini göstermektedir (Army, 2022).

Birleşik Devletler Ordusu, GNN'leri yapay zeka ajanları olarak kullanmak istemektedir. İnsansız hava ve yer sistemlerinde haberleşme ve iş birliği gerçekleşmesi için kullanılması planlanan GNN modelleri son gelişmeleri kullanması ve sürekli gelişmesi ile dikkat çekmektedir. Projenin üç farklı aşamadan oluşması planlanmış fakat daha sonra geliştirilmesi durdurulmuştur. İlk aşamada Python üzerinden GNN temelleri oluşturulacak ve oyun motoru yardımıyla sürü robotlar için denetimli öğrenme simülasyonu yapılacaktır. Aşama ikide ise gelişmiş platforma geçiş işlemi yapılacak, geliştirilen GNN modeli öncelikle Python ve oyun motorları ile simüle edilirken NVIDIA ile gelişmiş ortama aktarılarak testler bu platformda devam edecektir. Üçüncü aşamada ise ticarileşme gerçekleşerek model üretilecek ve kontrol edilmiş güvenli bir yazılım halinde orduya teslim edilecektir. Bu teknolojinin en önemli özelliği ise Balistik Düşük Drone Sözleşmesi (BLADE) ve diğer C-UAS sistemlerini desteklemesidir. Sürü sistemlerde iletişim süresinin azalması ve bu sayede hızın artacağı düşünülmektedir (SAM, 2022).

Farklı alanlarda kullanılan GNN modellerinin askeri alanlara giriş yapması ya da bu alanlarda farklı görevler için düşünülmesi GNN modellerinin gelişmişlik düzeyini göstermektedir. Gelecek yıllarda tahmin yeteneği sayesinde strateji belirleme, istihbarat önerisi ve iletişim esnekliği gibi konularda askeri sistemlerde görülebilecektir. Bu durum karşısında gelişimin sadece tek bir orduda kaldığı, diğer ülke ordularının bu konu hakkında bir çalışma yapmadığı görülmektedir. Sistem genel işleyişiyle hala yoğunluğunu akademik teorilere vermekte ve uygulama aşaması için bekleme süresini uzatmaktadır. GNN ve çizgelerden öğrenmenin geleceğin vazgeçilmez teknolojilerinden birisi olacağı sadece bu iki düşünce ile bile görülmektedir.

3. ÇİZGE MODELLERİN UYGULAMA ALANLARI

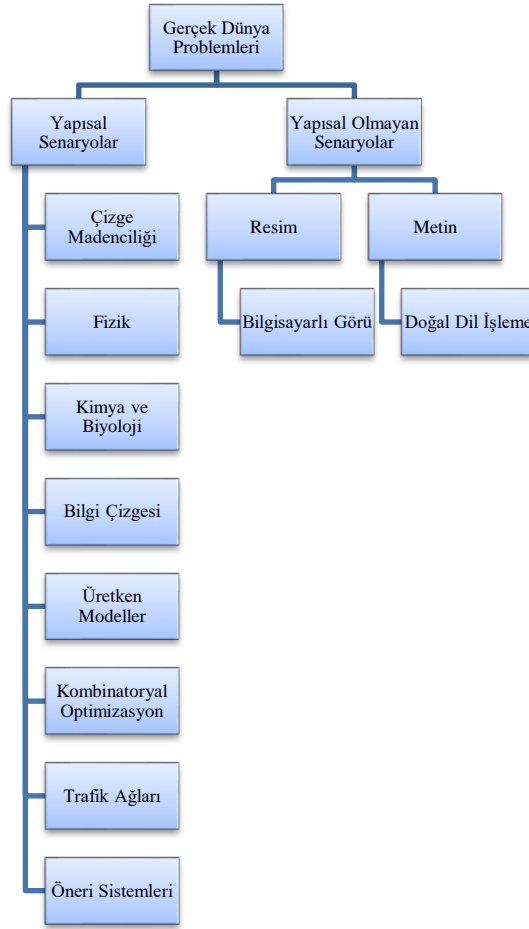
GNN'ler farklı alanlarda kullanılmaktadır. Şekil 4'te (Asıf ve ark., 2021) görülen çizge ağları yöntemlerinden veriye dayalı yöntemler (çizge teorisi) ve genel uygulamalar daha önceki bölümlerde anlatılmıştır. Veriye dayalı yöntemler problemlerin teorik çözümler ile pratiğe dökülmeden çözüm önerileri geliştirilmesinden oluşmaktadır. Genel uygulamalar ise gerçek dünya problemlerinin çizgesel olgular ile teorik çözümlerinin geliştirilmesidir. Bu iki yöntem gerçek dünya problemlerinde geliştirilen uygulamaların öncülü olmaktadır (Asıf ve ark., 2021). Öncül örnekler bakıldığı zaman teorik yönler görülmektedir. Bu yönler, çizge sinyal işleme, genelleme, dışavurumculuk, değişmezlik, aktarılabilirlik ve etiket verimliliği olarak ayrılmaktadır. Bu teorik yönler ile deneylerin yapılması ve deneyler sonucu karşılaştırılması ise deneysel yön olarak adlandırılmaktadır (Zhou ve ark., 2019). Çizge sinyal işleme, giriş özelliklerinin evrimsel geçirmesini teorik olarak incelemektedir. Genelleme, sınır ağlarındaki genelleştirme yeteneğidir. Dışavurumculuk, WL testi kullanılarak özellik öğrenme ve temsil yeteneğinin gelişmişlik seviyesidir. Düğüm sırası olmayan çizgelerde çıktılar giriş özelliklerine göre eşdeğer olma durumu değişmezlik olarak adlandırılmaktadır. Aktarılabilirlik, GNN özelliklerinden çizge ile çözülmüş bir parametrenin verim garantisini sunması ve iletim kabiliyeti kazanması olarak tanımlanmaktadır. Son teorik yön olan etiket verimliliği ise performansın artması için ihtiyaç duyulan etiketlerin güvenilir olma durumudur (Zhou ve ark., 2019). GNN modellerinin uyarlanması için ilk deneylerde gerekli olan veri setleri olmaktadır. Sonraki süreçte değerlendirme ve açık kaynak uygulamaları devreye girmektedir. Değerlendirme süreci çizge sınıflandırma ve düğüm sınıflandırma ile yapılmaktadır. Açık kaynak uygulamaları ise temel deneylerin gerçekleştirilmesi ve simülasyonların yapılmasıdır. GNN'lerde en yaygın kullanılan açık kaynak uygulamaları PyTorch ve MXNet derin öğrenme platformlarıdır (Wu ve ark., 2021).

GNN'ler gerçek dünyada kullanılabilen uygulamalar da geliştirmektedir. Belirli modellerin kullanımı ile geliştirilen uygulamalar gündelik yaşantı, askeri alanlar, bilişim teknolojileri ve doğa bilimlerinde kullanılmaktadır. Şekil 5'te görülen GNN uygulamaları gerçek dünya sorunlarını yapısal ve yapısal olmayan senaryolar olarak ele almaktadır (Zhou ve ark., 2019). Aynı şekilde Şekil 6'da görüldüğü gibi gerçek dünya problemlerinin uygulamaları gelecek çalışmalara da örnek olmaktadır. Yapısal senaryolar, açık veri ilişkisine sahip genellikle bilimsel çalışma olarak karşımıza çıkmaktadır. Genelleştirilmesi ile endüstriyel uygulamalara da katkı sağlamaktadır. Yapısal olmayan senaryolar ise, ilişkisel yapının bulunmadığı, bulunuyorsa bile gizli olduğu uygulamalardır. Çoğunlukla yapay zeka araştırmaları için geliştirilmişlerdir. En bilinen yöntemleri ise bilgisayarlı görü ve doğal dil işleme alanlarındadır (Zhou ve ark., 2019).

Çizge madenciliği, temel zorluklar üzerinde GNN görevlerinden en bilinen çizge sınıflandırma, çizge eşleştirme ve çizge kümeleme gibi görevleri kullanarak çözüme ulaşmaya çalışmaktadır (Zhou ve ark., 2019).




Şekil 4. Çizge ağları yöntemleri.



Şekil 5. Gerçek dünya problemleri.

Bilgi çizgeleri, algılanan gerçek dünya içerisindeki varlık ilişkilerini nitelemektedir. Kullanılan görevler sayesinde akıl yürütme ve tahmin etme yeteneğine sahiptir. Farklı diller arasında çizge eşitleme yapabilir ve eğitim kümesi sayesinde bilgi tabanı dışı varlıklar için de bilgi tabanı tamamlayabilmektedir. Bilgi çizgeleri, gerçek dünya için üretici modeller arasında da yer almaktadır. Üretici modeller, moleküler yapı keşfi ve sosyal etkileşim modelleme ile ön plana çıkmaktadır. Bu modellerden biri olan NetGAN gerçek dünyada ağ taklidi yapabilmektedir. GAN mimari modeli üzerine geliştirilen NetGAN, bağlantı tahmini görevi sayesinde de genelleştirme özelliğine sahiptir (Shchur ve ark., 2018). Bu modele ek olarak farklı sayılarda düğüme sahip ağ çıktısı gerçekleştiren GraphRNN (You ve ark., 2018a), oluşumu sıralama ile gerçekleştiren GraphAF (Shi ve ark., 2020), permütasyon değişmez ayırıcı ile bitişiklik matrisinde bulunan düğüm değişkeni sorununu çözen MolGAN (Cao ve Kipf, 2018), pekiştirmeli öğrenme kullanan GCPN (You ve ark., 2018b), normalizasyonu çizgeye uyarlayabilen GNF (You ve ark., 2018b) ve otomatik kodlayıcı sayesinde nitelik ve temsilleri gizli değişkenlere kodlayan Graphite (Grover ve ark., 2019) modelleri de üretici modeller arasındadır. Kombinatoriyal optimizasyon ise odak noktasını sıralamalara çevirmiştir. Önemli olan husus ise nesnelere bir sıralama durumunun olup olmaması değil en iyi sıralamanın nasıl olması gerektiğine bakılmaktadır. Bağlantılar arasında en kısa mesafeyi bularak çizge içerisinde genel en kısa mesafenin arandığı MST (Minimum Spanning Tree – Minimum Kapsayan Ağaç) algoritması ve belirli mesafeler arasında düğümlerden sadece bir kez geçecek şekilde başlangıç noktasına dönebilen bu işlem sırasında en kısa yolu kullanarak aynı zamanda en düşük maliyeti sağlamaya odaklı TSP (Traveling Salesman Problem – Gezgin Satıcı Problemi) algoritmalarına odaklanan kombinatoriyal optimizasyon, önemli bir uygulama alanı haline gelmiştir (Zhou ve ark., 2019). TSP sorunu için geliştirilen yöntemde sıralı giriş ve çıkış verisi sağlayan işaretçi ağı (pointer network) ile pekiştirmeli öğrenmede doğrudan optimizasyon için kullanılan ilke gradyan yöntemleri kullanılmıştır (Bello ve ark., 2017). Bir başka yaklaşım ise çizge ve dağıtık yerel algoritma bağlantısını sağlayarak teorik analiz ile optimal sonuca ulaşabileceğini belirtmiştir (Sato ve ark., 2019). Öneri sistemleri, çizge tabanında sosyal öneri ve bağlantı tahmininden yola çıkarak kullanıcı-öğre etkileşim tahmini görevlerini yapmaktadır. Düğüm bilgilerinden yararlanılarak gerçekleştirilen işlemlerde eksik bağlantılar tahmin edilebilmekte ve bu tahmin için otomatik kodlayıcı kullanılmaktadır (Wu ve ark., 2021). Sosyal öneri için ise asıl amaç öneri verimini

yükseltmektedir. Geliştirilen GraphRec (Fan ve ark., 2019) modeli ile öge ve kullanıcı için gizli faktör öğrenmesi gerçekleştirilmektedir. Bu öğrenim sonrası yerleşme gerçekleşmekte ve tutarlı bir model ortaya çıkmaktadır.



Şekil 6. Gerçek dünya problemlerinin uygulamaları.

Trafik ağları da GNN modelleri için önemli bir araştırma ve uygulama konusu olmuştur. Uzamsal-zamansal bağımlılık yakalama görevin odak noktasıdır. Bu durum için LSTM kullanmakta ve dikkat katmanı ile işlem yapmaktadır (Zhou ve ark., 2019). STGNN modeli de akıllı ulaşım sistemini hedeflemektedir. LSTM’de olduğu gibi uzamsal-zamansal çizgeler kullanmaktadır. Bu sayede trafik hızı tahmini, trafik hacmi ve yol yoğunluğu tahmin edebilmektedir (Wu ve ark., 2021). Bir başka tahmin ise taksi talebi tahminidir. Geçmiş talepler, konum, hava durumu ve özellikler kullanılarak konum-talep tahmini yapılabilmektedir (Yao ve ark., 2018).

