

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

ZAMANSAL BİLGİ GRAFİKLERİ İÇİN EVRİMSEL VE KARŞITSAL
TEMSİL: YAPAY ZEKA BİLİNCİNİN İNŞASI

Mustafa Sıtkı ATMACA

ENFORMATİK ANABİLİM DALI

ANKARA
2025

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

ZAMANSAL BİLGİ GRAFİKLERİ İÇİN EVRİMSEL VE KARŞITSAL TEMSİL: YAPAY ZEKA BİLİNCİNİN İNŞASI

Mustafa Sıtkı ATMACA

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Enformatik Anabilim Dalı

Danışman: Doç. Dr. Erinç KARATAŞ

Bilginin zaman içerisindeki evrimi, günümüzün veri-yoğun dünyasında giderek daha kritik bir araştırma alanı hâline gelmiştir. Zamansal bilgi grafi (Temporal Knowledge Graph, TKG) çıkarımı ise değişen ilişkileri anlamak ve geleceğe dönük kestirimler yapabilmek adına araştırmacılara güçlü imkânlar sunmaktadır. Bu tezin temel motivasyonu, TKG çıkarımında öne çıkan iki farklı yaklaşımı; evrimsel temelli gösterim öğrenimi (evolutional representation learning) ve tarihsel/karşıtsal öğrenim (historical contrastive learning) bir araya getirerek her iki yöntemin güçlü yanlarını tek bir çatı altında toplamak ve böylece daha anlamlı, genellenebilir ve yüksek performanslı sonuçlar elde edebilecek bir hibrit model ortaya koymaktır. Çalışma kapsamında önce “Evrimsel Temsil Öğrenmesine Dayalı Zamansal Bilgi Grafiği Akıl Yürütme” ve “Tarihsel Karşıtlıklı Öğrenme ile Zamansal Bilgi Grafiği Akıl Yürütme” yaklaşımları özgün biçimde yeniden uygulanmış, daha sonra bu iki modelin mimari prensipleri bütünleştirilerek yeni bir hibrit model tasarlanmıştır. Deneysel sonuçlar, önerilen hibrit modelin hem doğruluk hem de genelleme kapasitesi bakımından diğer iki modele kıyasla kayda değer bir üstünlük sağladığını göstermektedir. Böylece tezin hedefi olan “evrimsel” (değişimi yakalama) ve “tarihsel/karşıtsal” (bağlamsal ayrımı güçlendirme) bakış açılarını birlikte kullanarak zamansal bilgi grafi çıkarımında ileriye dönük bir adım atma amacı başarılı bir şekilde gerçekleştirilmiştir.

Temmuz 2025, 62 sayfa

Anahtar Kelimeler: Zamansal Bilgi Grafiği, Evrimsel Öğrenme, Karşıtsal Öğrenme

ABSTRACT

Master Thesis

EVOLUTIONAL AND CONTRASTIVE REPRESENTATION FOR TEMPORAL KNOWLEDGE GRAPHS: THE CONSTRUCTION OF AI CONSCIOUSNESS

Mustafa Sıtkı ATMACA

Ankara University
Graduate School of Natural and Applied Science
Department of Informatics

Supervisor: Doç. Dr. Erinc KARATAŞ

The evolution of knowledge over time has become an increasingly critical area of research in today's data-intensive world. Temporal Knowledge Graph (TKG) inference offers researchers powerful opportunities to understand changing relationships and make future predictions. The main motivation of this thesis is to bring together two different approaches in TKG inference evolutionary representation learning and historical/contrastive learning to bring together the strengths of both methods under a single roof and thus to present a hybrid model that can achieve more meaningful, generalizable and high-performance results. Within the scope of the study, first, "Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning" and "Temporal Knowledge Graph Reasoning with Historical Contrastive Learning" approaches are re-implemented in an original way, and then a new hybrid model is designed by integrating the architectural principles of these two models. Experimental results show that the proposed hybrid model provides a significant superiority over the other two models in terms of both accuracy and generalization capacity. Thus, the aim of the thesis to take a forward step in temporal knowledge graph extraction by using the "evolutionary" (capturing change) and "historical/contrastive" (strengthening contextual distinction) perspectives together has been successfully achieved.

July 2025, 62 pages

Keywords: Temporal Knowledge Graph, Evolutionary Learning, Contrative Learning

TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında bana her zaman yol gösteren, bilgi ve deneyimiyle çalışmalarımı şekillendiren, sabrıyla ve desteğiyle süreci anlamlı kılan değerli danışmanım Sayın Doç. Dr. Erinç KARATAŞ'a en içten teşekkürlerimi sunarım.

Araştırma sürecinde fikir alışverişinde bulunduğum, moral ve motivasyonlarıyla yanımda olduklarını hissettiren sevgili arkadaşlarıma da teşekkür ederim.

Hayatım boyunca yanımda olan, beni her koşulda destekleyen ve sevgileriyle güç veren aileme minnettarım.

Ayrıca, bu zorlu süreçte anlayışı, sabrı ve sevgisiyle bana en büyük desteği sağlayan canım eşime sonsuz teşekkürlerimi sunarım.

Mustafa Sıtkı ATMACA

Ankara, Haziran 2025

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT.....	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	x
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	4
2.1 Bilinç ve Bilinç Problemi	4
2.2 Bilinç Teorileri.....	5
2.2.1 Entegre bilgi teorisi.....	5
2.2.2 Küresel çalışma alanı teorisi	6
2.2.3 Yüksek düzeyli teoriler.....	8
2.2.4 Yeniden giriş ve öngörücü işleme teorileri	9
2.2.5 Uzay-Zaman teorisi ve bilincin seviyeleri	10
2.3 Yapay Sinir Ağları ve Biyolojik Sinir Ağları.....	11
2.3.1 Yapay sinir ağları	12
2.3.2 Yapay sinir ağları ve biyolojik sinir ağları ilişkisi.....	13
2.4 Bilgi Grafikleri	14
2.4.1 Bilgi grafiği tamamlama.....	16
2.5 Grafik Sinir Ağları.....	16
2.5.1 Grafik sinir ağları uygulamaları	17
2.5.2 Grafik türleri.....	20
2.5.3 Hesaplama modülleri.....	20
2.5.4 Grafik evrişimli ağlar	21
2.5.5 Grafik dikkat ağları.....	22
2.5.6 Grafik tekrarlayan sinir ağları.....	22
2.5.7 Evrişimli sinir ağları.....	23
3. KAYNAK ÖZETLERİ	26
4. MATERYAL VE YÖNTEM	34
4.1 Zamansal Bilgi Grafi Modelleri.....	34
4.1.1 Evrimsel temsilli öğrenme (ERL).....	34
4.1.2 Tarihsel ve karşıtsal öğrenme (HCL)	36
4.2 ERL Modelinde Evrişimli Sinir Ağlarının Kullanımı	37
4.3 Zaman Serisi Bileşenleri.....	38
4.3.1 Uzun kısa süreli bellek ağları.....	38
4.3.2 Kapılı tekrarlayan birimler (GRU).....	38
4.4 Kayıp Hesaplamaları	39
4.4.1 Dinamik ağırlık ortalaması (DWA)	39
4.4.2 Denetlenen projeksiyon kontrastlı kaybı.....	41
4.4.3 Gürültü karşıt tahmini kaybı	42
4.4.4 Kosinüs benzerliği.....	43

4.5	Veri Setinin Yapısı ve İçeriği	44
4.6	Hibrit Model(ERL&CENET) Tasarımı.....	46
4.7	MRR (Mean Reciprocal Rank) Metriği ve Uygulama Yöntemi	47
5.	BULGULAR VE TARTIŞMA	49
5.1	ERL Modelinin Performans Değerlendirmesi	49
5.2	CENET Modelinin Performans Değerlendirmesi.....	50
5.3	Önerilen Hibrit Modelin Performans Değerlendirmesi	51
5.4	Karşılaştırmalı Değerlendirme ve Yorum	52
5.5	Hibrit Modelin Çoklu Veri Ortamlarında Kullanımı	54
6.	SONUÇ	57
	KAYNAKLAR	59
	ÖZGEÇMİŞ.....	62



KISALTMALAR DİZİNİ

ANN	Yapay Sinir Ağları (Artificial Neural Network)
CAMEO	Malzeme Araştırması İçin Kapalı Döngü Otonom Sistem (Closed-Loop Autonomous System for Materials Exploration)
CENET	Karşıtsal Olay Ağı (Contrastive Event Network)
CNN	Evrişimli Sinir Ağlarının (Convolutional Neural Networks)
CVE	Yaygın Güvenlik Açıkları ve Maruz Kalmalar (Common Vulnerabilities and Exposures)
DWA	Dinamik Ağırlık Ortalaması (Dynamic Weight Average)
ERL	Evrimsel Temsil Öğrenmesi (Evolutional Representation Learning)
GAT	Grafik Dikkat Ağları (Graph Attention Networks)
GCN	Grafik Evrişimli Ağlar (Graph Neural Networks)
GDELT	Küresel Olay, Dil ve Ton Veritabanı (Global Database of Events, Language, and Tone)
GNN	Grafik Sinir Ağları (Graph Neural Networks)
GRU	Kapılı Yineleyen Birim (Gated Recurrent Unit)
GWT	Küresel Çalışma Alanı Teorisi (Global Workspace Theory)
GRNN	Grafik Tekrarlayan Sinir Ağları (Graph Recurrent Neural Networks)
HCL	Tarihsel Karşıtsal Öğrenme (Historical Contrastive Learning)
HOT	Yüksek Düzeyli Teoriler (Higher Order Theories)
ICEWS	Entegre Kriz Erken Uyarı Sistemi (The Integrated Crisis Early Warning System)
IIT	Entegre Bilgi Sistemi (Integrated Information Theory)
KG	Bilgi Grafiği
KGC	Bilgi Grafiği Tamamlama (Knowledge Graph Completion)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)

MRR	Ortalama Karşılıklı Sıralama (Mean Reciprocal Rank)
NCC	Bilincin Sinirsel Bağlantıları (Neural Correlates of Consciousness)
NCE	Gürültü Karşıt Tahmin Kaybı (Noise Contrastive Estimation Loss)
PSC	Bilincin Fiziksel Altyapısı (Physical Substrate of Consciousness)
RE-GCN	İlişkisel Geliştirilmiş Grafik Evrişimli Ağlar (Relation Enhanced Graph Convolutional Networks)
RDF	Kaynak Tanımlama Çerçevesi (Resource Description Framework)
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
SOTA	State-Of-The-Art
SPC	Denetlenen Projeksiyon Kontrastlı (Supervised Projection Contrastive)
TKG	Zamanlı bilgi grafi (Temporal Knowledge Graph)
YAGO	Yet Another Great Ontology
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 2.1	Bir bilgi grafiğinde varlık ve ilişkilerle bilgi temsili.....	15
Şekil 2.2	Evrişimli sinir ağları.....	24
Şekil 4.1	Hibrit modelin(ERL&CENET) eğitim döngüsü.....	46



ÇİZELGELER DİZİNİ

Çizelge 5.1	ERL modelinin performans çıktıları.....	49
Çizelge 5.2	CENET modelinin performans çıktıları.....	50
Çizelge 5.3	Hibrit modelin (ERL&CENET) performans çıktıları.....	51
Çizelge 5.4	ERL ve Hibrit modellerinin MRR ve Hits performans karşılaştırması...	52



1. GİRİŞ

Bilinç, evrenin doğasının anlaşılmasında büyük bir gizem olarak var olmaya devam etmektedir. Fizik ve biyoloji bilimleri büyük ilerlemeler kaydetmiş olsa da, hala açıklığa kavuşturulması gereken bilimsel problemler bulunmaktadır.. Zihin bilimindeki gelişmeler, özellikle bilişsel bilim ve sinirbilim alanındaki çalışmalar, insan davranışını ve altında yatan süreçleri daha iyi anlaşılmasını sağlamaktadır. Biliş konusundaki teoriler henüz tam olmasa da, gelişmeye devam etmektedir (Tononi, 2016; Baars, 1997).

