

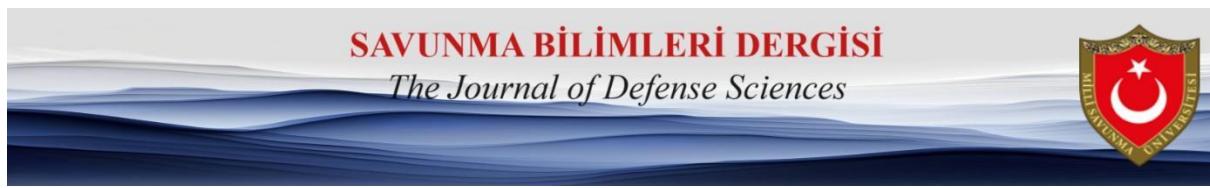
PAPER DETAILS

TITLE: Grafik Sinir Aglari Üzerine Bir Inceleme

AUTHORS: Hamza Talha Gümüs,Can Eyüpoglu

PAGES: 105-138

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/3088158>



<https://dergipark.org.tr/tr/pub/khosbd>

Grafik Sinir Ağları Üzerine Bir İnceleme

A Review on Graph Neural Networks

Hamza Talha GÜMÜŞ^{1,*} Can EYÜPOĞLU²

¹Milli Savunma Üniversitesi, Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul, Türkiye

²Milli Savunma Üniversitesi, Hava Harp Okulu, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

Makale Bilgisi

Derleme
Başvuru: 16.04.2023
Düzelte: 21.08.2023
Kabul: 28.08.2023

Keywords

Grafik Sinir Ağları
Yapay Sinir Ağları
Derin Öğrenme
Grafik Evrişimli Ağlar

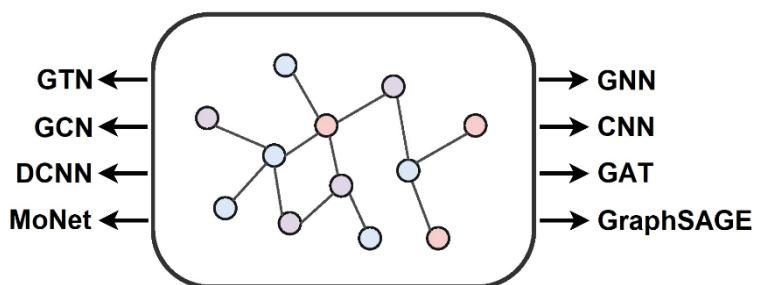
Anahtar Kelimeler

Graph Neural Networks
Artificial Neural Networks
Deep Learning
Graph Convolutional Networks

Önemli Noktalar / Highlights

Yapay sinir ağları ailesinin bir üyesi olan grafik sinir ağları, son yıllarda gözle görülebilir bir yaygınlıkla kazanarak büyük bir ilgi odağı haline gelmiştir. Çizge sinir ağları olarak da adlandırılan grafik sinir ağları düğümler ve kenarlar arasındaki ilişkilerin modellenmesiyle farklı bilim alanlarında yeni çalışmaların ortaya çıkışmasını sağlamıştır. Ayrıca farklı amaçlar için tasarlanmış alt modelleriyle güncelliliğini korumaktı ve uluslararası çalışmaların odak noktasını oluşturmaktadır. Bu çalışma modellerin kullanımı ve detaylandırılması üzerine yapılan kapsamlı bir araştırma olmasının yanı sıra Türkçe literatürde bu alanda yapılan ilk çalışmalarдан biri olması sebebiyle de önem arz etmektedir.

Grafiksel Özeti / Graphical Abstract



Özet

Grafik sinir ağları (Graph Neural Networks-GNN), yapay sinir ağları (Artificial Neural Networks-ANN) ailesine mensup ve grafikler üzerinden bilgi çıkarımı işlemi gerçekleştiren bir derin öğrenme yöntemidir. Bilinen ilk modeller GNN tabanlı oluşturulsa da evrişimli ağların kullanımının yaygınlaşması ile grafik evrişimli ağ (Graph Convolutional Network-GCN) modeli de popülerlik kazanmıştır. Bu durum GNN'lerin gelişmesine katkı sağlarken, iki ağ tabanında yeni modeller oluşturulmasına öncül olmuştur. Bu çalışmada GNN ve GCN modelleri tabanında oluşturulmuş 65 alt model ve bu modellerin etkilediği diğer modeller incelenmiştir.

Abstract

Graph neural networks (GNN) are a deep learning method that belongs to the family of artificial neural networks (ANN) and perform information extraction over graphs. Although the first known models were created based on GNN, the Graph Convolutional Network (GCN) model has gained popularity with the widespread use of convolutional networks. While this has contributed to the development of GNNs, it led to the creation of new models on two network bases. In this study, 65 sub-models created on the basis of GNN and GCN models and other models affected by these models were examined.

*Corresponding author, e-mail: 238004030@gazi.edu.tr

1. GİRİŞ (INTRODUCTION)

Grafik sinir ağları (Graph Neural Networks – GNN), farklı modellerden oluşmakta, görevler farklı ve benzer modeller ile dikkate alınmaktadır. İlk grafik sinir ağı kavramı temel olarak 2009 yılında GNN modeli başlığıyla literatüre katılmıştır [1]. Teknolojinin gelişmesi ve bilişim dünyasına artan ilgi ve merakla birlikte kavram yıllar içerisinde gelişmiş, farklı modellere ayrılmış ve tek başına alt alan olma durumuna yükselmiştir. Araştırmamız kapsamında incelenen site öznelinde toplam 65 grafik model tespit edilmiştir. Bu modeller; GCN (Graph Convolutional Networks – Grafik Evrişimli Ağlar), DCNN (Diffusion-Convolutional Neural Networks – Difüzyon-Evrişimli Sinir Ağları), HMGNN (Heterogeneous Molecular Graph Neural Network – Heterojen Moleküler Grafik Sinir Ağı), GAT (Graph Attention Network – Grafik Dikkat Ağrı), DualGCN (Dual Graph Convolutional Networks – Çift Grafik Evrişimli Ağlar), GraphSAGE, CGMM (Contextual Graph Markov Model – Bağlamsal Grafik Markov Modeli), GraphTransformator, StoGCN, MPNN (Message Passing Neural Network – Mesaj Aktarma Sinir Ağı), NN4G (Neural Network for Graphs – Grafikler için Sinir Ağı), SSE (Stochastic Steady-State Embedding – Stokastik Kararlı Durum Gömme), PNA (Principal Neighbourhood Aggregation – Temel Komşuluk Toplaması), MONET (Mixture Model Network – Karışım Modeli Ağrı), BiGG (Big Graph Generation – Büyük Grafik Oluşturma), DGCNN (Deep Graph Convolutional Neural Network – Derin Grafik Konvolüsyonel Sinir Ağı), TGN

(Temporal Graph Network – Geçici Grafik Ağrı), ARMA (Auto-Regressive Moving Average – Otomatik Gerileyen Hareketli Ortalama), MXMNet (Multiplex Molecular Graph Neural Network – Çoklu Moleküller Grafik Sinir Ağı), GIN (Graph Isomorphism Network – Grafik İzomorfizm Ağrı), PinvGCN (Pseudoinverse Graph Convolutional Network – Sözde Ters Grafik Evrişimli Ağ), LightGCN (Light Graph Convolution Network – Hafif Grafik Evrişim Ağrı), S-GCN (Spherical Graph Convolutional Network – Küresel Grafik Evrişimli Ağ), RGCN (Relational Graph Convolution Network – İlişkisel Grafik Evrişim Ağrı), TaxoExpan, SchNet (Schrödinger Network – Schrödinger Ağrı), Point-GNN (Point Graph Neural Network – Nokta Grafiği Sinir Ağı), GGS-NNs (Gated Graph Sequence Neural Networks – Geçitli Grafik Dizisi Sinir Ağları), IPA-GNN (Instruction Pointer Attention Graph Neural Network – Talimat İşaretçi Dikkat Grafiği Sinir Ağı), DiffPool, HEGCN (Hierarchical Entity Graph Convolutional Network – Hiyerarşik Varlık Grafiği Evrişimli Ağ), AGCN (Adaptive Graph Convolutional Neural Networks – Uyarlanabilir Grafik Evrişimli Sinir Ağları), AdaGPR (Adaptive Generalized Pageranks – Uyarlanabilir Genelleştirilmiş Pageranks), GNS (Graph Network-based Simulators – Grafik Ağı Tabanlı Simülatörler), NeuroTactic, GCNII (Graph Convolutional Networks II – Evrişimli Sinir Ağları II), GAGNN (Group-Aware Neural Network – Gruba Duyarlı Sinir Ağı), FastGCN (Fast Graph Convolutional Networks – Hızlı Evrişimli Sinir Ağları II), Hi-LANDER (Hierarchical Link Approximation And Density

Estimation Refinement – Hiyerarşik Bağlantı Yaklaşımı ve Yoğunluk Tahmini İyileştirme), DGI (Deep Graph Infomax – Derin Grafik Infomax), CayleyNet, CGNN (Crystal Graph Neural Network – Kristal Grafik Sinir Ağı), GeniePath, BiGCN (Bi-Directional Graph Convolutional Network – Çift Yönlü Grafik Evrişimli Ağ), MinCutPool, GraphESN (Graph Echo State Network – Grafik Yankı Durum Ağı), TGN (Temporal Graph Network – Geçici Grafik Ağı), PGChebNet, PGC-DGCNN, RE-NET (Recurrent Event Network – Tekrarlayan Etkinlik Ağı), Cluster-GCN (Cluster Graph Convolutional Networks – Küme Evrişimli Sinir Ağları), GNNCL (Graph Neural Networks with Continual Learning – Sürekli Öğrenme ile Grafik Sinir Ağları), MeshGraphNet, GCNFN (Graph Convolutional Networks for Fake News Detection – Sahte Haber Tespiti için Grafik Evrişimli Ağlar), Symbolic Deep Learning (Sembolik Derin Öğrenme), GATv2 (Graph Attention Network v2 – Grafik Dikkat Ağı v2), Graph Contrastive Coding (Grafik Karşılaştırmalı Kodlama), LGCL (Learnable Graph Convolutional Layer – Öğrenilebilir Grafik Evrişim Katmanı), AutoGL (Automated Graph Learning – Otomatik Grafik Öğrenme), GAP-Layer (Spectral Gap Rewiring Layer – Spektral Boşluk Yeniden Kablolama Katmanı), CT-Layer (Commute Times Layer – İşe Gidiş Süreleri Katmanı) ve GaAN (Gated Attention Networks – Geçitli Dikkat Ağları) şeklindedir. Modeller GNN tasarımda kullanıldığı gibi zorlu görevler öznelinde ya da GNN tasarım modülleri dışında özel görevler için de üretilmiştir [2]. Tablo 1 ve Tablo 2’de grafik modeller ile ilgili literatür taraması yapılmış ve

makale sayıları gösterilmiştir. Grafik modeller CNN ve GNN’ler dışında kendi üretilen alt modellerden de türetilmiştir.

Tablo 1: Grafik model makale sayıları.

Model	Makale Sayısı	Model	Makale Sayısı
GCN	685	GaAN	2
DCNN	235	HMGNN	1
GAT	107	DualGCN	1
GraphSAGE	70	CGMM	2
GraphTransformer	87	StoGCN	1
MPNN	36	NN4G	0
SSE	25	PNA	3
MONET	18	BiGG	1
DGCNN	30	TGN	1
ARMA	24	MXMNet	1
GIN	22	PinvGCN	1
LightGCN	12	S-GCN	2
RGCN	18	TaxoExpan	1
SchNet	12	Point-GNN	1
GGS-NNs	9	IPA-GNN	1
DiffPool	6	HEGCN	1

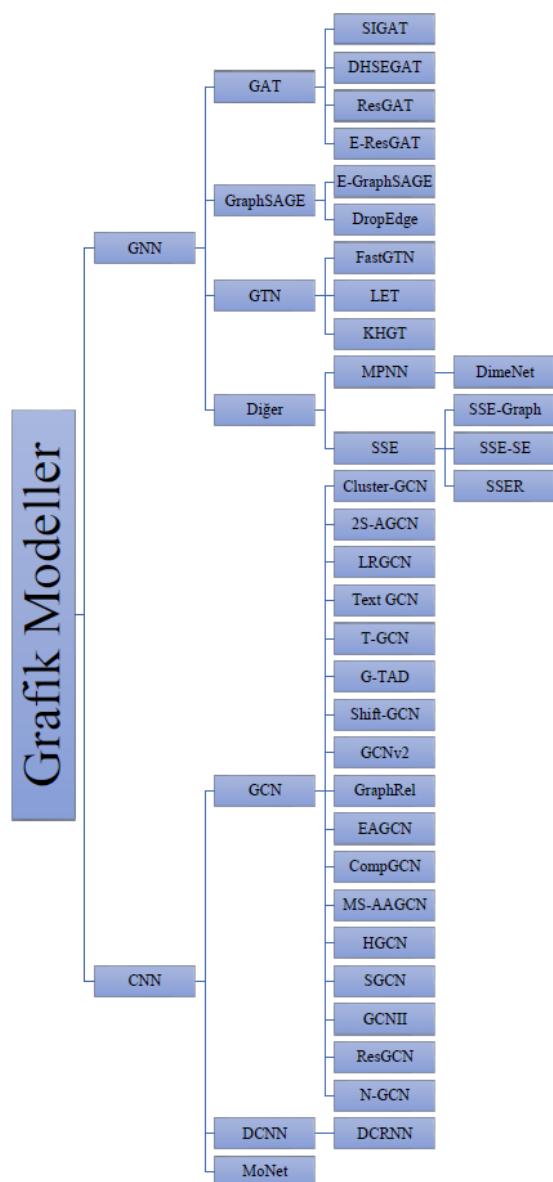
Tablo 2: Grafik model makale sayıları.

Model	Makale Sayısı	Model	Makale Sayısı
AGCN	7	AdaGPR	1
GNS	9	NeuroTactic	1
GCNII	7	GAGNN	1
FastGCN	4	Hi-LANDER	1
DGI	7	CayleyNet	1
CGNN	5	GeniePath	1
BiGCN	3	MinCutPool	1
DGCNN	3	GraphESN	0
TGN	4	MXMNet	1
ChebNet	4	PGC-DGCNN	1
RE-NET	2	Cluster-GCN	3
GNNCL	2	MeshGraphNet	1
GCNFN	2	SDL	1
GATv2	3	GCC	2
LGCL	3	GaAN	2
CT-Layer	1	GAP-Layer	1
AutoGL	1		

2. GRAFİK SİNİR AĞLARI (GRAPH NEURAL NETWORKS)

İlk incelenen model olan GCN'ler bilinen adıyla grafik evrişim ağları olarak adlandırılmaktadır. GCN'ler CNN (Convolutional Neural Networks – Evrişimli Sinir Ağları)'lerin bir türevi olarak literatüre eklenmiştir. Yarı denetimli eğitimi kullanarak geliştirilmiş bir yaklaşımdır. Düğüm sınıflandırma, genel sınıflandırma, grafik sınıflandırma, grafik öğrenme, eylem tanıma, bağlantı tahmini, iskelet tabanlı eylem tanıma ve grafik gömme gibi alanlarda kullanılmaktadır. Evrişimsel mimari kullanılmasının amacı CNN'lerin grafik ve 3 boyutlu öklid uzayında veriminin düşük olmasıdır. Grafiklerde yapı ve düğüm özelliklerini kodlama yapan gizli katman öğrenimi gerçekleştirilmektedir [3]. Şekil 1'de grafik modellerin alt modelleri görülmektedir.

GCN'ler birçok farklı katman ve alanda uygulanmaktadır. Bu uygulama GCN'lerin zorluklarını da ortaya koymaktadır. Büyük ölçeklerde eğitim zorluğu GCN'lerin ortak zorluluklarından birisi olmuştur. Basit çözüm olarak öne sürülen; SGD tabanı algoritmalar, katman sayısı artışı ile maliyetin artması ve grafigin tamamının tutulması sebebiyle büyük bir alan gereksinimine ihtiyaç duymaktadır. Bu zorluğu aşmak için küme-GCN geliştirilmiştir. Küme-GCN, her adımda ilişkili düğüm bloklarını örnekleyerek komşuluk aramasını kolaylaştırmaktadır [4]. GCN'ler sinir ağları ailesi arasında yaygın kullanılan ve güçlü sinir ağları denilebilecek potansiyel ve performansta olan sinir ağlarıdır.



Şekil 1: Grafik modellerin alt modeller ile ilişkisi.