GNN'ler doğa bilimlerinde de kullanılmaktadır. Özellikle kimya ve biyoloji alanlarında moleküler çizgelerde kullanılmaktadır. Bunların dışında yaygın uygulama alanları, moleküler parmak izleri, kimyasal reaksiyon tahmini ve protein arayüz tahminidir. GNN modelleri molekül yapısını kodlayarak daha iyi parmak izleri elde edebilmektedir. Bu durum ilaç keşfini geliştirmekte ve bilgisayarlı ilaç tasarımında kullanılmaktadır. Tahmin yeteneği yüksek olan GNN modelleri kimya biliminde reaksiyon tahmini için de kullanılmaktadır. Aynı şekilde öneri sistemleri de kimyasal reaksiyon tahminine bu durumda yardım etmektedir. Çizge içerisinde bulunan belirli düğümlerin protein parçası olup olmadığını anlamamızı sağlayan protein arayüz tahmini, kimya ve biyoloji alanlarında kullanılmaktadır. Biyoloji alanında kullanım yöntemlerinden bir diğeri de teknik kısım olan biyomedikal mühendisliğidir. Biyoloji uygulamalarında protein-protein etkileşimi ile kanser sınıflandırması yapılabilmektedir. İlaç yan etkileri için de tahmin yeteneği kullanılmaktadır (Zhou ve ark., 2019). Fizik alanında da sistem modellemesi için kullanılan sinir ağları, ikili etkileşim kullanılmaktadır. Öğrenme sonrası tahminlerde bulunarak sistemi simüle edebilmektedir. Aynı zamanda çizge temsil, güçlü öğrenme ve kontrol görevleri de fizik alanında kullanılmaktadır. Tüm bunların dışında yapısal senaryolarda finans, borsa, hisse senedi etkileşimi, piyasa endeksi, yazılım tabanlı ağlarda optimizasyon ve metin oluşturma uygulamaları da kullanılmaktadır (Zhou ve ark., 2019). Farklı alanlara bakıldığında, kapalı tekrarlayan kullanarak tümevarımlı önyargılara sahip program doğrulama (Li ve ark., 2015), kaynak kod odağında öğrenme düşünerek değişken adı tahmini yapabilen VarNaming ile kullanım amacı seçimi için geliştirilerek akıllı yürütme kullanan VarMisuse modelini kullanan program muhakemesi (Allamanis ve ark., 2017), bağımlılık ağaçları kullanarak oluşturulan havuzlama modeli ile olay algılama (Nguyen ve Grishman, 2018), klinik nöral gelişim sonuç tahmini olarak geliştirilmesi ile deneylerini 18 aylık - prematüre kapsamında gerçekleştiren beyin ağları uygulaması BrainNetCNN (Kawahara ve ark., 2017), sosyal ağlar üzerinde gizli etkiyi öğrenerek sosyal etki tahmini yapabilen DeepInf (Qiu ve ark., 2018), çizge yapısı ile düğüm özelliklerine odaklanarak ters işlemler ile düşman saldırısı önleme (Zügner ve ark., 2018), veri yetersizliği ile yorumlama sorunlarına odaklanarak elektriksel sağlık kayıtları (EHR) uygulaması gerçekleştiren ve yorum yeteneğini tıbbi onkoloji ile tamamlayabilen dikkat modeli GRAM (Choi ve ark., 2017) ve son olarak EHR kayıtları ile düğüm gömme işlemi gerçekleştirerek öğrenme gerçekleştiren, kalp ve sıralı hastalık test deneylerinde başarılı olan MiMe (Multilevel Medical Embedding – Çok Düzeyli Tıbbi Gömme) (Choi ve ark., 2018) uygulamaları da yapısal senaryolara örnek olarak verilebilir.

Yapısal olmayan senaryolarda ise performansı iyileştirme amaçlı yapısal senaryo dâhili ve ilişkisel yapı çıkarımı sonrasında metini çizge üzerinde modelleme durumları söz konusudur. Yapısal olmayan senaryolar resim, metin ve kaynak kod olarak ayrılmaktadır.

Resim bölümünde görüntü sınıflandırma, görsel akıl yürütme, nesnelere arası anlamsal ilişki tanıma, nokta bulutu sınıflandırması ve semantik segmentasyon uygulamaları bulunmaktadır. Birkaç çekimli görüntü sınıflandırması, eğitim örnekleriyle öğrenme gerçekleştirerek genelleme yapmaktadır. Bu durumda bilgi çizgelerini yönlendirici olarak kullanılabilir. Görsel akıl yürütme, uzamsal-anlamsal çalışmaktadır. Görsel soru cevaplama en bilinen uygulamalarındandır. Aynı zamanda nesne ve etkileşim algılama ile bölge sınıflandırması da görsel akıl yürütme uygulamalarındandır. Bilgisayarlı görme alanında sıklıkla kullanılan GNN modelleri insan-nesne etkileşimi ve anlamsal bölümlenme alanında da yapısal olmayan senaryolara yardımcı olmaktadır (Zhou ve ark., 2019; Wu ve ark., 2021).

Metin bölümünde ise metin sınıflandırma, dizileri kategori haline getirerek etiket atama işlemi olan sıra etiketleme, dizi etiketlemeyi söz dizimsel olarak gerçekleştiren semantik rol etiketleme, diller arası otomatik çeviri yapabilen NMT (Neural Machine Translation – Sinirsel Makine Çevirisi), anlamsal ilişki çıkarımı, olay çıkarma, eş anlam cümleler oluşturabilen çizgeden diziye öğrenme, kanıt çıkararak gerçekleştirilen gerçek doğrulama ve doğal dil işleme görevleri bulunmaktadır (Zhou ve ark., 2019). Tablo 12-16'da çizge modellerin uygulamaları görülmektedir.

Tablo 12. Çizge modellerin uygulamaları (1).

Kullanım Alanı	Uygulama	Model	Çalışma
Çizge Madenciliği	Çizge Eşleştirme	GNN	(Li ve ark., 2018a) (Riba ve ark., 2018)
	Çizge Kümeleme	GNN	(Zhang ve ark., 2019d) (Ying ve ark., 2018b) (Tsitsulin ve ark., 2020)
	Derin Çizge Eşleştirme	GCN (Bölünmüş GNN)	(Fey ve ark., 2020)
Fizik	Fiziksel Sistem Modelleme	GNN	(Sukhbaatar ve ark., 2016) (Battaglia ve ark., 2016) (Hoshen, 2017) (Fey ve ark., 2020) (Watters ve ark., 2017) (Kipf ve ar k., 2013) (Sanchez ve ark., 2018)
	Sahne Görüntülerini Tahmin Etme	GNN	(Raposo ve ark., 2017)
	Nesne Keşfi ve İlişkileri	VAE	(Raposo ve ark., 2017)
	İlişkisel Akıl Yürütme	İlişki Ağları	(Santoro ve ark., 2017)
	Videodan Fizik Simülasyonu	Etkileşim Ağları	(Watters ve ark., 2017)
	Etkileşim Sistemleri	GNN	(Xu ve ark., 2019f)
Kimya	İklim Gözlemi	GNN	(Wang ve ark., 2020b)
	Moleküler Parmak İzleri	GCN	(Duvenaud ve ark., 2015) (Kearnes ve ark., 2016)
	Kimyasal Reaksiyon Tahmini	GCN	(Do ve ark., 2019)
	Polieczacılık Yan Etkisinin Modellenmesi	GCN	(Zitnik ve ark., 2018)
	Moleküllerde Polieczacılık İstismarı	GCN	(Knyazev ve ark., 2018)
	Moleküler Optimizasyon	GAN	(Jin ve ark., 2018)
	Yapılandırılmış Varlık Etkileşimleri Tahmini	GCN	(Xu ve ark., 2019f)
Retrosentez Tahmini	GCN	(Dai ve ark., 2019a)	
Biyoloji	Protein Arayüz Tahmini	GNN	(Fout ve ark., 2017)
	Yan Etki Tahmini	GNN	(Zitnik ve ark., 2018)
	Hastalık Sınıflandırılması	GNN	(Rhee ve ark., 2018)
Bilgi Çizgesi – Bilgi Tabanı	Bilgiye Dayalı Tamamlama	GNN	(Schlichtkrull ve ark., 2018) (Hamaguchi ve ark., 2017) (Shang ve ark., 2019)
	Bilgi Çizgesi Hizalama	GNN	(Wang ve ark., 2018f) (Zhang ve ark., 2019b) (Xu ve ark., 2019e)
	İlişkisel Verileri Modelleme	GNN	(Schlichtkrull ve ark., 2018)
	Bilgi Çizgesi Hizalama	GCN	(Wang ve ark., 2018f)
	İlişkisel Bilgi Üretimi	DGNN	(Kim ve ark., 2018)
	Düğüm Önem Tahmini	GNN	(Park ve ark., 2019)
	İlişkisel Tahmin	GAT	(Nathani ve ark., 2019)
	Bilgi Çizgesi Hizalama	GMNN	(Xu ve ark., 2019e)
	Bilgi Çizgesi Akıl Yürütme	GNN	(Xu ve ark., 2019g)
	Bilgiye Dayalı Tamamlama	SACN	(Shang ve ark., 2019)
Bilgi Çizgesi Gömme	LABNAN	(Wang ve ark., 2018b)	
Mantıksal Akıl Yürütme	GNN	(Zhang ve ark., 2020b)	

Tablo 13. Çizge modellerin uygulamaları (2).

Kullanım Alanı	Uygulama	Model	Çalışma
Oluşturma	Çizge Oluşturma	GNN	(You ve ark., 2018a) (You ve ark., 2018b) (Cao ve Kipf, 2018) (Li ve ark., 2018b) (Shchur ve ark., 2018) (Shi ve ark., 2020) (Grover ve ark., 2019) (Nowak ve ark., 2018) (Ma ve ark., 2018b) (Liu ve ark., 2019a)
	Anlamsal Doğrulama	VAE	(Ma ve ark., 2018b)
	Çizge Oluşturma	GNN	(Li ve ark., 2018b)
	Küçük Moleküler Çizgeler	GAN	(Cao ve Kipf, 2018)
	Çizge Oluşturma	GAN	(Shchur ve ark., 2018)
	Çizge Oluşturma	VAE	(Grover ve ark., 2019)
	Kod Oluşturma	GNN	(Bojhevski ve Günneman, 2018)
	Çizge Oluşturma	RNN	(Liao ve ark., 2019)
Bilgisayar Ağı	SDN’de Ağ Modelleme ve Optimizasyon	GNN	(Rusek ve ark., 2019)
Program Temsili	Program Temsil Etme	Gated GNN	(Allamanis ve ark., 2017)
	Çizge Yapılı Önbellek	GNN	(Cvitkovic ve ark., 2019)
Sosyal Ağ	Haber Medyasında Siyasi Perspektif Tespiti	GNN	(Li ve ark., 2019a)
	İnci Taneli Olay Kategorizasyonu	GCN	(Peng ve ark., 2019)
	Sosyal Spam Gönderici Algılama	GCN	(Wu ve ark., 2020)
	Söylenti Tespiti	GCN	(Bian ve ark., 2017)
Öneri Sistemleri	Kullanıcı Ögesi Etkileşim Tahmini	GNN	(Ying ve ark., 2018a) (Berg ve ark., 2017)
	Sosyal Tavsiye	GNN	(Fan ve ark., 2019) (Wu ve ark., 2019b)
	Matris Tamamlama	GCN	(Berg ve ark., 2017)
	Web Ölçeğinde Öneri sistemleri	GCN	(Ying ve ark., 2018a)
	Öneri Sistemleri	Star-GCN	(Zhang ve ark., 2019c)
	İşbirlikçi Filtreleme	Distiling-GCN	(Wang ve ark., 2019a)
	Oturuma Dayalı Öneri	SAN	(Xu ve ark., 2019a)
	Birebir Aynı Öneri	MCO	(Gong ve ark., 2019)
	Birebir Aynı Öneri	GAT	(Wang ve ark., 2019c)
	Öneri Sistemleri	GCN	(Wang ve ark., 2019b)
Endüktif Matris Tamamlama		GNN	(Zhang ve ark., 2019a)
	İşbirlikçi Filtreleme	LRGCN	(Chen ve ark., 2020a)
Diğer (Yapısal)	Borsa	GNN	(Matsunaga ve ark., 2017) (Yang ve ark., 2019) (Chen ve ark., 2018b) (Li ve ark., 2020a)
	Yazılım Tanımlı Ağlar	GNN	(Rusek ve ark., 2019)
	Çizgeden Metne	GNN	(Beck ve ark., 2018) (Song ve ark., 2018c)
Diğer (Yapısal Olmayan)	Program Doğrulama	GNN	(Allamanis ve ark., 2017) (Li ve ark., 2015)
Bilgisayarlı Görü	Görsel Soru – Cevaplama	GRU	(Teney ve ark., 2017)
	Semantik Segmentasyon	3D GNN	(Qi ve ark., 2017)
	Durum Tanıma	GNN	(Li ve ark., 2017c)
	İnsan – Nesne Etkileşimi	GPNN	(Qi ve ark., 2018)
	Yorumlanabilir Görsel Soru Cevaplama	GCN + GLM	(Norcliffe-Brown ve ark., 2018)
	Gerçek Görsel Soru Cevaplama	GCN	(Narasimhan ve ark., 2018)
	Sosyal İlişki Anlayışı	GRM	(Wang ve ark., 2018e)
Eylem Tanıma	GCN	(Guo ve ark., 2018)	

Tablo 14. Çizge modellerin uygulamaları (3).