Bilinç problemi “kolay problem” ve “zor problem” olarak ikiye ayrılmaktadır (Chalmers, D. J., 2017). Kolay problem, beynin duyuşal verileri işleme, entegrasyon ve davranış üretme mekanizmalarını incelemeyi kapsamaktadır. Bu yaklaşım, bilincin empirik olarak gözlemlenebilen fonksiyonel özellikleri ve kapasiteleri üzerine odaklanmaktadır. "Bilincin Zor Problemi", beyindeki fiziksel süreçlerin zihinsel ve çevresel deneyimleri nasıl meydana getirdiğini inceleyen temel bir araştırma alanıdır. Beyin, yaklaşık 84 milyar nöronun koordineli bir şekilde çalıştığı son derece kompleks bir organdır. Görsel algı sürecinde, ışık uyarımları retinaya ulaştığında, optik sinir aracılığıyla beynin görsel merkezlerine iletilmekte, buradan da nöral ağlar boyunca yayılarak davranışsal tepkilerin oluşmasını sağlamaktadır. Bilince ilişkin dört önemli teori bulunmaktadır. Bunlar, Yüksek Düzeyli Teoriler (Higher Order Theories), Küresel Çalışma Alanı Teorileri (Global Workspace Theory), Entegre Bilgi Teorisi (Integrated Information Theory), Yeniden Giriş ve Öngörücü İşleme Teorileridir (Re-entry and Predictive Processing Theories).

Yapay zeka sistemlerinin bir bilinç oluşturabilmesinin mümkün olup olmadığıyla ilgili yoğun bilimsel tartışmalar sürmektedir. Mevcut durumda, gelişmiş üretken yapay zeka sistemleri, kapsamlı veri kaynakları ve sofistike makine öğrenimi algoritmalarını kullanarak orijinal kaynak verilerden anlamlı çıktılar üretmektedir. Üretken yapay zeka teknolojisi, eğitim verilerindeki örüntüleri ve yapısal özellikleri analiz ederek metin, görsel ve çeşitli medya formatlarında yeni içerikler oluşturma kabiliyetine sahiptir. Bu sistemlerin içerik üretim metodolojisi, yapılandırılmış bir öngörü mekanizmasına benzer şekilde çalışmaktadır (Johnson A. T., 2024).

Yapılan birçok çalışmada, insanın bilinçli deneyiminin zaman içinde ve zamansal periyotlar şeklinde bütünleşik bir yapı oluşturduğu görülmüştür. Zaman içinde ve zamansal olarak genişleyen fenomenlerin bilinçli algısını oluşturan deneyimler yaşıyor gibi görünmekteyiz (Butlin vd., 2023; Kaku, 2014). Bir yapay zekanın bilinç sahibi olup olmadığına ilişkin bazı göstergelerin belirlendiği araştırmalar bulunmaktadır (Li vd., 2021). Gelecek öngörüsü yapan bu çalışmalar, bilincin zamansallık olgusunu modellemektedirler.

Derin öğrenme algoritmalarının altyapısını oluşturan yapay sinir ağları insan beynindeki nöral yapılardan esinlenerek geliştirilmiştir. Bu gelişimin tarihsel sürecinde önemli bir dönüm noktası, 1958'de Frank Rosenblatt'ın beyindeki nöronal yapıları modellediği perceptron sinir ağıdır. Perceptron öğrenme algoritması, bir yapay sinir ağının insanlardaki öğrenmeye benzer bir şekilde girdilerle çıktıları ilişkilendirmeyi öğrenmesini sağlamıştır (Rosenblatt, 1958).

Perceptronlar ve genel olarak sinir ağları, işlevsel ve yapısal açıdan insan belleğiyle birçok yönden benzerlik taşımaktadırlar (Zou, 2022). Son birkaç yıldan beri araştırmacılar, biyolojik sinir ağındaki temel bağlantıların insan beyni işlevlerini nasıl açıkladığını anlamaya çalışmaktadırlar (Bessadok vd., 2023). Bir yapay sinir ağı türü olan ve düğüm-kenar ilişkilerinin modellenmesi ile oluşan Grafik Sinir Ağları (GNN), bu işlevlerin anlaşılmasında önemli bir rol üstlenmektedir (Tanis J. H., 2024).

Son zamanlarda, bilgi grafiklerinin makine öğrenimi ve derin öğrenme teknikleriyle işlenmesine yönelik araştırmalar, grafik ağlarıyla anlam düzeyi yüksek çıktılar elde edilebilmesi nedeniyle giderek daha fazla ilgi görmektedir. Grafik ağlar, çeşitli alanlarda (ör. sosyal bilimler, doğa bilimleri, fiziksel sistemler) çok sayıda sistemin açıklanabilmesi amacıyla kullanılabilmektedir. Grafik Sinir Ağları (GNN) kullanılarak gerçekleştirilen grafik analizleri, düğüm sınıflandırması, bağlantı tahmini ve kümeleme gibi görevlere odaklanmaktadırlar. Tatmin edici performansı nedeniyle, GNN son zamanlarda yaygın olarak uygulanan bir grafik analiz yöntemi haline gelmiştir (Zhou vd., 2020). Bilgi grafiklerinin en temel birimi olan düğümlerden (Başlık-iliski-kuyruk) oluşan standart bilgi grafiklerine zaman boyutu da dahil edilerek zaman içinde varlıkların ve ilişkilerin dinamiklerinin modellendiği zamansal bilgi grafikleri (Temporal Knowledge Graphs)

elde edilmektedir (Li Caia vd., 2024). Bu grafikler sayesinde bilginin zaman içinde evriminin temsilleri oluşturulabilmekte ve bu temsillerle gelecek tahminleri yapılabilmektedir. İnsan beyninin nöral yapısının bu zamansal grafik ağlarıyla modellenmesinin bilinç probleminin aydınlatılmasına bir kapı aralayacağı ve bilinçle ilişkili karmaşık bilişsel süreçlerin zamansal örüntüler aracılığıyla daha nesnel bir biçimde incelenmesini mümkün kılacağı öngörmekteyiz (Butlin, 2023). Ancak bu yaklaşımın, bilinç gibi çok katmanlı ve öznel bir olgunun yalnızca nöral örüntülerle temsil edilip edilemeyeceği sorusunu da beraberinde getirdiği unutulmamalıdır.

Zamansal bilgi grafiklerinin ortaya çıkması, araştırmacıların zamansal bilgi grafiği temsil öğrenmesine olan ilgisini artırmıştır. Elde edilen vektör temsilleri, varlıkların ve ilişkilerin dinamiklerini zaman içinde modellemekte ve böylece zaman farkında bilgi muhakemesi gerçekleştirilebilmektedir. Bu modeller, varlık, ilişki ve zaman tahmini yaparak gelecek öngörülerini gerçekleştirebilmektedir (Li vd., 2024). Gelecek simülasyonu yapan bir yapay zeka, geleceği tahmin etme, belirsizlikleri modelleme ve olasılık hesaplamaları yapma yetisiyle insanlığın bilimsel, teknolojik ve felsefi sınırlarını genişletebilecektir. Bu tür bir sistem, uzay keşiflerinden küresel kriz yönetimine, sürdürülebilir şehir planlamasından biyomedikal araştırmalara kadar birçok alanda insanlığın karar alma süreçlerini destekleyebilecektir (Jiang vd., 2023). Özellikle, geleceğin olasılıklarını değerlendirerek en optimal senaryoları sunabilecek, krizleri öngörerek proaktif çözümler üretebilecek ve yeni bilimsel keşiflerin önünü açabilecektir (Nasseri vd., 2008).

Bu çalışmada, belirtilen özellikleri taşıyan ve farklı yöntemler kullanan “Evrimsel Temsil Öğrenmesine Dayalı Zamansal Bilgi Grafiği Muhakemesi” (RE-GCN/ERL) (Zixuan Li vd., 2015) ve “Tarihsel Karşıtlıklı Öğrenme ile Zamansal Bilgi Grafiği Muhakemesi” (CENET) (Yi Xu vd., 2022) üzerinde çalışılmıştır. Bu iki model dışında belirli bir algoritma kullanılarak iki modelin bütünleştirildiği yeni bir hibrit model oluşturulmuştur. Üç modelin test ve doğrulama performansları ölçülmüş olup karşılaştırılmalı analizleri yapılmıştır.

2. KURAMSAL TEMELLER

2.1 Bilinç ve Bilinç Problemi

Christopher Koch (2018) bilince dair “hayatı deneyimlediğimiz görüntüler, sesler ve diğer duyumlar, posterior korteks içindeki bölgeler tarafından üretiliyor gibi görünüyor. Bildiğimiz kadarıyla, neredeyse tüm bilinçli deneyimlerin kökeni oradadır” ifadelerini kullanmaktadır. Buradan yola çıkarak bilinci, kafanıza takılan melodi, çikolatalı kekin tatlılığı gibi her gün deneyimlediğimiz, farkındalığımızı ve hayatlarımızın deneyimini oluşturan şeylerin tamamı olarak ifade edebiliriz. Bununla birlikte bilinç, düşüncelerimizin, anılarımızın, hislerimizin, duyumlarımızın ve ortamlarımızın bireysel farkındalığıdır (Koch, 2018). Psikologlar ve sinir bilimciler bilincin açıklığa kavuşturulamamış yönlerini uzun zamandır araştırmaktadırlar, ancak bu problemin çözümüne ilişkin yaklaşım konusunda hala çok fazla tartışma bulunmaktadır.

David Chalmers, bilinç problemini “kolay problem” ve “zor problem” olarak ikiye ayırmaktadır. Kolay problem, bilincin nöral sistemle olan ilişkilerini veya NCC (Neural Correlates of Consciousness)'leri içermektedir (Rosen vd., 2015). Bu, belirli bilinçli deneyimler yaşadığımızda beynin ne yaptığıyla ilgilidir. Zor problem ise deneyimle ilgilidir. Birçok organizmanın öznel deneyimlere sahip olduğuna inanılır, ancak bunların ortaya çıktığı kesin mekanizmalar derin bir bilimsel gizem olmaya devam etmektedir. Görsel veya işitsel bilgiler gibi duyuşal girdilerin işlenmesinin renk veya ses gibi duyumlar ürettiğini kabul etsek de belirli sinirsel aktivitenin neden bu içsel, hissedilen deneyimlere yol açmakta olduğu gibi temel bir soru cevapsız kalmaktadır. Bilincin biyolojik süreçlerde kök salmış fiziksel bir temele sahip olduğu konusunda geniş bir fikir birliğine rağmen, fiziksel aktivitenin zengin içsel deneyim dokusuna nasıl dönüştüğüne dair anlayışımız sınırlı kalmaktadır. Bilgideki bu ilgi çekici boşluk, bilincin doğasına ilişkin anlayışımızı zorlamaktadır ve fiziksel beyin ile öznel farkındalık arasındaki karmaşık ilişkiye dair daha fazla araştırmaya davet etmektedir (Rosen vd., 2015).

2.2 Bilinç Teorileri

Modern bilinç biliminin ilk dönemlerinde, araştırmacılar bilinçli deneyimin çeşitli yönleri ile beyin aktivitesinin özellikleri arasındaki deneysel ilişkileri belirlemeye odaklanmışlardı. "Bilincin sinirsel ilişkileri" arayışı, kısmen 20. yüzyılın büyük bir bölümünde yaygın bir kanı olan bilincin bilimin tamamen kapsamı dışında kaldığı yönündeki endişelere bir yanıt olarak ortaya çıkmıştı. Ancak birçok başarısına rağmen, bu yaklaşım sınırlıdır çünkü ne kadar çok ilişki tanımlarsanız tanımlayın, ilişkiler birer açıklama değildir. Ancak son yıllarda, bilince dair nörobiyolojik teorilerde bir artış yaşandı. Bu, alanın giderek olgunlaştığının bir işaretidir, çünkü deneysel bulgular ancak bir teori çerçevesinde ele alındığında bilince dair tatmin edici bir anlayış sunabilir.