Düğüm temsili hesaplamasında özyineleme kullanılmaktadır ve komşuluk değerleri de kullanıldığından, katman sayısı ve alan boyutunun artmasına neden olmaktadır. Düğüm başına alan boyutu yüksek olması sebebiyle alt örnekleme uygulanması da sonucu tam olarak çözmemektedir. Bunun için geliştirilen metotta iki komşu kullanıldığından başarı sağlanan kontrol değişkeni tabanlı algoritmalar yardımıyla komşu boyutu öneklenmiştir [5]. Yarı denetimli öğrenme için etiket yama algoritmaları olarak bilinen LPA algoritmaları

da kullanılmaktadır. LPA’lar, özellik yayılımı kullanan GNN’nin aksine etiket yayılımı kullanmaktadır. İki algoritmada verimli olmasına karşılık birleştirilmek için henüz bir model geliştirilmemiştir. Bu sebeple benzer özellikler gösteren, eğitim ve sonuçta özellik ile birlikte yayılımı birleştirerek kullanılan UniMP (Unified Message Passing – Birleşik Mesaj Geçiş) modeli geliştirilmiştir. Model, ilk adımda grafik dönüştürücü ağını benimsemekte, ikinci adımda ise ağı eğiterek maskeli etiket tahmini yapmaktadır [6]. GCN’ler aynı zamanda insan bedeni iskelet sistemini uzay-zamansal grafikler şeklinde modellemiştirlerdir. Model giriş değeri sabit ayarlama ve manuel topoloji ile oluşturulmuştur. Bu modelde ikinci derece bilgiler yani uzunluk ve yön bilgileri hesaplama maliyetini arttırması sebebiyle nadir durumlarda araştırılmaktadır. Bu sorunu çözmek için 2s-AGCN (Two-Stream Adaptive Graph Convolutional Network – İki Akışlı Uyarlanabilir Grafik Evrişim Ağı) modeli önerilmiştir [7]. GCN’ler aynı zamanda gerçek dünya modelleri içinde kullanılmaktadır. Bunun en bilinen örneklerinden birisi yol hatası tahminidir. Grafiklerde yapı dinamiği ve zaman bağımlılığını belirleme için kullanılan LRGCN (Long Short-Term Memory R-GCN – Uzun Kısa Süreli Bellek R-GCN) modeli önerilmiştir. Zamansal kavramlarda zaman içi ve zamanlar arası ilişkiler için GCN’yi kullanan LRGCN, SAPE (Self-Attentive Path Embedding – Özlenli Yol Gömme) modeline de ilham olmuştur. Bu modelin özelliği ise keyfi uzunlukları grafiklerde bulunan sabit uzunluklara ekleyebilmesidir. Bu sayede gerçek dünya

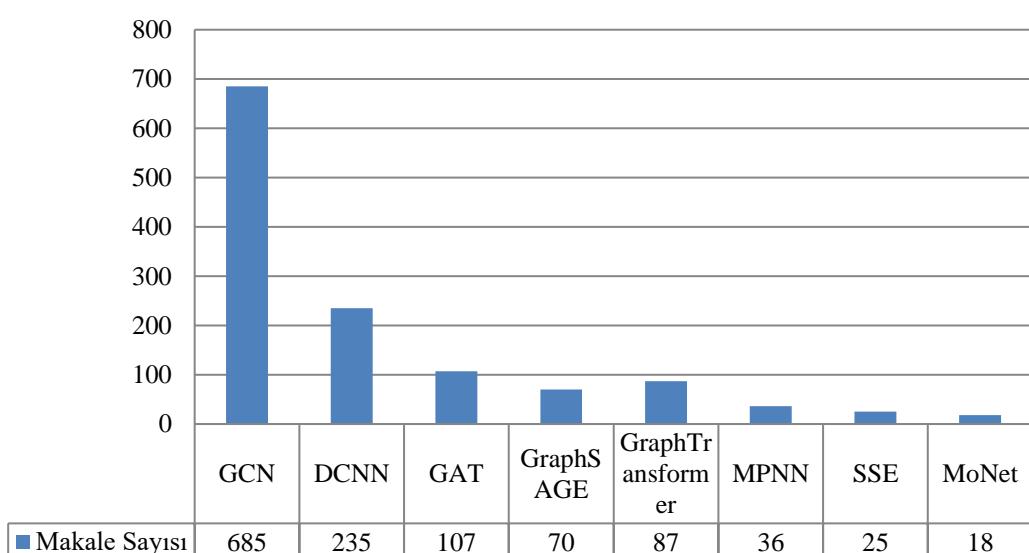
tahmini kolaylaşmaktadır [8]. GCN’ler aynı zamanda dizi içerisinde bulunan nesnelerin tahmini için de kullanılmaktadır. Bu tahmin görüntü tanıma olarak adlandırılmaktadır [9]. Metin sınıflandırma görevi CNN’ler içerisinde oldukça yaygındır. CNN’ler arasında çok fazla metin sınıflandırma çalışması olsa da GCN’ler içerisinde bu sayı oldukça azdır. Bu sorunu ortadan kaldırmak için Text GCN (Metin GCN) modeli önerilmiştir [10]. Makine öğrenimi problemlerinden biri olan ve eğitim esnasında gözlemlenmeyen sınıfları inceleyerek aitlik sınıfını tahmin eden ZSL (Zero Shot Learning – Sıfır Atışlı Öğrenme), anlamsal ve kategorize edilmiş ilişkili ölçeklendirmek için GCN ile ilişkilendirilmiştir. Geliştirilen model bilinen sınıflardan elde edilen bilgiler ile çıkarm yaparak bilinmeyen sınıflar için tahminde bulunmaktadır. Grafik üzerinde anlamsal boyutlar girdi olarak işlenir ve kategorisel olarak tahminler elde edilir [11]. GCN’ler yol tahmini için kullanıldığı gibi trafik tahmini için de kullanılmaktadır. Gerçek zaman içerisinde doğru trafik tahmini için geliştirilmiş T-GCN (Temporal GCN – Geçici GCN) modeli, günümüzde gelişen akıllı trafik sistemleri için gerçekleşen sorunlara değinmiştir. Model aynı zamanda gelişimi ile kentsel tasarım ve trafik kontrol yönetimine de atıfta bulunmaktadır [12]. Video anlamalarının önemli konularından biridir. Videolar içerisinde zamana bağlı eylem algılama, anlamsal bağlam yerine zamansal bağlama odaklı olmuştur. Bu soruna çözüm için G-TAD (Graph Temporal Action Detection – Grafik Zamansal Eylem Algılama) modeli önerilmiştir. Model alt grafik yerelleştirmede

zaman ve anlamı birleştirerek sonuçlar üretmektedir [13]. GCN'ler iskelet tabanlı görevlerde eylem tanıma için de kullanılmaktadır. Bunun başlıca sebebi bu görevin bilgisayarlı görme alanında etkin olması olmuştur. Uzay-Zaman grafiğinin esnek olmaması ve hesaplama maliyetinin yüksek olması sebebiyle sınırlandırıcı olmaktadır. Bu sorunların çözümü için geliştirilen Shift GCN (Kaydırma GCN), eylem tanıma görevlerini başarıyla yerine getirmiştir [14]. GCN'ler metin tahmini dışında yazışma tahmini için de kullanılmaktadır. Yazışma tahmininde asıl etken tanımlayıcı oluşturma ve kilit noktalar olmaktadır. Bu sorun için geliştirilen GCNv2 modeli, 3 boyutlu geometri için eğitilmiş fakat orb ile tasarlanması gerçek zamanlı eşzamansal yerelleştirme ve haritalamada yapabilmektedir [15]. İlişki tahmini GCN'lerde yaygın kullanılan bir görev olmuştur. Farklı modeller geliştirilerek ilişki tahminleri yapılmıştır. Bu modellerden biri de GCN kullanarak geliştirilen GraphRel modelidir. GraphRel, kelime grafiği kullanarak metin tahmini benzeri bir yol izlemektedir. Araştırdığı metnin bölgesel ve metinsel özelliklerinden yararlanarak metin içerisinde bulunan çiftlerin örtük özelliklerini çıkarmaktadır [16]. İlişkili grafikler farklı alanlarda yaygın olarak kullanılmaktadır. Bu alanlardan biri de kimya bilimidir. CNN'lerin yetersiz kalarak genelleştirilmesiyle oluşturulan GCN'ler moleküller grafiklerde kullanılması farklı modellerle zenginleştirilmiştir. Bu modellerden biri olan EAGCN (Edge Attention-Based Multi-Relational GCN – Uç Dikkat Tabanlı Çok İlişkisel GCN) modeli, düğüm özellikleri ve dikkat ağı görevlerini birlikte

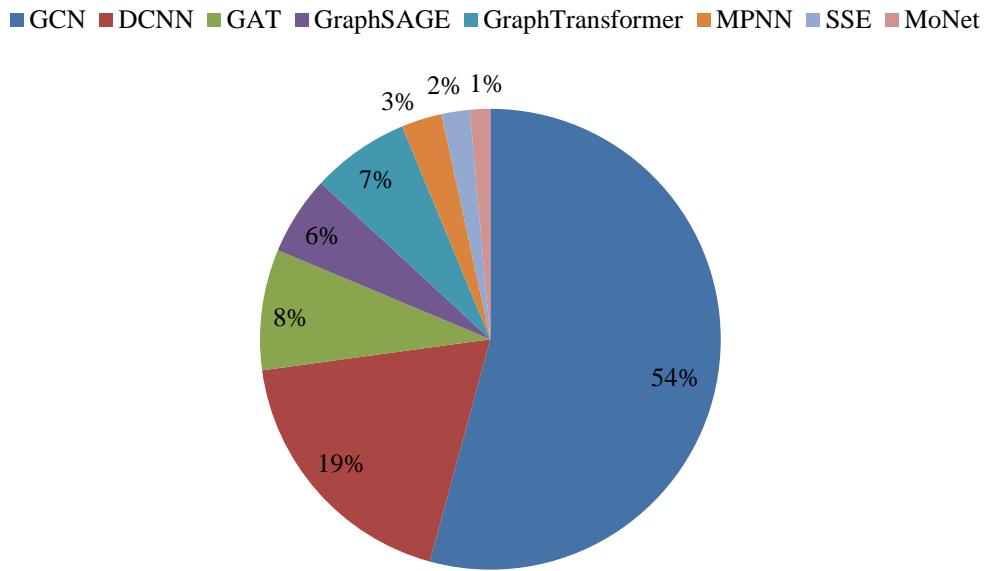
görerek öğrenmektedir. Model dikkat matrisi kullanarak verimini artırmaktadır [17]. GCN'ler kullanılmaya başlanmasından itibaren ana odak noktasını yönsüz grafikler üzerinden gerçekleştirmektedir. Çok ilişkili ve yönlü grafiklerin hesaplama maliyetleri fazlalığı, parametre sayısının yüksekliği ve düğüm öğrenme sınırlaması gibi sebeplerden dolayı çalışmaların önünde zorluk oluşturmaktadır. Bu zorluğa karşılık ilişkileri tahmin eden ve düğümleri öğrenme kullanan ilişkisel grafik modeli CompGCN (Composition GCN – Kompozisyon GCN) modeli geliştirilmiştir. Geliştirilen model yüksek başarı elde etmiştir [18]. Sinir ağlarında geliştirme esnasında karşılaşılan yeni sorunlar ve zorluklar diğer modellere her zaman örnek olmuştur. Bir model geliştirilirken, deneyler esnasında karşılaşılan zorluk farklı bir modelde çözüm önerisi olarak sunulmuştur. Karşılaşılan zorluklar yeni modellerin gelişimini büyük ölçüde etkilemiştir. Bu zorluklar CNN'lerin öklid dışı yapıları için GCN'leri genellemesiyle farklı bir bakış kazanmış ve gelişimi hızlandırmıştır. İskellet tabanlı eylem tanıma görevi, farklı modellerde kullanılmış ve bazı modeller sadece bu zorluğa çözüm oluşturmak için geliştirilmiştir. GCN'lerde bulunan zorluklar iskelet eylem tanıma ile birleşince grafik topolojisi manuel ya da bulusal olarak ayarlama ve uzunluk ile yön hesaplama zorluğu başlıca sorunlarından biri olmaktadır. Bu duruma karşılık önerilen MS-AAGCN (Multi-Stream Attention-Enhanced Adaptive Graph Convolutional Neural Network – Çoklu Akış Dikkati Artırılmış Uyarlanabilir Grafik Evrişimli Sinir Ağı) modeli bireysel ve uçtan

uca öğrenme ile grafik esnekliği sağlayarak uyumluluğu artırmaktadır. Model zaman-yön dikkat modeli ile üstün performans göstermektedir [19]. GCN'ler 3 boyutlu uzayda yüksek başarı elde etmektedir. Grafikler üzerinde yapılan çalışmalarında başarıları kendilerini kanıtlamıştır. Farklı sekillerde başarıları bilinse de hiperbolik durumlarda sorunlarla yaşamaktadırlar. Bu sorunu aşmak için geliştirilen HGCN modeli öznitelikleri doğru analiz ederek egrilik seviyesini belirlemesiyle GCN işlemlerini gerçekleştirmektedir. Giriş özellikleri öklid olan Hiperbolik GCN her katmanda eğitim yaparak verimini artırmaktadır [20]. Grafik modellerde sekiz model hem fazla çalışma sayısı ile hem de kullanımından dolayı öne çıkmaktadır. Şekil 2'de bu modellerle ilgili makalelerin sayısını, Şekil 3'te ise bu modellerle ilgi yazılmış olan makalelerin oranlarını Şekil 4'te ise zaman içerisinde kullanımlarını gösteren grafikler verilmiştir.

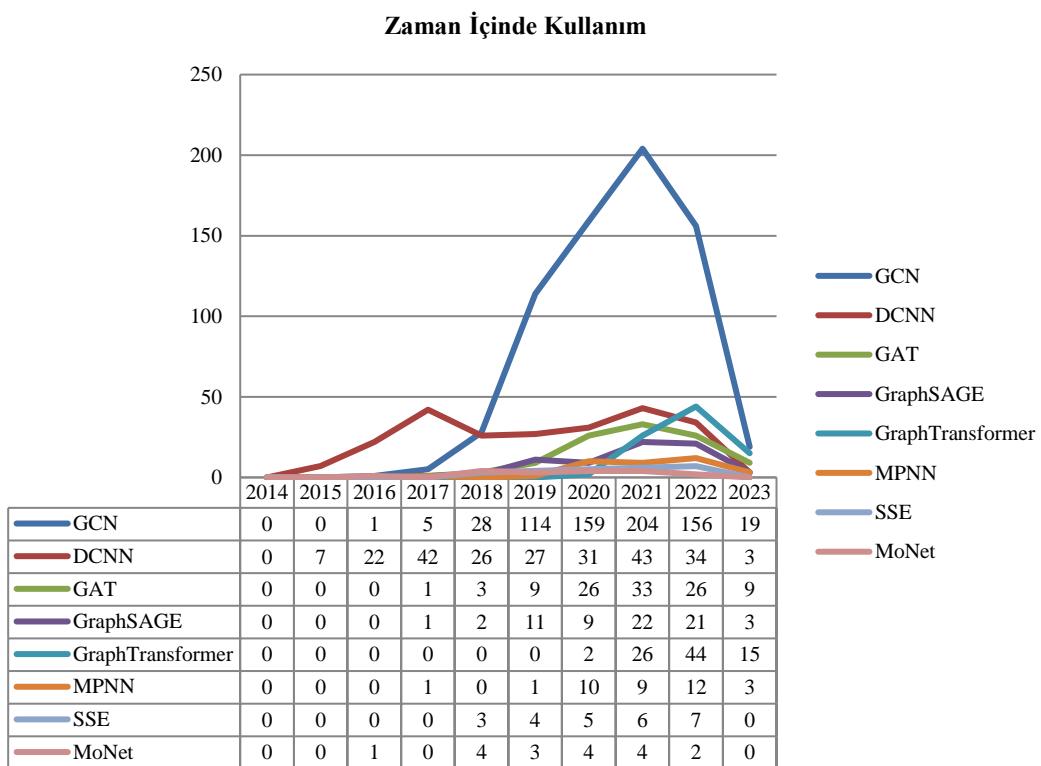
Difüzyon – evrişim işlemlerinin tanıtımı ve kullanımının başlanmasıyla, difüzyon kullanan grafiksel verilerden öğrenme gereksinimi ve düğüm sınıflandırma yönteminin kullanımı için DCNN modeli geliştirilmiştir. Modelin öne çıkan özelliği, grafiksel verilerde gizli temsiller ile birlikte çok boyutlu verilerin geometrik nesneler ile temsil edilmesine olanak tanımasıdır [21]. DCNN'ler farklı alanlarda kullanılmaktadır. Bu alanlardan birisi de tıbbi görüntülemedir. Tıbbi görüntüleme yöntemleri veri biliminin gelişmesi ve veri setlerinin çoğalmasıyla birlikte tahmin algoritmaları ile kullanımı yaygınlaşmıştır. Bu veri setlerinden biri olan ChestX-ray14, 14 farklı göğüs hastalığı için büyük veri olarak kullanılmaktadır. DCNN'ler eğitilerek bilgisayarlı tanı sistemleri oluşturulabilmektedir. ChestX-ray14 veri kümesi DCNN ile kullanılmasıyla teşhis edilebilen eğitilmiş bir model geliştirilmiştir [22].



Şekil 2: Makale sayısı.



Şekil 3: Yazılmış makalelerin yüzdelik oranı.



Şekil 4: Modellerin zaman içerisindeki kullanımı.