Kullanım Alanı	Uygulama	Model	Çalışma
Kombinatoriyal Optimizasyon	Kombinatoriyal Optimizasyon	GNN	(Bello ve ark., 2017) (Sato ve ark., 2019) (Nowak ve ark., 2018) (Khalil ve ark., 2017) (Kool ve ark., 2018) (Vinyals ve ark., 2015) (Sutton ve Barto, 2018) (Dai ve ark., 2016) (Gasse ve ark., 2019) (Zheng ve ark., 2020c) (Selsam ve ark., 2019)
	İkinci Dereceden Atama	GNN	(Nowak ve ark., 2017)
	Kombinatoriyal Optimizasyon	GCN	(Li ve ark., 2018d)
	Dikkat Çözücü	GAT	(Kool ve ark., 2018)
	Tam Problemler	GNN	(Prates ve ark., 2019)
	Kombinatoriyal Problemler	GNN	(Sato ve ark., 2019)
	Topolojik Gürültü Giderme	GNN	(Nowak ve ark., 2017)
Trafik Ağı	Trafik Durum Tahmini	GNN	(Yu ve ark., 2018a) (Lou ve ark., 2020b) (Zheng ve ark., 2020a) (Guo ve ark., 2019)
	Trafik Tahmini	GCN	(Yu ve ark., 2018a)
	Trafik Akış Tahmini	GCN	(Guo ve ark., 2019)
	Yolcu Talep Yönlendirme	GCN	(Wang ve ark., 2019d)
	Yüksek Çözünürlüklü Yönlendirme	GCN	(Hu ve ark., 2019)
	Çok Adımlı Yolcu Talep Tahmini	GCN	(Bai ve ark., 2019a)
	Şehir Çapında Park Yeri Durumu Tahmini	GNN	(Zhang ve ark., 2020a)
Az Sayılı Öğrenme	Çizge Yapılı Önbellek Yapılandırılmış Bilgi Çizgeleri	GRU	(Lee ve ark., 2018a)
	Sınıflandırma Ağırlığı Oluşturma	GNN	(Gidaris ve Komodakis, 2019)
	Çizge Meta Öğrenme	GAT	(Li ve ark., 2019b)
	Nitelik Yayılım Ağı	KNN	(Li ve ark., 2020c)
	Bilgi Aktarımı	GNN	(Yao ve ark., 2020)
	Çizge Spektral Ölçüm	GNN	(Chauhan ve ark., 2020).
	Bilgi Tahmini	GNN	(Baek ve ark., 2020)
Düşman Saldırısı	Çizge Yapılandırılmış Veri	GNN	(Zügner ve ark., 2018)
	Çizge Yapılandırılmış Veri	GNN	(Dai ve ark., 2018b)
	Saldırı ve Savunma	GCN	(Wu ve ark., 2019a)
	Topolojik Saldırı ve Savunma	GNN	(Xu ve ark., 2019d)
	Düşman Saldırısı	GCN	(Zhu ve ark., 2019)
	Düğüm Gömme	GNN	(Bojhevski ve Günneman, 2019a)
	Çizge Pertürbasyon	GNN	(Bojhevski ve Günneman, 2019b)
Güvenlik Analizi	Etkili Güvenlik Açığı Tanımlama	GNN	(Zhou ve ark., 2020)
	Mantık Şifresini Kırma	RNN	(Tehranipoor ve ark., 2019)
	Şaşırtma Politikasını Geliştirme	GCN	(Chen ve ark., 2020b)
	Veri Yönetimi ve Anormallik Algılama	GCN	(Wang ve ark., 2020d)
	Kötü Amaçlı Yazılım Algılama	GCN	(Pei ve ark., 2020)

Tablo 15. Çizge modellerin uygulamaları (4).

Kullanım Alanı	Uygulama	Model	Çalışma
Resim	Sosyal İlişki Anlama	GNN	(Wang ve ark., 2018e)
	Görüntü Sınıflandırma	GNN	(Garcia ve Bruna, 2018) (Marino ve ark., 2017) (Lee ve ark., 2018a) (Wang ve ark., 2018c) (Kampffmeyer ve ark., 2019)
	Görsel Soru Cevaplama	GNN	(Teney ve ark., 2017) (Wang ve ark., 2018e) (Narasimhan ve ark., 2018)
	Nesne Algılama	GNN	(Hu ve ark., 2018) (Gu ve ark., 2018)
	Etkileşim Algılama	GNN	(Qi ve ark., 2018) (Jain ve ark., 2016)
	Bölge Sınıflandırması	GNN	(Chen ve ark., 2018c)
	Semantik Segmentasyon	GNN	(Qi ve ark., 2017) (Liang ve ark., 2016) (Liang ve ark., 2017) (Wang ve ark., 2018d)
Doğal Dil İşleme	Hücrel Otomasyonu Yönetme Kurallarını Keşfetme	GST	(Johnson, 2016)
	Çapraz Cümle İlişki Çıkarma	GLSTM	(Peng ve ark., 2017)
	Makine Aktarımı	GCE	(Basting ve ark., 2017).
	Semantik Rol Etiketleme	GCN	(Marcheggiani ve ark., 2017)
	Olay Algılama	GCN	(Nguyen ve Grishman, 2018)
	Çok Atlı Okuduğunu Anlama	GNN	(Song ve ark., 2018a)
	İlişki Çıkarma	GCN	(Zhang ve ark., 2018d)
	İlişki Çıkarma	GSLSTM	(Song ve ark., 2018d)
	AMR'den Metne Dönüştürme	LSTM	(Song ve ark., 2018b)
	Metne Dönüştürme	GGNN	(Beck ve ark., 2018)
	Metin Temsili Öğrenme	SSLSTM	(Zhang ve ark., 2018c)
	Kullanıcı Coğrafi Konumu	GCN	(Rahimi ve ark., 2018)
	Soru Cevaplama	GGNN	(Sorokin ve Gurevych, 2018)
	Konuşma Modelleme	GSLSTM	(Zayats ve ark., 2018)
	Bulmaca Çözümü Soru Cevaplama	RRN	(Palm ve ark., 2018)
Metin	Metin Sınıflandırma	GNN	(Zhang ve ark., 2019b) (Peng ve ark., 2018) (Tai ve ark., 2015)
	Sıra Etiketleme	GNN	(Marcheggiani ve ark., 2017) (Zhang ve ark., 2019b)
	Sınırsal Makine Çevirisi	GNN	(Basting ve ark., 2017) (Marcheggiani ve ark., 2018)
	İlişki Çıkarımı	GNN	(Peng ve ark., 2017) (Zhang ve ark., 2018d) (Song ve ark., 2018d) (Miwa ve ark., 2016)
	Olay Çıkarımı	GNN	(Nguyen ve Grishman, 2018) (Liu ve ark., 2018b)
	Bilgi Doğrulama	GNN	(Nt ve ark., 2019) (Liu ve ark., 2019b) (Zhong ve ark., 2020)
	Soru Cevaplama	GNN	(Cao ve Kipf, 2018) (Song ve ark., 2018a) (Qiu ve ark., 2019) (Tu ve ark., 2019) (Ding ve ark., 2019)
	İlişkisel Okuma	GNN	(Santoro ve ark., 2017) (Palm ve ark., 2018) (Battaglia ve ark., 2016)

Tablo 16. Çizge modellerin uygulamaları (5).

Kullanım Alanı	Uygulama	Model	Çalışma
Çizge Sınıflandırma	Moleküler Özellik Tahmini ve Çizge Sınıflandırma	GCN	(Sun ve ark., 2019)
	Düğüm Sınıflandırma	GAN	(Zheng ve ark., 2020b)
	Keyfi Makine Öğrenimi Görevleri	GNN	(Lou ve ark., 2020a)
	Çizge Kümeleme ve Sınıflandırma	VAE	(Wang ve ark., 2020a)
	Düğüm Sınıflandırma	GRU + ATM	(Xu ve ark., 2019c)
	Bağlantı Tahmini Öğrenme	GAN + ATM	(Yu ve ark., 2019)
	Düğüm Sınıflandırma	GRU + ATM	(Xu ve ark., 2019b)
	Çizge Sınıflandırma	GAT	(Bai ve ark., 2019b)
	Çizge Sınıflandırma	GNN + ATM	(Al-Rfou ve ark., 2019)
	Çizge Sınıflandırma	GCN + ATM	(Peng ve ark., 2016)
Olasılıksal Tür Çıkarımı	GNN	(Ye ve ark., 2020)	

4. AVANTAJ, DEZAVANTAJ VE KISITLAR

GNN, çizge öğrenme kullanan bir derin öğrenme yöntemidir. Kendi modelinde avantaj, dezavantaj ve kısıtları olduğu gibi çizge öğrenmeden gelen aynı özellikleri de bulunmaktadır. Şekil 7’de çizge öğrenmenin özellikleri görülmektedir.


**Şekil 7.** Çizge öğrenmenin özellikleri.

Çizge öğrenme genellikle yapısal verileri işlemek, anlamlandırmak ve tahmin yeteneği için kullanılmaktadır. GNN’lerde olduğu gibi düğüm ve kenar öğrenmesi gerçekleştiren derin öğrenme yöntemlerini kullanmaktadır. Sosyal ve trafik ağları, biyolojik ve kimyasal molekül yapıları gibi çizgesel veriler için uygunluk oluşturmaktadır. Yapısında derin sinir ağlarını ve GNN’leri kullanması sebebiyle büyük ve karmaşık verilerin analizinde kullanılabilir. GNN’lerde olduğu gibi sınıflandırma, kümeleme, tahmin ve keşif gibi görevleri bulunmaktadır. İşlem gerçekleştirirken duyarlılığı ön planda tutmakta ve yapısal özellikleri dikkatle işlemektedir. Özellik çıkarma ve dönüşüm işlemlerinde, ham veri işlemlerinde yeni özellik çıkarma metotları olan özellik mühendisliğini kullanmaktadır. Büyük çizge verileri işleyebilir ve analiz için uygun modeller barındırmaktadır. Üretilen model diğer modeller tarafından anlaşılabilir ve birlikte kullanılabilir. Temel özelliklerine ek olarak çizge öğrenmenin avantaj ve dezavantajları bulunmaktadır. Modelden modele geçişle birlikte çizge öğrenmenin temel avantaj ve dezavantajları Tablo 17’de görülmektedir.

Tablo 17. Çizge öğrenmenin avantaj ve dezavantajları.

Avantaj	Dezavantaj
Yapısal Veri İşleme	Veri Yoğunluğu Gerekliliği
Özellik Mühendisliği	Hesaplama Gücü
Duyarlılık	Model Karmaşıklığı
Geniş Uygulama Alanları	Aşırı Öğrenme Eğilimi
Büyük Veri Setleri	

Çizge modeller yapısal verileri işleyebilmekte ve etkili bir yaklaşım sunmaktadır. Yapının bağlantıları dikkate alınarak analiz yapar ve bütünlük sağlar, özellik mühendisliği otomatikleştirilmiştir, modeller kendi kendine öğrenme yeteneğine sahiptir. Karmaşık ve büyük boyutlu verilerde etkinlik göstermektedir. Bu durum hem avantaj sağlarken aynı zamanda modellerin büyük veri gereksinimi ve veri işleme maliyeti sebebiyle dezavantaj oluşturmaktadır. Aşırı öğrenme eğilimi ile model açıklanabilirliğini de etkilemektedir. Model genelleme yaparak dezavantaj oluşturmaktadır. Uygulama alanı oldukça geniş ve her geçen gün genişlemektedir. Çizge öğrenmenin gelişimi her gün devam etse de genel kısıtları bulunmaktadır. Çizge öğrenmenin kısıtları Şekil 8’de görülmektedir.

**Şekil 8.** Çizge öğrenme kısıtları.

Çizge öğrenmede en büyük kısıt büyük verilerin kalitesi olarak görülmektedir. Temelde tüm kısıtlar bu kısıta dayanmaktadır. Model kalitesiz ise sonuçlar yanlış üretilir, model genelleme yaparak açıklanabilirliği düşürmektedir. Aynı zamanda işlem sürecinde maliyeti artırmaktadır. GNN'lere bu durumlar genetik olarak geçmiştir. Genel karşılaştırma Tablo 18’de görülmektedir.

GNN'ler her ne kadar çizge öğrenme alt alanı olarak bilinse de benzerliklerinden çok farklılıkları bulunmaktadır. Geliştirilen her modelin kendine özgü olması bu durumun en büyük sebebidir. Modeller uygulamaya yönelik geliştirilmektedir. Genele bakıldığında bu durum en büyük avantajı sağlamakta ve gelişmiş bir uygulama alanı oluşturmaktadır. Modeller farklı alanları etkilemekte ve yeni alanların önünü açmaktadır.

Tablo 18. Çizge öğrenme ve GNN.

	Çizge Öğrenme	GNN
Avantaj	Yorumlanabilirlik	Etki Alanı Birleştirme
	Ölçeklenebilirlik	Uyarlanabilir
	Yapısal Öğrenme	Transdüktif Öğrenme
Dezavantaj	Basit Gösterim	Sınırlı Genelleme
	Varsayımsal Bağ	Yorumlanabilir Temsil
Kısıt	Çıkarım Karmaşıklığı	Uyum
	Sınırlı Anlatım	Maliyet
Benzerlik	Çizge Gösterimi	
Farklılık	Model Karmaşıklığı	
	Yorumlanabilirlik	
	Eğitim Paradigması	
	Veri Gereksinimi	

Çizge öğrenme ve GNN'ler ayrı kavramlar olsa da birbirlerini desteklemektedir. Geliştirilen modeller her geçen gün farklı alanlara yol göstermektedir. Öğrenme yol göstermede başta gelmektedir. Takviyeli öğrenme ile modeller durum ve ortamı analiz ederek geri bildirim sağlar. Karar verme aşamasında analizi ve geri bildirimini kullanmaktadır. Modeller öğrenmeyi de öğrenebilmektedir. Meta-öğrenme olarak bu durumla bir model başka bir modeli geliştirebilir ve analiz yeteneğini güçlendirebilir. Modeller yorumlama işlemlerini örneklerle açıklayabilmektedir. Yorumlama çizge öğrenmenin avantajlarından olsa da GNN'lerin dezavantajlarındandır. Bu sorun yeni modellerle aşılmaya çalışılmakta, kısıtı kaldırmak için yeni modeller üretmektedir. Modelsel durumda yorumlama yeteneği GNN modellerinde bulursa da çizge modeller karşısında daha az yorumlama yeteneği bulunmaktadır. Bu sebeple GNN'ler ile çizge öğrenme arasında etkileşimli alan oluşmaktadır. İki alan da fizik, kimya, metin sınıflandırma ve bilgi çizgilerinde etkili olmaktadır. Fakat burada ayrışan durum, GNN'lerin sinir ağı mimarisini kullanırken, çizge öğrenmenin rastgele yürüyüş ve matris faktörizasyonu kullanmasıdır. Bu sebeple GNN'ler göreve özgü modeli benimsemiştir. Her iki alan da kendi modellerini geliştirmektedir. Çizge öğrenme yaklaşımında çizgesel verileri sinir ağı mimarisi dışında mimariler kullanılarak da geliştirilebilir. GNN'lerin temeli olan derin öğrenme çizge öğrenmenin kullandığı metotlardan sadece birisidir. Bu sebeple daha geniş bir çerçeveye sunmaktadır (Gümüş ve Eyüpoğlu, 2023; Gümüş ve Eyüpoğlu, 2024; Wei ve ark., 2021; Zia ve ark., 2021).