2.2.1 Entegre bilgi teorisi

Entegre Bilgi Teorisi (Integrated Information Theory, IIT), bilinçli deneyimin doğasına ilişkin nüanslı bir bakış açısı sunarak, onun içsel, yapılandırılmış ve birleşik niteliklerini vurgulamaktadır. IIT'ye göre, deneyimler doğası gereği kesindir ve yalnızca bağımsız bileşenlere indirgenememektedir. Teori, deneyimin her bir yönünün, genellikle Bilincin Fiziksel Altyapısı (Physical Substrate of Consciousness) olarak adlandırılan, altta yatan fiziksel alt yapının doğasında bulunan nedensel özelliklere doğrudan karşılık geldiğini ileri sürmektedir (Tononi, Boly, Massimini, & Koch, 2016). Bu özelliklerin bilinçli deneyime yol açması için, sistem içindeki diğer unsurları etkilemelerini ve onlardan etkilenmelerini sağlayan güçlü bir neden-sonuç gücüne sahip olmaları gerekmektedir. Bu etkileşim, bilinçli farkındalığın zengin dokusunu destekleyen belirli, entegre ve birleşik bir yapı ile sonuçlanır ve fiziksel süreçlerin deneyime nasıl yol açtığına dair kapsamlı bir anlayışı teşvik etmektedir (Tononi et al., 2016).

Entegre Bilgi Teorisi'nin temel ilkesi, bilinçli deneyimin, dışarıdan doğrulamaya ihtiyaç duymadan doğrudan kendisine tezahür ettiği için içsel olarak var olduğunu ileri sürmektedir (Tononi vd., 2016). Bu içsel varoluş, bilinci gerçekliğin temel bir yönü olarak tanımanın önemini vurgulamaktadır. Bunu tamamlayan teorinin varsayımı, bu tür deneyimden sorumlu fiziksel alt yapının, genellikle Bilincin Fiziksel Altyapısı olarak

kavramsallaştırılan, aynı zamanda içsel varoluşa sahip olması gerektiğini vurgulamaktadır. Özellikle, kendi içinde neden-sonuç etkileşimleri için kapasiteye sahip olmalı ve kendi kendini sürdüren bir dinamik oluşturmalıdır. Özünde, bir sistemin gerçekten fiziksel olması için, hem etkileme hem de etkilenme yeteneğini göstermeli ve fiziksel gerçekliğinin temelini oluşturan karşılıklı bir nedensel ilişkiyi somutlaştırmalıdır (Tononi et al., 2016).

Bir nöron, gelen sinyaller tarafından şekillendirilen çeşitli durumlar aracılığıyla varlığını sürdürmekte ve karşılığında diğer nöronları etkilemektedir. İki nöron birbirine bağlandığında, karşılıklı etkileşimler yoluyla karşılıklı etki edebilen temel bir sistem kurmaktadır. Bu karşılıklı ilişki, yalnızca aktivitelerini sürdürmekle kalmaz, aynı zamanda bu tür minimal sistemlerin içsel varoluş için gerekli kriterleri nasıl karşılayabileceğini örnekleyerek karmaşık ağlar içindeki sinirsel bağlantının karmaşık ve dinamik doğasını vurgulamaktadır (Pautz, 2019).

Entegre Bilgi Teorisi, bilinci anlamak için karmaşık bir matematiksel çerçeve sunarak bir sistem içindeki bilgi entegrasyonunun önemini vurgulamaktadır. Bu teorinin merkezinde, entegre bilginin derecesini ölçen Phi olarak bilinen ölçü yer almaktadır. Yüksek bir Phi değeri, sistemin daha zengin bir bilinçli deneyimle ilişkili olarak yüksek bir entegrasyon seviyesine sahip olduğunu göstermektedir. Tersine, sıfır Phi, böyle bir entegrasyonun eksikliğini gösterir ve bilincin yokluğunu ima etmektedir. Bu yaklaşım, bilinçli fenomenlerin doğası hakkında değerli içgörüler sağlar ve sinirbilim, yapay zeka ve felsefe genelinde önemli çıkarımlara sahiptir.

2.2.2 Küresel çalışma alanı teorisi

Küresel Çalışma Alanı Teorisi (Global Workspace Theory, GWT), sinir sistemini her biri bilginin kusursuz bir şekilde bütünleşmesine katkıda bulunan, paralel işlemcilerden oluşan karmaşık bir ağ olarak kavramsallaştırmaktadır (Baars, 1997). Çevresel sensörler, sürekli olarak ortamdan veri toplar ve bunları bu sinyalleri analiz eden ve yorumlayan merkezi işlem birimlerine iletmektedir. Gelen sayısız bilgi arasında, belirli veriler (özellikle de yüksek öneme sahip olanlar) dinamik ve geçici bir bellek alanı olan Küresel Çalışma Alanına erişim kazanmaktadır. Bu paylaşılan çalışma alanında, kritik bilgiler

çeşitli işlemciler arasında dağıtılmakta ve koordineli yanıtlar ve etkili eylemler kolaylaştırılmaktadır. Bu çerçevede, sinirsel işlemenin işbirlikçi doğasını vurgulamakta ve bilinçli farkındalık ve karar alma süreçlerinin kapsamlı bir şekilde anlaşılmasını teşvik etmektedir (Signa vd., 2021).

Küresel Çalışma Alanı Teorisi, bilinci, dikkatin bir spot ışığı işlevi gördüğü, altta yatan bilinçdışı süreçleri ustalıkla aydınlatıp farkındalığa getirdiği ve böylece çeşitli bilişsel işlevler arasında iletişimi ve bütünleşmeyi kolaylaştıran büyük bir sahneye benzetmektedir. Sahne, bilincin bir metaforu olarak hizmet etmekte ve yalnızca spot ışığıyla aydınlatılan olayları odak noktasına getirmektedir. Bir oyun yazarı ve sahne düzenleyicileri tarafından yönetilen bu aydınlık alanda konumlandırılan oyuncular, bilinçli deneyimimizin yönlerini canlandırmakta ve gelişen anlatıya aktif olarak katılmaktadırlar. Bu arada, sahne arkasında, bilinçsiz sistemlerin karmaşık bir ağı sessizce ama derinlemesine çalışmaktadır. Görünür olayları şekillendirmekte ve etkilemektedir. Bu sahne arkası süreçleri, daha geniş bilinçsiz rutinlere ve bilgi rezervuarlarına hayati mesajlar iletmekte ve bunlar da bilinçli farkındalığımızı desteklemekte ve düzenlemektedir. Bu dinamik etkileşim, insan zihnindeki bilinçli algı ve bilinçsiz temel arasındaki karmaşık uyumu vurgulamaktadır (Baars, 1997).

Bilinç, küresel çalışma alanının bellek sistemiyle yakından bağlantılı olduğu görünmekte ve bilgileri bütünleştirmek için bir merkez görevi görmektedir. Buna karşılık, bilinçsiz süreçler, bu paylaşılan çalışma alanına erişmek için sürekli olarak rekabet eden uzmanlaşmış, otomatik işlemciler aracılığıyla çalışmaktadır. Sonunda galip gelen işlemci, mevcut hedeflerle, duygusal durumlarla veya bağlamsal taleplerle en uyumlu şekilde hareket ederek bunu yapmakta ve böylece sonraki eylemleri yönlendirmektedir. Bu bilinçsiz mekanizmalar, duygusal girdileri ayrıntılı olarak işlemede ve bilinçli farkındalık altında karmaşık bilgileri işlemede hayati bir rol oynamaktadır. Bunların çalıştırılması, alaka, öncelik ve öğrenilmiş kalıplar dahil olmak üzere çeşitli faktörlerden etkilenmekte ve dinamik bir ortamda verimli ve uyarlanabilir işleyişi garanti etmektedir. Küresel Çalışma Alanı için bilinçsizce işlenen bilgilerin uygunluğu, çeşitli bilişsel işlevler arasındaki iş birliği ve rekabet arasındaki dinamik etkileşimi yansıtarak değişmektedir. Küresel Çalışma Alanı Teorisi, farklı bilinçsiz işlemcilerin birlikte çalışmasını ve etkili bir şekilde rekabet etmesini sağlayarak bu süreci kolaylaştırmakta ve böylece izole

edilmiş bilinçsiz işlemenin ötesine uzanan alışılmadık veya karmaşık sorunları ele alma yeteneğimizi artırmaktadır. Bu işbirlikçi yaklaşım, uyarlanabilir ve yenilikçi sorun çözme desteklemektedir (Signa vd., 2021).

2.2.3 Yüksek düzeyli teoriler

Bilincin Yüksek Dereceli Teorileri (Higher-Order Theories, HOT), dış nesnelerin doğrudan algılarını içeren yalnızca birinci derece temsillerin bilinçli deneyimi tam olarak açıklamak için yetersiz olduğunu öne sürmektedir. Bunun yerine, HOT'lar farkındalık duygusu yaratan bu birinci derece durumlar hakkındaki düşünceler veya algılar gibi ek yüksek dereceli mekanizmaların gerekliliğini vurgulamaktadır. Birinci derece durumlar tepkileri ve çevreyle etkileşimleri yönlendirmek için gerçekten temel olsa da, HOT'lar bu durumların bilinçli farkındalık yaratmadan bilinçsizce meydana gelebileceğini öne sürmektedir. Bilinçli deneyimin zenginliğini ve şeffaflığını nihayetinde sağlayan, bilincin doğasına dair nüanslı bir anlayışı vurgulayan yüksek dereceli süreçlerin etkileşimidir. HOT'un bu gereksinimi, onu yinelemeli işleme teorileri gibi birinci dereceden teorilerin yerel varyantlarından ayıran bir özelliktir (Brown vd., 2019).

Bu teorinin ikinci gereksinimi, bir bireyin bilinçli olarak nitelendirilebilmesi için birinci dereceden bir zihinsel durumun farkındalığına sahip olması gerektiğini ileri sürmektedir. Bu kavram Geçişlilik İlkesine dayanır. Bu ilke, bilinçli deneyimin kişinin devam eden zihinsel süreçlerinin içsel bir tanınmasını veya meta-temsili içerdiğini vurgulamaktadır. Temel olarak yaygın bilişsel işleme ve bilgi erişilebilirliğinin rolünü, zorunlu olarak içsel farkındalık gerektirmeden vurgulayan Küresel Çalışma Alanı Teorisi'nin aksine, HOT perspektifi minimal bir içsel izleme biçiminin önemini vurgulamaktadır. Bu içsel izleme, bilincin bir bireyin kendi zihinsel durumlarının farkında olma kapasitesinden kaynaklandığını, hatta yalnızca temel düzeyde bile olsa, öne sürerek önemli bir farklılaştırıcı faktör olarak hizmet etmektedir. İçsel farkındalığa böyle bir odaklanma, HOT çerçevesini tamamen bilişsel modellerden ayırmakta ve bilinçli deneyimin öznel boyutunu vurgulamaktadır (Brown vd., 2019).