DCNN'ler aynı zamanda yeni modellere ilham olmustur. DCRNN (Diffusion Convolutional Recurrent Neural Network – Difüzyon Evrişimli Tekrarlayan Sinir Ağları) modeli, uzay-zamansal tahmini verimli bir şekilde

kullanmakta ve sinirbilim, ulaşım ile iklim alanlarında tahmin gerçekleştirmektedir. Trafik tahmini sinir ağları tarafından yaygın kullanılan ve deneyler yapılan bir modeldir. Trafik akışının bir grafik üzerinde modellenmesi ve

mekânsal-zamansal bağımlılığı kullanan trafik tahmini için grafiklerde çift yönlü yürüyüşler kullanmaktadır [23]. DCRNN üzerinden geliştirilen bir başka modelde ise trafik tahminin yanı sıra tıkanıklık tahmini de yapılmıştır [24].

GAT, maskeli öz-dikkat katmanlarını kullanarak grafik kıvrım ve yaklaşımlarında bulunan eksikliklerin giderilmesi için geliştirilmiş bir GNN modelidir [25]. İlişkisel grafik evrişim ağlarının eğitilmesi ile ilişkisel grafik dikkat ağları modeli oluşturulmuştur. İlişkisel dikkat ağlarının asıl amacı moleküller grafiklere çözüm üretmektir. Yapılan deneyler sonucunda modelin ilişkisel GCN'lere göre başarısız olduğu görülmüştür [26]. GNN'lerde mevcut anlayışlardan birisi eş yönsüz modellerin geliştirilmesinin gerekli olduğu yönünde olmuştur. Anizotropik modellerin izotropik modellerden daha başarılı olacağı düşünülmüş ayrıca grafik dikkat ağları ile karşılaşmalıdır bir model geliştirilmiştir. EGC (Efficient Graph Convolution – Verimli Grafik Evrişim), mekansal değişim uyarlanabilirlik filtreleri ile modellenerek GAT'lara rakip olmuştur [27]. Grafik dikkat ağları başarısını sadece pozitif bağlantılı ağlarda sağlamaktadır. Pozitif ve negatif bağlantılarda verimli değildir. Bu sebeple GAT geliştirilerek SIGAT (Signed Graph Attention Networks – İmzalı Grafik Dikkat Ağları) modeli geliştirilmiştir. Modelin asıl amacı, agdaki mesajları toplamak ve yaymaktır. Bu amaç için denge ve durum teorilerini genelleyerek imzalı bağlantı tahmini yapmaktadır. Model benzer model SGCN (Signed Graph Convolutional Network – İmzalı Grafik Evrişim Ağı) ve ağ gömme

yöntemlerinden daha verimli sonuçlar almıştır [28]. Model bağlantı tahmini görevi için kullanılmak üzere yenilerek işaretli bağlantıları da tahmin edebilme özelliği kazandırılmıştır. wsGAT olarak bilinen model, SGCN ve GCNII ile karşılaştırıldığında daha verimli bir sonuç vermiştir [29]. GNN'lerin başka bir sorunu olan mevcut komşu ortalama yapılarına GAT'lar ile bir bakış sağlanmıştır. Mesafe dağılım bilgisini konum ve uzaysal değerler ile hesaplayan model düğümü iç özellikleri ile bir araya getirerek vektör uzayında toplamaktadır. DHSEGAT (Distance and Hop-wise Structures Encoding Enhanced Graph Attention Networks – Mesafe ve Hop-wise Yapıları Kodlama Geliştirilmiş Grafik Dikkat Ağları), gömme vektörlerinde başarı sağlayarak verimli sonuçlar elde etmiştir [30]. Bir başka kullanım alanı ise anomali tespitidır. Anomali tespiti, veri içerisinde beklenilmeyen durum ve kalıpların bulunduğu tespit yöntemidir. GAT tespit üzerinde çok değişkenli zaman kullanmaktadır. Bu sebeple tespit veri madenciliği ve endüstriyel anlamda önem arz etmektedir. En büyük sorun ise farklı zaman dilimlerinin birbirlerinde hata oluşturması ve birbirleri ile etkileşime geçmemesidir. Bu duruma çözüm olarak kendi denetimini kendisi yapabilen bir model geliştirilmiştir, paralel olarak zaman serileri işlenmiştir [31].

GraphSAGE, tek tek gözlemlemeye dayalı olarak geliştirilmiş bir çerçeve modeldir. Düğümler GNN'lerde birçok farklı alanda kullanılmaktadır. Düğüm gömme eğitimlerinin başında gelen sorun ise tüm düğümlerin bilinmesi durumudur. Görünmeyen ve bilinmeyen düğümler için önceki yıllarda

geliştirilmiş olan düğüm gömme modelleri işlevsellliğini kaybetmektedir. Bu sebeple metin tabanlı ve tek tek gözlemlemeye dayalı öğrenme gerçekleştirilen GraphSAGE modeli geliştirilmiştir. Modelin çalışma prensibi komşu örneklemeye dayanmaktadır [32]. Grafik temsil öğrenmesi için en gelişmiş çerçeve olan GNN'ler, komşu özelliklerini üzerinden çıkarım yapabilmektedir. Geliştirilen modeller genellikle tek tip grafik yapıları üzerine dayanmaktadır. Farklı grafik yapılarında modeller başarısız olmakta ve bu GNN'ler içerisinde bir sorun haline gelmektedir. GNN'lerde modellerin ayırt etme gücü için geliştirilen Weisfeiler-Lehman çizge izomorfizm testi yaygın olarak kullanılmaktadır. Test ayrıca grafik çekirdeği tasarımlı için de kullanılmaktadır. Test analiz işleminde kullanılırken aynı kategori ya da benzer biçimli grafikler içerisinde eş yapı yani eşbiçim olarak ayırt etmektedir. Testin farklı alanlarda kullanılması ve akademik gelişim sebebiyle benzer modelleri ortaya çıkmıştır [33-34]. Günümüzde siber güvenliğin gelişimi ve bu gelişime ek olarak siber tehdit kavramının ortaya çıkarak yaygınlaşması GNN modellerine etki etmiştir. Bu durum karşısında en önemli görevlerden birisi de izinsiz giriş tespiti olmaktadır. Geliştirilen modeller çoğunlukla ağ topolojisi üzerine olsa da farklı alt alanlara da degenilmesi yeni görev ve modellerin ortaya çıkışmasını sağlamaktadır. İzinsiz giriş tespiti, yetkisiz girişlerin farkına varırken veri bütünlüğünü de koruma temelindedir. GraphSAGE modeli temelleştirilerek izinsiz giriş tespiti için E-GraphSAGE modeli oluşturulmuştur. Bu modelde temel fikir GNN

üzerinden genelleştirme yaparak modelin izinsiz giriş tespiti üzerinde kullanılması amaçlanmaktadır. Model işlem yaparken orijinal bilgi verisini korumakta ayrıca az seviye sınırlarda da iyileştirme yapmaktadır [35]. İzinsiz giriş tespiti GraphSAGE modelleri için bir başlangıç noktası olmaktadır. Geliştirilen başka bir model GNN tabanında NIDS (Network Intrusion Detection System – Ağ Saldırı Tespit Sistemi) kullanarak analiz yapmaktadır. Model temelinde DOS (Disk Operating System – Disk İşletim Sistemi) ve IoT (Internet of Things – Nesnelerin İnterneti) bağlantılarında bulunan ağ izinsiz giriş tespitleri için geliştirilmiştir. Modelin gelişmişlik seviyesi yüksek ayrıca ağ anormalligi tespit etme yeteneğiyle de ön plana çıkmaktadır. Yapılan deneyler sonucunda başarısını kanıtlamış NIDS'lar üzerinde farklı veri kümeleri ile test edilerek başarısını pekiştirmiştir [36]. GNN modelleri siber güvenlik alanında birçok farklı model ortaya çıkarmıştır. İzinsiz giriş tespiti dışında siber güvenlik alanının temel konularından olan ve ayrıca birçok makale ve tez ile incelenen zararlı yazılım tespiti, GNN modelleri için de büyük bir önem arz etmektedir. LIN (Leaping Information Networks – Sıçrayan Bilgi Ağları) modelleri ile tanıtılan ve JK (Jumping Knowledge – Atlama Bilgisi) mimarisini olarak bilinen komşuluktan yararlanan GNN modeli ile birleştirilmiştir. LIN analiz için kullanılmakta ve özellik-uyum görevlerini kolaylaştırmaktadır. Program görevleri ve görev arası etkileşim iletişim için kullanılan Android FCGs (Function Call Graphs – İşlev İletişim Grafikleri) görev için iletişim temelinde

kalıpları analiz ederek çalışmaktadır. GNN sorunu olan aşırı yumuşatma için kullanılan atlama bilgisi sorunu en düşük seviyeye indirerek verimi yükseltmektedir [37-38]. Bir başka görev düğüm öğrenmesi için GraphSAGE modelleri aktif olarak kullanılmaktadır. Düğüm öğrenmesi görevindeki ana temel bellek verimliliği artırımı ve düğüm çıkarımlarındaki hesaplamalar olmaktadır. GraphSAGE bu zorlukları başarı ile aşmakta, yüksek doğruluğu elde etmektedir. Geliştirilen model veri temelinde düğüm örneklemesi yapmaktadır [39]. Düğüm öğrenmesi görevi farklı görevlerin toplamı olarak da tanımlanabilir. Bu görevlerden birisi düğüm sınıflandırma görevidir. DropEdge isimli model temelinde GCN kullanılarak geliştirilmiştir. Model eğitimlerini engelleyen başlıca faktörler olan aşırı yumuşatma ve sığdırmanın zorluklarına karşı geliştirilen model veri artırımı ve mesaj geçişlerini azaltarak bu zorlukları aşabilmektedir. Model GraphSAGE, ResGCN ve JKNet ile birleştirilerek farklı veri setleri üzerinde başarı göstermiştir [40]. GCN modelleri GNN'lerde yaygın kullanımı ve farklı modeller ile birleştirilmesi ile üstün performans sağlamaktadır. Yarı denetimli öğrenme ve grafik öğrenmede yerleştirmelerin denetimsiz öğrenimi konularını birleştirerek N-GCN modelini oluşturmuştur. Modelin başarısı birden fazla GCN'i eğitmesi ve çıktı kombinasyonu öğrenmesi ile kendini kanıtlamıştır. N-GCN modeli GraphSAGE ile tekrar modellenerek bozulmalara karşı N-SAGE modelinin temelini oluşturmuştur [41].

Grafik dönüştürücü sinir ağları, rastgele grafikler için geliştirilmiş sinir ağı mimarisidir. GraphTransformatör adı ile bilinen ağa, NLP (Natural Language Processing – Doğal Dil İşleme) için tasarlanmış, düğüm özelliklerinin belirsizliği, grafik topolojisinin önem arz ettiği ve temelden öngörü verimsizliği ile zorluklar çıkarmakta ve düşük verim elde etmektedir. İlk modele nazaran sonradan geliştirilen modellere dikkat katmanı, konumsal kodlama, katman normalizasyonu ve bağlantı tahmini görevlerini gerçekleştirecek eklemeler ile model verimli hale getirilmektedir. Mimari her ne kadar basit olarak tanımlanmış olsa da gelecek çalışmalara örnek olacağı savunulmuştur. Grafik dikkat katmanı grafik dönüştürücü sinir ağları için de diğer modellerde olduğu gibi önem arz etmektedir [42]. GNN'ler farklı kenar ve düğüm sayısından oluşan heterojen grafiklerin öğrenmelerinde büyük bir sorun teşkil etmektedir. Grafik dönüştürücü ağları bu soruna değinerek gürültü engelleme ve düğüm temsillerini öğrenebilen bir model olmaktadır. Bu sorun için geliştirilen model standart grafik dönüştürücü ağlarına göre 230 kat daha hız ve az bellek kullanımı ile verimini göstermektedir. Model hızı ve verimi sebebiyle FastGTN (Fast Graph Transformer Networks – Hızlı Grafik Dönüştürücü Ağ) adını almaktadır [43]. Grafik dönüştürücü ağlarının dil işlemesinde kullanımı yaygınlaşmaktadır. Uzakdoğu dilleri, batılı dillere göre daha zor öğrenme seviyesinde olduğundan öğrenim hem önemli bir hale gelmekte hem de anlamsallık sebebiyle zorlaşmaktadır. Bu sebepten grafik dönüştürücü ağları dil işleme konusunda farklı çalışmalar ortaya çıkmıştır. Bu çalışmalardan birisi de

LET (Linguistic Knowledge Enhanced Graph Transformer – Dil Bilgisi Gelişmiş Grafik Dönüştürücü) modelidir. Model Çin dili üzerine geliştirilmiş ve anlamsal-yazım sorunlarına karşı verim elde etmiştir [44]. Grafik dönüştürücü ağları, farklı kullanıcı davranışları, bilgi tabanlı öğelerde ilişkisel çıkarım ve kullanıcı-öge özelliklerini gibi farklı zorluklarla ilgilenmektedir. Modeller zorluklara karşı verimlilik alma ve zorluklara son verme amaçlı geliştirilmektedir. Bu zorluklara karşı olarak KHGT (Knowledge-Enhanced Hierarchical Graph Transformer Network – Bilgiyle Geliştirilmiş Hiyerarşik Grafik Dönüştürücü Ağ) modeli geliştirilmiştir. Model kullanıcı-öge arasındaki etkileşim özelliklerini araştırırken türlerle özel davranış durumları belirleyebilmektedir. Ayrıca model tahmin görevlerinde hedef davranış kullanarak etkileşimi ayırt edebilmektedir [45]. GraphTransformatör modelleri aynı zamanda biyoloji ve kimya grafiklerinde de kullanılmaktadır. İlaç keşfi için en önemli konulardan olan ara yüz temas tahminine yönelik hesaplamalarda doğruluk seviyesi yüksek olmalıdır. Bu yükseklik grafik dönüşüm ağları modellerinde de incelenerek verimin artırılması sağlanmıştır. Bu durum grafik dönüşüm ağlarının zengin öğrenmede etkili olduğunu göstermektedir [46].

GNN'lerin bilişim dışında da birçok farklı alanda kullanıldığı bilinmektedir. GNN'ler; kimya, biyoloji, malzeme bilimi ve ilaç keşfi gibi moleküller grafikler üzerinde başarılı olmaktadır. Modellerin çalışmasında giriş parametre değerlerini hesaplamak için mesaj geçiş algoritmaları kullanılmaktadır. Bu durum

MPNN'nin ortaya çıkışında etkili olmuştur [47]. Moleküller grafiklerin bilimsel araştırmalarda kullanılması MPNN'lere değer katmıştır. Fakat standart modellerde bulunan düğüm arası mesafe kullanımının grafik temsil edilmesi ve yön bilgisinin dikkate alınmaması mesaj ileten ağlarda zorluklar oluşturmaktadır. Bu zorluklara karşılık DimeNet (Directional Message Passing Neural Network – Yönlü Mesaj Geçiren Sinir Ağı) modeli geliştirilerek, mesajların yönler ile ilişkilendirilmesiyle eşdeğerlik kazanılmaktadır. Model yön bilgisini düğümler arasındaki açıları dönüştürerek elde etmektedir. Geliştirilme sürecinde dik ve verimli temsil oluşturulmak için global Bassel fonksiyonları ve harmonikleri kullanılmıştır. Deneyler sonucu yaygın kullanılan ve etki-tepki prensiplerine dayanan gauss radyal tabanı kullanılarak geliştirilmiş olan modellerden daha fazla verimli olduğu kanıtlanmıştır. RBNN (Radial Basis Neural Network – Radyal Tabanlı Yapay Sinir Ağları) biyolojide başarısını kanıtlamış sinir ağları modeli olurken MPNN modelleri moleküller grafiklerde başarısını kanıtlayarak RBNN modellerini geride bırakmıştır [48,49]. Moleküller grafikler arasında yaygınlaşan MPNN modelleri grafiklerin arasında mesafe ölçümü için de kullanılmaktadır. Mesafe ölçümünde modelleri zorlayan hesaplama karmaşıklığı, geometrik derin öğrenme yöntemleri ile ortadan kaldırılmaktadır. Bu verimi sağlayabilmek için ikiz sinir ağları olarak bilinen ve çıktıları karşılaştırabilir bir şekilde eşit seviye hesaplamaya dayalı SNN (Siamese Neural Network – Siyam Sinir Ağı) kullanılmaktadır [50]. MPNN'lerde bulunan bir başka durum ise

seyrek grafiklerde başarısını kanıtlamış olmasına rağmen karmaşık grafiklere olan uyarlamaları verimli fakat teoride sınırlı durumda olmasıdır. WL testi birçok modelde kullanıldığı gibi MPNN modellerinin bazlarında da kullanılmaktadır. Buradaki asıl amaç spektral alanda yerelleştirmektir. Kullanım sonucunda alt görev olarak tanımlanan görevlerde de başarı göstermektedir [51].