5. SONUÇLAR

GNN'ler temelde CNN'ler ile ilişkilendirilmektedir. Bu durum CNN'lerin üç boyutlu verilerde performansının düşük olması sebebiyle oluşmuştur. GNN'ler CNN'lerin limitlerini aşmış ağlardır. Kullanımı her ne kadar dünya genelinde yaygın olsa da ülkemizde yaygınlaşmasının gelecek yıllarda olacağı düşünülmektedir. GNN'lerin avantaj ve dezavantajları hem CNN hem de çizge öğrenme olarak bilinen kavramlardan gelmektedir. Kavramlar her ne kadar farklı çalışmalarda birbirinin altında gösterilse de ayrı kavramların birbirleri ile ilişkilendirilmesi sonucu bu durum ortaya çıkmaktadır. Bu durum temel olarak doğrudur fakat kullanım alanları dahil olduğunda değişim göstermektedir. Bu çalışmada çizge öğrenme ve GNN arasındaki farklar ve benzerlikler ortaya koyulmaktadır. Ayrıca kullanım alanları ve yapılan çalışmalar özetlenerek gelecekte yapılacak araştırmalar için bir bibliyografya oluşturmaktadır. Avantaj, dezavantaj ve kısıtlar incelendiğinde iki kavramın da alan bazlı başarısının kendisini kanıtladığı görülmektedir. Araştırmacılar kavramların kısıtlarını ortadan kaldıracak çalışmalar üretmeye odaklanırken, dezavantajları avantaj haline getirmeye çalışmaktadırlar. Bu sayede gelecek yıllarda kavramların gelişiminin daha hızlı olacağı düşünülmektedir. Bu çalışmanın amacı, çizge öğrenme ve GNN arasındaki ilişkiyi ortaya koyarak yeni çalışmaların gerçekleştirilmesi için kaynak oluşturmaktır. Bu sayede dünyada kullanımı yaygınlaşan GNN'ler ile ilgili çalışmaların artacağı ve çalışmamızın bu çalışmalara yol göstereceği düşünülmektedir.

KAYNAKLAR

Abu-El-Haija, S., Perozzi, B., Al-Rfou, R., Alemi, A. (2018). Watch your step: learning graph embeddings through attention. In Proceedings of Adv. Neural Inf. Process. Syst., 2018, pp. 9180–9190.

Ahmed, A., Shervashidze, N., Narayanamurthy, S., Josifovski, V., and Smola, A.J. (2013). Distributed large-scale natural graph factorization. In Proceedings of 22nd Int. Conf. World Wide Web, May 2013, pp. 37–48.

- Allamanis, M., Brockschmidt, M., Khademi, M. (2017). Learning to represent programs with graphs. In Proceedings of the 7th International Conference on Learning Representations 2017, arXiv:1711.00740.
- Al-Rfou, R., Perozzi, B., Zelle, D. (2019). DDGK: Learning graph representations for deep divergence graph kernels. In Proceedings of World Wide Web Conf., 2019, pp. 37–48.
- Army. (2022). Ordu araştırması, | son teknoloji siber güvenlik yöntemlerini geliştiriyor Madde | Amerika Birleşik Devletleri Ordusu. (army.mil).
- Asif, N.A., Sarker, Y., Chakraborty, R.K., Ryan, M.J., Ahamed, H., Saha, D.K., Badal, F.R., Das, S.K., Ali, F., Moyeen, S.I., Islam, R., Tasneem Z. (2021). Graph Neural Network: A Comprehensive Review on Non-Euclidean Space. IEEE Access, vol. 9, pp. 60588–60606.
- Atwood, J., Towsley, D. (2016). Diffusion-Convolutional Neural Networks. In Proceedings of the 29th Conference on Neural Information Processing Systems (NIPS 2016), Barcelona, Spain, pp. 1993–2001.
- Baek, J., Lee, D.B., Hwang, S.J. (2020). Learning to extrapolate knowledge: Transductive few-shot out-of-graph link prediction. 2020, arXiv:2006.06648.
- Bai, L., Yao, L., Kanhere, S.S., Wang, X., Sheng, Q.Z. (2019). STG2Seq: Spatial-temporal graph to sequence model for multi-step passenger demand forecasting. 2019, arXiv:1905.10069.
- Bai, Y., Ding, H., Qiao, Y., Marinovic, A., Gu, K., Chen, T., Sun, Y., Wang, W. (2019). Unsupervised inductive graph-level representation learning via graph-graph proximity. 2019, arXiv:1904.01098.
- Baingana, B., Giannakis, G.B. (2016). Tracking switched dynamic network topologies from information cascades. IEEE Trans. Signal. Process., vol. 65, no. 4, 2016, pp. 985–997.
- Bastings, J., Titov, I., Aziz, W., Marcheggiani, D., Simaan, K. (2017). Graph convolutional encoders for syntax-aware neural machine translation. In Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017, arXiv:1704.04675.
- Battaglia, P.W., Pascanu, R., Lai, M., Rezende, D., Kavukcuoglu, K. (2016). Interaction networks for learning about objects, relations and physics. In Proceedings of the 30th Conference on Neural Information Processing Systems, 2016.
- Beck, D., Haffari, G., Cohn, T. (2018). Graph-to-sequence learning using gated graph neural network. In Proceedings of ACL 2018, pp. 273–283. arXiv:1806.09835.
- Belkin, M., Niyogi, P. (2003). Laplacian eigenmaps for dimensionality reduction and data representation. Neural Comput., vol. 15, no. 6, 2003, pp. 1373–1396.
- Bello, I., Pham, H., Le, Q.V., Norouzi, M., Bengio, S., (2017). Neural Combinatorial Optimization with Reinforcement Learning. arXiv preprint, 2017, arXiv:1611.09940.
- Berg, R.V.D., Kipf, T.N., Welling, M. (2017). Graph convolutional matrix completion. 2017, arXiv:1706.02263.
- Bian, T., Xiao, X., Xu, T., Zhao, P., Huang, W., Rong, Y., Huang, A. (2017). Rumor detection on social media with bi-directional graph convolutional networks. In Proceedings of AAAI Conf. Artif. Intell., vol. 34, 2020, pp. 549–556.
- Bojchevski, A., Günnemann, S. (2019a). Adversarial attacks on node embeddings via graph poisoning. In Proceedings of Int. Conf. Mach. Learn., 2019, pp. 695–704.
- Bojchevski, A., Günnemann, S. (2019b). Certifiable robustness to graph perturbations. In Proceedings of Adv. Neural Inf. Process. Syst., 2019, pp. 8319–8330.
- Brockschmidt, M., Allamanis, M., Gaunt, A.L., Polozov, O. (2018). Generative code modeling with graphs. 2018, arXiv:1805.08490.

- Bruna, J., Zaremba, W., Szlam, A., LeCun, Y. (2014). Spectral networks and locally connected networks on graphs. In Proceedings of the 2nd Int. Conf. Learn. Repres., Banff, AB, Canada 2014.
- Cao, S., Lu, W., Xu, Q. (2015). Grarep: Learning graph representations with global structural information. In Proceedings of the 24th ACM International on Conference on Information and Knowledge Management, 2015, ACM, pp. 891–900.
- Cao, N.D., Kipf, T. (2018). MolGAN: An implicit generative model for small molecular graphs. In Proceedings of ICML 2018 workshop on Theoretical Foundations and Applications of Deep Generative Models, 2018.
- Cao, S., Lu, W., Xu, Q. (2016). Deep neural networks for learning graph representations. In Proceedings of the 30th AAAI Conference on Artificial Intelligence, 2016, pp. 1145–1152.
- Chauhan, J., Nathani, D., Kaul, M. (2020). Few-shot learning on graphs via super-classes based on graph spectral measures. 2020, arXiv:2002.12815.
- Chen, D. (2009). A novel clustering algorithm for graphs. In Proceedings of 2009 International Conference on Artificial Intelligence and Computational Intelligence, vol. 4, pp.279–283.
- Chen, H., Perozzi, B., Hu, Y., Skiena, S. (2018a). HARP: Hierarchical representation learning for networks. In Proceedings of the 32nd AAAI Conference on Artificial Intelligence, 2018, pp. 2127–2134.
- Chen, J., Zhang, Q., Huang, X. (2016). Incorporate group information to enhance network embedding. In Proceedings of the 25th ACM International Conference on Information and Knowledge Management, 2016, pp. 1901–1904.
- Chen, J., Zhu, J., Song, L., (2018b). Stochastic Training of Graph Convolutional Networks with Variance Reduction. In Proceedings of the 35 th International Conference on Machine Learning, Stockholm, Sweden, PMLR 80.
- Chen, L., Wu, L., Hong, R., Zhang, K., Wang, M., (2020a). Revisiting Graph based Collaborative Filtering: A Linear Residual Graph Convolutional Network Approach. In Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence (AAAI-20), 2020, pp. 27–35.
- Chen, X., Li, L.-J., Fei-Fei, L., Gupta, A. (2018c). Iterative visual reasoning beyond convolutions. In Proceedings of CVPR, pp. 7239–7248.
- Chen, Z., Kolhe, G., Rafatirad, S., Lu, C.T., Manoj, S.P.D., Homayoun, H., Zhao, L. (2020b). Estimating the circuit de-obfuscation runtime based on graph deep learning. In Proceedings of Design, Automat. Test Eur. Conf. Exhib. (DATE), Mar. 2020, pp. 358–363.
- Choi, E., Bahadori, M.T., Song, L., Stewart, W.F., Sun, J. (2017). Gram: graph-based attention model for healthcare representation learning. In Proceedings of KDD. ACM, 2017, pp. 787–795.
- Choi, E., Xiao, C., Stewart, W., Sun, J. (2018). Mime: Multilevel medical embedding of electronic health records for predictive healthcare. In Proceedings of NeurIPS, 2018, pp. 4548–4558.
- Coley, C.W., Barzilay, R., Green, W.H., Jaakkola, T.S., Jensen, K.F. (2017). Convolutional embedding of attributed molecular graphs for physical property prediction. *Journal of Chemical Information and Modeling*, vol. 57, no. 8, pp. 1757–1772.
- Cvitkovic, M., Singh, B., Anandkumar, A. (2019). Open vocabulary learning on source code with a graph-structured cache. In Proceedings of Int. Conf. Mach. Learn., 2019, pp. 1475–1485.
- Dai, H., Dai, B., Song, L. (2016). Discriminative embeddings of latent variable models for structured data. In Proceedings of ICML, 2016, pp. 2702–2711.
- Dai, H., Kozareva, Z., Dai, B., Smola, A., Song, L. (2018a). Learning Steady-States of Iterative Algorithms Over Graphs. In the 35th International Conference on Machine Learning, PMLR 80, pp. 1106–1114.

- Dai, H., Li, C., Coley, C., Dai, B., Song, L. (2019a). Retrosynthesis prediction with conditional graph logic network. In Proceedings of Adv. Neural Inf. Process. Syst., 2019, pp. 8872–8882.
- Dai, H., Li, H., Tian, T., Huang, X., Wang, L., Zhu, J., Song, L. (2018b). Adversarial attack on graph structured data. In Proceedings of the 35th International Conference on Machine Learning, 2018, arXiv:1806.02371.
- Dai, Q., Li, Q., Tang, J., Wang, D. (2019b). Adversarial network embedding, In Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence.
- Das, R., Dhuliawala, S., Zaheer, M., Vilnis, L., Durugkar, I., Krishnamurthy, A., Smola, A., McCallum, A. (2018). Go for a walk and arrive at the answer: Reasoning over paths in knowledge bases using reinforcement learning. In Proceedings of the 7th International Conference on Learning Representations.
- De Bacco, C., Power, E.A., Larremore, D.B., Moore, C. (2018). Community detection, link prediction, and layer interdependence in multilayer networks. Phys. Rev. E., vol. 95, no. 4, 2017, 042317.
- Defferrard, M., Bresson, X., Vandergheynst, P. (2016). Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering. In Proceedings of NeurIPS 2016, pp. 3844–3852.
- Deng, Z., Dong, Y., Zhu, J. (2019). Batch Virtual Adversarial Training for Graph Convolutional Networks. ArXiv abs/1902.09192 (2019).
- Derr, T., Ma, Y., Tang, J. (2018). Signed graph convolutional networks. In Proceedings of 2018 IEEE International Conference on Data Mining (ICDM), IEEE, 2018, pp. 929–934.
- Ding, C.H., He X., Zha H., Gu M., Simon H.D. (2001). A min-max cut algorithm for graph partitioning and data clustering. In Proceedings of the 2001 IEEE International Conference on Data Mining, IEEE, 2001, pp. 107–114.
- Ding, M., Tang, J., Zhang, J. (2018). Semi-supervised learning on graphs with generative adversarial nets, In Proceedings of the 27th ACM International Conference on Information and Knowledge Management, 2018.
- Ding, M., Zhou, C., Chen, Q., Yang, H., Tang, J. (2019). Cognitive graph for multi-hop reading comprehension at scale. In Proceedings of ACL, 2019, pp. 2694–2703.
- Do, K., Tran, T., Venkatesh, S. (2019). Graph transformation policy network for chemical reaction prediction. Proceedings of SIGKDD, pp. 750–760. J. Zhou et al. AI Open 1, pp. 57–81 77, In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2019.
- Dong, X., Thanou, D., Frossard, P., Vandergheynst, P. (2016). Learning Laplacian matrix in smooth graph signal representations. IEEE Trans. Signal. Process., vol. 64, no. 23, 2016, pp. 6160–6173.
- Donnat, C., Zitnik, M., Hallac, D., Leskovec, J. (2017). Spectral graph wavelets for structural role similarity in networks. arXiv preprint arXiv:1710.10321, 2017.
- Dourisboure, Y., Geraci, F., Pellegrini, M. (2007). Extraction and classification of dense communities in the web. In Proceedings of the 16th International Conference on World Wide Web, ACM, pp. 461–470.
- Du, M., Li, F., Zheng, G., Srikumar, V. (2017). Deeplog: anomaly detection and diagnosis from system logs through deep learning. In Proceedings of Acm Sigsac Conference on Computer & Communications Security 2017.
- Dutil, F., Cohen, J.P., Weiss, M., Derevyanko, G., Bengio, Y. (2018). Towards gene expression convolutions using gene interaction graphs. In Proceedings of International Conference on Machine Learning Workshop on Computational Biology, 2018.
- Duvenaud, D.K., Maclaurin, D., Aguileraiparraguirre, J., Gomezbombarelli, R., Hirzel, T.D., AspuruGuzik, A., Adams, R.P. (2015). Convolutional networks on graphs for learning molecular fingerprints. In Proceedings of NIPS, Neural Inf. Process. Syst., 2015, pp. 2224–2232.
- Entezari, N., Al-Sayouri, A.S., Darvishzadeh, A., Papalexakis, E.E. (2020). All you need is low (rank) - defending against adversarial attacks on graphs. In WSDM '20: the Thirteenth ACM International Conference on Web Search

and Data Mining, Houston TX USA February, 2020, pp. 169–177.