Hem HOT hem de Küresel Çalışma Alanı Teorisi, yalnızca erken duyuşsal temsillerin bilinçli deneyimi açıklamak için yeterli olmadığını öne sürmektedir. Bunun yerine, bilinci

ortaya çıkarmak için ek bilişsel süreçlerin gerekli olduğunu öne sürmektedirler. HOT, algısal durumlarımız hakkındaki düşüncelerimiz olan yüksek düzey farkındalığın önemini vurgularken, GWT yaygın bir sinirsel çalışma alanı içindeki duyuşal sinyallerin yükseltilmesine ve sabitlenmesine odaklanmaktadır. Özellikle, GWT bilinci bilginin küresel yayınına attığı için birinci dereceden bir teori olarak kabul edilirken, HOT ikinci dereceden, yansıtıcı bir farkındalığı vurgulamaktadır. Her iki çerçeve de bilincin karmaşık doğasına dair değerli içgörüler sunmaktadır (Brown vd., 2019).

2.2.4 Yeniden giriş ve öngörücü işleme teorileri

Bilinç araştırmaları alanında, iki önemli yaklaşım yukarıdan aşağıya sinyalleme­nin önemini vurgulamaktadır. Yeniden giriş teorileri, bilinçli algının özellikle sinir devreleri içindeki tekrarlayan sinyallemeden kaynaklandığını öne sürerek sürekli geri bildirim döngülerinin önemini vurgulamaktadır. Buna karşılık, öngörücü işleme teorileri daha kapsamlı bir çerçeve sunarak beynin hiyerarşik işlevlerinin (tahmin ve hata düzeltme dahil) toplu olarak bilinçli deneyimi şekillendirmeye ve bilgilendirmeye hizmet ettiğini öne sürmektedir (Seth, A., & Bayne, T., 2022).

Öngörücü İşleme Teorileri, bilinçli deneyimlerimizin nasıl oluşturulduğuna dair ayrıntılı bir anlayış sunmaktadır. Yerel bilinçli durumların temelde yukarıdan aşağıya algısal öngörüler tarafından şekillendirildiğini öne sürmektedirler; beyin bu öngörülerini duyuşal girdinin nedenlerine ilişkin en iyi hipotezleri olarak görmektedir. Bu öngörüler deneyimsel niteliklerimizi etkiler, etrafımızdaki dünyayı nasıl algıladığımızı ve yorumladığımızı şekillendirmektedir. Örneğin, nesneleri algı­larken beyin beklenen duyuşal sonuçlar hakkında tahminler üretmekte ve bu da verimli tanıma ve etkileşimi kolaylaştırmaktadır. Benzer şekilde, duyuşal deneyimler, fizyolojik süreçleri düzenlemeye yardımcı olan ve öznel hislerimize katkıda bulunan içsel algı tahminlerine yakından bağlıdır. Bu çerçeve, duyuşal bilgi ile öngörücü modeller arasındaki dinamik etkileşimi vurgulamakta ve bilincin devam eden sinirsel hipotezlere dayanan aktif, çıkarımsal bir süreç olduğu yönünde kapsamlı bir görüş geliştirmektedir (Seth, 2022).

Öngörücü işleme, algının duyuşal girdiler hakkında bir 'en iyi tahmin' üretmeyi içerdiğini varsayarak bilinçli ve bilinçsiz durumlar arasındaki ayrımı anlamak için ikna edici bir

çerçeve sunmaktadır. Bu paradigmada, beyin sürekli olarak ikili rekabet süreci yoluyla çevre hakkında rekabet eden hipotezleri değerlendirmektedir. Algılama sırasında, birden fazla olası yorum baskınlık için yarışmakta ve biriken tahmin hatası (beklenen ve gerçek duyuşal sinyaller arasındaki tutarsızlıklar) algısal bir geçişi gerektirene kadar bir hipotez hakim olmaktadır. Bu devam eden döngü, mevcut hipotez tarafından üretilen duyuşal sinyallerin tutarlılık açısından değerlendirilmesini sağlar ve bu sinyaller önemli bir hata ürettiğinde, alternatif bir yoruma geçiş gerçekleşmektedir. Önemlisi, bilinçli algısal değişimin yalnızca bu inanç güncellemelerine eylem eşlik ettiğinde ortaya çıktığına inanılmaktadır (göz hareketleri gibi açık veya içsel bilişsel kaymaları içeren gizli). Bu da belirsizliği çözmeye ve algıyı iyileştirmeye yaramaktadır. Bu dinamik etkileşim, eylemin ve inanç güncellemesinin, öngörücü bir çerçeve içinde bilinçli deneyimi şekillendirmedeki bütünleştirici rolünün altını çizmektedir (Seth, 2022).

2.2.5 Uzay-Zaman teorisi ve bilincin seviyeleri

Michio Kaku'nun (2014) "Uzay-Zaman Teorisi", bilincin doğası hakkında ikna edici bir bakış açısı sunarak, onu sıcaklık, uzay ve zaman gibi çeşitli parametrelerde çalışan çoklu geri bildirim döngüleri aracılığıyla çevrenin zihinsel modellerini oluşturmanın karmaşık bir süreci olarak çerçevelemektedir. Bu geri bildirim mekanizmaları temel bir amaca hizmet etmektedir: organizmaları yiyecek veya barınak sağlama gibi temel hedeflere ulaşmaya yönlendirmektir. Bu bağlamda, bilinç, dış dünyanın içsel temsilini sürekli olarak uyarlayarak ve etkili bir şekilde hayatta kalarak iyileştiren dinamik bir sistem olarak görülebilmektedir.

Kaku'nun (2014) görüşlerine göre, her biri bir organizmanın bilgiyi işleme ve uyarlanabilir şekilde yanıt verme kapasitesindeki artan karmaşıklığı ve karmaşıklığı temsil eden dört farklı bilinç seviyesini tasvir etmektedir. Temel seviye olan Seviye 0, termostatlar veya bitkiler gibi basit organizmaları kapsamaktadır. Bu varlıklar temel geri bildirim döngülerini göstermektedir. Termostatlar sıcaklığı sensör girdisine göre düzenlerken, bitkiler büyüme modellerini ışığa veya yerçekimine yanıt olarak ayarlamaktadır. İlkel olsalar da, bu mekanizmalar bilincin temel bir birimi olan çevresel uyaranlara geri bildirim odaklı bir şekilde yanıt verme yeteneğini örneklendirmektedirler.

Seviye I'e doğru ilerlerken, sürüngenler gibi hareket kabiliyeti ve merkezi sinir sistemi olan organizmalarla karşılaşmaktadır. Bu canlılar, hareketi koordine etmek, tehditleri tespit etmek ve kaynak aramak için duyuşal bilgileri entegre ederek daha geniş bir geri bildirim döngüsü dizisini yönetmektedir. Bu seviye, organizmanın yalnızca çevresini algılamakla kalmayıp aynı zamanda birbiriyle bağlantılı geri bildirim süreçleri ağı aracılığıyla onunla aktif olarak etkileşime girmesi nedeniyle karmaşıklıkta önemli bir sıçramayı yansıtmaktadır (Kaku, 2014).

Seviye II bilinci, organizmaların başkalarıyla ilişkilerinin modellerini geliştirdiği sosyal farkındalığı ortaya çıkarmaktadır. Bazı memeliler ve sosyal böcekler de dahil olmak üzere bu tür yaratıklar ittifaklar kurabilmekte, tehditleri tanıyabilmekte ve karmaşık sosyal dinamiklerde gezinebilmektedir. Bu davranışlar, organizmanın etkileşimleri ve hayatta kalma stratejilerini optimize etmek için aynı anda birden fazla sosyal ve çevresel bilgi akışını işlemesi gerektiğinden, katlanarak daha fazla geri bildirim döngüsü içermektedir (Kaku, 2014).

Olağanüstü bilişsel kapasiteleriyle öne çıkan insanlar, bilincin Seviye III'ünde bulunur. Dünyadaki yerlerinin karmaşık modellerini oluşturarak gelecekteki olayları anlama ve tahmin etme konusunda dikkate değer bir yeteneğe sahiptirler. Bu, yalnızca geçmiş deneyimleri bütünleştirmeyi değil, aynı zamanda zaman içinde olası sonuçları simüle etmeyi, stratejik planlama ve öngörüye olanak sağlamayı da içermektedir. Bu tür gelişmiş bilinç, insanların geçmiş eylemleri değerlendirmesini, gelecek senaryolarını tahmin etmesini ve bilinçli kararlar almasını sağlamakta ve böylece birden fazla parametrede karmaşık geri bildirim sistemlerinde derin bir ustalık göstermektedir (Kaku, 2014).

Özünde, Kaku'nun çerçevesi, insan deneyimini karakterize eden olağanüstü bilişsel yeteneklerle sonuçlanan, her seviye bir öncekinin üzerine inşa edilen, geri bildirim odaklı süreçlerin evrimleşen bir hiyerarşisi olarak bilincin nüanslı bir görünümünü sunmaktadır.

2.3 Yapay Sinir Ağları ve Biyolojik Sinir Ağları

İlk olarak 1944'te Warren McCulloch ve Walter Pitts tarafından önerilen Yapay Sinir Ağları, insan beyninin işlevi ve yapısından esinlenerek tasarlanmış makine öğrenimi

modelleridir. Karmaşık sorunları ele almak için iş birliği yapan birbirine bağlı düğümlerin veya nöronların oluşturduğu ağlardır. Yapay Sinir Ağlarını oluşturan düğümler (yapay nöronlar) "katmanlar" halinde düzenlenmiştir. Bilgi bu düğümlerden akmakta ve ağ, verilerden öğrenmek için eğitim sırasında bağlantı güçlerini temsil eden "ağırlıkları" ayarlar, bu da desenleri tanımasını, tahminlerde bulunmasını, makine öğrenimi ve yapay zeka uygulamalarında çeşitli problemleri çözmesini sağlamaktadır. Tek bir katmandan, katmanlar halinde düzenlenmiş birbirine bağlı düğümlerin (nöronların) oluşturduğu çok katmanlı bir yapıya kadar değişim gösterebilmektedir.

2.3.1 Yapay sinir ağları

Yapay sinir ağları, nöronlar olarak adlandırılan düğümlerin birbirine bağlı düzenlemesi yoluyla insan beyninin işlevsel mekanizmalarını taklit etmek üzere tasarlanmış karmaşık hesaplama çerçeveleridir. Biyoloji biliminden ilham alınan bu sistemler, çeşitli uyaranlara yanıt olarak uyum sağlayan ve kendini organize eden insan öğrenme süreçlerinin özünü kapsayan basitleştirilmiş modeller olarak hizmet etmektedir. Sinir ağları, doğası gereği karmaşık olsa da çeşitli çevresel girdileri işleyerek kalıpları tanımlarını, kararlar almalarını ve zamanla performansı iyileştirmelerini sağlamaktadırlar. Öğrenme yeteneklerini kolaylaştırmak için paralel işleme ve sinaptik ağırlıklandırma gibi beyindeki sinirsel aktivitelerden alınan metaforları kullanılmaktadırlar. Sonuç olarak, yapay sinir ağları, bilişsel işlevlere ilişkin anlayışımızı derinleştirmeye devam ederken yapay zeka, veri analizi ve otonom sistemler gibi alanlarda ilerlemeleri teşvik ederek çok sayıda alanda paha biçilmez araçlar haline gelmiştir (Bhari, P. L. 2016).

Yapay sinir ağları (YSA), bilgi işlemenin karmaşık modellemesi yoluyla insan düşünce süreçlerinin karmaşıklıklarını taklit etmeye çalıştıkları için yapay zeka alanında önemli bir ilerlemeyi temsil etmektedir. Biyolojik sinir ağlarını yansıtmak üzere tasarlanan YSA'lar, dendritler, aksonlar, soma ve miyelin kılıflarına benzer yapısal bileşenlere sahip, elektriksel uyarıların iletilmesini kolaylaştıran birbirine bağlı düğümlerden veya "nöronlardan" oluşmaktadır. Bu mimari, YSA'ların karmaşık görevleri olağanüstü bir verimlilikle gerçekleştirmesini sağlayarak onları dil işleme, görüntü tanıma ve karar alma

sistemleri gibi çeşitli uygulamalarda paha biçilmez araçlar haline getirmektedir. Çok miktarda veriyi hızlı ve doğru bir şekilde analiz etme kapasiteleri, insan benzeri işlevlere sahip makineler geliştirmedeki önemlerini vurgulamaktadır. Bununla birlikte, bu sistemler günlük yaşama daha fazla entegre hale geldikçe, insan bilişle etkileşimleri ve olası etik etkileriyle ilgili sorular doğal olarak ortaya çıkmaktadır. YSA'ların devam eden gelişimi, teknolojiyi ve toplumu derinden etkileyebilecek yenilikler vaat ederken daha geniş etkilerinin dikkatli bir şekilde değerlendirilmesini gerektiren etkili ve dinamik bir alan olmaya devam etmektedir (Bhari, 2016).