Grafiklerde sinir ağı tabanında geliştirilen modeller çoğunlukla bir sorun nedeniyle gelişime ihtiyaç duymaktadır. Geleneksel algoritmalar bu durumlar sırasında yetersiz olduğundan farklı kararlı modeller geliştirilmektedir. Bu algoritmaların birisi de otomatik, ölçeklenebilir ve etkili model olan ayrıca gömme temsili ile güncellemeler arasında sabitlik sağlayarak yansıtabilen SSE algoritmasıdır [52]. Veri setleri analizinde bulunan karmaşıklık, grafiklerde düzenleme ve sabit parametre sorunları SGD (Stochastic Gradient Descent – Stokastik Gradyan İnişi) algoritmalarıyla düzenlenmektedir. SGD tabanında geliştirilen SSE modelinde büyük ölçüde sinir ağı eğitimi için kullanılmıştır. Model ile SSE tabanlı iki faktör algoritma (SSE-Graph, SSE-SE) geliştirilmiş ayrıca grafik gömme kullanılarak ağırlık azaltma ile yüksek performansa ulaşması sağlanmıştır [53]. SSE algoritması ayrıca olay tahmini için de kullanılmaktadır. Olay tahmini genellikle mühendislikte ve karmaşık sistemlerin analizinde kullanılmaktadır. Model temelinde LSF (Limit-State Function – Limit Durum Fonksiyonu), SSE modeline uyarlayarak yeni modeli ortaya çıkarmıştır. SSER (Spectral

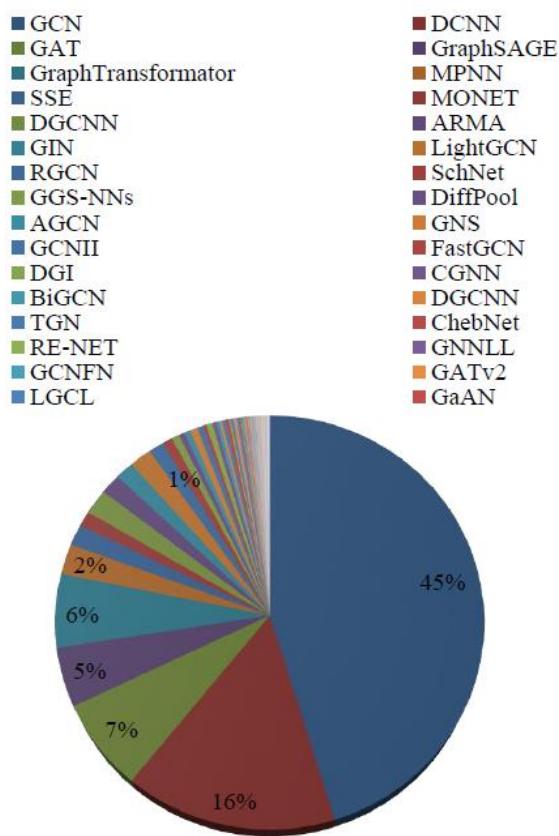
Embedding-Based Reliability – Stokastik Sprektral Tabanlı Güvenilirlik) modeli hata ihtimalini hesaplayarak eleme yöntemiyle çalışmaktadır [54].

GNN için 65 farklı model olsa da genellikle yaygın kullanım GCN, DCNN, GAT, GraphSAGE, GraphTransformer, SSE ve MoNet modellerinden oluşmaktadır. MoNet modeli, karışım modeli sinir ağı olarak tanımlanmaktadır. MoNet temelinde derin öğrenmeye dayanan bir algoritmadır. CNN modellerinde konuşma tanıma, dil işleme, bilgisayarlı görüş, akustik sinyaller ve görüntü analizi görevleri grafik ve öklid düzlemlerde karşılaştığı sorunlar sebebiyle geometrik derin öğrenme kavramını ortaya çıkarmıştır. Farklı modeller bu alan üzerine gerçekleşse de CNN temelinde GNN’ler geliştirilmiş ve bu modellere artan ilgi sayesinde hızlı bir gelişim göstermiştir [55]. Sinir ağları bu alanlar dışında gelecek tahmini, otonom sürüş, akıllı sistem güvenliği ve nokta bulutları gibi birçok alanda da kullanılmaktadır. Akıllı araç sistemlerinde 3B nokta bulutları bilgi modellemesi ve algılama gibi sebeplerden dolayı önem arz etmektedir. Düzensiz yapıları ve yapılandırılmamış olma sebeplerinden dolayı tahminlerde zorluk oluşturmaktadır. Bu zorluğa karşılık, hareket özelliği tanımı ve grafiksel hareket bilgisi tahminini yakalayacak bir model geliştirilmiştir. MoNet adı birçok farklı modelde CNN ve GNN temelinde geliştirilmiştir. Belirlenen iki özelliğinde zaman-uzay durumunu tahmin etmek için MotionRNN tekrarlayan sinir ağı geliştirilmiştir. MoNet algoritması bu sorumlara CNN ve RNN bağlantıları yardımı ile çözüm

bulmakta ayrıca dikkat tabanını da hareket katmanına yerleştirmektedir [56]. Aynı şekilde MoNet algoritmaları tespit işlemi için de kullanılmaktadır. Bir başka MoNet modeli çoklu görüntü akışı kullanarak yarı denetimli öğrenme modeli anahtar nokta detektörü olarak modellenmiştir. İnsan olmayan türlerde yani genelleştirilmiş konularda ve büyük nitelikli açıklama gereksinimi bulunan veriler düşünülerek işlenmiştir. Eğitim esnasında hesaplama sorunu, karmaşıklık ve örneklemeye uyuşmasını önemli ölçüde azaltmaktadır. Bu sayede modelin verimi artmaka ayrıca iki görünüm yöntem ile de karşılaştırma yapmaktadır. Model insan-köpek-maymun gibi farklı tür grafiklerde kilit noktalarını yerelleştirebilmektedir. Yarı denetimli model olan MoNet tarafından belirli sayıda etiketlenmiş ve farklı tür varlıkların kilit nokta tespiti yapılmıştır. Ayrıca modelde poz algılama kullanılarak 3 boyutlu yapılandırma revize edilebilmektedir [57]. Ayrıca Şekil 5'te grafik modeller ile ilgili yazılmış makalelerin yüzdelik dilimleri ve en fazla kullanılan modellerin grafiği görülmektedir.

Veri kümeleri modellerin denenmesi ve verimlerini göstermeleri için en önemli etmenlerden birisi olmuştur. Tablo 3'te en fazla kullanılan modellerin hangi veri setleri ile test edildiği gösterilmiştir. Tabloda gösterilen sekiz model dışında en fazla örnek veren modeller LightGCN, DGCNN, GIN, ARMA ve RGCN modelleri olmuştur. Modeller GCN tabanında geliştirilmiştir.

Makale Sayısı



Şekil 5: Yazılmış makale sayısı yüzdelik oranı. LightGCN modeli, GCN tabanlı olarak geliştirilmiş bir modeldir. GCN'ler sınıflandırma görevi için tasarlanmış olmalarına rağmen ritimsel bozukluk analizi yapamamaktadır. GCN'lerde özellik dönüşümü ve doğrusal olmayan etkinlik tasarımlarının ortak bir filtre ile birleştirilmesi sonucu yapılan deneylerle az da olsa verimin arttığı gözlemlenmiştir. Bu iki tasarımın dâhil olması verimi artırmışına rağmen eğitim zorluğu oluşturmaktadır. Bu zorluğun aşımı için LightGCN komşuluğu etken olarak kullanıcı-öğretim tabanında katmanlara yayılım yapmaktadır. Bunun sonucunda ağırlık toplamı kullanılır ve rasyonel analizler elde edilir. NGCF (Neural Graph Collaborative Filtering – Nöral Grafik İşbirlikçi Filtreleme) modeline göre daha fazla verim sergilemektedir [58].

UltraGCN ise LightGCN içerisinde bulunan mesaj geçiş katmanı sorununu katman atlaması ile basitleştirerek kenar ağırlığı atamaktadır. Bu sayede model kolay eğitilmekte ve verimi artmaktadır. LightGCN ile yapılan karşılaştırmasında 10 kat fazla verim ve hız elde etmiştir [59].

Tablo 3: Grafik modellerde yaygın kullanılan veri kümeleri ve modeller.

Veri Kümesi	G N	G C	D C	G A	G S	G T	M P	S N	M o s e t
	N	N	N	N	T	S	N	S	N
Pubmed	X	X		X	X		X		X
Reddit	X	X							
OGB	X	X		X	X				
PPI	X	X		X		X			
CORA	X	X		X	X		X		X
Nell	X	X							
ZINC	X	X		X	X	X	X		X
EgoGesture	X	X							
ImageNet	X	X					X		
PASCAL VOC	X	X	X						
COCO	X	X	X						
OHSUMED	X	X							
CIFAR 10	X			X	X				X
Flickr30k	X			X	X				
Citeeser	X				X		X		
Cluster	X					X			
Pattern	X					X			
OpenAI Gym	X					X			
Human3.6 M	X						X		
Faust	X							X	
MNIST	X							X	

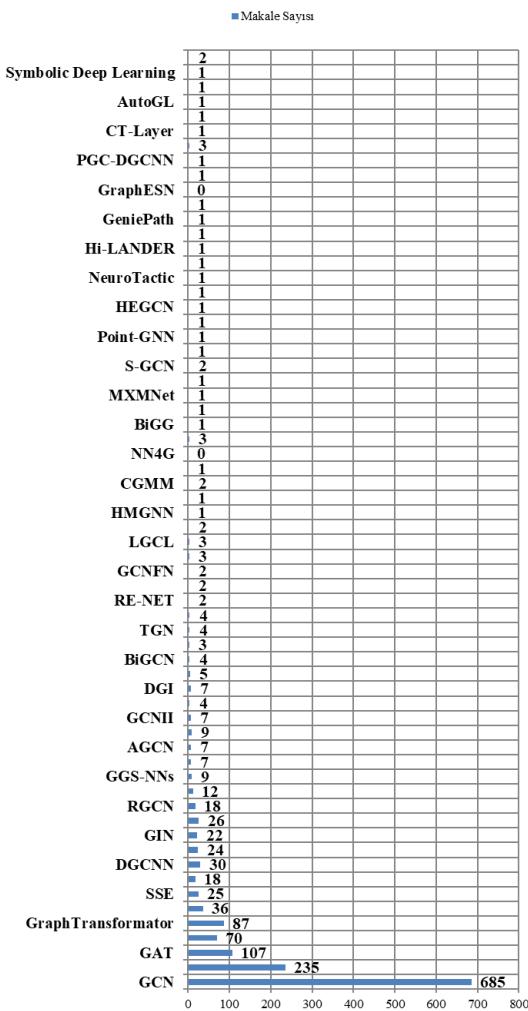
CNN'lerin kullanım alanlarından birisi de grafik benzerlik eşleme görevidir. Bu görev için GCN'ler geliştirilmiş ancak geliştirilen modeller düzenli verilere odaklanmış ve başarılarını burada yakalamıştır. Analiz esnasında sabit forma geçilmektedir ve bu geçiş sürecinde veriler düzensizleşebilmektedir. Bu soruna çözüm olarak DGCL (Disordered Graph

Convolutional Layer – Düzensiz Grafik Evrişim Katman) geliştirilmiş, Gauss modeli ile revize edilerek DGCNN (Disordered Graph Convolutional Neural Network – Düzensiz Grafik Evrişim Sinir Ağları) modellenmiştir [60]. DGCNN modeli, zengin bilgiyi karakterleştirerek faydalı özellik çıkarımı ve grafik anlam-tutarlılık okumasında zorluk yaşamaktadır. Bu zorluğun da aşılması için SortPooling katmanı tasarlanmış ve vektörel dönüşüm gereklilik kalmaksızın orijinal grafik eğitimi yapabilmektedir [61]. DGCNN modeli genişletilerek 3B nesne algı mimarisini ile nesneyi tahmin etme görevinde kullanılmıştır. Model otonom güvenlik konusunda yüksek verim elde etmektedir [62].

Grafik İzomorfizm ağları, WL testini genelleştirerek modellerde ayırt edici gücünü artırmaktadır. Modelin amacı grafik ve düğüm sınıflandırma görevlerini verimli bir şekilde yerine getirebilmektir [33]. GNN modelleri sağlık alanında da farklı alanlarda kullanılmaktadır. Son yıllarda farklı modeller geliştirilmiş bu modellerden birisi de fMRI (Functional Magnetic Resonance Imaging – Fonksiyonel Manyetik Rezonans Görüntü) verileri üzerine olmuştur. Komşuluk matrisini kullanarak kaydırma yapılması ile ikili analiz yöntemi kullanılmaktadır. İkili analiz sayesinde görselleştirme yapılmaktadır ve model beyinin görselleştirme deneylerinde verim elde edebilmektedir [63]. GNN'ler genellikle spektral polinom filtrelere dayanmaktadır. Frekans tepkisi, küresel yapı yakalama ve gürültü dayanıklılığı sağlayan ayrıca esnek bir filtre olan ARMA, eğitim için verimli ve özyineleme sayesinde dağınık formüle sahiptir.

Grafik regresyonu, yarı denetimli sınıflandırma, grafik sinyal sınıflandırma ve grafik sınıflandırma görevlerinde kullanılan ARMA, verimli bir katman olarak kullanımı yaygınlaşmaktadır [64]. ARMA aynı zamanda bilgi önem düzeyinin yüksek olduğu görevler için de modellenmiştir. Çıkış bilgilerinin tüm girdileri kapsamasıyla kendisini eğitebilmekte ve evrişime indirgemektedir [65]. RGCN, bilgi grafiklerinin bilgi okuma ve yanıt arama amaçlı geliştirilmiş GNN modelidir. Bu görevler neticesinde eksik bilgilerin kurtarılmasını sağlayan bağlantı tahmini yapabilmekte ayrıca eksik nitelikleri kurtararak bilgi alışını sağlayan varlık sınıflandırması görevlerini başarıyla tamamlamaktadır. RGCN modeli gerçekSEL bilgi veri tabanı deneylerinde başarı elde etmiş ve tahmin-sınıflandırma için bağımsız bir model olduğunu kanıtlamıştır [66]. Model diğer modellerde de sıkça karşılaşıldığı üzere araştırmacılar tarafından güncellenerek düğüm sınıflandırma görevi için yeniden modellenmiştir. Test süresince kıyaslamalı bilgi grafikleri kullanılarak modelin veriminin yüksek olduğu hesaplanmıştır. İlişkisel veri tahmini ve modellemesi yapabilen RGCN, özne-nesne-ilişki arasındaki bağlantıyı başarılı bir şekilde kurabilmektedir [67].

Bu çalışma kapsamında en fazla makale yazılan modeller incelenerek karşılaştırılmıştır. Toplam 65 ana model arasından yaygın kullanılan 11 model detaylı olarak ele alınmıştır. Şekil 6'da yazılan makalelerin adet grafiği görülmekte ayrıca tüm modeller en az bir kaynak çalışma ile elde edilmiştir.



Şekil 6: Makale sayısı.

Grafik modeller içinde 51 farklı model daha bulunmaktadır. İlk incelenen SchNet modeli kesin konum ayırması sonrası bilgi kaybı sorununa geliştirilmiş filtreli bir evrişim katmanıdır. Kuantum ve moleküler grafikler üzerinde düğüm arası kuvvet ile toplam enerji ortak modeli oluşturulmuştur [68]. Grafik modeller girdi öznitelik öğrenmesi üzerinde de çalışmaktadır. Optimizasyon gereksinimi ve kapsamlı teknik katmanlarının verimi artırma düşüncesi ile GGS-NN modeli ortaya çıkmıştır. Grafik tabanlı işlemlerde dizi tabanına sahip olan LSTM modelleri gibi modellere göre daha kapsamlı bir model olmuştur [69]. Grafik yapılarındaki boyutsal-bağlantısal farklılıklar

ve karmaşıklıklar yeni modellerin gelişmesine ilham olan bir sorun olmuştur. Rastgele grafiklerde genelleştirme ve esneklik sağlayan AGCN modeli, metrik öğrenme ile grafiği verimli bir şekilde öğrenebilmiştir. Model eğitim sırasında görev odaklı ve uyarlanabilir model olduğu için bu ismi almıştır [70]. GNN modellerinin hiyerarşik temsilleri öğrenememe sorunu tahmin ve sınıflandırma görevleri için sorun teşkil etmekte ve sınırlandırmaktadır. Bu sebeple havuz modülü olarak DiffPool geliştirilmiştir. Diffpool, katmanlarda bulunan düğümleri türevlemeye yarayan bir eğitim ile öğrenmesini gerçekleştirir. Eğitim sonucunda eşleme ve girişi oluşturabilme yeteneğini kazanmaktadır. Model deneyler ile birlikte %5-%10 arası iyileştirme sağladığı gözlemlenmiştir [71]. Bir başka deneyde ise DiffPool modelinin popular sınıflandırma doğruluğu dikkat çekmiş ve GCN, TAGCN ve GraphSAGE modelleri ile karşılaştırılmıştır. TAGCN (Topology Adaptive Graph Convolutional Network – Topoloji Uyarlanabilir Grafik Evrişimsel Ağ) modelinin diğer iki modele göre daha fazla verim elde ettiği gözlemlenmiştir [72]. Mühendislik ve doğa bilimleri alanlarında malzeme tahmini önemli bir görev olarak kullanılmaktadır. Kristal grafiklerde karmaşık görünüm sebebiyle gerçekleşen zorluk uzay-bilgi dengelemesi ile tahminini başarılı bir şekilde gerçekleştirmiştir. Araştırma neticesinde bağ mesafesi kullanmayan modelin daha verimli olduğu gözlemlenmiş ve CGNN’ler (Cyrystal) toplu özellik tahmini ile kendini öne çıkarmıştır. Model iki farklı sınıflandırma kullanmış, sınıflandırmanın merkezine ise bant boşluğu-manyetizma