Fan, W., Ma, Y., Li, Q., He, Y., Zhao, E., Tang, J., Yin, D. (2019). Graph neural networks for social recommendation. In Proceedings of WWW, 2019, pp. 417–426.

Feder, T., Motwani, R. (1995). Clique partitions, graph compression and speeding-up algorithms. *J. Comput. Syst. Sci.*, vol. 51, no. 2, 1995, pp. 261–272.

Feng, R., Yang, Y., Hu, W., Wu, F., Zhuang, Y. (2018a). Representation learning for scale-free networks. In Proceedings of the 32nd AAAI Conference on Artificial Intelligence, 2018, pp. 282–289.

Feng, Y., You, H., Zhang, Z., Ji, R., Gao, Y., (2018b). Hypergraph neural networks. In Proceedings of AAAI, vol. 33, 2018, pp. 3558–3565.

Fey, M., Lenssen, J.E., Morris, C., Masci, J., Kriege, N.M. (2020). Deep graph matching consensus. Arxiv 2020, arXiv:2001.09621.

Fortunato, S. (2010). Community detection in graphs. *Phys. Rep.*, vol. 486, no. 3-5, 2010, pp. 75–174.

Fout, A., Byrd, J., Shariat, B., Ben-Hur, A. (2010). Protein interface prediction using graph convolutional networks. In Proceedings of NIPS, 2017, pp. 6533–6542.

Gao, H., Wang Z., Ji S. (2018). Large-scale learnable graph convolutional networks. In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, ACM, 2018, pp. 1416–1424.

Garcia, V., Bruna, J. (2018). Few-shot learning with graph neural networks. In Proceedings of the 7th International Conference on Learning Representations, 2018.

Gasse, M., Chetelat, D., Ferroni, N., Charlin, L., Lodi, A. (2019). Exact combinatorial optimization with graph convolutional neural networks. In Proceedings of NeurIPS 2019, pp. 15580–15592.

Gidaris, S., Komodakis, N. (2019). Generating classification weights with GNN denoising autoencoders for few-shot learning. In Proceedings of IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun. 2019, pp. 21–30.

Gilmer, J., Schoenholz, S.S., Riley, P.F., Vinyals, O., Dahl, G.E. (2017). Neural Message Passing for Quantum Chemistry. In Proceedings of International Conference on Machine Learning, 2017. ArXiv, abs/1704.01212.

Girvan, M., Newman, M.E. (2002). Community structure in social and biological networks. In Proceedings of Natl. Acad. Sci., vol. 99, no. 12, pp. 7821–7826.

Gong, Y., Zhu, Y., Duan, L., Liu, Q., Guan, Z., Sun, F., Ou, W., Zhu, K.Q. (2019). Exact-K recommendation via maximal clique optimization. In Proceedings of the 25th ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining, Jul. 2019, pp. 617–626.

Green, S.B., Yang Y. (2009). Reliability of summed item scores using structural equation modeling: an alternative to coefficient alpha. *Psychometrika*, vol. 74, no. 1, 2009, pp. 155–167.

Grover, A., Leskovec, J. (2016). node2vec: Scalable feature learning for networks. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016, pp. 855–864.

Grover, A., Zweig, A., Ermon, S. (2019). Graphite: iterative generative modeling of graphs. In Proceedings of ICML, 2019, pp. 2434–2444.

Gu, J., Hu, H., Wang, L., Wei, Y., Dai, J. (2018). Learning region features for object detection. In Proceedings of ECCV, 2018, pp. 381–395.

Guo, M., Chou, E., Huang, D.A., Song, S., Yeung, S., Fei-Fei, A. (2018). Neural graph matching networks for fewshot 3D action recognition. In Proceedings of Eur. Conf. Comput. Vis. (ECCV), 2018, pp. 653–669.

Guo, S., Lin, Y., Feng, N., Song, C., Wan, H. (2019). Attention based spatial temporal graph convolutional networks for traffic flow forecasting. In Proceedings of AAAI Conf. Artif. Intell., vol. 33, 2019, pp. 922–929.

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.

Hamaguchi, T., Oiwa, H., Shimbo, M., Matsumoto, Y. (2017). Knowledge transfer for out-of-knowledge-base entities: a graph neural network approach. In Proceedings of IJCAI, 2017, pp. 1802–1808.

Hamilton, W.L., Ying, R., Leskovec, J. (2017a). Representation learning on graphs: methods and applications. 2017, arXiv preprint arXiv:1709.05584, 2017b.

Hamilton, W.L., Ying, R., Leskovec, L. (2017b). Inductive representation learning on large graphs. In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17), Red Hook, NY, USA, pp. 1025–1035.

Harandi, M.T., Sanderson, C., Shirazi, S., Lovell, B.C. (2011). Graph embedding discriminant analysis on Grassmannian manifolds for improved image set matching. In Proceedings of CVPR 2011, IEEE, 2011, pp. 2705–2712.

Henaff, M., Bruna, J., Lecun, Y. (2015). Deep Convolutional Networks on Graph-Structured Data. 2015, arXiv preprint arXiv:1506.05163.

Hoshen, Y. (2017). Vain: attentional multi-agent predictive modeling. In Proceedings of NIPS, pp. 2698–2708, Advances in Neural Information Processing Systems, 2017.

Hu, C., Cheng, L., Sepulcre, J., Johnson, K.A., Fakhri, G.E., Lu, Y.M., Li, Q. (2015). A spectral graph regression model for learning brain connectivity of Alzheimer's disease. PLoS ONE, vol. 10, no. 5, 2015, e0128136.

Hu, J., Guo, C., Yang, B., Jensen, C.S. (2019). Stochastic weight completion for road networks using graph convolutional networks. In Proceedings of IEEE 35th Int. Conf. Data Eng. (ICDE), Apr. 2019, pp. 1274–1285.

Hu, R., Long, G., Jiang, J., Yao, L., Zhang, C. (2018). Adversarially regularized graph autoencoder for graph embedding. In Proceedings of IJCAI, 2018, pp. 2609–2615.

Huang, X., Li, J., Hu, X. (2017). Label informed attributed network embedding. In Proceedings of the 10th ACM International Conference on Web Search and Data Mining, 2017, pp. 731–739.

Ioannidis, V.N., Berberidis, D., Giannakis, G.B. (2019). Graphsac: Detecting Anomalies in Large-Scale Graphs. arXiv preprint arXiv:1910.09589.

Jain, A., Zamir, A.R., Savarese, S., Saxena, A. (2016). Structural-rnn: deep learning on spatio-temporal graphs. In Proceedings of CVPR, 2016, pp. 5308–5317.

Jiang, J., Chen, J., Gu, T., Choo, K.K.R., Liu, C., Yu, M., Huang, W., Mohapatra, P. (2019). Anomaly detection with graph convolutional networks for insider threat and fraud detection. In Proceedings of MILCOM 2019 - 2019 IEEE Military Communications Conference (MILCOM).

Jin, W., Li, Y., Xu, H., Wang, Y., Tang, J. (2020). Adversarial Attacks and Defenses on Graphs: A Review and Empirical Study. ArXiv, abs/2003.00653.

Jin, W., Yang, K., Barzilay, R., Jaakkola, T. (2018). Learning multimodal graph-to-graph translation for molecular optimization. 2018, arXiv:1812.01070.

Johnson, D.D. (2016). Learning graphical state transitions. In Proceedings of Int. Conf. Learn. Represent. (ICLR), 2016.

- Jolliffe, I.T., Cadima, J. (2016). Principal component analysis: a review and recent developments. *Philos. Trans. A Math. Phys. Eng. Sci.*, vol. 374, no. 2065, 2016, 20150202.
- Jørgensen, P.B., Jacobsen, K.W., Schmidt, M.N. (2018). Neural Message Passing with Edge Updates for Predicting Properties of Molecules and Materials. *ArXiv*, abs/1806.03146.
- Kampffmeyer, M., Chen, Y., Liang, X., Wang, H., Zhang, Y., Xing, E.P. (2019). Rethinking Knowledge Graph Propagation for Zero-Shot Learning. In *Proceedings of CVPR, 2019*, pp. 11487–11496.
- Karypis, G., Kumar, V. (1998). Multilevel k-way partitioning scheme for irregular graphs. *J. Parallel. Distrib. Comput.*, vol. 48, no. 1, 1998, pp. 96–129.
- Kawahara, J., Brown, C.J., Miller, S.P., Booth, B.G., Chau, V., Grunau, R.E., Zwicker, J.G., Hamarneh, G. (2017). Brainnetcn: convolutional neural networks for brain networks; towards predicting neurodevelopment. *NeuroImage*, vol. 146, pp. 1038–1049.
- Kearnes, S., McCloskey, K., Berndl, M., Pande, V., Riley, P. (2016). Molecular graph convolutions: moving beyond fingerprints. *J. Comput. Aided Mol. Des.*, vol. 30, pp. 595–608.
- Kermarrec, A.M., Leroy V., Trédan G. (2011). Distributed social graph embedding. In *Proceedings of the 20th ACM international conference on Information and Knowledge Management, ACM, 2011*, pp. 1209–1214.
- Khalil, E., Dai, H., Zhang, Y., Dilkina, B., Song, L. (2017). Learning combinatorial optimization algorithms over graphs. In *Proceedings of NIPS, 2017*, pp. 6348–6358.
- Kim, D., Yoo, Y., Kim, J., Lee, S., Kwak, N. (2018). Dynamic graph generation network: Generating relational knowledge from diagrams. In *Proceedings of IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, Jun. 2018, pp. 4167–4175.
- Kingma, D.P., Welling, M. (2013). Auto-encoding variational Bayes. *arXiv preprint arXiv:1312.6114*, 2013.
- Kipf, T.N., Fetaya, E., Wang, K., Welling, M., Zemel, R.S. (2013). Neural relational inference for interacting systems. In *Proceedings of ICML. PMLR, 2018*, pp. 2688–2697.
- Kipf, T.N., Welling, M. (2017). Semi-supervised classification with graph convolutional networks. In *Proceedings of 5th International Conference on Learning Representations, Toulon, France, April 24-26*.
- Knyazev, B., Lin, X., Amer, M.R., Taylor, G.W. (2018). Spectral multigraph networks for discovering and fusing relationships in molecules. *ArXiv abs/1811.09595*.
- Kool, W., Hoof, H.V., Welling, M. (2018). Attention, learn to solve routing problems!. *Arxiv, 2018*, arXiv:1803.08475.
- Ktena, S.I., Parisot, S., Ferrante, E., Rajchl, M., Lee, M., Glocker, B., Rueckert, D. (2017). Distance metric learning using graph convolutional networks: Application to functional brain networks. In *Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention, 2017*.
- Lake, B., Tenenbaum, J. (2010). Discovering structure by learning sparse graphs. In *Proceedings of the 32nd Annual Meeting of the Cognitive Science Society CogSci 2010, Portland, Oregon, United States, 11-14 August, 2010, Cognitive Science Society, Inc., 2010*. pp. 778–784.
- Lee, C., Fang, W., Yeh, C., Wang, Y.F. (2018a). Multi-label zero-shot learning with structured knowledge graphs. In *Proceedings of CVPR, Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, Jun. 2018, pp. 1576–1585.
- Lee, J.B., Rossi, R., Kong, X. (2018b). Graph classification using structural attention. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 1666–1674.
- Li, C., Goldwasser, D. (2019a). Encoding social information with graph convolutional networks for political perspective detection in news media. In *Proceedings of 57th Annu. Meeting Assoc. Comput. Linguistics, 2019*, pp. 2594–2604.