2.3.2 Yapay sinir ağları ve biyolojik sinir ağları ilişkisi

Sinir ağları, nöronların karmaşık işlevleri kolaylaştırmak için elektrokimyasal sinyaller aracılığıyla iletişim kurduğu insan beyninin karmaşık ve son derece birbirine bağlı nöron sisteminden ilham almaktadır. İç bellek yapıları biyolojik muadilleriyle aynı olmasa da, yapay sinir ağları beynin desen tanıma ve veri işleme yoluyla öğrenme ve uyum sağlama konusundaki olağanüstü yeteneğini taklit etmek üzere tasarlanmıştır. Bu teknolojik yaklaşım, sinir ağlarının görüntü tanıma ve doğal dil işleme gibi belirli uzmanlaşmış görevlerde olağanüstü hız ve hassasiyetle insan performansını geride bırakmasını sağlayarak önemli ilerlemelere yol açmıştır. Bununla birlikte, yeteneklerinin belirli uzmanlık alanlarıyla sınırlı kaldığını kabul etmek önemlidir. Henüz insan bilişinin geniş, esnek ve bağlam farkında zeka özelliğine sahip değillerdir. Araştırma ilerledikçe, devam eden çabalar bu sistemlerin uyarlanabilirliğini genişletmeyi, daha kapsamlı ve çok yönlü yapay zeka çözümlerini teşvik etmeyi amaçlamaktadır (Bhari, 2016).


Nöronlar, düşüncelerimizi, algılarımızı ve eylemlerimizi destekleyen karmaşık bir ağı düzenleyerek insan beyninin ve sinir sisteminin temel yapı taşları olarak hizmet etmektedir. İnsan beyni, yaklaşık 10 milyar ile 500 milyar arasında olduğu tahmin edilen olağanüstü sayıda nöron içermektedir. Bu, karmaşık işleme ve adaptasyon için muazzam bir kapasiteyi yansıtmaktadır. Her nöron, aksonları aracılığıyla komşu nöronlarla yaklaşık 1.000 sinaps oluşturarak yüksek derecede birbirine bağlıdır ve bu kritik iletişim bağlantılarını kurmak için nöral ağda yayılmaktadır. Sinapslar, sinyallerin dendritlere iletildiği özel kavşaklar olarak işlev görür ve nöron için etkili bir şekilde giriş arayüzü

görevi görmektedir. Aksonlar, sinyalleri diğer nöronlara veya hedef dokulara ileten çıkış kanalları olarak işlev görmektedir. Önemlisi, bu sinaptik bağlantıların gücü sabit değildir; modüle edilebilmektedir. Beynin sinaptik etkinliği ayarlayarak öğrenme ve hafıza oluşumu gibi süreçler yoluyla uyum sağlamasını sağlamaktadır. Nöronlar, öncelikle çevremizden gelen duyuşal girdiyi işleyen erken katmanlardan başlayarak, muhakeme, karar verme ve bilgi bütünleştirme gibi daha karmaşık işlevlerde yer alan daha yüksek katmanlara doğru ilerleyen katmanlı yapılar halinde organize edilmiştir. Bu son derece organize ve uyarlanabilir nöronal mimari, bilişsel yeteneklerimiz ve davranışsal tepkilerimiz için temel gereksinimdir (Bhari, 2016).

2.4 Bilgi Grafikleri

Yapay zeka alanında, insan uzmanlığının entegrasyonu problem çözme yeteneklerini geliştirmede hayati bir rol oynamaktadır. Varlıkları ve bunların karşılıklı ilişkilerini kapsayan gerçek bilgilerin yapılandırılmış temsilleri olan bilgi grafikleri, daha akıllı ve ayrıntılı sistem işlevlerini kolaylaştırma potansiyelleri nedeniyle dikkate değer bir ilgi görmüştür. Bu tür kapsamlı bilgi çerçevelerini dahil ederek, yapay zeka sistemleri bağlamı daha iyi anlayabilmektedir. Bilinçli kararlar alabilmekte ve karmaşık görevleri daha büyük doğruluk ve verimlilikle ele alabilmektedirler. Nihayetinde daha sofistike ve güvenilir akıllı çözümlerin geliştirilmesini ilerletebilmektedirler (Ji S. vd., 2021).

Bilgi grafiği yerleştirmedeki son gelişmeler, bilgi tamamlama, varlık tanıma ve ilişki çıkarma gibi çeşitli uygulamaları kolaylaştıran varlıkları ve ilişkileri düşük boyutlu vektörler olarak temsil etmeye odaklanmıştır. Bu bilgi farkında modeller, veri temsili derinliğini ve doğruluğunu artırmak için ontolojiler ve yapılandırılmış bilgi tabanları dahil olmak üzere çeşitli bilgi kaynaklarından etkili bir şekilde yararlanmaktadır. Bu zengin bilgi kaynaklarını entegre ederek, bu tür modeller çeşitli doğal dil işleme ve veri madenciliği görevlerinin sağlamlığını ve yorumlanabilirliğini iyileştirmeyi, daha akıllı ve bağlamsal olarak farkında sistemleri teşvik etmeyi amaçlamaktadır (Ji S. vd., 2021).



Şekil 2.1 Bir bilgi grafiğinde varlık ve ilişkilerle bilgi temsili

Bilgi Grafikleri (KG'ler), çeşitli ilişki türleri aracılığıyla birbirine bağlı çeşitli varlık düğümleri arasındaki karmaşık etkileşimleri modelleyen karmaşık ağlar olarak hizmet etmektedir. Bu grafikler, verileri RDF üçlülere olarak temsil ederek olgusal bilgileri etkili bir şekilde kapsüller, örneğin, "Springfield, Illinois'in başkentidir", böylece ilgili varlıklar arasında "capitalOf" gibi anlamlı bağlantılar kurmaktadır. Heterojen Bilgi Ağları olarak hareket eden KG'ler, hem düğümlerin hem de kenarların genellikle ek nitelikler ve bağlamsal bilgilerle zenginleştirildiği çok çeşitli varlık türlerini ve ilişki kategorilerini birleştirme ve yönetme yetenekleriyle ayırt edilmektedir. Bu yapısal çok yönlülük, KG'lerin semantik aramadan yapay zekaya kadar uzanan uygulamaları destekleyerek, birden fazla alanda gelişmiş veri entegrasyonunu, muhakemeyi ve almayı kolaylaştırmasını sağlamaktadır. Verilere ilişkin daha bağlantılı ve kapsamlı bir anlayışı teşvik ederek, Bilgi Grafikleri küresel olarak akıllı sistemleri ve bilgi yönetimi uygulamalarını ilerletmede hayati bir rol oynamaktadır (Baoxu S., 2018).

2.4.1 Bilgi grafiği tamamlama

Bilgi Grafiği Tamamlama (KGC), bilgi grafiklerinin içsel eksikliklerini etkili bir şekilde ele alarak onları iyileştirmede ve zenginleştirmede hayati bir rol oynamaktadır. KGC, karmaşık tahmin mekanizmaları aracılığıyla eksik veya hatalı ilişkileri belirlemekte ve düzeltmektedir. Böylece verilerin genel doğruluğunu ve güvenilirliğini artırmaktadır. Örneğin, grafikteki topolojik benzerlikleri ve kalıpları analiz ederek Indianapolis ve Indiana arasındaki "capitalOf" ilişkisini çıkarabilmektedir. Bu tür gelişmeler, daha kapsamlı ve anlamlı veri temsillerini kolaylaştırmaktadır. Çeşitli alanlarda gelişmiş karar alma ve bilgi keşfini desteklemektedir (Baoux S., 2018).

Word2vec gibi teknikler ve TransE, TransH ve TransR gibi modeller de dahil olmak üzere düşük boyutlu yerleştirmelerdeki ilerlemeler, bilgi grafiği tamamlama yeteneklerini önemli ölçüde artırmıştır. Bu yöntemler, varlıkların ve ilişkilerin daha etkili bir şekilde temsil edilmesini kolaylaştırmaktadırlar. Böylece karmaşık veri yapıları içinde daha doğru çıkarım ve bağlantı tahmini sağlamaktadır. Bu tür ilerlemeler, anlamsal anlayışı iyileştirme ve daha sağlam, akıllı bilgi sistemleri geliştirme konusundaki devam eden bağlılığın altını çizmektedir (Baoux S. 2018).

2.5 Grafik Sinir Ağları

Grafik Sinir Ağları (GNN'ler), birbirine bağlı verilerdeki karmaşık ilişkileri modellemek için güçlü bir araç sağlayarak makine öğreniminde devrim yaratmıştır. Yenilikçi yaklaşımları, geleneksel modellerin sıklıkla gözden kaçırdığı bağımlılıklar, bağlantılar ve kalıplar dahil olmak üzere yapısal bilgilerin etkili bir şekilde yakalanmasını sağlamaktadır. Bu yetenek, topluluk yapılarını ve etki yollarını anlamının çok önemli olduğu sosyal ağ analizi gibi çeşitli alanlarda yeni yollar açtı; GNN'lerin biyoloji çalışmalarında protein etkileşimlerini ve ilaç keşfini tahmin etmeye ve ayrıca siber ağ trafiğindeki kötü amaçlı faaliyetleri belirlemeye yardımcı olmaktadır. Sonuç olarak, GNN'ler yaygın bir şekilde benimsendi ve daha doğru tahminler ve karmaşık sistemlere ilişkin daha derin içgörüler elde etmek için potansiyeli önemli ölçüde genişletti.

Esneklikleri ve verimlilikleri, ilerlemeleri yönlendirmeye devam ederek onları modern veri biliminin ve yapay zekanın temel taşı haline getirmiştir (Khemani, 2024).

Bir grafik, düğümler kümesinden (köşeler olarak da bilinir) ve bu düğümler arasındaki bağlantılardan (kenarlar) oluşan temel bir veri yapısıdır. Genellikle $G = (V, E)$ olarak gösterilir; burada V , köşelerin toplamını ve E , kenarlar kümesini göstermektedir. Bu kenarlar, bir düğümden diğerine tek yönlü bir ilişkiyi gösteren “yönlendirilmiş” veya karşılıklı veya çift yönlü bir bağlantıyı gösteren “yönlendirilmemiş” grafik olabilmektedir. Bu esneklik, grafikleri çok sayıda gerçek dünya sistemini modellemek için oldukça çok yönlü hale getirmektedir. Örneğin, sosyal ağlar bireyler arasındaki ilişkileri tasvir etmek için grafikleri kullanırken, protein etkileşim ağları gibi biyolojik sistemler de karmaşık etkileşimleri anlamak için grafiklerle gösterilmektedirler. Öklid uzaylarının aksine, grafikler Öklid dışıdır, yani düğümler arasındaki mesafe kavramı geleneksel düz çizgi ölçümlerini takip etmemektedirler Bu karmaşıklık, görüntüler gibi Öklid verilerinde üstünlük sağlayan geleneksel sinir ağları için zorluklar sunmaktadır. Bunu aşmak için grafik sinir ağları (GNN'ler) geliştirilmiştir. GNN'ler, özel toplama işlevleri ve mesaj geçirme mekanizmaları aracılığıyla düğümler arasındaki ilişkileri ve bağımlılıkları birleştirerek grafik tabanlı verilerden etkili bir şekilde öğrenmektedir ve karmaşık ağ verileri üzerinde gelişmiş analiz ve tahmin olanağı sağlamaktadır (Khemani B. vd., 2024).