bilgisini koymaktadır. Araştırmalar sonucunda taramadan yüksek verim sağlanmış Ayrıca veri madenciliği kavramlarına da atıfta bulunulmuştur [73]. Katman boşluklarında bulunan boşluklar analizi etkilemeye ve bu etkiyi en az seviyeye indirmek için DCGAN (Deep Convolutional Generative Adversarial Network – Derin Evrişimli Üretken Düşman Ağı) geliştirilmiş fakat modelin kendini sürekli yenileyebilmesi için revize edilerek CGNN (Continuously Generative Neural Networks – Sürekli Üretken Sinir Ağları) modelleri geliştirilmiştir. Model ters problemlere odaklanmakta ve kararlılık tahmini üretmektedir. Simülasyon için de kullanılan model görüntü bulanıklaştırma konusunda başarısını kanıtlamıştır [74]. GNN’lerin düğüm topoloji ve düğüme özgü ayrımlarda sorunlar yaşadığı bilinmekte ayrıca bu sorun üzerine de birçok model geliştirilmektedir. Bu modellerden biri de CGNN (Curvature Graph Neural Network – Eğrilik Grafiği Sinir Ağı) modelidir. Model grafik içerisinde bulunan eğriliklerden yararlanarak GNN’ye uyarlanabilmektedir. Negatif eğrilik işleme modülü ve eğrilik normalleştirme modülü kullanılarak komşu düğüm ağırlığı elde edilmektedir. Deneyler sentetik ve reel dünya verileri üzerinde gerçekleştirilmiştir. Modelin en önemli özelliği ise topoloji kullanımının derinleştirilmesi ve eğrilik ile komşu düğüm önemini göstermesidir [75]. Simüle sistemler GNN modellerinde inceleme konusu olan görevlerden birisi olmuştur. Bu görev üzerine geliştirilen modellerden birisi olan GNS (Graphics Network Based Simulators – Grafik Ağı Tabanlı Simülatörler) modeli genellikle

fiziksel sistemleri simüle etmek için kullanılmaktadır. Çalışması ise düğümler fiziksel sistemi temsil ederken öğrenilen mesaj geçişi sayesinde dinamik hesaplanmaktadır [76]. GCN modelleri sadece GNN için değil sinir ağları modelleri arasında da en çok incelenen modellerden birisi olmaktadır. Fakat bilinen GCN modelleri her ne kadar derin olsa da yumuşatma sorunu sebebiyle derinliğe karşılık sıç kalmaktadır. Bu soruna karşılık GCNII modeli geliştirilmiştir. Model her ne kadar GCN tabanında geliştirilmiş olsa da ayrı bir model olarak kabul edilmekte ve yüksek verimi ile başarısını göstermektedir [77]. CNN modellerinden türetilen bir diğer model ise ChebNet'tir. Sayısal grafik ve matematiksel tanımlamaları sayesinde evrişimli ve hızlı filtreler tasarlayabilmektedir. Yaygın kullanım alanları; görüntü–konuşma-video temsili, sosyal ağı, beyin bağlaçları ve metin gömme alanları olmaktadır [78]. GCN modelleri eğitim ve test verileri üzerinden öğrenme gerçekleştirmektedir. Bu durum büyük ve karmaşık veriler için öğrenme zorluğu oluşturmaktadır. Zorluğu ortadan kaldırmak için kullanılan integral dönüşümleri sayesinde, eğitim için verim arttılmıştır. İntegral dönüşümlerinin çok sayıda tekrar eden rastgele örneklemelere karşılık nümerik sonuçlar elde edilen Monte Carlo yaklaşımı kullanılması çıkarımlarda da genelleme yeteneğini artırmaktadır [79]. Denetimsiz öğrenme ile düğüm temsillerinin kullanımı için geliştirilen DGI, yerleşik evrişim kullanarak karşılıklı bilgiyi ve üretilen temsilleri üst seviyeye çıkarmaktadır. Yama temsili özetleme ve alt düğümler için öğrenim görevlerini

tekrarlamasıyla verim elde etmektedir. DGI modelinin en önemli özelliği ise dönüştürücütümevarımsal öğrenmenin uyarlanabilirliğidir [80]. GCN'lerde sinyaller çoğunlukla düşük geçişli filtreler ile tasarılmaktadır. Bunun başlıca sebebi hesaplama maliyetinin düşmesi ve verimin arttırılmasıdır. BIGCN modelinde ise çift yönlü filtreler ile de verim alınabileceği ortaya atılmıştır. İki yönlüfiltreleme dayanan model, orijinal grafik ile birlikte gizli özelliklerin bağlantı grafik sinyallerini de filtreleyebilme yeteneğine sahiptir. Modeli öne çikaran özellik ise karşılaştırmada aldığı verimi dışında güçlü gürültü önleme yeteneğine sahip olmasıdır [81]. Derin öğrenme, GNN modelleri için ana çalışma konularından birisi olmasına rağmen zamansal özellik gelişimi konusunda çok sayıda çalışma bulunmamaktadır. Bu durum araştırmacıların dikkatini çekerek dinamik grafiklerin temelinde zamansal olay dizilerini temsil eden bir öğrenme modeli geliştirilmiştir. TGN grafik vektörü ve bellek modülü sayesinde eş zamanda hesaplamalarda verimli bir sonuç çıkarmaktadır [82]. Görevlerin zamanlarla ilişkilendirilmesi zamanbilgi grafiği için bir sorun haline gelmektedir. Modellerin çoğu geçmişe dayalı tahmin kullanırken gelecek durumlar için yapamamaktadır. Gelecek tahmini için geliştirilen RE-NET, zaman-bilgi grafiklerinin geçmiş durumlarını analiz ederek olasılık dağılımlarını hesaplamaktadır. Çalışmasında tekrar eden olay kodlayıcı kullanırken modelleme için de komşu bilgisi toplama kullanılmaktadır [83]. Grafik modellerin bir diğer kullanım alanı teyit ve tespit işlemidir. Sosyal medya platformlarının gelişimi ve

kullanımının yaygınlaşması neticesinde teyit edilmiş bilginin ve sahte haber tespitinin önemi artmıştır. Yayılım odaklı sahte bilgi tespitine karşılık GNN kullanımını, metin bilgisine ihtiyaç duyulmadan GNN doğruluğu ne kadar kabul edilir ve yeni oluşturulan ya da gizli veriler ile nasıl analiz yapılır düşüncesi ile ortaya çıkmıştır. Makine öğrenimi modelleri saldırılara karşı tam savunma gösterememesi sebebiyle sahte haber kaynağının oluşturacağı etmenlere karşı duyarlılığı düşük olacaktır. Eğitilmiş sistemlerde ise yeni ya da gizli veriler beklenen verimi sağlayamazsa bu duruma karşılık yeniden eğitilmesi gerekecektir. Tüm süreç düşünüldüğünde uzun bir süreç gerçekleşeceği için bir model geliştirilme ihtiyacı duyulmuştur. Geliştirilen modele GNNCL adı verilmiş ve metin bilgisi olmadığı süreçler için de verimli olduğu gösterilmiştir. Model de cevaplanamayan diğer sorun olan farklı veri kümesi eğitimi ise deneyler sonucu beklenildiği gibi düşük performans göstermiş fakat denge konumuna getirilmiştir [84]. Sahte haber tespiti modellerde başarı yakalaması ve yaygınlaşması ile farklı modellere konu olmuş sadece sahte haber tespiti yapılan ve GCNFN adında bir model bile geliştirilmiştir. Modelde yayılım tabanlı modül kullanılarak içerik kıyaslama, bağımsız dil ve saldırılara karşı direnç yetenekleri kazandırılmıştır. Geometrik derin öğrenme kullanımını sayesinde profil, etkinlik, yayılım ve sosyal grafik gibi heterojen grafiklerin anlaşılması sağlanmıştır. Twitter üzerinde yapılan testler neticesinde model stratejik olarak da başarısını göstermiştir [85]. Tahmin görevler her geçen gün kendisini genişletmekte ve yeni modellere fırsat

sunmaktadır. Tahmin görevleri genellikle sayılabilir özellik uzayı ile eş biçimlilik görevlerine odaklanmaktadır. Odak noktasına gerçek dünya girdileri ve gizli katman sürekli özelliklerinde eklenmesiyle birden çok toplayıcı genelleştiren PNA modeli geliştirilmiştir. PNA çoklu toplama ile birden fazla görevi gerçek dünya girdileri ile analiz ederek işlem yapmaktadır [86]. Karşılaştırma yapımı grafik modeller arasında görevlerde yaygın olarak kullanılmaktadır. Dil işleme ve bilgisayarlı görü kullanarak ağ topolojik özelliklerini kendi kendine denetleme ile modellemektedir. GCC (Grafik Kontrastlı Kodlama – Graph Contrastive Coding) olarak adlandırılan model ağ içi ve alt grafik örneği olarak içsel ve aktarılabilir yapısallığı ile karşıt öğrenme kullanmaktadır [87]. Model aynı zamanda sonraki yıllarda revize edilerek grafik tabanlı anomali tespiti için kullanılmaktadır. GCCAD (Graph Contrastive Coding Anomaly Detection – Grafik Kontrastlı Kodlama Anomali Algılaması) modeli grafik kontrastlı kodlama kullanarak tüm düğüm ortalamasını denetimli olarak gerçekleştirmektedir. Düşük etiket sayısı ve düğüm etiketi oluşturma için kendi kendini denetleme yeteneği de modele eklenmiştir. Karşı hedefe ulaşım, şüpheli bağlantıları kaldırma ve grafik bağlamı öğrenme ile verimli bir hale getirilmiştir [88]. Komşu grafiklerin sabit olmaması ve genelleştirilememesi evrişim işlemlerini engellemektedir. Bu sorunu aşmak için geliştirilen LGCL modeli dönüşüm için değerler sıralamasında her bir özellik için sabit sayıda komşu düğüm seçimini otomatik olarak gerçekleştirmektedir. Bu işlem sayesinde

evrişim işlemleri kullanılabilmektedir. Büyük ölçekli grafiklerde ise alt grafik eğitimi ile hesaplama ve bellek azaltılmakta bu sayede de verim artmaktadır [89]. Verilerin kullanımı ve anlamsal olarak çıkarımın daha basit şekilde yapılabilmesi için birleştirme yapılmaktadır. Yapılandırılmış verileri kodlayarak öğrenme sürecini gerçekleştiren ve olasılıksal model katmanları ile derin bir mimari oluşturan CGMM kenarlar ile tepe noktaları boyutunda ölçekli ve verimli bir şekilde dağılmıştır. Grafik kodlaması karşılaştırma yapabilmek için ayırmalı modeller ile kullanılmaktadır [90]. Grafik dikkat ağları grafik üzerinde öğrenme gerçekleştirmeye ve dikkat katmanlarının performansını artırma için geliştirilmiştir. Modellerinde genellikle çok başlıklı dikkat mekanizması bulunurken büyük grafiklerde bu hesaplama maliyetini artırmaktadır. Bu sorunu çözmek için evrişimli alt ağ kullanan ve her dikkat başlığının önemini kontrol eden GaAN modeli geliştirilmiştir. GaAN, tümevarımsal düğüm sınıflandırma için kullanılırken trafik tahmini gerçekleştirmek için de GGRU (Graph Gated Recurrent Unit – Grafik Kapılı Tekrarlayan Birimi) kullanmaktadır. Yapılan deneyler sonucunda verimli bir performans sergilemiştir [91]. Tümevarımsal yöntemler ile öğrenme gerçekleştiren modeller sembol temsili için de kullanılmaktadır. Eğitim ilk başta seyrek temsilleri öğrenirken bir sonraki aşamada açık ilişkiler için sembolik temsil uygulanmaktadır. Model kozmik yapılarda konsantrasyon tahmini ile analitik formül keşfeder. Çıkarılan veriler ile sinir ağlarının keşfi basitleşmekte ve sembolik öğrenme genelleştirilmektedir. Model, SDL (Symbolic

Deep Learning – Sembolik Derin Öğrenme) adıyla anılmaktadır [92]. Molekül analizlerin GNN'lerin başlıca önem gerektiren görevlerinden birisi olduğu bilinmektedir. Heterojen molekül kullanımı ve analizi kuantum özellik tahmini için zor bir görev olsa da alan öznelinde modeller geliştirilmektedir. Geliştirilen modellerden biri olan HMGNN, çok kenar ve cisim etkileşimlere dikkat etmektedir. Karmaşık grafiklerde kimya problemleri için eğitim sırasında edinilen bilgilerden yararlanmakta ayrıca sınırsız mesaj geçisi de yapılmaktadır [93]. Moleküller grafiklerde bir başka tahmin de fizikokimyasal özellikler üzerindedir. Geliştirilen model iki katmanlı olmakla birlikte ilk katman kovalent etkileşimlerle çalışırken diğer katman ise küresel bağlantılar ile çalışmaktadır. Anlam gücü ve hesaplama sorununu aşma ve denge sağlama amacıyla mesaj iletim modeli oluşturulmuştur. Geliştirilen modele MXMNet adı verilmiştir [94]. Yoğunluk ve büyülüklük GNN'ler için çözülmesi gereken bir sorun olmaktadır. Bu soruna çözüm için geliştirilen modellerden biri olan PinvGCN, üç takımlı filtrelerle yoğun grafiklere odaklanmaktadır. Model sorunun çözümü için Laplacian grafiklerini kullanmakta ve asıl kullanımını Laplacian tersi ile gerçekleştirilmektedir. Uygun parametre seçimi ile verim artırılmış ayrıca gerçek dünya veri setleri ile yapılan deneylerde başarılı olmuştur [95]. Moleküller grafikler üzerinde geliştirilen bir diğer model olan S-GCN modeli protein işlemede kullanılmaktadır. Protein içerisinde bulunan aminoasitleri yerel koordinatları ile ilişkilendirerek düğümler arasında açısal

bilgilerle küresel filtreler oluşturmaktadır. Model CASP (Critical Assessment of Structure Prediction – Yapı Tahmininin Kritik Değerlendirmesi) ile değerlendirilmiş ve rekabetçi bir tutum sergilemiştir [96]. Bir diğer model GAT üzerinden gelişim gösteren GATv2 operatördür. Statik dikkat problemine odaklanarak çözüm gerçekleştirmekte ve düğümler sıralanarak analiz gerçekleştirmektedir [97]. Sınıflandırma görevleri GNN’lerin başlıca görevlerinden birisi olmuştur. Anlamsal bakımından yorumlanabilirlik sınıflandırma görevlerini kolaylaştırmakta ve verimini artırmaktadır. TaksoExpan modeli, web içerikleri içinde kendi kendini denetlemeye dayalı geliştirilmiş tahmin ve sınıflandırma modelidir. TaksoExpan modeli yerel yapı kodlaması ile iyileştirilmiş konumlu GNN geliştirilmekte ayrıca modelin öğrenilmesiyle gürültüye dayanaklı eğitim içerişi etiket gürültüleri ile kendi kendine denetleme yapabilmektedir [98]. Nesne algılama için geliştirilen Point-GNN modeli her düğüm ve köşe için nesne kategorisi ve şekil tahmini gerçekleştirmektedir. Model kutu birleştirme ve puanlama işlemi ile 3 boyutlu nesne algılama için verimli bir potansiyel sergilemiştir [99]. Grafik modeller, hata tespiti, kod tamamlama ve program tamiri gibi yazılımsal konularda da görevleri yerine getirmektedir. Kontrol mekanizması ile görevleri tamamlarken akıl yürütme programlarında uygun değildir. Tekrarlayan sinir ağları ise akıl yürütme için uygundur fakat program yapısı içermemesi sebebiyle verim elde edememektedir. IPA-GNN modeli kontrol grafikleri ile program yönetimini öğrenme görevi için genelleştirilmiş

bir modeldir. RNN modeli gevşemesi ya da uygulama için uyumlanmış GNN alt türü olarak görülebilir [100]. Seyrek grafikler için geliştirilen gözlemsel model BIGG grafik üretici bir modeldir. Temel bilimler alanlarında yaygın kullanılan grafik oluşturma görevi, derin öğrenme yöntemlerinin ölçeklenmesinden dolayı sınırlı bir alana sahip olmuştur. BIGG tam bitişiklik matrisi oluşturmamak için seyreklikten faydalananmaktadır ve bu durum zaman karmaşasını azaltır [101]. Bir başka görev olan ilişki analizi, uzaktan denetlemede cümle çıkarımı yapmayı odak haline getirmiştir ancak bu durum kapsam bakımında çok az ilişki ile sınırlı kalmaktadır. HEGCN belgeler için çok bölümlü ilişki analizi için geliştirilmiş bir modeldir. Belgeler BiLSTM (Bi-Directional Long Short-Term Memory – Çift Yönlü Uzun Kısa Süreli Bellek) katmanı ile kodlanmakta, katman üstü hiyerarşi için ise GCN kullanılmaktadır [102]. GCN modelleri farklı görevler için uyarlanarak yeni modellerin doğusuna fırsat vermektedir. Bu modellerden biri de AdaGPR modelidir. Model GCNII modelinin uyarlanması ile geliştirilmiştir. Temelde GCNII modelinin Pagerank öğrenimi için genelleme sınırı ve katsayı sırası ile sınırlanırmıştır olusturulan model sınır analizi ile aşırı yumusatma yapmaktadır. Bu sayede komşuluk derecesi yüksek evrişimlerde model derinliğinin önemini göstermektedir [103]. Tahmin görevlerinin GNN modeller arasında büyük bir önem arz ettiği bilinmektedir. Tahmin türlerinden birisi de taktik tahmidir. Geliştirilen modeller derin sinir ağı ile donatılarak insan uzman gibi uzman ve ayrıntılı talimatların zorluğu ortadan

kaldırmaktadır. Geliştirilen modellerden biri olan NeuroTactic ise teorik ve temsil için GNN'lerden yararlanmaktadır. İlk tasarım görevi öncü seçimi ve grafik karşılaştırma olan model eğitim sonrası akış görevi ve taktiksel tahmin için kullanılmaya başlanmıştır [104]. Tahmin için geliştirilen bir diğer model ise GAGNN modelidir. Model temelde ülkesel alan içerisinde hava kalitesi tahmin görevi için geliştirilmiş aşamalı bir modeldir. Model çalışma mantığında bölgelerel grafikler ile gizli ve konum modelleme gerçekleştirir. Bölgeler arası fark olabileceği için gruplandırma işlemi ile bu sorunu ortadan kaldırın model mesaj geçiş mekanizması kullanımı ile bağımlılıkları modeller. Yapılan deneyler Çin üzerinde denenmiş ve modelin iyi bir performans gerçekleştirdiği belirtilmiştir [105]. Simülasyon uygulamaları da grafik modeller için ilgi çekici konulardan birisi olmuştur. Geliştirilen modellerden biri olan MeshGraphNet ağ tabanlı simülasyon öğrenimi çerçevesi olarak geliştirilmiştir. MeshGraphNet, ağ grafikleri ile mesaj传递 ve simülasyon esnasında ağ ayıklama için eğitilebilir bir modeldir. Tek yön denetim kullanırken kodlama-istem-cozme mimari modelini kullanmaktadır [106]. Kümeleme işlemleri için geliştirilen Hi-Lander, aşamalı bir GNN modelidir. Tahmin yeteneğini kullanarak grafik oluşturma işlemlerinde bağlantıları birleştirmektedir. Denetimsiz kümelenmeden farklı ise eğitimde denetimli öğrenme kullanmasıdır [107]. Grafiklerin zorluğu arttıkça GNN modellerine de ilgi artışı aynı seviyede olmuştur. Spektral grafiklerin evrişim öğrenimi geliştirilen CayleyNets modeli bu duruma örnektir. Frekans bantları