- Li, R., Wang, S., Zhu, F., Huang, J. (2018a). Adaptive graph convolutional neural networks. In Proceedings of Thirty-Second AAAI Conference on Artificial Intelligence, 2018.
- 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 IJCNLP, 2019.
- Li, C., Li, Z., Wang, S., Yang, Y., Zhang, X., Zhou, J. (2017a). Semisupervised network embedding. In Proceedings of International Conference on Database Systems for Advanced Applications, 2017, pp. 131–147.
- Li, C., Wang, S., Yang, D., Li, Z., Yang, Y., Zhang, X., Zhou, J. (2017b). PPNE: Property preserving network embedding. In Proceedings of International Conference on Database Systems for Advanced Applications, 2017, pp. 163–179.
- Li, R., Tapaswi, M., Liao, R., Jia, J., Urtasun, R., Fidler, S. (2017c). Situation recognition with graph neural networks. In Proceedings of IEEE Int. Conf. Comput. Vis. (ICCV), Oct. 2017, pp. 4173–4182.
- Li, W., Bao, R., Harimoto, K., Chen, D., Xu, J., Su, Q. (2020a). Modeling the stock relation with graph network for overnight stock movement prediction. In Proceedings of IJCAI, 2020, pp. 4541–4547.
- Li, Y., Jin, W., Xu, H., Tang, J. (2020b). Deeprobust: A Pytorch Library for Adversarial Attacks and Defenses. arXiv preprint arXiv:2005.06149.
- Li, Y., Tam, D.S., Xie, S., Liu, X., Ying, Q., Lau, W., Chiu, D., Chen, S.Z. (2020c). GTEA: Representation Learning for Temporal Interaction Graphs via Edge Aggregation. 2020, ArXiv, abs/2009.05266.
- Li, Y., Tarlow, D., Brockschmidt, M., Zemel, R. (2016). Gated graph sequence neural networks. In Proceedings of the 5th International Conference on Learning Representations, 2016.
- Li, Y., Vinyals, O., Dyer, C., Pascanu, R., Battaglia, P. (2018b). Learning Deep Generative Models of Graphs. arXiv preprint, 2018, arXiv:1803.03324.
- Li, Y., Yu, R., Shahabi, C., Liu, Y. (2018c). Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. In Proceedings of the 7th International Conference on Learning Representations, 2018.
- Li, Z., Chen, Q., Koltun, V. (2018d). Combinatorial optimization with graph convolutional networks and guided tree search. In Proceedings of Adv. Neural Inf. Process. Syst., 2018, pp. 539–548.
- Liang, J., Gurukar, S., Parthasarathy, S. (2018). Mile: a multi-level framework for scalable graph embedding. 2018, arXiv preprint arXiv:1802.09612, 2018.
- Liang, X., Lin, L., Shen, X., Feng, J., Yan, S., Xing, E.P. (2017). Interpretable structureevolving lstm. In Proceedings of CVPR, 2017, pp. 2175–2184.
- Liang, X., Shen, X., Feng, J., Lin, L., Yan, S. (2016). Semantic object parsing with graph lstm. In Proceedings of ECCV, 2016, pp. 125–143.
- Liao, R., Li, Y., Song, Y., Wang, S., Hamilton, W., Kduvenaud, D., Urtasun, R., Zemel, R. (2019). Efficient graph generation with graph recurrent attention networks, In Proceedings of Adv. Neural Inf. Process. Syst., 2019, pp. 4255–4265.
- Liu, J., Kumar, A., Ba, J., Kiros, J., Swersky, K. (2019a). Graph normalizing flows. In Proceedings of NeurIPS, 2019, pp. 13578–13588.
- Liu, R., Nejati H., Cheung N.M. (2018a). Joint estimation of low-rank components and connectivity graph in high-dimensional graph signals: application to brain imaging. arXiv preprint arXiv:1801.02303.
- Liu, X., Luo, Z., Huang, H. (2018b). Jointly multiple events extraction via attention-based graph information aggregation. In Proceedings of EMNLP, 2018, pp. 1247–1256.

- Liu, Z., Xiong, C., Sun, M., Liu, Z. (2019b). Fine-grained fact verification with kernel graph attention network. In Proceedings of ACL, 2019, pp. 7342–7351.
- Luo, D., Cheng, W., Xu, D., Yu, W., Zong, B., Chen, H., Zhang, X. (2020a). Parameterized explainer for graph neural network. Arxiv, 2020, arXiv:2011.04573.
- Luo, D., Cheng, W., Yu, W., Zong, B., Ni, J., Chen, H., Zhang, X. (2020b). Learning to drop: Robust graph neural network via topological denoising. Arxiv, 2020, arXiv:2011.07057.
- Lyu, T., Zhang, Y., Zhang, Y. (2017). Enhancing the network embedding quality with structural similarity. In Proceedings of the 2017 ACM on Conference on Information and Knowledge Management, 2017, pp. 147–156.
- Ma, T., Chen, J., Xiao, C. (2018b). Constrained generation of semantically valid graphs via regularizing variational autoencoders. In Proceedings of NeurIPS, 2018, pp. 7113–7124.
- Ma, Y., Guo, Z., Ren, Z., Zhao, E., Tang, J., Yin, D. (2018a). Streaming Graph Neural Networks. Arxiv, arXiv:1810.10627, October 2018.
- Manessi, F., Rozza, A., Manzo, M. (2020). Dynamic graph convolutional networks. Pattern Recogn. Pattern Recognition, vol. 97, 107000.
- Marcheggiani, D., Bastings, J., Titov, I. (2018). Exploiting semantics in neural machine translation with graph convolutional networks. In Proceedings of NAACL, 2018, pp. 486–492.
- Marcheggiani, D., I. Titov, I. (2017). Encoding sentences with graph convolutional networks for semantic role labeling. In Proceedings of EMNLP, 2017, pp. 1506–1515.
- Marino, K., Salakhutdinov, R., Gupta, A. (2017). The more you know: Using knowledge graphs for image classification. In Proceedings of CVPR, pp. 20–28.
- Matsunaga, D., Suzumura, T., Takahashi, T. (2019). Exploring Graph Neural Networks for Stock Market Predictions with Rolling Window Analysis. arXiv preprint, 2019, arXiv: 1909.10660.
- Miwa, M., Bansal, M., (2016). End-to-end relation extraction using lstms on sequences and tree structures. In Proceedings of ACL, 2016, pp. 1105–1116.
- Monti, F., Bronstein, B., Bresson, X. (2017). Geometric matrix completion with recurrent multi-graph neural networks, In Proceedings of Advances in Neural Information Processing Systems, 2017.
- Motsinger, A.A., Lee S.L., Mellick G., Ritchie M.D. (2006). GPNN: Power studies and applications of a neural network method for detecting gene-gene interactions in studies of human disease. BMC Bioinf., vol. 7, no. 1, 2006, pp. 39–11.
- Narasimhan, M., Lazebnik, S., Schwing, A. (2018). Out of the box: Reasoning with graph convolution nets for factual visual question answering. In Proceedings of Adv. Neural Inf. Process. Syst., pp. 2654–2665.
- Nathani, D., Chauhan, J., Sharma, C., Kaul, M. (2019). Learning attentionbased embeddings for relation prediction in knowledge graphs, arXiv:1906.01195, 2019.
- Newman, M.E. (2004). Detecting community structure in networks. Eur. Phys. J. B, vol. 38, no. 2, 2004, pp. 321–330.
- Nguyen, T.H., Grishman, R. (2018). Graph convolutional networks with argument-aware pooling for event detection. In Proceedings of 32nd AAAI Conf. Artif. Intell., pp. 5900–5907.
- Niepert, M., Ahmed, M., Kutzkov, K. (2016). Learning convolutional neural networks for graphs. In Proceedings of Int. Conf. Mach. Learn., pp. 2014–2023.
- Norcliffe-Brown, W., Vafeias, S., Parisot, S. (2018). Learning conditioned graph structures for interpretable visual question answering. In Proceedings of Adv. Neural Inf. Process. Syst., pp. 8334–8343.

- Nowak, A., Villar, S., Bandeira, A.S., Bruna, J. (2017). A note on learning algorithms for quadratic assignment with graph neural networks. In Proceedings of 34th Int. Conf. Mach. Learn. (ICML), vol. 1050, 2017, p. 22.
- Nowak, A., Villar, S., Bandeira, A.S., Bruna, J. (2018). Revised note on learning quadratic assignment with graph neural networks. In Proceedings of IEEE DSW, pp. 1–5.
- Nt, H., Jin, C.J., Murata, T. (2019). Learning Graph Neural Networks with Noisy Labels. In Proceedings of ICLR Workshop LLD.
- Nt, H., Maehara, T. (2019). Revisiting Graph Neural Networks: All We Have Is Low-Pass Filters. arXiv preprint, 2019, arXiv:1905.09550.
- Ou, M., Cui, P., Pei, J., Zhang, Z., Zhu, W. (2016). Asymmetric transitivity preserving graph embedding. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 1105–1114.
- Palm, R., Paquet, U., Winther, O. (2018). Recurrent relational networks. In Proceedings of Adv. Neural Inf. Process. Syst., pp. 3368–3378.
- Pan, P., Wu, J., Zhu, X., Zhang, C., Wang, Y. (2016). Tri-party deep network representation. In Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence (IJCAI'16). AAAI Press, pp. 1895–1901.
- Pan, S., Hu, R., Long, G., Jiang, J., Yao, L., Zhang, C. (2018). Adversarially regularized graph autoencoder for graph embedding. In Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence, pp. 2609–2615.
- 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 International Conference on Medical Image Computing and Computer-Assisted Intervention.
- Park, N., Kan, A., Dong, X.L., Zhao, T., Faloutsos, C. (2019). Estimating node importance in knowledge graphs using graph neural networks. In Proceedings of the 25th ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining, 2019, pp. 596–606.
- Pei, X., Yu, L., Tian, S. (2020). AMalNet: A deep learning framework based on graph convolutional networks for malware detection. *Comput. Secur.*, vol. 93, Jun. 2020, p. 101792.
- Peng, H., Li, J., Gong, Q., Ning, Y., Wang, S., He, L. (2020). Motif-matching based subgraph-level attentional convolutional network for graph classification. In Proceedings of AAAI, 2020, pp. 5387–5394.
- Peng, H., Li, J., Gong, Q., Song, Y., Ning, Y., Lai, K., Yu, P.S. (2019). Fine-grained event categorization with heterogeneous graph convolutional networks. Arxiv, 2019, arXiv:1906.04580.
- Peng, H., Li, J., He, Y., Liu, Y., Bao, M., Wang, L., Song, Y., Yang, Q., (2018). Large-scale hierarchical text classification with recursively regularized deep graph-cnn. In Proceedings of WWW, 2018, pp. 1063–1072.
- Peng, N., Poon, H., Quirk, C., Toutanova, K., Yih, W.T. (2017). Crosssentence N-ary relation extraction with graph LSTMs. *Trans. Assoc. Comput. Linguistics*, vol. 5, pp. 101–115.
- Perozzi, B., Al-Rfou, R., Skiena, S. (2014). DeepWalk: Online learning of social representations. In Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 701–710.
- Prates, M., Avelar, P.H., Lemos, H., Lamb, L.C., Vardi, M.Y. (2019). Learning to solve np-complete problems: A graph neural network for decision TSP. In Proceedings of AAAI Conf. Artif. Intell., vol. 33, 2019, pp. 4731–4738.
- Qi, S., Wang, W., Jia, B., Shen, J., Zhu, S.C. (2018). Learning humanobject interactions by graph parsing neural networks. In Proceedings of the European Conference on Computer Vision (ECCV), pp. 401–417.
- Qi, X., Liao, R., Jia, J., Fidler, S., Urtasun, R. (2017). 3d graph neural networks for rgb-d semantic segmentation. In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, pp. 5199–5208.

- Qiu, J., Tang, J., Ma, H., Dong, Y., Wang, K., Tang, J. (2018). Deepinf: Modeling influence locality in large social networks. In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, pp. 2110–2119.
- Qiu, L., Xiao, Y., Qu, Y., Zhou, H., Li, L., Zhang, W., Yu, Y. (2019). Dynamically fused graph network for multi-hop reasoning. In Proceedings of ACL, pp. 6140–6150.
- Rahimi, A., Cohn, T., Baldwin, T. (2018). Semi-supervised user geolocation via graph convolutional networks, vol. 1, pp. 2009–2019, arXiv:1804.08049.
- Raposo, D., Santoro, A., Barrett, D., Pascanu, R., Lillicrap, T., Battaglia, P. (2017). Discovering objects and their relations from entangled scene representations. Arxiv, 2017, arXiv:1702.05068.
- Rhee, S., Seo, S., Kim, S. (2018). Hybrid Approach of Relation Network and Localized Graph Convolutional Filtering for Breast Cancer Subtype Classification. In Proceedings of IJCAI, 2018, pp. 3527–3534.
- Riba, P., Fischer, A., Lladós, J., Fornes, A. (2018). Learning Graph Distances with Message Passing Neural Networks. In Proceedings of the 24th International Conference on Pattern Recognition (ICPR), pp. 2239–2244.
- Ribeiro, L.F., Saverese, P.H., Figueiredo, D.R. (2017). struc2vec: Learning node representations from structural identity. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 385–394.
- Robinson, S.L., Bennett, R.J. (1995). A typology of deviant workplace behaviors: A multidimensional scaling study. *Acad. Manage. J.*, vol. 38, no. 2, 1995, pp. 555–572.
- Roweis, S.T., Saul, L.K. (2000). Nonlinear dimensionality reduction by locally linear embedding. *Science*, vol. 290, no. 5500, pp. 2323–2326.
- Rusek, K., Suárez-Varela, J., Mestres, A., Barlet-Ros, P., Cabellos-Aparicio, A. (2019). Unveiling the potential of graph neural networks for network modeling and optimization in SDN. In Proceedings of ACM Symp. SDN Res., pp. 140–151.
- Said, A., De Luca, E.W., Albayrak, S. (2010). How social relationships affect user similarities. In Proceedings of the 2010 Workshop on Social Recommender Systems, pp. 1–4.
- SAM. (2022). <https://sam.gov/opp/178e0311b4d04df2bf25025d5c99473d/view>.
- Samko, O., Marshall, A.D., Rosin, P.L. (2006). Selection of the optimal parameter value for the isomap algorithm. *Pattern Recognit. Lett.*, vol. 27, no. 9, pp. 968–979.
- Sanchez, A., Heess, N., Springenberg, J.T., Merel, J., Hadsell, R., Riedmiller, M.A., Battaglia, P. (2018). Graph networks as learnable physics engines for inference and control. In Proceedings of ICML, pp. 4470–4479.
- Santoro, A., Raposo, D., Barrett, D.G., Malinowski, M., Pascanu, R., Battaglia, P., Lillicrap, T. (2017). A simple neural network module for relational reasoning. In Proceedings of Adv. Neural Inf. Process. Syst., pp. 4967–4976.
- Sato, R., Yamada, M., Kashima, H. (2019). Approximation Ratios of Graph Neural Networks for Combinatorial Problems. In Proceedings of NeurIPS, pp. 4081–4090.
- Scarselli, F., Gori, M., Tsoi, A.C., Hagenbuchner, M., Monfardini, G. (2009). The Graph Neural Network Model. *IEEE Transactions on Neural Networks*, vol. 20, no. 1, pp. 61–80.
- Schlichtkrull, M., Kipf, T.N., Bloem, P., van den Berg, R., Titov, I., Welling, M. (2018). Modeling relational data with graph convolutional networks. In Proceedings of ESWC. Springer, pp. 593–607.
- Selsam, D., Lamm, M., Bünz, B., Liang, P., de Moura, L., Dill, D.L. (2019). Learning a SAT solver from single-bit supervision. In Proceedings of ICLR 2019.