2.5.1 Grafik sinir ağları uygulamaları

Farklı gerçek dünya problemlerini çözmek için GNN'yi uygulayabileceğimiz çeşitli uygulamalar bulunmaktadır. Bu bölümde GNN'nin faydalarını ve GNN'yi uygulayabileceğimiz bazı alanlardan bahsedilmektedir.

1. Düğüm Sınıflandırması:

Her düğüme özelliklerine ve ilişkilerine göre belirli bir kategori veya etiket atanan grafik analizinde gerçekleştirilen temel bir görevdir. Bu tekniğin çeşitli alanlarda kapsamlı uygulamaları bulunmaktadır. Sosyal ağlarda, kullanıcı rollerini tahmin etmeye ve topluluk üyeliklerini belirlemeye yardımcı olmaktadır. İçerik

kategorizasyonunda, belgeleri, videoları ve web sayfalarını ilgili gruplara göre düzenlemektedir. Ayrıca, biyoenformatikte, düğüm sınıflandırması protein işlevlerini belirlemeye yardımcı olmaktadır. Biyolojik araştırmalardaki ilerlemelere ve karmaşık sistemlerin anlaşılmasına katkıda bulunmaktadır.

2. Bağlantı Tahmini:

Bağlantı tahmini, bir grafikteki iki düğüm arasında bir bağlantı olup olmadığını belirlemeyi içeren ağ analizinde kullanılmaktadır. Genellikle ikili bir sınıflandırma problemi olarak formüle edilen amaç, bir çift düğüm arasında bir kenarın varlığını veya yokluğunu tahmin etmektir. Bu süreç, görevin arkadaşlık, profesyonel işbirliği veya ailevi bağlar gibi bağlantının belirli doğasını belirlemek olduğu birden fazla ilişki türünü içeren daha karmaşık senaryoları ele almak için genişletilebilmektedir.

Bağlantı tahmininin uygulamaları çeşitli alanlarda yaygın ve etkilidir. Sosyal ağlarda, potansiyel arkadaşlıkları veya bağlantıları tahmin etmek için kullanılmaktadır ve platformların kullanıcılara yeni kişiler önermesine yardımcı olmaktadır. E-ticarete, bağlantı tahmini müşterileri muhtemelen ilgilenecekleri ürünlerle ilişkilendirerek ürün önerilerini kolaylaştırmakta ve böylece kişiselleştirilmiş alışveriş deneyimlerini geliştirmektedir. Ayrıca, aynı bireye veya varlığa atıfta bulunan farklı girdileri eşleştirerek yinelenen kayıtları çözme gibi veri temizleme görevlerinde de önemli bir rol oynamaktadır.

Biyoenformatikte, bağlantı tahmini olası ilaç-hedef etkileşimlerini belirlemeye, hastalıklar ve terapötik ajanlar arasındaki ilişkileri tahmin etmeye veya hastalıklar arasındaki benzerlikleri ortaya çıkarmaya yardımcı olmaktadır. Ayrıca, varlıklar arasında yeni ilişkiler keşfederek bilgi grafiklerini (gerçeklerin yapılandırılmış temsilleri) tamamlamada etkilidir. Bu da grafiğin bilgi içeriğini zenginleştirmekte ve daha iyi akıl yürütme ve çıkarımları desteklemektedir. Genel olarak, bağlantı tahmini karmaşık ağ verilerinin anlaşılmasını ve kullanımını geliştirmek için hayati bir araç görevi görmektedir.

3. Topluluk Tespiti:

Topluluk algılama algoritmaları, düğümleri benzerlik ölçütlerine göre gruplandıran ve genellikle gözetimsiz veya yarı gözetimli modlarda çalışan güçlü araçlardır. Bu yöntemler, karmaşık ağlar içindeki sosyal grupları, arkadaş kümelerini ve işlevsel modülleri tanımlamak için yaygın olarak kullanılmaktadırlar. Sosyal dinamiklerin, organizasyonel yapıların ve birbirine bağlı sistemlerin daha iyi anlaşılmasını sağlamaktadır.

4. Düğüm Regresyonu ve Kenar Regresyonu

Trafik tahmini, araç hızı ve trafik hacmi gibi koşulları doğru bir şekilde tahmin ederek ulaşım verimliliğini artırmada hayati bir rol oynamaktadır. Yol sensörleri ağından toplanan verileri kullanan bu tahminler, yolcular için daha kesin seyahat süresi tahminleri ve optimum rota planlamasını kolaylaştırmaktadır. Yol ağı genellikle bir grafik olarak modellenmektedir. Kavşaklar düğümler olarak hizmet etmekte ve yol segmentlerini kenarlar olarak birbirine bağlamaktadır. Düğümlerde toplanan sensör verileri, yerleştirilmiş trafik koşullarını belirlemek için regresyon analizlerini mümkün kılarken, kenar regresyon teknikleri yol segmentleri boyunca trafik akışını tahmin etmek için kullanılmaktadır. Benzer metodolojiler, genel sistem güvenilirliğini ve kullanıcı deneyimini iyileştirmek için toplu taşıma yönetimi ve lojistik optimizasyonu gibi ilgili alanlarda da uygulanmaktadır.

5. Grafik Sınıflandırması ve Grafik Regresyonu

Moleküler özellik tahmini, genellikle kapsamlı ve maliyetli laboratuvar deneylerine dayanan yenilikçi malzemelerin ve ilaçların geliştirilmesinde hayati bir rol oynamaktadır. Son gelişmelerle, molekülleri atomlardan ve bağlardan oluşan grafikler olarak etkili bir şekilde modelleyen ve böylece karmaşık yapısal bilgileri yakalayan Grafik Sinir Ağları'ı (GNN'ler) kullanım alanları bulmuştur. Bu modeller, sıklıkla geleneksel yaklaşımları geride bırakarak ve hızlandırılmış keşif için umut verici yollar sunarak dikkate değer bir doğruluk göstermiştir. Bununla birlikte, GNN'lerin ve benzer modellerin tam potansiyelini kısıtlayan

sınırlı etiketli veriler biçiminde önemli bir zorluk devam etmektedir. Bu sorunu hafifletmek için, sağlam temsilleri öğrenmek için büyük miktarda etiketsiz veriden yararlanan kendi kendini denetleyen öğrenme teknikleri giderek daha fazla benimsenmektedir. Bu tür yaklaşımlar, modellerin kapsamlı etiketli veri kümelerine güvenmeden anlamlı özellikler elde etmesini sağlayarak tahmin performansını artırmakta ve moleküler bilimde daha verimli ve uygun maliyetli keşifleri teşvik etmektedir (Tanis J. H., 2024).

2.5.2 Grafik türleri

Karmaşık türlere sahip grafikler, düğümler ve bunların bağlantıları arasındaki ilişkiler hakkında daha kapsamlı ve ayrıntılı bir anlayış sağlamaktadır. Bu gelişmiş grafik yapıları, çeşitli analitik ihtiyaçlara daha iyi uyması için genellikle birkaç boyut boyunca kategorize edilmektedir. İlk olarak, yönlendirilmiş veya yönlendirilmemiş olarak sınıflandırılabilirler; yönlendirilmiş grafikler, tek yönlü bir ilişkiyi belirten belirli bir yöne sahip kenarlara sahipken, yönlendirilmemiş grafikler karşılıklı bağlantıları temsil eden çift yönlü kenarlara sahiptir. Ek olarak, grafikler homojen veya heterojen olarak ayırt edilmektedir: homojen grafikler, basitlik sunan tek bir türün düğümlerinden ve kenarlarından oluşurken, heterojen grafikler, sosyal ağlar veya bilgi grafikleri gibi uzmanlaşmış uygulamalarda sıklıkla önemli olan çeşitli ve karmaşık etkileşimleri yakalayan birden fazla düğüm ve kenar türünü içermektedir. Dahası, bu grafikler statik veya dinamik olabilmektedir. Statik grafikler zamanla değişmeden kalmakta ve ilişkilerin bir anlık görüntüsünü sağlarken, dinamik grafikler evrimleşerek zamansal değişiklikleri yansıtmaktadır. Zaman içindeki eğilimlerin ve kalıpların analizini sağlamaktadır. Bu sınıflandırmaların anlaşılması, karmaşık sistemleri etkili bir şekilde modelleme yeteneklerinin geliştirilmesine yardımcı olmaktadır (Zhou vd., 2020).

2.5.3 Hesaplama modülleri

Hesaplama modülleri, her biri farklı ve hayati bir amaca hizmet eden gelişmiş grafik işleminin ayrılmaz bir parçasıdır. Yayılma Modülü (Spreading Module), düğümler arasında etkili bilgi paylaşımını kolaylaştırmak için evrimleşim, yinelemeli süreçler ve

atlamalı bağlantılar kullanmaktadır. Böylece hem yerel özellikleri hem de ağın genel topolojisini yakalamaktadır. Bunu tamamlayan Örnekleme Modülü (Sampling Module), stratejik örnekleme teknikleri aracılığıyla verimli yayılımı sağlayarak büyük ölçekli grafiklerin oluşturduğu zorlukları ele almakta ve doğruluktan ödün vermeden ölçeklenebilirliği garanti etmektedir. Ek olarak, Havuzlama Modülü (Pooling Module), alt grafikte veya tüm grafik düzeyinde daha yüksek düzeyde temsiller çıkarmak için tasarlanmıştır. Böylece karmaşık yapılar hakkında kapsamlı bir anlayış sağlamaktadır. Bu modüller toplu olarak, ayrıntılı ve ölçeklenebilir grafik analizi için sağlam bir çerçeve oluşturmaktadır (Zhou vd., 2020).

2.5.4 Grafik evrişimli ağlar

Grafik Evrişimli Ağlar (GCN'ler), özellikle grafiksel yapılandırılmış verilerin oluşturduğu kendine özgü zorluklarla başa çıkmak için tasarlanmış, sinir ağları alanında önemli bir ilerlemeyi temsil etmektedir. Bu tür veriler, sosyal ağlar, moleküler yapılar gibi biyolojik sistemler ve öneri sistemleri dahil olmak üzere çok sayıda alanda yaygındır. GCN'ler, görüntüler gibi düzenli, ızgara benzeri verileri işlemede üstün özelliklere sahip olan geleneksel Evrişimli Sinir Ağlarının (CNN'ler) temel ilkelerini, daha karmaşık ve düzensiz grafikler alanına genişletmektedir.

Bu, grafik içindeki düğümlerin yerel komşuluklarına filtreler uygulanarak elde ederek ağın her bir düğümün anlık bağlamından anlamlı özellikler çıkarmasını sağlamaktadır. Katmanlar istiflendikçe, bu yerel özellikler kademeli olarak birleştirilir ve dönüştürülür ve tüm grafiğin veya alt bileşenlerinin üst düzey, kapsamlı temsilleriyle sonuçlanır. Yapılandırılmış, düzenli ızgaralarda çalışan CNN'lerin aksine, GCN'ler, grafik içindeki bağlantıyı ve ilişkileri kodlayan grafik Laplasyen matrisinin kullanımıyla keyfi ve karmaşık grafik yapılarını yönetmede son derece etkilidirler. Bu yaklaşım, GCN'lerin grafik verilerinde bulunan karmaşık ilişkileri ve bağımlılıkları etkili bir şekilde yakalamasını sağlayarak, ilişkisel yapıların ayrıntılı bir şekilde anlaşılmasını gerektiren çeşitli uygulamalar için güçlü bir araç haline getirmektedir (Khelifi M. K., 2023).