üzerinde uzmanlaşan eğitimi sayesinde filtreleri verimli bir şekilde hesaplamaktadır. Cayley polinomları sayesinde seyrek grafiklerde veri boyutuyla ölçeklenebilir ve zengin yönlü spektral filtreler üretmektedir [108]. Uyarlanabilirlik ile değişmez grafiksel verilerde alan öğrenimi gerçekleştirebilmesi için geliştirilen GeniePath, önem öğrenmesi, filtreleme ve ayıklama işlemi gerçekleştirmektedir [109]. Cluster-GCN modeli de kümelenmeden yararlanarak geliştirilmiş GCN türevi modeldir. Kümelenme dışında bağlantı tahmini ve düğüm sınıflandırma görevleri için de kullanılan verimli bir performans elde etmiştir [4]. GCN türevi bir başka model olan StoGCN ise, komşu boyut örneklemesi izni ile çalışan bir algoritmadır [79]. NN4G modeli ise grafikler için geliştirilmiş sinir ağlarındandır. İleri besleme ile geri beslemenin olmadığı nöronları kullanarak farklı grafik türlerinde etkin bir şekilde çalışmaktadır. Model konum bilgilerinden yararlanarak aşamalı biçimde grafik topolojisinde etkinliğini göstermektedir [110]. Evrişim filtreleri modelleme ve analiz için sinir ağlarında önemli bir yer edinmektedir. PGC-DGCNN modeli GNN'ler öznelinde kullanılan filtreyi genelleştirerek komşu mesafesini hesaplayarak filtreyi zenginleştirir. Bu sayede modeller içerisinde verim artacak ve etkisi görülecektir [111]. Eğitim için geliştirilen modellerden birisi de MinCut Pooling modelidir. Düğüm-küme eşlemesi gerçekleştiren havuzlama operatörü olarak bilinmektedir. Sınıflandırma ve kümeleme için verimli bir model olan MinCut, denetimli ve denetimsiz görevlerde de başarısını göstermiştir

[112]. ESN (Echo State Network – Yankı Durum Ağı) modelinin grafikler üzerinde genellenmesiyle ortaya çıkan GraphESN, farklı tür grafiklere karşı genişletilmiş RecNN (Recursive Neural Networks – Özyinelemeli Sinir Ağları) modeli üzerinde verimli bir yaklaşım gerçekleştirmektedir. İleri besleme okuma kullanan GraphESN, uyarlanabilirlik özelliği sayesinde doğrusal çıktılar vermektedir [113]. İncelenen son model olan DualGCN modeli de GCN temelinde geliştirilmiş modellerden birisidir. Model en-boy üzerinde duyu analizi gerçekleştirmek için modellenmiştir. Model temelinde bağımlılık ağaçlarına dayanmaktadır. Bağımlılık ağaçlarında ayrıştırma sorunları sonuç hatası, gayri resmi ifadeler, karmaşıklık) nedeniyle sınırlılık getirmektedir. SnGCN modülü ile ayrıştırma hatalarının yanlışlık oranını azaltmak planlanırken SemGCN modülü ile de dikkat mekanizması yardımıyla anlamsal çıkarımlar yapılmaktadır. Deneyler sonucunda üstün performans gösteren model, ortogonal ve diferansiyel düzenleyiciler sayesinde de öğrenme gerçekleştirmektedir [114].

2.1 Grafik Sinir Ağlarının Limitleri

GNN’ler, farklı modellerden oluşan grafik sinir ağları ailesine mensup bir yapıdır. CNN modellerinin 3D veriler üzerinde etkili olamaması sebebiyle ortaya çıkmıştır. Modeller kendilerine özgü olmalarına rağmen ortak özellikler barındırmaktadır. GNN’lerin temel özellikleri Tablo 4’te görülmektedir [115].

Tablo 4: Grafik sinir ağlarının özellikleri.

Giriş Verileri	Dügümlerin ve kenarların sırasıyla varlıklarını ve ilişkilerini temsil ettiği, sosyal ağlar, moleküler grafikler vb. gibi grafik yapılı veriler.
Veri Gösterimi	Dügümlerin ve kenarların sırasıyla varlıklarını ve ilişkilerini temsil ettiği, sosyal ağlar, moleküler grafikler vb. gibi grafik yapılı veriler.
Topoloji İşleme	Dinamik grafik topolojilerini modelleyebilir ve grafik yapısındaki değişikliklere uyum sağlayabilir.
Komşuluk Toplama	Mesaj geçiş veya grafik konvolusyon işlemleri yoluyla komşu düğümlerden/kenarlardan özellikler toplar.
Özellik Öğrenme	Dügümlerin ve kenarların temsillerini grafik yapısına ve düğüm/kenar özniteliklerine dayalı özellikler olarak öğrenir.
Ölçeklenebilirlik	Dinamik çizge yapıları ve mesaj geçirme işlemleriyle başa çıkma ihtiyacı nedeniyle ölçeklenebilirlik sorunları ile karşı karşıya kalabılır.
Yorumlanabilirlik	Cizge yapısına dayalı olarak düğüm ve kenar özelliklerinin yorumlanabilir gösterimlerini sağlayabilir.
Uygulama	Sosyal ağ analizi, ilaç keşfi, tavsiye sistemleri gibi çizge yapılı veriler üzerindeki görevler için çok uygundur.

GNN özellikleri gibi benzer şekilde avantaj, dezavantaj ve kısıtlara sahiptir. GNN modelleri grafik verilerinde varlık ilişkileri bulabilirler ve veri işleme gerçekleştirirler. Düğüm, kenar ve komşulardan oluşması sebebiyle sınıflandırma bilgileri düğüm ve kenar öğrenme ile gerçekleştirilmektedir. Bu sayede eğitim sırasında işlenmemiş düğümlere genelleme yapabilmekte ve yarı denetimli öğrenmelerini geliştirebilmektedir. Komşulardan öğrendikleri bilgiler ile çoklu ilişkileri başarı ile yakalayarak sınıflandırmalı öğrenmeye olanak tanımaktadır. Öğrenme denetimli – denetimsiz olarak algılansa da yapı ve giriş özellikleri ile düğüm ve kenarlardan özellik öğrenme işlemini gerçekleştirebilmektedir. Model geliştirilmesi esnasında katmanların esnekliği sayesinde ön bilgi ile performans artırılabilmektedir [115-116].

118]. Tablo 5'te en yaygın sekiz modelin başarı gösterdiği alanlar sıralanmıştır.

Tablo 5: Grafik modellerin kullanım alanları.

GCN	Düğüm Sınıflandırması, Genel Sınıflandırma, Grafik Öğrenme, Grafik Sınıflandırma, Eylem Tanıma, Bağlantı Tahmini, İskelet Tabanlı Eylem Tanıma, Öneri Sistemleri, Grafik Gömme
DCNN	Genel Sınıflandırma, Semantik Segmentasyon, Görüntü Sınıflandırma, Nesne Tanıma, Nesne Algılama, Bilgisayarlı Tomografi (BT), Yüz Tanıma, Tümör Segmentasyonu
GAT	Grafik Dikkat, Düğüm Sınıflandırma, Grafik Öğrenme, Bağlantı Tahmini, Grafik Sınıflandırma, Genel Sınıflandırma, Bilgi Grafikleri, Grafik Temsil Öğrenme, Öneri Sistemleri
Graph Transformer	Düğüm Sınıflandırması, Grafik Sınıflandırması, Grafik Temsil Öğrenme, İlaç Keşfi, Bilgi Grafikleri, Bağlantı Tahmini, İlişki Çıkarımı, İlişki Sınıflandırması
GraphSAGE	Düğüm Sınıflandırması, Düşman Savunması, Grafik Bölme, Grafik Dikkat, Grafik Madenciliği, Grafik Öğrenme, İzinsiz Giriş Tespit, Öneri Sistemleri, Sahte Haber Algılama, Veri Depolama
MPNN	Oluşum Enerjisi, Düğüm Sınıflandırması, Grafik Sınıflandırması, Moleküler Özellik Tahmini, İlaç Keşfi, Grafik Regresyon, Grafik Temsil Öğrenme, Bulanıklaştırma, Grafik Özellik Tahmini
SSE	Derecelendirmeyi Öğrenme, Atama, Açıklama Üretimi, Aktif Öğrenme, Zaman Serisi, Borsa Tahmini, Çok Aracılı Güçlendirme Öğrenimi, Duygu Analizi, Ortak Filtreleme
MoNet	Optik Akış Tahmini, Görüntü Oluşturma, Nesne Keşfi, Denetimsiz Nesne Segmentasyonu, Eylem Birimi Algılama, Yüz Hareketi Birimi Algılama, Çok Görevli Öğrenme, Kalabalık Sayma

Birçok farklı alanda uygulanması popülerlik sağlarken yeni çalışmalara yol gösterebilmektedir. Bu durum hem belirtilen avantajları sağlarken hem de dezavantaj ve limitleri oluşturmaktadır. Tablo 5'te görülen bu sekiz model bu alanlarda başarı iken kullanıldıkları diğer alanlarda başarı ölçütleri bu alanlara kıyasla daha düşüktür. Günümüzde tüm GNN modelleri için bu durum geçerlidir. GNN modelleri genellemede komşuluk bilgileri

kullanarak işlenmektedir. Komşuluklar arası seyrek bağlantılar öğrenmeyi güçlendirmektedir. Bu durum sınırlı genellemeye olarak adlandırılmaktadır. Gerçek dünya uygulamalarında sık karşılaşılan bir durum olan esneklik ve karmaşıklık GNN modelleri için hem dezavantaj hem de kısıt oluşturmaktadır. Çoklu katmanların düğümlere olan etkisi sebebiyle GNN modelleri düğüm özelliklerini karıştırabilir ve bu durum düğüm ile kenarların öznitelik verilerinin kaybına yol açar. Özellikle büyük grafiklerde bu duruma ek olarak ölçekleme zorlaşır ve maliyet ile bellek kullanımını artırmaktadır. Bu durum performansa olumsuz etki etmektedir. Ek olarak bu hususlar göz önüne alınınca dikkat içermesi gereken özellik mühendisliği gerektirmektedir. Homojen veriler üzerinde yüksek etki sağlasa da bu hususlar heterojen verilerde zorluk oluşturmaktadır. Grafik yapısı sebebiyle de yorumlama etkisi azalmaktadır. Tablo 6'da GNN avantaj-dezavantaj-limit gösterildiği gibi sadece heterojen grafiklerde değil, yapısında birden fazla farklı grafik bulunduran dinamik grafiklerde de zorluk çıkarmaktadır. Maliyet ve bellek kullanımının artması performansı olumsuz etkilemektedir [115-118].

Farklı alanlar için yeni modeller oluşturulmuş olsa da GNN'ler, sinir ağları ailesine mensup diğer modeller gibi sınırlar bulundurmaktadır. Derin sinir ağ modellerinin grafik sürümü olan derin grafik sinir ağları, yüksek boyut sebebiyle performansı düşürmektedir. Büyük grafik modelleri ile işlem gerçekleştirmeye modellerin önündeki en büyük sınırdır.

Tablo 6: Grafik sinir ağlarının avantaj – dezavantaj – limitleri.

Avantaj	Dezavantaj	Limit
Grafik Verileri İşleme	Sınırlı Genellemeye	Grafik Boyutu
Dügüm ve Grafik Sınıflandırması	Aşırı Yumuşatma	Sınırlı Küresel Bağlam
Transdüktif Öğrenme	Ölçeklenebilirlik	Zamansal Bilgi Eksikliği
Hiyerarşik Temsil	Özellik Mühendisliği	Saldırı Karşı Savunma
Özellik Öğrenme	Heterojen Veriler	Veri Dengesizliği
Etki Alanı Birleştirme	Yorumlanabilir Temsiller	Belirsizlikle Mücadele
Uygulanabilirlik	Dinamik Grafikleri İşleme	Dinamik Grafikleri İşleme

Yerel ve yakın komşu-kenar öğrenmesi gerçekleştiren modeller geniş kapsamında bağamları yakalamakta zorluk çekmektedir. İlk modellerde zaman serisi zorlukları da bu sebeple ortaya çıkmıştır. Heterojen ve dinamik verilerde bulunan sınıf dengesizliği yine grafik modellere zorluk oluşturmaktadır. Kullanım bakımından tahminlerde oluşan sorunlar sebebiyle dikkat ağları ortaya çıkmıştır. Dikkat ağları tahmin görevlerinde önceki yıllarda olan belirsizliği azaltmaktadır. Fakat bazı modeller deneyisel kapsamında ürettiği için bu durum GNN'lerin sınırlarından kabul edilmektedir. En büyük sınır ise siber güvenlik sağlanmasıdır. Grafik verileri çok çabuk bozulabilen verilerdir. Grafiklerde hafif bozulma bile sınıflandırma ve tahmin gücünü etkilemektedir. Sinir ağları düşman saldırılara açıktır ve bu durum sinir ağlarında bulunan en büyük sınır olarak kabul edilebilir.

3. SONUÇLAR (CONCLUSIONS)

GNN modelleri, sinir ağlarının gelişmesine katkı sağlayarak yeni modeller için öncül olmuştur. Model, CNN üzerinde etkide

bulunarak GCN kavramını oluşturmuş ve bu gelişmeyle GNN ailesinde büyük bir genişlemenin önünü açmıştır. 2008 yılında ilk modelin yayınlanması ile başlayan süreç günümüzde bu iki modelin altında 65 farklı alt model oluşturarak popülerlik kazanmıştır. Bir modelin yeni oluşturulacak modelleri etkilemesi ile araştırmacılar GNN'ler hakkında her geçen gün yeni çalışmalar yapmaktadır ve sinir ağları kavramını geliştirmektedir. Bu çalışmada öncelik olarak yaygın 8 model öznelinde inceleme gerçekleştirilmiş, temelde ise 65 modele etki eden ve etkilendiği modeller incelenerek değerlendirilmiştir. Genel anlamda modeller GNN ve Grafik CNN mimarileri özelliklerini taşımaktadır. Modeller arası farklılıkların oluşma sebebi geliştirilen modellerin ortak mimari kullanılsa da farklı alanlara odaklanması ve alana özgü olmasıdır. Modellerin ortak kullanım alanları temel alındığında (örn. sınıflandırma görevleri) alana özgü olma hali devam etmektedir. Bir modelin başka bir modelden üstün olması ya da aynı modelin farklı alanlarda gösterdiği performans değişken olmakla beraber karşılaştırma yapılması bu sebeple oldukça zordur. GNN modellerin dezavantajları genellikle sınırları belirlemektedir. Grafik verilerinin büyük olması performansı düşürse de verim üzerinde etkisi oldukça azdır. Model avantajları, dezavantajları göz önüne alındığında modellerin verimi kendini avantajlı göstermektedir. Her modelin alana özgü olması bu durumun bir ispatıdır. GNN modelleri mimarının avantaj elde edebilecek bölümlerini kullanmaktadır. Tüm bu hususlar dikkate alındığında modellerin başarı sergilediği ve

sergilemeye de devam edecek gibi düşünülmektedir. Aynı zamanda deney için geliştirilen modeller bu sınırları kaldırırmak için de etkin faktör olmaktadır. Günümüzde sınırlılık ve dezavantajları bulunsa da GNN modelleri en avantajlı modeller olma yolunda ilerlemektedir.