- Shang, C., Tang, Y., Huang, J., Bi, J., He, X., Zhou, B. (2019). End-to-end structure-aware convolutional networks for knowledge base completion. In Proceedings of AAAI 33, pp. 3060–3067.
- Shchur, O., Zügner, D., Bojchevski, A., Gunnemann, S. (2018). Netgan: generating graphs via random walks. In Proceedings of ICML, pp. 609–618.
- Shi, C., Xu, M., Zhu, Z., Zhang, W., Zhang, M., Tang, J. (2020). Graphaf: a Flow Based Autoregressive Model for Molecular Graph Generation. In Proceedings of ICLR 2020.
- Singh, A.P., Gordon, G.J. (2008). Relational learning via collective matrix factorization. In Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, pp. 650–658.
- Song, L., Wang, Z., Yu, M., Zhang, Y., Florian, R., Gildea, D. (2018a). Exploring GraphStructured Passage Representation for Multi-Hop Reading Comprehension with Graph Neural Networks. ArXiv, 2018, arXiv preprint arXiv:1809.02040.
- Song, L., Zhang, Y., Wang, Z., Gildea, D. (2018b). A graph-to-sequence model for AMR-to-text generation. ArXiv. 2018, arXiv:1805.02473.
- Song, L., Zhang, Y., Wang, Z., Gildea, D. (2018c). A graph-to-sequence model for amr-to-text generation. In Proceedings of ACL 2018, pp. 1616–1626.
- Song, L., Zhang, Y., Wang, Z., Gildea, D. (2018d). N-ary relation extraction using graph state lstm. In: Proceedings of EMNLP, 2018, pp. 2226–2235. arXiv:1808.09101.
- Sorokin, D., Gurevych, I. (2018). Modeling semantics with gated graph neural networks for knowledge base question answering. ArXiv. 2018, arXiv:1808.04126.
- Sukhbaatar, S., Fergus, R. et al. (2016). Learning multiagent communication with backpropagation. In Proceedings of Advances in Neural Information Processing Systems, 2016, pp. 2244–2252.
- Sun, F.Y., Hoffmann, J., Verma, V., Tang, J. (2019). InfoGraph: Unsupervised and semi-supervised graph-level representation learning via mutual information maximization. ArXiv. 2019, arXiv:1908.01000.
- Sutton, R.S., Barto, A.G. (2018). Reinforcement Learning: an Introduction. MIT press, 2018.
- Tai, K.S., Socher, R., Manning, C.D. (2015). Improved semantic representations from treestructured long short-term memory networks. In Proceedings of IJCNLP, 2015, pp. 1556–1566.
- Tang, J., Qu M., Wang M., Zhang M., Yan J., Mei Q. (2015). LINE: Large-scale information network embedding. In Proceedings of the 24th International Conference on World Wide Web, pp. 1067–1077.
- Tang, L., Liu, H. (2009a). Relational learning via latent social dimensions. In Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2009, pp. 817–826.
- Tang, L., Liu, H. (2009b). Scalable learning of collective behavior based on sparse social dimensions. In Proceedings of the 18th ACM International Conference on Information and Knowledge Management, 2009, pp. 1107–1116.
- Tang, L., Liu, H. (2011). Leveraging social media networks for classification. Data Mining and Knowledge Discovery, vol. 23, no. 3, pp. 447–478.
- Tang, X., Li, Y., Sun, Y., Yao, H., Mitra, P., Wang, S. (2020). Transferring robustness for graph neural network against poisoning attacks. In Proceedings of the 13th International Conference on Web Search and Data Mining, pp. 600–608.
- Tehranipoor, F., Karimian, N., Kermani, M.M., Mahmoodi, H. (2019). Deep RNN-oriented paradigm shift through bocanet: Broken obfuscated circuit attack. In Proceedings of Great Lakes Symp. VLSI, 2019, pp. 335–338.

- Teney, D., Liu, L., Den Hengel, A.V. (2017). Graph-structured representations for visual question answering. In Proceedings of CVPR, pp. 3233–3241, Jul. 2017, pp. 1–9.
- Thanou, D., Dong, X., Kressner, D., Frossard, P. (2017). Learning heat diffusion graphs. IEEE Trans. Signal Inform. Proc. Over Netw., vol. 3, no. 3, 2017, pp. 484–499.
- Tsitsulin, A., Palowitch, J., Perozzi, B., Müller, E. (2020). Graph Clustering with Graph Neural Networks. ArXiv. arXiv preprint, 2020, arXiv:2006.16904.
- Tu, C., Zhang, W., Liu, Z., Sun, M. (2016). Max-Margin DeepWalk: discriminative learning of network representation. In Proceedings of the 25th International Joint Conference on Artificial Intelligence, pp. 3889–3895.
- Tu, K., Cui P., Wang X., Wang F., Zhu W. (2017). Structural deep embedding for hyper-networks. 2017, CoRR. abs/1711.10146, 2017.
- Tu, K., Cui, P., Wang, X., Yu, P.S., Zhu, W. (2018). Deep recursive network embedding with regular equivalence. In Proceedings of 24th ACM Int. Conf. Knowl. Discov. Data Mining, pp. 2357–2366.
- Tu, M., Wang, G., Huang, J., Tang, Y., He, X., Zhou, B. (2019). Multi-hop reading comprehension across multiple documents by reasoning over heterogeneous graphs. In Proceedings of ACL, 2019, pp. 2704–2713.
- Velickovic, P., Cucurull, G., Casanova, A., Romero, A., Lio, P., Bengio, Y. (2018). Graph attention networks. In Proceedings of Int. Conf. Learn. Representations. 2018.
- Vinyals, O., Fortunato, M., Jaitly, N. (2015). Pointer networks. In Proceedings of NIPS, 2015, pp. 2692–2700.
- Wang D., Cui P., Zhu W. (2016). Structural deep network embedding. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2016, 1225–1234.
- Wang, H., Wang, J., Wang, J., Zhao, M., Zhang, W., Zhang, F., Xie, X., Guo, M. (2018a). Graphgan: graph representation learning with generative adversarial nets. In Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence.
- Wang, H., Lian, D., Ge, Y. (2019a). Binarized collaborative filtering with distilling graph convolutional networks. ArXiv. 2019, arXiv:1906.01829.
- Wang, H., Zhang, F., Zhang, M., Leskovec, J., Zhao, M., Li, W., Wang, Z. (2019b). Knowledge-aware graph neural networks with label smoothness regularization for recommender systems. In Proceedings of the 25th ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining. Jul. 2019, pp. 968–977.
- Wang, L., Zong, B., Ma, Q., Cheng, W., Ni, J., Yu, W., Liu, Y., Song, D., Chen, H., Fu, Y. (2020a). Inductive and unsupervised representation learning on graph structured objects. In Proceedings of ICLR 2020, pp. 1–20.
- Wang, P., Han, J., Li, C., Pan, R. (2018b). Logic attention based neighborhood aggregation for inductive knowledge graph embedding. In Proceedings of AAAI Conf. Artif. Intell., vol. 33, pp. 7152–7159.
- Wang, S., Li, Y., Zhang, J., Meng, Q., Meng, L., Gao, F. (2020b). PM2.5- GNN: A domain knowledge enhanced graph neural network for PM2.5 forecasting. ArXiv. 2020, arXiv:2002.12898.
- Wang, S., Tang, J. Morstatter, F., Liu, H. (2016). Paired restricted Boltzmann machine for linked data. In Proceedings of the 25th ACM International Conference on Information and Knowledge Management, pp. 1753–1762.
- Wang, X., Cui, P., Wang, J., Pei, J., Zhu, W., Yang, S. (2017). Community preserving network embedding. In Proceedings of the 31st AAAI Conference on Artificial Intelligence, pp. 203–209.
- Wang, X., He, X., Cao, Y., Liu, M., Chua, T.S. (2019cv). KGAT: Knowledge graph attention network for recommendation. In Proceedings of the 25th ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining, Jul. 2019, pp. 950–958.

- Wang, X., Jin, B., Du, Y., Cui, P., Yang, Y. (2020c). One-class Graph Neural Networks for Anomaly Detection in Attributed Networks. Fast Is Better than Free: Revisiting Adversarial Training. arXiv preprint arXiv:2001.03994.
- Wang, X., Ye, Y., Gupta, A. (2018c). Zero-shot Recognition via Semantic Embeddings and Knowledge Graphs. In Proceedings of CVPR 2018.
- Wang, Y., Sun, Y., Liu, Z., Sarma, S.E., Bronstein, M.M., Solomon, J.M. (2018d). Dynamic Graph Cnn for Learning on Point Clouds, ACM Transactions on Graphics, vol. 38.
- Wang, Y., Yin, H., Chen, H., Wo, T., Xu, J., Zheng, K. (2019d). Origin destination matrix prediction via graph convolution: A new perspective of passenger demand modeling. In Proceedings of the 25th ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining, Jul. 2019, pp. 1227–1235.
- Wang, Y.C., Wang, B., Kuo, J. (2019e). Graph representation learning: a survey, SIP, vol. 9, e15.
- Wang, Z., Chen, T., Ren, J., Yu, W., Cheng, H., Lin, L. (2018e). Deep reasoning with knowledge graph for social relationship understanding. Proceedings of IJCAI, 2018, pp. 1021–1028. arXiv:1807.00504. Available: <http://arxiv.org/abs/1807.00504>.
- Wang, Z., Luo, N., Zhou, P. (2020d). GuardHealth: Blockchain empowered secure data management and Graph Convolutional Network enabled anomaly detection in smart healthcare. Journal of Parallel and Distributed Computing, vol. 142, August 2020, pp. 1–12.
- Wang, Z., Lv, Q., Lan, X., Zhang, Y. (2018f). Cross-lingual knowledge graph alignment via graph convolutional networks. In Proceedings of EMNL, pp. 349–357.
- Watters, N., Zoran, D., Weber, T., Battaglia, P., Pascanu, R., Tacchetti, A. (2017). Visual interaction networks: learning a physics simulator from video. In Proceedings of NIPS, 2017, pp. 4539–4547.
- Wei, S., Chen, X., Li, Q., Zhuang, F., Liu, J., Kou, G. (2021). Graph Learning and Its Applications: A Holistic Survey, ArXiv.
- Wu, H., Wang, C., Tyshetskiy, Y., Docherty, A., Lu, K., Zhu, L. (2019a). Adversarial Examples on Graph Data: Deep Insights into Attack and Defense. ArXiv, arXiv:1903.01610.
- Wu, Q., Zhang, H., Gao, X., He, P., Weng, P., Gao, H., Chen, G. (2019b). Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems. In Proceedings of WWW, 2019, pp. 2091–2102.
- Wu, Y., Lian, D., Xu, Y., Wu, L., Chen, E. (2020). Graph convolutional networks with Markov random field reasoning for social spammer detection. In Proceedings of AAAI Conf. Artif. Intell., vol. 34, 2020, pp. 1054–1061.
- Wu, Z., S. Pan, S., Chen, F., Long, G., Zhang, C., Yu, P.S. (2021). A Comprehensive Survey on Graph Neural Networks. IEEE Transactions on Neural Networks and Learning Systems, vol. 32, no. 1, pp. 4–24.
- Xie, T., Grossman, J.C. (2018). Crystal graph convolutional neural networks for an accurate and interpretable prediction of material properties. Physical Review Letters, 2018.
- Xiong, W., Hoang, T., Wang, W.Y. (2017). Deeppath: A reinforcement learning method for knowledge graph reasoning. In Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing.
- Xu, Q., Wang, Q., Xu, C., Qu, L. (2017). Attentive graph-based recursive neural network for collective vertex classification. In Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. ACM, 2017, pp. 2403–2406.
- Xu, C., Zhao, P., Liu, Y., Sheng, V.S., Xu, J., Zhuang, F., Fang, J., Zhou, X. (2019a). Graph contextualized self-attention network for session-based recommendation. In Proceedings of IJCAI, Aug. 2019, pp. 3940–3946.