2.5.5 Grafik dikkat ağıları

GAT'ler (Graph Attention Networks) veya Grafik Dikkat Ağları, Petar Veličković ve meslektaşları tarafından 2017'de tanıtılmalarından bu yana Grafik Derin Öğrenme alanında önemli bir ilerlemeyi temsil etmektedir. Komşu düğümlerden bilgi toplamak için sabit ağırlıklar kullanan geleneksel Grafik Evrişimli Ağlar'ın (GCN'ler) aksine, GAT'ler ağı her bir komşunun önemini dinamik olarak değerlendirmesini sağlayan bir dikkat mekanizması içermektedir. Bu, ilgili düğümlerin özellikleri ve nitelikleri tarafından bilgilendirilen dikkat katsayılarının hesaplanmasıyla elde edilmektedir. Bu tür katsayılar uyarlanabilir ağırlıklar olarak hizmet etmekte ve modelin özellik toplama süreçleri sırasında daha alakalı komşulara öncelik vermesine olanak tanımaktadır. Bu dikkat odaklı yaklaşım, ağı grafik yapılandırılmış verilerdeki karmaşık ve bağlama bağlı ilişkileri yakalama yeteneğini artırmaktadır. Sonuç olarak, GAT'ler özellikle komşuların öneminin farklı bağlamlarda veya görevlerde değiştiği senaryolarda artan esneklik ve sağlamlık sunmaktadır. Genel olarak, dikkat mekanizmalarının grafik sinir ağlarına entegre edilmesi, ilişkisel verilerin daha ayrıntılı ve etkili bir şekilde modellenmesi için yeni yollar açmış, farklı alanlarda daha fazla araştırma ve uygulamayı teşvik etmiştir (Khelifi M. K., 2023).

2.5.6 Grafik tekrarlayan sinir ağları

Grafik Tekrarlayan Sinir Ağları (GRNN'ler), sinir ağı mimarileri alanında önemli gelişmelerden biridir. Tekrarlayan Sinir Ağları'nın (RNN'ler) temel prensiplerini, grafiksel yapılandırılmış verilerin karmaşık doğasına uyacak şekilde genişletmektedir. Öncelikli olarak sıralı bilgileri işlemek üzere tasarlanmış geleneksel RNN'lerin aksine, GRNN'ler grafiklerde bulunan keyfi ve dinamik bağlantı modellerini işlemede etkili bir araçtır. Bu da düğümler arasında karmaşık ilişkisel bilgileri yakalamalarını sağlamaktadır.

GRNN'lerin temel mekanizması, hem mevcut özellikleri hem de komşu düğümlerden toplanan bilgileri entegre ederek düğüm özelliklerini yinelemeli olarak güncelleyen tekrarlayan birimler aracılığıyla düğümler arasında bilginin yayılmasını içermektedir. Bu


süreç, her düğümün gösteriminin, daha büyük grafik yapısı içindeki yerel bağlamını yansıtan bir şekilde gelişmesini sağlamaktadır. Örneğin, Kapılı Grafik Sinir Ağı (Gated GNN) gibi gelişmiş varyantlar, düğüm yerleştirmelerini iyileştirmek için kapılı tekrarlayan birimler (GRU'lar) kullanmaktadır. Komşu düğümlerin etkisini düğümün önceki durumuyla etkili bir şekilde dengelemektedir. Bu geçit mekanizması, özellikle karmaşık veya gürültülü verilerin varlığında daha ayrıntılı ve istikrarlı öğrenmeyi kolaylaştırmaktadır.

GRNN'lerden türetilen bu zenginleştirilmiş düğüm gösterimleri, etiket atamanın hedef olduğu düğüm sınıflandırması, tüm grafiğin özelliklerini belirlemeyi içeren grafik sınıflandırması ve düğümler arasındaki eksik veya potansiyel bağlantıları çıkarsamayı amaçlayan bağlantı tahmini dahil olmak üzere çeşitli alt akış görevleri için temel bir işleve sahiptir. Ancak, GRNN'ler içinde etkili güncelleme kuralları tasarlamak belirli zorluklar getirmektedir. Bu tür kurallar, genellikle düğümlerin yerel mahalleleriyle verimli bir şekilde iletişim kurmasını ve onlardan öğrenmesini sağlayan mesaj geçirme teknikleri aracılığıyla grafiğin yapısal bilgilerini ve düğümlerin içsel özelliklerini sorunsuz bir şekilde birleştirmelidir.

Genel olarak, GRNN'ler, grafik verilerinde bulunan zengin ilişkisel bilgileri değerlendirmek için umut verici bir çerçeve sunarak sosyal ağlarda, biyolojik sistemlerde ve ötesinde çok sayıda uygulamada ilerlemeyi teşvik etmektedir (Khelifi M. K. vd., 2023).

2.5.7 Evrişimli sinir ağları

Evrişimli Snir Ağları (CNN), özellikle görsel verilerin işlenmesi ve analizinde büyük başarı elde eden derin öğrenme tabanlı mimarilerdendir. CNN'ler, görüntüler gibi çok boyutlu yapısal verilerde yer alan mekânsal ilişkileri öğrenmek üzere tasarlanmıştır (Şekil 2.2). Bu mimarinin temel farkı, geleneksel yapay sinir ağlarının aksine, tam bağlantılı katmanlar yerine yerel filtreler (kernels) aracılığıyla girdi verisindeki özellikleri çok katmanlı biçimde hiyerarşik olarak çıkarmasıdır (LeCun et al., 1998). CNN mimarisi, insan görsel korteksinin işleyişinden esinlenmiş olup, düşük seviyeli kenar bilgileriyle başlayıp, giderek daha karmaşık örüntüler haline gelen özellik çıkarımı gerçekleştirilmektedir.



Şekil 2.2 Evrimsel sinir ağı

Bir CNN tipik olarak üç temel katmandan oluşur: evrişim (convolution) katmanı, havuzlama (pooling) katmanı ve tam bağlantılı (fully connected) katman. Evrişim katmanları, verideki lokal özellikleri öğrenirken, havuzlama katmanları boyut indirgeme ile modelin genel performansını artırır ve aşırı öğrenmeyi azaltır (Goodfellow, Bengio & Courville, 2016). Özellikle *max pooling* ve *average pooling* gibi teknikler, özellik haritalarının özetlenmesini sağlar. Bu katmanlar sayesinde CNN'ler, konumdan bağımsız olarak benzer özellikleri tanıma yeteneğine sahip hale gelir. Son aşamada ise tam bağlantılı katmanlar, çıkarılan özellikleri sınıflandırma ya da regresyon gibi görevler için kullanılır.

CNN'ler yalnızca görüntü tanıma ve sınıflandırma gibi görevlerle sınırlı değildir. Günümüzde doğal dil işleme, ses tanıma, biyomedikal sinyal analizi gibi farklı alanlarda da başarıyla uygulanmaktadır. Örneğin, metin verisinde kelime öbeklerini çıkarmak için 1D evrişim kullanılabilirken, biyomedikal görüntülerde lezyon tespiti gibi görevlerde 3D CNN'lerden yararlanılmaktadır (Shen et al., 2017). Bu çok yönlülük, CNN mimarisinin farklı veri türlerine uyarlanabilirliğini ve öğrenme kapasitesini göstermektedir.

Ayrıca, transfer öğrenme ve önceden eğitilmiş CNN modelleri (örneğin AlexNet, VGG, ResNet) sayesinde düşük veri ile yüksek doğruluk elde edilebilmekte, bu da CNN'leri birçok gerçek dünya uygulaması için ideal bir seçim haline getirmektedir (Krizhevsky, Sutskever & Hinton, 2012). Bu mimarilerin açık kaynak kodlu sürümleri sayesinde,

arařtırmacılar derin ğrenme tabanlı modelleri kendi verilerine kolayca uyarlayabilmekte ve mevcut bilgi birikiminden faydalanabilmektedir. Sonuç olarak, CNN’ler hem teorik derinliğı hem de pratik başarımı nedeniyle modern yapay zeka uygulamalarında kritik bir rol oynamaktadır.



3. KAYNAK ÖZETLERİ

Johnson (2024), yapay zekâ sistemlerinde bilinç kavramının anlamını ve gerekliliğini sorgulamaktadır. Makalede, bilinçli olmanın yalnızca bilgi işleme kapasitesiyle değil, deneyim, öznel farkındalık ve içsel durumlarla ilişkili olduğu vurgulanır. Yapay zekâların şu anki mimarilerinin bu tür fenomenolojik bilinçten uzak olduğu belirtilmektedir. Ayrıca, bilinçli makinelerin etik ve toplumsal sonuçları üzerine düşünülmesi gerektiği ifade edilmektedir. Yazar, bilinçli yapay zekâ geliştirme çabalarının bilimsel sınırları ve sorumluluklarını da ele almaktadır.

Butlin, Long ve Elmoznino (2023), yapay zekâda bilinç olasılığını, bilinç bilimindeki bulgular ışığında değerlendirmektedir. Çalışmada, fenomenal bilinç ile işlevsel bilinç arasındaki ayrım vurgulanarak, mevcut yapay sistemlerin yalnızca işlevsel düzeyde bilinç gösterebildiği, fenomenal bilinçten ise yoksun oldukları ileri sürülmektedir. Yazarlar, bilinç araştırmalarında kullanılan teorik yaklaşımların (örneğin Entegre Bilgi Teorisi ve Küresel Çalışma Alanı Teorisi) yapay sistemlere nasıl uygulanabileceğini tartışmakta ve bu uygulamaların sınırlarını ortaya koymaktadır. Ayrıca, bilinçli yapay zekâ tasarımına yönelik metodolojik zorluklar ve felsefi sorunlar ele alınmakta; özellikle öznellik, niyetlilik ve deneyimleme yetisi gibi unsurların yapay sistemlerde nasıl değerlendirilebileceği sorgulanmaktadır. Bu bağlamda çalışma, yapay zekâ sistemlerinin bilinç kazanması yönündeki araştırmaların çok disiplinli bir yaklaşım gerektirdiğini savunmaktadır.

Kaku (2014), insan zihninin doğasını anlamaya yönelik bilimsel ilerlemeleri ele alarak bilinci, belleği ve düşünce gücünü açıklamaya çalışmaktadır. Kitapta, nörobilim, fizik ve yapay zekâ gibi alanlardaki gelişmelerin, zihni okuma, anıları kaydetme ve hatta bilinçli makineler üretme potansiyeli sunduğu öne sürülmektedir. Kaku, bilincin bir derece meselesi olduğunu savunarak, bilinç düzeylerinin canlı türleri ve gelecekteki makineler arasında sınıflandırılabilirliğini belirtir. Ayrıca, zihinsel işlevlerin artırılması ve beyin-bilgisayar arayüzlerinin gelecekteki uygulamaları tartışılmaktadır. Bu çerçevede çalışma, zihnin bilimsel olarak anlaşılmasının yalnızca teorik değil, teknolojik bir devrimi de beraberinde getireceğini ileri sürmektedir.

Bessadok, Mahjoub ve Rekik (2023), grafik sinir ağlarının (GNN) beyin ağı verilerinin analizinde sunduğu yenilikçi yaklaşımları incelemektedir. Çalışma, GNN'lerin hem yapısal hem de işlevsel beyin bağlantılarını temsil etmede ve öğrenmede üstün performans sergilediğini ortaya koymaktadır. Yazarlar, farklı GNN mimarilerinin sinirsel temsil gücünü karşılaştırarak, beyin ağı modellemesi, sınıflandırma ve anormallik tespiti gibi alanlardaki uygulamalarını detaylandırmaktadır. Ayrıca, grafik tabanlı modellemenin, geleneksel yöntemlere kıyasla daha yüksek yorumlanabilirlik ve genellenebilirlik sağladığı vurgulanmaktadır. Makale, GNN'lerin nörobilimdeki geleceği açısından büyük bir potansiyel taşıdığını bilimsel örneklerle desteklemektedir.