Bilgisayar biliminin gelişmesi ile GNN'lerin gelişimi doğru orantılıdır. İlk e-ticaret şirketlerinden olan Amazon, GNN'leri başlıca araştırma alanlarına dâhil etmiştir. Amazon, sinir ağlarını ürün önermesi, veri modelleme ve işleme ile araştırma alanlarında kullanmaktadır. İlerleyen yıllarda yeni modeller e-ticaret sisteminde yaygınlaşacak ve e-ticaret alanında farklı işlemler üzerinde kullanılmaya başlanacaktır [119]. GNN'ler temel bilimler alanında da etkin şekilde kullanılmaktadır. Fizik alanında fiziksel sistem modellemesi ve ilişkisel akıl yürütme; kimya alanında moleküler parmak izi, kimyasal reaksiyon tahmini, polieczacılık yan etki modellemesi ve retrosentez tahmini; biyoloji alanında ilaç keşfi, protein arayüz tahmini, yan etki tahmini ve hastalık sınıflandırılmasında kullanılmaktadır. Metin alanında sıra etiketleme, ilişki ve olay çıkarımı, soru cevaplama ve bilgi doğrulama; görüntü alanında sınıflandırma, görsel soru cevaplama, nesne ve etkileşim algılama; doğal dil işlemedede ilişki çıkarma, coğrafi konum, konuşma modelleme ve makine aktarımı; bilgisayarlı görü uygulamalarında sosyal ilişki anlayışı, insan – nesne etkileşimi, durum ve eylem tanıma; trafik ağlarında yolcu talep yönlendirme, park yeri tahmini, durum ve akış tahmini uygulamalarında yaygın olarak kullanılmaktadır. GNN modelleri, 2014 yılında

popülerlik kazanmasına rağmen dokuz yıl gibi bir sürede farklı alanlarda başarı göstermiştir. Bilişim güvenliğinin önem kazanması ile GNN'ler siber güvenlik alanında da kötü amaçlı yazılım algılama, güvenlik açığı tanımlama, topolojik saldırısı ve savunma, anomali algılama, spam algılama ve söylenti tespiti alanlarında etkili olmuştur. Her model farklı bir alan için geliştirilmiş olsa da ortak çerçeveler ile kullanılarak dönüşüm sağlanabilmektedir. Bu sebeple kullanılan modeller farklı alanlar ile de kullanılmaktadır. Bilgisayar biliminin gelişimi GNN'lere yeni alanlar açarak popülerliğini artıracak ve yeni modellerin oluşmasına yol açacaktır. Bu çalışma özelinde modeller tanıtılrken kaynaklar gösterilerek çalışmaların incelenmesi basitleştirilmiştir. Ayrıca ilk Türkçe kaynaklardan olması sebebiyle ülkemizde GNN alanında bir farkındalık yaratacağı ve ardılı olacak çalışmalara öncülük edeceği düşünülmektedir.

TEŞEKKÜR (ACKNOWLEDGMENTS)

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.

YAZAR KATKILARI (AUTHORSHIP CONTRIBUTION STATEMENT)

Hamza Talha GÜMÜŞ: Kavramsal tasarım, Araştırma, Metodoloji, Onaylama, Yazma - Taslak, Yazma - Gözden geçirme ve Düzenleme.

Can EYÜPOĞLU: Kavramsal tasarım, Araştırma, Metodoloji, Denetim, Onaylama, Yazma - Taslak, Yazma - Gözden geçirme ve Düzenleme.

Yazarların makaleye katkıları eşit orandadır.

ÇIKAR ÇATIŞMALARI (CONFLICTS OF INTEREST)

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

KAYNAKLAR (REFERENCES)

- [1] F. Scarselli, M. Gori, A. C. Tsoi, M. Hagenbuchner, and G. Monfardini, “The Graph Neural Network Model,” IEEE Transactions on Neural Networks, vol. 20, no. 1, pp. 61-80, Jan. 2009, doi: 10.1109/TNN.2008.2005605.
- [2] paperswithcode.com, “Papers with Code - An Overview of Graph Models,” <https://paperswithcode.com/methods/category/graph-models> (accessed May 5, 2023).
- [3] T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” 5th International Conference on Learning Representations, ICLR 2017, arXiv preprint arXiv:1609.02907 (2016).
- [4] W. L. Chiang, X. Liu, S. Si, Y. Li, S. Bengio, and C. J. Hsieh, “Cluster-GCN: An Efficient Algorithm for Training Deep and Large Graph Convolutional Networks,” Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19). Association for Computing Machinery, New York, NY, USA, 2019, pp. 257-266, doi: 10.1145/3292500.3330925.
- [5] J. Chen, J. Zhu, and L. Song, “Stochastic training of graph convolutional networks with variance reduction,” Proceedings of the 35th International Conference on Machine Learning, arXiv preprint arXiv:1710.10568 (2017).
- [6] Y. Shi, Z. Huang, S. Feng, W. Wang, and Y. Sun, “Masked label prediction: Unified message passing model for semi-supervised classification,” arXiv, arXiv:2009.03509 (2020).
- [7] L. Shi, Y. Zhang, J. Cheng, and H. Lu, “Two-Stream Adaptive Graph Convolutional Networks for Skeleton-Based Action Recognition,” 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019, pp. 12018-12027, doi: 10.1109/CVPR.2019.01230.
- [8] Jia et al., “Predicting Path Failure In Time-Evolving Graphs,” Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, July 2019, pp. 1279-1289, doi: 10.1145/3292500.3330847.
- [9] B. Chen, R. Barzilay, and T. Jaakkola, “Path-Augmented Graph Transformer Network,” arXiv, May 2019, doi: 10.48550/arxiv.1905.12712.
- [10] L. Yao, C. Mao, and Y. Luo, “Graph Convolutional Networks for Text Classification,” Proceedings of the AAAI Conference on Artificial Intelligence, vol. 33, no. 01, pp. 7370-7377, Jul. 2019, pp. 7370-7377, doi: 10.1609/aaai.v33i01.33017370.
- [11] X. Wang, Y. Ye, and A. Gupta, “Zero-Shot Recognition via Semantic Embeddings and Knowledge Graphs,” 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018, pp. 6857-6866, doi: 10.1109/CVPR.2018.00717.
- [12] L. Zhao et al., “T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction,” IEEE Transactions on Intelligent Transportation Systems, vol. 21, no. 9, pp. 3848-3858, Sept. 2020, doi: 10.1109/TITS.2019.2935152.
- [13] M. Xu, C. Zhao, D. S. Rojas, A. Thabet, and B. Ghanem, “G-TAD: Sub-Graph Localization for Temporal Action Detection,” 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020, pp. 10153-10162, doi: 10.1109/CVPR42600.2020.01017.

- [14] K. Cheng, Y. Zhang, X. He, W. Chen, J. Cheng, and H. Lu, “Skeleton-Based Action Recognition With Shift Graph Convolutional Network,” 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020, pp. 180-189, doi: 10.1109/CVPR42600.2020.00026.
- [15] J. Tang, L. Ericson, J. Folkesson, and P. Jensfelt, “GCNv2: Efficient Correspondence Prediction for Real-Time SLAM,” IEEE Robotics and Automation Letters, vol. 4, no. 4, pp. 3505-3512, Oct. 2019, doi: 10.1109/LRA.2019.2927954.
- [16] X. Zhu, Q. Huang, C. Li, J. Cui, and Y. Chen, “Skeleton-Based Action Recognition with Combined Part-Wise Topology Graph Convolutional Networks,” Lecture Notes in Computer Science, pp. 43-59, Dec. 2023, doi: 10.1007/978-981-99-8429-9_4.
- [17] C. Shang et al., “Edge Attention-based Multi-Relational Graph Convolutional Networks,” arXiv, Feb. 2018, doi: 10.48550/arxiv.1802.04944.
- [18] S. Vashishth, S. Sanyal, V. Nitin and P. Talukdar, “Composition-based Multi-Relational Graph Convolutional Networks,” arXiv, Jan 2020, doi: 10.48550/arXiv.1911.03082.
- [19] J. Li, L. Chen, M. Li, M. Wu, W. Pedrycz, and K. Hirota, “Skeleton-Based Multi-Stream Adaptive Graph Convolutional Network for Indoor Scene Action Recognition,” 2023 China Automation Congress (CAC), Chongqing, China, 2023, pp. 6103-6108, doi: 10.1109/CAC59555.2023.10451388.
- [20] I. Chami, R. Ying, C. Ré, and J. Leskovec, “Hyperbolic Graph Convolutional Neural Networks,” Advances in Neural Information Processing Systems, vol. 32, pp. 4869-4880, 2019.
- [21] J. Atwood and D. Towsley, “Diffusion-Convolutional Neural Networks,” arXiv.org, Jul. 08, 2016. <https://arxiv.org/abs/1511.02136>.
- [22] P. Kumar, M. Grewal, and M. M. Srivastava, “Boosted Cascaded Convnets for Multilabel Classification of Thoracic Diseases in Chest Radiographs,” arXiv, Nov. 2017, doi: 10.48550/arxiv.1711.08760.
- [23] C. Li and D. Goldwasser, “Encoding Social Information with Graph Convolutional Networks for Political Perspective Detection in News Media,” Jan. 2019, doi: 10.18653/v1/p19-1247.
- [24] D. Andreoletti, S. Troia, F. Musumeci, S. Giordano, G. Maier, and M. Tornatore, “Network Traffic Prediction based on Diffusion Convolutional Recurrent Neural Networks,” IEEE INFOCOM 2019 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS), Paris, France, 2019, pp. 246-251, doi: 10.1109/INFCOMW.2019.8845132.
- [25] P. Veličković, G. Cucurull, A. Casanova, A. Romero, Pietro Liò, and Y. Bengio, “Graph Attention Networks,” arXiv, Oct. 2017, doi: 10.48550/arxiv.1710.10903.
- [26] D. Busbridge, et al., “Relational graph attention networks,” arXiv preprint, Apr 2019, arXiv:1904.05811.
- [27] S. A. Tailor, F. L. Opolka, P. Liò, and N. D. Lane, “Do We Need Anisotropic Graph Neural Networks?,” arXiv, Apr. 2021, doi: 10.48550/arxiv.2104.01481.
- [28] J. Huang, H. Shen, L. Hou, and X. Cheng, “Signed Graph Attention Networks,” Lecture Notes in Computer Science, pp. 566-577, Jan. 2019, doi: 10.1007/978-3-030-30493-5_53.
- [29] M. Grassia and G. Mangioni, “wsGAT: Weighted and Signed Graph Attention Networks for Link Prediction,” Studies in computational intelligence, pp. 369-375, Jan. 2022, doi: 10.1007/978-3-030-93409-5_31.
- [30] Z. Huang, “DHSEGATs: distance and hop-wise structures encoding enhanced graph attention networks,” Journal of Systems Engineering and Electronics, vol. 34, no. 2, pp. 350-359, April 2023, doi: 10.23919/JSEE.2023.000057.
- [31] H. Zhao et al., “Multivariate Time-Series Anomaly Detection via Graph Attention Network,” 2020 IEEE International Conference

- on Data Mining (ICDM), Sorrento, Italy, 2020, pp. 841-850, doi: 10.1109/ICDM50108.2020.00093.
- [32] W. Hamilton, Z. Ying, and J. Leskovec, “Inductive Representation Learning on Large Graphs,” Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017, doi: 10.48550/arXiv.1706.02216.
- [33] K. Xu, W. Hu, J. Leskovec, and S. Jegelka, “How Powerful are Graph Neural Networks?,” arXiv, Oct. 2018, doi: 10.48550/arxiv.1810.00826.
- [34] S. Chen, S. Lim, F. Mémoli, Z. Wan, and Y. Wang, “Weisfeiler-Lehman meets Gromov-Wasserstein,” arXiv, Feb. 2022, doi: 10.48550/arxiv.2202.02495.
- [35] L. Chang and P. Branco, “Graph-based Solutions with Residuals for Intrusion Detection: the Modified E-GraphSAGE and E-ResGAT Algorithms,” arXiv, Nov. 2021, doi: 10.48550/arxiv.2111.13597.
- [36] W. W. Lo, S. Layeghy, M. Sarhan, M. Gallagher and M. Portmann, “E-GraphSAGE: A Graph Neural Network based Intrusion Detection System for IoT,” NOMS 2022-2022 IEEE/IFIP Network Operations and Management Symposium, Budapest, Hungary, 2022, pp. 1-9, doi: 10.1109/NOMS54207.2022.9789878.
- [37] K. Xu, C. Li, Y. Tian, T. Sonobe, K. Kawarabayashi, and S. Jegelka, “Representation Learning on Graphs with Jumping Knowledge Networks,” Proceedings of the 35th International Conference on Machine Learning, PMLR 80:5453-5462, 2018, doi: 10.48550/arXiv.1806.03536.
- [38] W. W. Lo, S. Layeghy, M. Sarhan, M. Gallagher, and M. Portmann, “Graph Neural Network-based Android Malware Classification with Jumping Knowledge,” 2022 IEEE Conference on Dependable and Secure Computing (DSC), Edinburgh, United Kingdom, 2022, pp. 1-9, doi: 10.1109/DSC54232.2022.9888878.
- [39] J. Oh, K. Cho, and J. Bruna, “Advancing GraphSAGE with A Data-Driven Node Sampling,” arXiv, Apr. 2019, doi: 10.48550/arxiv.1904.12935.
- [40] Y. Rong, W. Huang, T. Xu, and J. Huang, “Dropedge: Towards Deep Graph Convolutional Networks On Node Classification,” ArXiv, 2020, doi: 10.48550/arXiv.1907.10903.
- [41] S. Abu-El-Haija, A. Kapoor, B. Perozzi, and J. Lee, “N-GCN: Multi-scale Graph Convolution for Semi-supervised Node Classification,” Proceedings of the 35th Uncertainty in Artificial Intelligence Conference, PMLR 115, pp. 841-851, 2020, doi: 10.48550/arXiv.1802.08888.
- [42] V. P. Dwivedi and X. Bresson. “A generalization of transformer networks to graphs,” AAAI 2021 Workshop on Deep Learning on Graphs: Methods and Applications, 2021, doi: 10.48550/arXiv.2012.09699.
- [43] S. Yun et al., “Graph Transformer Networks: Learning meta-path graphs to improve GNNs,” Neural Networks, vol. 153, pp. 104-119 Jun. 2022, doi: 10.1016/j.neunet.2022.05.026.
- [44] B. Lyu, L. Chen, S. Zhu, and K. Yu, “LET: Linguistic Knowledge Enhanced Graph Transformer for Chinese Short Text Matching,” AAAI, vol. 35, no. 15, pp. 13498-13506, May 2021, doi: 10.1609/aaai.v35i15.17592.
- [45] L. Xia, “Knowledge-Enhanced Hierarchical Graph Transformer Network for Multi-Behavior Recommendation,” The Thirty-Fifth AAAI Conference on Artificial Intelligence, vol. 35, no. 5, pp. 4486-4493, May 2021, doi: 10.1609/aaai.v35i5.16576.
- [46] A. Morehead and C. Chen, “Geometric Transformers for Protein Interface Contact Prediction,” arXiv, Oct. 2021, doi: 10.48550/arxiv.2110.02423.
- [47] J. Gilmer, S. S. Schoenholz, P. F. Riley, O. Vinyals, and G. E. Dahl, “Neural Message Passing for Quantum Chemistry,” Proceedings of the 34th International Conference on