- Xu, D., Cheng, E., Luo, D., Liu, X., Zhang, X. (2019b). Spatio-temporal attentive RNN for node classification in temporal attributed graphs. In Proceedings of IJCAI. 2019, pp. 3947–3953.
- Xu, D., Cheng, W., Luo, D., Gu, Y., Liu, X., Ni, J., Zong, B., Chen, H., Zhang, X. (2019c). Adaptive neural network for node classification in dynamic networks. In Proceedings of IEEE Int. Conf. Data Mining (ICDM), Nov. 2019, pp. 1402–1407.
- Xu, J., Chen, J., You, S., Xiao, Z., Yang, Y., Lu, J. (2021). Robustness of deep learning models on graphs: A survey. *AI Open* 2, pp. 69-78.
- Xu, K., Chen, H., Liu, S., Chen, P.Y., Weng, T.W., Hong, M., Lin, X. (2019d). Topology attack and defense for graph neural networks: An optimization perspective. *ArXiv*, 2019, arXiv:1906.04214.
- Xu, K., Wang, L., Yu, M., Feng, Y., Song, Y., Wang, Z., Yu, D. (2019e). Cross-lingual knowledge graph alignment via graph matching neural network. In Proceedings of ACL (Association for Computational Linguistics), pp. 3156–3161.
- Xu, N., Wang, P., Chen, L., Tao, J., Zhao, J. (2019f). MR-GNN: Multiresolution and dual graph neural network for predicting structured entity interactions. *ArXiv*. arXiv:1905.09558.
- Xu, X., Feng, W., Jiang, Y., Xie, X., Sun, Z., Deng, Z.H. (2019g). Dynamically pruned message passing networks for large-scale knowledge graph reasoning. *ArXiv*. 2019, arXiv:1909.11334.
- Xu, X., Yu, Y., Li, B., Song, L., Liu, C., Gunter, C. (2018). Characterizing Malicious Edges Targeting on Graph Neural Networks.
- Xu, X., Yu, Y., Song, L., Liu, C., Kailkhura, B., Gunter, C., Li, B. (2020). Edog: Adversarial Edge Detection for Graph Neural Networks. Tech. Rep. Lawrence Livermore National Lab. (LLNL), Livermore, CA (United States).
- Yan, S., Xiong, Y., and Lin, D. (2018). Spatial temporal graph convolutional networks for skeleton-based action recognition. In Proceedings of the 32nd AAAI Conf. Artif. Intell., pp. 3634–3640.
- Yang, C., Liu, Z., Zhao, D., Sun, M., Chang, E. (2015a). Network representation learning with rich text information. In Proceedings of Twenty-Fourth International Joint Conference on Artificial Intelligence 2015.
- Yang, T., Jin, R., Chi, Y., Zhu, S. (2009). Combining link and content for community detection: a discriminative approach. In Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2009, pp. 927–936.
- Yang, Z., Tang, J., Cohen, W. (2015b). Multi-modal Bayesian embeddings for learning social knowledge graphs. *ArXiv*. arXiv preprint arXiv:1508.00715, 2015b.
- Yang, Y., Wei, Z., Chen, Q., Wu, L. (2019). Using external knowledge for financial event prediction based on graph neural networks. In Proceedings of CIKM, 2019, pp. 2161–2164.
- Yang, Z., Cohen, W.W., Salakhutdinov, R. (2016). Revisiting semisupervised learning with graph embeddings. In Proceedings of the 33rd International Conference on International Conference on Machine Learning (ICML), pp. 40–48.
- Yao, H., Wu, F., Ke, J., Tang, X., Jia, Y., Lu, S., Gong, P., Ye, J., Li, Z. (2018). Deep multi-view spatial-temporal network for taxi demand prediction. In Proceedings of AAAI, 2018. pp. 2588–2595.
- Yao, H., Zhang, C., Wei, Y., Jiang, M., Wang, S., Huang, J., Chawla, N., Li, Z. (2020). Graph few-shot learning via knowledge transfer. In Proceedings of AAAI Conf. Artif. Intell., vol. 34, 2020, pp. 6656–6663.
- Ye, F., Zhao, J., Sarkar, V. (2020). Advanced Graph-Based Deep Learning for Probabilistic Type Inference. *ArXiv*, 2020, abs/2009.05949.
- Ying, R., He, R., Chen, K., Eksombatchai, P., Hamilton, W.L., Leskovec, J. (2018a). Graph convolutional neural networks for web-scale recommender systems. In Proceedings of the 24th ACM SIGKDD Int. Conf. Knowl.

Discovery Data Mining, Jul. 2018, pp. 974–983.

Ying, Z., You, J., Morris, C., Ren, X., Hamilton, W., Leskovec, J. (2018b). Hierarchical graph representation learning with differentiable pooling. In Proceedings of the 32nd NeurIPS 2018.

You, J., Liu, B., Ying, Z., Pande, V., Leskovec, J. (2018b). Graph convolutional policy network for goal-directed molecular graph generation. In Proceedings of NeurIPS 2018, pp. 6410–6421.

You, J., Ying, R., Ren, X., Hamilton, W., Leskovec, J. (2018a). Graphrnn: Generating realistic graphs with deep auto-regressive models. In Proceedings of ICML, pp. 5694–5703.

Yu, B., Yin, H., Zhu, Z. (2018a). Spatiotemporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. In Proceedings of IJCAI, pp. 3634–3640.

Yu, W., Cheng, W., Aggarwal, C., Zong, B., Chen, H., Wang, W. (2019). Selfattentive attributed network embedding through adversarial learning. In Proceedings of IEEE Int. Conf. Data Mining (ICDM), Nov. 2019, pp. 758–767.

Yu, W., Zheng, C., Cheng, W., Aggarwal, C.C., Song, D., Zong, B., Chen, H., Wang, W. (2018b). Learning deep network representations with adversarially regularized autoencoders. In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018.

Yuruk, N., Mete, M., Xu, X., Schweiger, T.A. (2009). Ahscan: Agglomerative hierarchical structural clustering algorithm for networks. In Proceedings of 2009 International Conference on Advances in Social Network Analysis and Mining, IEEE, pp. 72–77.

Zayats, V., Ostendorf, M. (2018). Conversation modeling on reddit using a graph-structured LSTM. Trans. Assoc. Comput. Linguistics, TACL. vol. 6, pp. 121–132.

Zhang, C., Zhang, K., Yuan, Q., Peng, H., Zheng, Y., Hanratty, T., Wang, S., Han, J. (2017a). Regions, periods, activities: Uncovering urban dynamics via cross-modal representation learning. In Proceedings of the 26th International Conference on World Wide Web. 2017, pp. 361–370.

Zhang, D., Yin, J., Zhu, X., Zhang, C. (2016a). Homophily, structure, and content augmented network representation learning. In Proceedings of IEEE 16th International Conference on Data Mining (ICDM), pp. 609–618.

Zhang, D., Yin, J., Zhu, X., Zhang, C. (2018a) Network representation learning: a survey. IEEE Transactions on Big Data, 2018.

Zhang, F., Yuan, N.J., Lian, D., Xie, X., Ma, W.Y. (2016b). Collaborative knowledge base embedding for recommender systems. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, pp. 353–362.

Zhang M., Chen, Y. (2019a). Inductive matrix completion based on graph neural networks. ArXiv. 2019, arXiv:1904.12058.

Zhang Y., Wu B. (2015b). Finding community structure via rough k-means in social network. In Proceedings of 2015 IEEE International Conference on Big Data (Big Data), IEEE, pp. 2356–2361.

Zhang, D., Yin, J., Zhu, X., Zhang, C. (2016c). Collective classification via discriminative matrix factorization on sparsely labeled networks. In Proceedings of the 25th ACM International Conference on Information and Knowledge Management, 2016. pp. 1563–1572.

Zhang, D., Yin, J., Zhu, X., Zhang, C. (2017b). User profile preserving social network embedding. In Proceedings of the 26th International Joint Conference on Artificial Intelligence, 2017. pp. 3378–3384.

Zhang, F., Liu, X., Tang, J., Dong, Y., Yao, P., Zhang, J., Gu, X., Wang, Y., Shao, B., Li, R., et al. (2019b). Oag: toward linking large-scale heterogeneous entity graphs. In Proceedings of KDD 2019, pp. 2585–2595.

- Zhang, J., Shi, X., Xie, J., Ma, H., King, I., Yeung, D. (2018b). GaAN: Gated Attention Networks for Learning on Large and Spatiotemporal Graphs. In Proceedings of 34th Conference on Uncertainty in Artificial Intelligence 2018, pp. 339–349.
- Zhang, J., Shi, X., Zhao, S., King, I. (2019c). STAR-GCN: Stacked and reconstructed graph convolutional networks for recommender systems. 2019, ArXiv. arXiv:1905.13129.
- Zhang, W., Liu, H., Liu, Y., Zhou, J., Xiong, H. (2020a). Semi-supervised hierarchical recurrent graph neural network for city-wide parking availability prediction. In Proceedings of AAAI Conf. Artif. Intell., vol. 34, 2020, pp. 1186–1193.
- Zhang, X. Chen, W., Yan, H. (2016d). TLINE: scalable transductive network embedding. In Proceedings of the 12th Asia Information Retrieval Societies Conference, pp. 98–110.
- Zhang, X., Liu, H., Li, Q., Wu, X. (2019d). Attributed graph clustering via adaptive graph convolution. In Proceedings of IJCAI, pp. 4327–4333.
- Zhang, Y., Chen, X., Yang, Y., Ramamurthy, A., Li, B., Qi, Y., Song, L. (2020b). Efficient probabilistic logic reasoning with graph neural networks. ArXiv. 2020, arXiv:2001.11850.
- Zhang, Y., Khan, S., Coates, M. (2019e). Comparing and detecting adversarial attacks for graph deep learning. In Proceedings of Int. Conf. Representation Learning on Graphs and Manifolds Workshop, New Orleans, LA, USA.
- Zhang, Y., Liu, Q., Song, L. (2018c). Sentence-state LSTM for text representation. In Proceedings of ACL. 1, pp. 317–327 arXiv:1805.02474.
- Zhang, Y., Qi, P., Manning, C.D. (2018d). Graph convolution over pruned dependency trees improves relation extraction. In Proceedings of EMNLP, pp. 2205–2215. arXiv:1809.10185.
- Zhang, Z., Cui, P., Zhu, W. (2015a). Deep Learning on Graphs: A Survey. Journal of Latex Class Files, vol. 14, no. 8.
- Zheleva, E., Getoor, L., Golbeck, J., Kuter, U. (2008). Using friendship ties and family circles for link prediction. In International Workshop on Social Network Mining and Analysis. Springer, 2008, pp. 97–113.
- Zheng, C., Fan, X., Wang, C., Qi, J. (2020a). A graph multi-attention network for traffic prediction. In Proceedings of AAAI 34, 2020, pp. 1234–1241.
- Zheng, C., Zong, B., Cheng, W., Song, D., Ni, J., Yu, W., Chen, H., Wang, W. (2020b). Robust graph representation learning via neural sparsification. In Proceedings of Int. Conf. Mach. Learn., pp. 11458–11468.
- Zheng, X., Dan, C., Aragam, B., Ravikumar, P., Xing, E. (2020c). Learning sparse nonparametric dags. In Proceedings of AISTATS. PMLR, 2020, pp. 3414–3425.
- Zhong, W., Xu, J., Tang, D., Xu, Z., Duan, N., Zhou, M., Wang, J., Yin, J. (2020). Reasoning over semantic-level graph for fact checking. In Proceedings of ACL, 2020, pp. 6170–6180.
- Zhou, D., Huang, J., Schölkopf, B. (2007). Learning with hypergraphs: Clustering, classification, and embedding. In Proceedings of Advances in Neural Information Processing Systems, pp. 1601–1608.
- Zhou, Z., Li, X. (2017b). Graph convolution: A high-order and adaptive approach. ArXiv. Jun. 2017, arXiv:1706.09916
- Zhou, C., Liu, Y., Liu, X., Liu, Z., Gao, J. (2017a). Scalable graph embedding for asymmetric proximity. In Proceedings of the 31st AAAI Conference on Artificial Intelligence, pp. 2942–2948.
- Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., Wang, L., Li, C., Sun, M. (2020). Graph neural networks: A review of methods and applications. AI Open, vol. 1, 2020, pp. 57–81.

- Zhou, Y., Liu, S., Siow, J., Du, X., Liu, Y. (2019). Devign: Effective vulnerability identification by learning comprehensive program semantics via graph neural networks. In Proceedings of Adv. Neural Inf. Process. Syst., 2019, pp. 10197–10207.
- Zhu, D., Zhang, Z., Cui, P., Zhu, W. (2019). Robust graph convolutional networks against adversarial attacks. In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp. 1399–1407.
- Zhu, J., Ahmed, A., Xing, E.P. (2012). MedLDA: Maximum margin supervised topic models. Journal of Machine Learning Research. vol. 13, no. pp. 2237–2278.
- Zhuang, C., Ma, Q. (2018). Dual graph convolutional networks for graphbased semi-supervised classification. in Proc. Web Conf., 2018, pp. 499–508.
- Zia, F., Sun, K., Yu, S., Aziz, A., Wan, L., Pan, S., Liu, H. (2021). Graph Learning: A Survey. IEEE Transactions On Artificial Intelligence, vol. 2, no. 2, pp. 109–127.
- Zitnik, M., Agrawal, M., Leskovec, J. (2018). Modeling polypharmacy side effects with graph convolutional networks. Bioinformatics, vol. 34, no. 13, i457–i466.
- Zügner, D., Gunnemann, S. (2019a). Adversarial attacks on graph neural networks via meta learning. In Proceedings of the 8th International Conference on Learning Representations, 2019.
- Zügner, D., Akbarnejad, A., Gunnemann, S. (2018). Adversarial attacks on neural networks for graph data. In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp. 2847–2856.
- Zügner, D., Gunnemann, S. (2019b). Certifiable robustness and robust training for graph convolutional networks. In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp. 246–256.
- Zügner, D., Gunnemann, S. (2020). Certifiable robustness of graph convolutional networks under structure perturbations. In Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp. 1656–1665.

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.