- Machine Learning, PMLR 70:1263-1272, 2017, doi: 10.48550/arXiv.1704.01212.
- [48] M. Gastegger, A. McSloy, M. Luya, Kristof Schütt, and R. J. Maurer, “A deep neural network for molecular wave functions in quasi-atomic minimal basis representation,” The Journal of Chemical Physics, vol. 153, no. 4, Jul. 2020, doi: 10.1063/5.0012911.
- [49] D. S. Broomhead and D. Lowe, “Multivariable Functional Interpolation and Adaptive Networks,” Complex Systems, vol. 2, no. 6, pp. 568-576, 1988.
- [50] P. Riba, A. Fischer, J. Lladós and A. Fornés, “Learning Graph Distances with Message Passing Neural Networks,” 2018 24th International Conference on Pattern Recognition (ICPR), Beijing, China, 2018, pp. 2239-2244, doi: 10.1109/ICPR.2018.8545310.
- [51] M. Balcilar, P. Heroux, B. Gauzere, P. Vasseur, S. Adam, and P. Honeine, “Breaking the Limits of Message Passing Graph Neural Networks,” 38th International Conference on Machine Learning, pp. 599-608, 2021, doi: 10.48550/arXiv.2106.04319.
- [52] H. Dai, Z. Kozareva, B. Dai, A. Smola, and L. Song, “Learning Steady-States of Iterative Algorithms over Graphs,” Proceedings of the 35th International Conference on Machine Learning, PMLR 80, pp. 1106-1114, 2018.
- [53] L. Wu, S. Li, C.-J. Hsieh, and J. Sharpnack, “Stochastic Shared Embeddings: Data-driven Regularization of Embedding Layers,” Proceedings of the 33rd International Conference on Neural Information Processing Systems, p. 3, pp. 24-34, May 2019, doi: 10.48550/arxiv.1905.10630.
- [54] P.-R. Wagner, S. Marelli, I. Papaioannou, D. Straub, and B. Sudret, “Rare event estimation using stochastic spectral embedding,” Structural Safety, vol. 96, p. 102179, May 2022, doi: 10.1016/j.strusafe.2021.102179.
- [55] F. Monti, D. Boscaini, J. Masci, E. Rodolà, J. Svoboda, and M. M. Bronstein, “Geometric Deep Learning on Graphs and Manifolds Using Mixture Model CNNs,” 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017, pp. 5425-5434, doi: 10.1109/CVPR.2017.576.
- [56] F. Lu et al., “MoNet: Motion-Based Point Cloud Prediction Network,” IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 8, pp. 13794-13804, Aug. 2022, doi: 10.1109/TITS.2021.3128424.
- [57] Y. Yao, Y. Jafarian, and H. S. Park, “MONET: Multiview Semi-Supervised Keypoint Detection via Epipolar Divergence,” 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea (South), 2019, pp. 753-762, doi: 10.1109/ICCV.2019.00084.
- [58] X. He, K. Deng, X. Wang, Y. Li, Y. Zhang, and M. Wang, “LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation,” Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 639-648, Jul. 2020, doi: 10.1145/3397271.3401063.
- [59] K. Mao, J. Zhu, X. Xiao, B. Lu, Z. Wang, and X. He, “UltraGCN: Ultra Simplification of Graph Convolutional Networks for Recommendation,” CIKM’21: Proceedings of the 30th ACM International Conference on Information & Knowledge Management, pp. 1253-1262, Oct. 2021, doi: 10.1145/3459637.3482291.
- [60] B. Wu, Y. Liu, B. Lang, and L. Huang, “DGCNN: Disordered graph convolutional neural network based on the Gaussian mixture model,” Neurocomputing, vol. 321, pp. 346-356, Dec. 2018, doi: 10.1016/j.neucom.2018.09.008.
- [61] M. Zhang, Z. Cui, M. Neumann, and Y. Chen, “An End-to-End Deep Learning Architecture for Graph Classification,” Proceedings of the AAAI Conference on Artificial Intelligence, vol. 32, no. 1, Apr. 2018, doi: 10.1609/aaai.v32i1.11782.
- [62] Y. Wang and J. M. Solomon, “Object DGCNN: 3D Object Detection using Dynamic Graphs,” Advances in Neural Information

- Processing Systems, vol. 34, pp. 20745-20758, 2021, doi: 10.48550/arXiv.2110.06923.
- [63] B.-H. Kim and J. C. Ye, "Understanding Graph Isomorphism Network for rs-fMRI Functional Connectivity Analysis," *Frontiers in Neuroscience*, vol. 14, Jun. 2020, doi: 10.3389/fnins.2020.00630.
- [64] F. M. Bianchi, D. Grattarola, L. Livi, and C. Alippi, "Graph Neural Networks With Convolutional ARMA Filters," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 7, pp. 3496-3507, 1 July 2022, doi: 10.1109/TPAMI.2021.3054830.
- [65] J. Su, S. Wang, and F. Huang, "ARMA Nets: Expanding Receptive Field for Dense Prediction," *European Semantic Web Conference, ESWC 2018: The Semantic Web*, pp. 593-607, Feb. 2020, doi: 10.48550/arxiv.2002.11609.
- [66] M. Schlichtkrull, T. N. Kipf, P. Bloem, R. van den Berg, I. Titov, and M. Welling, "Modeling Relational Data with Graph Convolutional Networks," *The Semantic Web*, pp. 593-607, 2018, doi: 10.1007/978-3-319-93417-4_38.
- [67] T. Thanapalasingam, L. van Berkel, P. Bloem, and P. Groth, "Relational graph convolutional networks: a closer look," *PeerJ Computer Science*, vol. 8, p. e1073, Nov. 2022, doi: 10.7717/peerj-cs.1073.
- [68] K. Schütt, P.-J. Kindermans, H. E. Sauceda Felix, S. Chmiela, A. Tkatchenko, and K.-R. Müller, "SchNet: A continuous-filter convolutional neural network for modeling quantum interactions," *Neural Information Processing Systems, NeurIPS 2017*, vol. 30, pp. 992-1002, 2017, doi: 10.48550/arXiv.1706.08566.
- [69] Y. Li, D. Tarlow, M. Brockschmidt, and R. S. Zemel, "Gated Graph Sequence Neural Networks," *Proceedings of the 5th International Conference on Learning Representations*, pp. 273-283, Apr. 2016, doi: 10.48550/arxiv.1511.05493.
- [70] R. Li, S. Wang, F. Zhu, and J. Huang, "Adaptive Graph Convolutional Neural Networks," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 32, no. 1, pp. 105-132, Apr. 2018, doi: 10.1609/aaai.v32i1.11691.
- [71] Z. Ying, J. You, C. Morris, X. Ren, W. Hamilton, and J. Leskovec, "Hierarchical Graph Representation Learning with Differentiable Pooling," *Neural Information Processing Systems*, 2018, doi: 10.48550/arXiv.1806.08804.
- [72] M. Cheung, J. Shi, L. Y. Jiang, O. Wright, and Moura, "Pooling in Graph Convolutional Neural Networks," *53rd Asilomar Conference on Signals, Systems, and Computers*, pp. 462-466, Apr. 2020, doi: 10.48550/arxiv.2004.03519.
- [73] T. Yamamoto, "Crystal Graph Neural Networks for Data Mining in Materials Science," *Research Institute for Mathematical and Computational Sciences, LLC*, 2019.
- [74] G. S. Alberti, M. Santacesaria, and S. Sciuotto, "Continuous Generative Neural Networks," *arXiv*, May 2022, doi: 10.48550/arxiv.2205.14627.
- [75] H. Li, J. Cao, J. Zhu, Y. Liu, Q. Zhu, and G. Wu, "Curvature Graph Neural Network," *Information Sciences*, vol. 592, pp. 50-66, doi: 10.1016/j.ins.2021.12.077.
- [76] A. Sanchez-Gonzalez, J. Godwin, T. Pfaff, R. Ying, J. Leskovec, and P. Battaglia, "Learning to Simulate Complex Physics with Graph Networks," *International Conference on Machine Learning*, pp. 8459-8468, Nov. 21, 2020, doi: 10.48550/arXiv.2002.09405.
- [77] M. Chen, Z. Wei, Z. Huang, B. Ding, and Y. Li, "Simple and Deep Graph Convolutional Networks," *International Conference on Machine Learning*, pp. 1725-1735, Nov. 21, 2020, doi: 10.48550/arXiv.2007.02133.
- [78] M. Defferrard, X. Bresson, and P. Vandergheynst, "Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering," *Advances in Neural Information Processing Systems*, pp. 3844-3852, 2016, doi: 10.48550/arXiv.1606.09375.

- [79] J. Chen, T. Ma, and C. Xiao, “FastGCN: Fast Learning with Graph Convolutional Networks via Importance Sampling,” arXiv, Jan. 2018, doi: 10.48550/arxiv.1801.10247.
- [80] P. Veličković, W. Fedus, W. L. Hamilton, P. Liò, Y. Bengio, and R. D. Hjelm, “Deep Graph Infomax,” arXiv, Sep. 2018, doi: 10.48550/arxiv.1809.10341.
- [81] Z. Chen, T. Ma, Z. Jin, Y. Song, and Y. Wang, “BiGCN: A Bi-directional Low-Pass Filtering Graph Neural Network,” Analysis and Applications, vol. 20, no. 6, pp. 1193-1214, 2022, doi: 10.1142/s0219530522400048.
- [82] E. Rossi, B. Chamberlain, F. Frasca, D. Eynard, F. Monti, and M. Bronstein, “Temporal Graph Networks for Deep Learning on Dynamic Graphs,” arXiv, Jun. 2020, doi: 10.48550/arxiv.2006.10637.
- [83] W. Jin, M. Qu, X. Jin, and X. Ren, “Recurrent Event Network: Autoregressive Structure Inference over Temporal Knowledge Graphs,” Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), Nov. 2020, pp. 6669-6683, doi: 10.18653/v1/2020.emnlp-main.541.
- [84] Y. Han, S. Karunasekera, and C. Leckie, “Continual Learning for Fake News Detection from Social Media,” Artificial Neural Networks and Machine Learning – ICANN 2021: 30th International Conference on Artificial Neural Networks, pp. 372-384, Sep. 2021, doi: 10.1007/978-3-030-86340-1_30.
- [85] F. Monti, F. Frasca, D. Eynard, D. Mannion, and M. M. Bronstein, “Fake News Detection on Social Media using Geometric Deep Learning,” arXiv, Feb. 2019, doi: 10.48550/arxiv.1902.06673.
- [86] C. Gabriele, C. Luca, B. Dominique, L. Pietro, and V. Petar, “Principal Neighbourhood Aggregation for Graph Nets,” Advances in Neural Information Processing Systems, vol. 33, pp. 13260-13271, 2020, doi: 10.48550/arXiv.2004.05718.
- [87] J. Qiu et al., “GCC: Graph Contrastive Coding for Graph Neural Network Pre-Training,” Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, Aug. 2020, pp. 1150-1160, doi: 10.1145/3394486.3403168.
- [88] B. Chen et al., “GCCAD: Graph Contrastive Coding for Anomaly Detection,” IEEE Transactions on Knowledge and Data Engineering, vol. 35, no. 8, pp. 8037-8051, Aug. 2023, doi: 10.1109/TKDE.2022.3200459.
- [89] H. Gao, Z. Wang, and S. Ji, “Large-Scale Learnable Graph Convolutional Networks,” Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, Jul. 2018, pp. 1416-1424, doi: 10.1145/3219819.3219947.
- [90] D. Bacciu, F. Errica, and A. Micheli, “Contextual Graph Markov Model: A Deep and Generative Approach to Graph Processing,” 35th International Conference on Machine Learning, pp. 294-303, Jul. 03, 2018, doi: 10.48550/arXiv.1805.10636.
- [91] J. Zhang, X. Shi, J. Xie, H. Ma, I. King, and D.-Y. Yeung, “GaAN: Gated Attention Networks for Learning on Large and Spatiotemporal Graphs,” Mar. 2018, arXiv:1803.07294.
- [92] C. Miles et al., “Discovering Symbolic Models from Deep Learning with Inductive Biases,” Advances in Neural Information Processing Systems, vol. 33, 2020, doi: 10.48550/arXiv.2006.11287.
- [93] Z. Shui and G. Karypis, “Heterogeneous Molecular Graph Neural Networks for Predicting Molecule Properties,” 2020 IEEE International Conference on Data Mining (ICDM), Sorrento, Italy, 2020, pp. 492-500, doi: 10.1109/ICDM50108.2020.00058.
- [94] S. Zhang, Y. Liu, and L. Xie, “Molecular Mechanics-Driven Graph Neural Network with Multiplex Graph for Molecular Structures,” ArXiv, arXiv:2011.07457.
- [95] D. Alfke and M. Stoll, “Pseudoinverse graph convolutional networks,” Data Mining and Knowledge Discovery, vol. 35, pp. 1318-1341, Apr. 2021, doi: 10.1007/s10618-021-00752-w.

- [96] I. Igashov, N. Pavlichenko, and S. Grudinin, “Spherical convolutions on molecular graphs for protein model quality assessment,” *Machine Learning: Science and Technology*, vol. 2, no. 4, p. 045005, Jul. 2021, doi: 10.1088/2632-2153/abf856.
- [97] S. Brody, U. Alon, and E. Yahav, “How Attentive are Graph Attention Networks?,” arXiv, May 2021, arXiv:2105.14491.
- [98] J. Shen, Z. Shen, C. Xiong, C. Wang, K. Wang, and J. Han, “TaxoExpan: Self-supervised Taxonomy Expansion with Position-Enhanced Graph Neural Network,” *Proceedings of The Web Conference*, pp. 486-497, Apr. 2020, doi: 10.1145/3366423.3380132.
- [99] W. Shi and R. Rajkumar, “Point-GNN: Graph Neural Network for 3D Object Detection in a Point Cloud,” *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, WA, USA, 2020, pp. 1708-1716, doi: 10.1109/CVPR42600.2020.00178.
- [100] D. Bieber et al., “Learning to execute programs with instruction pointer attention graph neural networks,” *Advances in Neural Information Processing Systems*, vol. 33, no. 2020, pp. 8626-8637, doi: 10.48550/arXiv.2010.12621.
- [101] H. Dai, A. Nazi, Y. Li, B. Dai, and D. Schuurmans, “Scalable Deep Generative Modeling for Sparse Graphs,” *International Conference on Machine Learning*, Nov. 21, 2020, pp. 2302-2312, doi: 10.48550/arXiv.2006.15502.
- [102] T. Nayak and H. T. Ng, “A Hierarchical Entity Graph Convolutional Network for Relation Extraction across Documents,” arXiv, Aug. 2021, doi: 10.48550/arxiv.2108.09505.
- [103] K. Wimalawarne and T. Suzuki, “Layer-wise Adaptive Graph Convolution Networks Using Generalized Pagerank,” *Proceedings of the 14th Asian Conference on Machine Learning*, PMLR, vol. 189, pp. 1117-1132, 2023.
- [104] Z. Li, B. Chen, and X. Si, “Graph Contrastive Pre-training for Effective Theorem Reasoning,” *International Conference on Machine Learning (ICML)*, vol. 139, <http://arxiv.org/abs/2108.10821>.
- [105] L. Chen et al., “Group-Aware Graph Neural Network for Nationwide City Air Quality Forecasting,” *ACM Transactions on Knowledge Discovery From Data*, vol. 18, no. 3, pp. 1-20, Dec. 2023, doi: 10.1145/3631713.
- [106] T. Pfaff, M. Fortunato, A. Sanchez-Gonzalez, and P. W. Battaglia, “Learning Mesh-Based Simulation with Graph Networks,” arXiv.org, Jun. 18, 2021, <https://arxiv.org/abs/2010.03409>
- [107] Y. Xing et al., “Learning Hierarchical Graph Neural Networks for Image Clustering,” *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, QC, Canada, 2021, pp. 3447-3457, doi: 10.1109/ICCV48922.2021.00345.
- [108] R. Levie, F. Monti, X. Bresson and M. M. Bronstein, “CayleyNets: Graph Convolutional Neural Networks With Complex Rational Spectral Filters,” *IEEE Transactions on Signal Processing*, vol. 67, no. 1, pp. 97-109, Jan. 2019, doi: 10.1109/TSP.2018.2879624.
- [109] Z. Liu, et al., “GeniePath: Graph Neural Networks with Adaptive Receptive Paths,” *AAAI*, vol. 33, no. 01, pp. 4424-4431, Jul. 2019, doi: 10.1609/aaai.v33i01.33014424.
- [110] A. Micheli, “Neural Network for Graphs: A Contextual Constructive Approach,” *IEEE Transactions on Neural Networks*, vol. 20, no. 3, pp. 498-511, March 2009, doi: 10.1109/TNN.2008.2010350.
- [111] D. V. Tran, N. Navarin, and A. Sperduti, “On Filter Size in Graph Convolutional Networks,” *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, Bangalore, India, 2018, pp. 1534-1541, doi: 10.1109/SSCI.2018.8628758.
- [112] F. M. Bianchi, D. Grattarola, and C. Alippi, “Spectral clustering with graph neural networks for graph pooling,” *Proceedings of the 37th International Conference on Machine Learning (ICML'20)*, vol. 119, p. 82, pp. 874-883, 2020.

- [113] C. Gallicchio and A. Micheli, “Graph Echo State Networks,” The 2010 International Joint Conference on Neural Networks (IJCNN), Barcelona, Spain, 2010, pp. 1-8, doi: 10.1109/IJCNN.2010.5596796.
- [114] R. Li, et al., “Dual graph convolutional networks for aspect-based sentiment analysis,” Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, pp. 6319-6329, 2021.
- [115] H. T. Gümüş ve C. Eyüpoğlu, “Grafik Sinir Ağlarına Genel Bir Bakış,” EMO Bilimsel Dergi, vol. 13, no. 2, pp. 39-56, 2023.
- [116] Waikhom and R. Patgiri, “Graph Neural Networks: Methods, Applications, and Opportunities,” arXiv.org, Sep. 08, 2021, arXiv:2108.10733.
- [117] C. Liu et al., “Graph Pooling for Graph Neural Networks: Progress, Challenges, and Opportunities,” arXiv.org, Jun. 22, 2023, arXiv:2204.07321.
- [118] S. Georgousis, M. P. Kenning, and X. Xie, “Graph Deep Learning: State of the Art and Challenges,” IEEE Access, vol. 9, pp. 22106-22140, 2021, doi: 10.1109/ACCESS.2021.3055280.
- [119] Amazon Science “Amazon at WSDM: The future of graph neural networks,” <https://www.amazon.science/blog/amazon-at-wsdm-the-future-of-graph-neural-networks> (accessed May 7, 2023).