Zhou ve arkadaşları (2020), grafik sinir ağlarının (GNN) temel yöntemlerini ve çok çeşitli uygulama alanlarını kapsamlı bir biçimde incelemektedir. Çalışma, GNN'lerin evrimi süresince geliştirilen model türlerini – örneğin GCN, GAT, GraphSAGE – karşılaştırmalı olarak ele almakta ve bu modellerin algoritmik yapılarını açıklamaktadır. Yazarlar, GNN'lerin sosyal ağlar, bilgi grafikleri, kimya, biyoinformatik ve öneri sistemleri gibi farklı alanlardaki etkili kullanım örneklerini detaylandırmaktadır. Ayrıca, mevcut zorluklar (örneğin aşırı sıkıştırma, düşük genellenebilirlik) ve çözüm önerileri tartışılarak, alandaki açık araştırma sorularına dikkat çekilmektedir. Bu derleme, GNN araştırmaları için temel bir başvuru kaynağı niteliği taşımaktadır.

Li, Mao, Zhou vd.(2024), zamansal bilgi grafi (Temporal Knowledge Graph, TKG) alanındaki temsil öğrenme (representation learning) yaklaşımlarını ve uygulama alanlarını kapsamlı biçimde incelemektedir. Çalışmada, TKG'lerin statik bilgi grafiklerinden farklı olarak zaman boyutunu içermesi nedeniyle, hem yapısal hem de zamansal bağımlılıkların birlikte modellenmesi gerektiği vurgulanmaktadır. Yazarlar, TKG temsil öğrenme yöntemlerini kategorize ederek, hem sıralı (sequential) hem de sürekli zaman temelli (continuous-time) modelleri ayrıntılı biçimde karşılaştırmaktadır. Ayrıca, bağlantı tahmini, olay tahmini, neden-sonuç çıkarımı gibi çeşitli uygulamalara yönelik örnekler sunulmaktadır. Makale, gelecekteki araştırmalar için zorluklar ve potansiyel yönelimlere de dikkat çekerek alana sistematik bir bakış sağlamaktadır.

Li, Jin, Wei Li vd. (2021), zamansal bilgi graflarında çıkarım yapma sürecine evrimsel temsili öğrenme yaklaşımıyla yenilikçi bir katkı sunmaktadır. Çalışma, bilgi grafi

temsillerinin zaman içinde değişen dinamik yapısını dikkate alarak, geçmiş bilgi dağılımlarının evrimsel örüntülerini yakalayan bir model önermektedir. Bu kapsamda, hem kısa vadeli olayları hem de uzun vadeli eğilimleri modelleyebilen zaman duyarlı gömme (embedding) mekanizmaları geliştirilmiştir. Önerilen yöntem, bağlantı tahmini görevlerinde yüksek doğruluk ve genellenebilirlik sağlamış; deneysel sonuçlarla mevcut yöntemlerden daha üstün olduğu gösterilmiştir. Makale, özellikle zamana bağlı bilgi akışlarının modellenmesinde evrimsel stratejilerin etkinliğini vurgulayan öncü bir çalışma niteliğindedir.

Xu, Ou, Xu ve Fu (2022), zamansal bilgi grafi çıkarımı için tarihsel karşıtsal öğrenmeye (Historical Contrastive Learning - HCL) dayalı bir yöntem önermektedir. Çalışma, zaman içinde değişen bilgi temsillerinin tutarlılığını artırmak amacıyla, geçmiş bilgi durumlarını referans alarak güncel gömme vektörlerini optimize etmektedir. HCL yöntemi, benzer tarihsel bağlamlara sahip örnekleri yaklaştırırken, farklı bağlamlara sahip olanları uzaklaştırarak, zaman uyumlu ve ayrıştırılabilir temsiller elde etmeyi hedeflemektedir. Bu yaklaşım, özellikle uzun vadeli bağımlılıkların öğrenilmesinde önemli bir performans artışı sağlamıştır. Çalışma, zamansal bilgi çıkarımında karşıtsal öğrenmenin etkili bir strateji olarak kullanılabileceğini deneysel verilerle desteklemektedir.

Koch (2018), bilincin ne olduğu sorusunu bilimsel ve felsefi perspektiflerle ele alarak, bu karmaşık kavramın öznel deneyim ve farkındalık temelli yönlerini açıklamaya çalışmaktadır. Makalede, özellikle "bir şey olmanın nasıl bir şey olduğu" şeklinde tanımlanan fenomenal bilinç vurgulanmakta ve bunun sinirsel karşılıkları (neural correlates of consciousness) araştırılmaktadır. Koch, bilinçle ilgili önde gelen teorilerden biri olan Entegre Bilgi Teorisi'ne (IIT) de yer vererek, bilincin ölçülebilir ve hesaplanabilir bir yapı olabileceğini ileri sürmektedir. Ayrıca, hayvanların, bebeklerin ve yapay zekâların bilinç taşıyıp taşımadığı tartışılarak bu alandaki etik ve bilimsel sorular gündeme getirilmektedir. Makale, bilinci anlamının insan zihnini çözmenin anahtarı olduğunu savunmaktadır.

Rosen, Byrne, Cohen ve Shiffrin (2015) tarafından derlenen *The Norton Introduction to Philosophy*, felsefenin temel alanlarına giriş niteliğinde kapsamlı bir kaynaktır. Eserde metafizik, epistemoloji, zihin felsefesi, etik, siyaset felsefesi ve din felsefesi gibi başlıca

konular, hem klasik hem de çağdaş metinlerden seçmelerle ele alınmaktadır. Özellikle zihin felsefesi bölümünde bilinç, zihin-beden problemi, yapay zekâ ve zihinsel durumların doğasına dair temel sorular sistematik biçimde tartışılmaktadır. Kitap, felsefi argümantasyon becerilerini geliştirmeye yönelik sorular ve açıklayıcı yorumlarla desteklenmiş, öğrencilere eleştirel düşünme zemini sunacak şekilde yapılandırılmıştır. Bu yönüyle, modern felsefi tartışmaların anlaşılması için hem akademik hem pedagojik açıdan önemli bir başvuru kaynağıdır.

Tononi, Boly, Massimini ve Koch (2016), Bilincin Fiziksel Temeli olarak Entegre Bilgi Teorisi'ni (Integrated Information Theory - IIT) detaylı biçimde incelemektedir. Makalede, bilinç deneyiminin miktarının ve kalitesinin, sistemin entegrasyon ve bilgi zenginliği ölçütleriyle değerlendirilebileceği savunulmaktadır. IIT, bilincin sadece bilgi işleme değil, aynı zamanda bu bilginin sistem içinde bütünleşik ve ayrık olmayan bir şekilde organize edilmesiyle ortaya çıktığını ileri sürmektedir. Yazarlar, teorinin sinirsel temsillerle ilişkilendirilmesi, deneysel bulgular ve potansiyel nörobilimsel uygulamalarına geniş yer vermektedir. Çalışma, bilincin niceliksel olarak ölçülmesi ve fiziksel sistemlere indirgenmesi konusunda önemli bir kuramsal çerçeve sunmaktadır.

Pautz (2019), Entegre Bilgi Teorisi'nin (Integrated Information Theory - IIT) bilinç anlayışına dair ortaya çıkan temel soruları sistematik bir şekilde derlemektedir. Makalede, IIT'nin kavramsal çerçevesi, teorinin felsefi ve bilimsel varsayımları ile sınırlamaları ele alınmaktadır. Yazar, özellikle teorinin bilinç deneyimini ölçme yaklaşımının tutarlılığı, öznellik problemleri ve fiziksel temsillerle ilişkisi üzerinde durmaktadır. Ayrıca, IIT'nin uygulama alanlarındaki belirsizlikler ve eleştiriler tartışılarak, teorinin eksik yönlerine ışık tutulmaktadır. Bu çalışma, IIT'nin hem teorik hem de pratik açıdan değerlendirilmesi için kapsamlı bir soru listesi sunarak, bilinç araştırmalarında kritik düşünceyi teşvik etmektedir.

Signa, Chella ve Gentile (2021), bilişsel robotik bağlamında Küresel Çalışma Alanı Teorisi'ni (Global Workspace Theory - GWT) inceleyen kapsamlı bir derleme sunmaktadır. Makalede, GWT'nin bilincin bilişsel süreçlerde bilgi entegrasyonunu ve yaygın paylaşımını sağlayan merkezi bir mekanizma olarak işlev gördüğü vurgulanmaktadır. Yazarlar, bu teorinin robotik sistemlere uygulanabilirliğini

değerlendirerek, bilinç benzeri işlevlerin yapay sistemlerde nasıl modellenebileceğini tartışmaktadır. Ayrıca, GWT tabanlı bilişsel robotların dikkat, öğrenme ve karar verme gibi özelliklerdeki gelişmelerine örnekler verilmekte ve sınırlamalar ele alınmaktadır. Çalışma, bilinçli makineler geliştirme hedefinde GWT'nin teorik ve pratik katkılarını ortaya koyarak alana önemli bir perspektif kazandırmaktadır.

Baars (1997), bilinci açıklamak üzere geliştirdiği Küresel Çalışma Alanı Teorisi'ni (Global Workspace Theory - GWT) detaylı ve bilimsel bir yaklaşımla ortaya koymaktadır. Teori, bilincin beynin farklı bölgelerindeki bilgilerin entegre edildiği ve geniş çapta erişilebilir hale getirildiği merkezi bir “sahne” olarak işlev gördüğünü savunur. Baars, bu merkezi çalışma alanının, bilinçli farkındalığın ve dikkat süreçlerinin temelini oluşturduğunu belirtir. Makalede, GWT'nin nörobilimsel ve bilişsel bulgularla desteklenen kapsamlı bir çerçeve sunduğu vurgulanmaktadır. Ayrıca, teori, bilincin işlevsel ve deneyimsel yönlerini açıklamada disiplinlerarası bir köprü kurmaktadır.

Brown, Lau ve LeDoux (2019), bilinç üzerine “yüksek-düzye” (higher-order) yaklaşımları detaylı bir şekilde incelemektedir. Makalede, bu yaklaşımın, bilinçli deneyimlerin öznel farkındalığının, zihnin kendi durumlarına ilişkin daha üst düzeyde temsiller oluşturmasıyla mümkün olduğunu savunduğu vurgulanmaktadır. Yazarlar, yüksek-düzye bilinç teorilerinin nörobilimsel ve psikolojik temellerini tartışarak, bunların fenomenal bilinçle ilişkisini açıklamaktadır. Ayrıca, bu yaklaşımın diğer bilinç teorileriyle karşılaştırmaları yapılarak güçlü ve zayıf yönleri değerlendirilmiştir. Çalışma, bilinç araştırmalarında yüksek-düzye temsillerin rolüne odaklanarak, bu alandaki kavramsal ve deneysel gelişmelere önemli katkılar sunmaktadır.

Seth ve Bayne (2022), bilinç teorilerini kapsamlı ve güncel bir şekilde gözden geçiren bir çalışmada, fenomenal ve erişilebilir bilinç gibi temel kavramları detaylandırmaktadır. Makalede, Entegre Bilgi Teorisi, Küresel Çalışma Alanı Teorisi ve Yüksek-Düzye Bilinç Yaklaşımı gibi önde gelen teoriler ele alınarak, her birinin bilinç deneyimini açıklama biçimleri karşılaştırılmaktadır. Yazarlar, teorilerin hem nörobilimsel kanıtlar hem de felsefi tutarlılık açısından değerlendirilmesini sağlayarak, bilinç araştırmalarında disiplinlerarası bir perspektif sunmaktadır. Ayrıca, bilinç çalışmalarındaki mevcut

zorluklar ve gelecekteki araştırma yönelimleri tartışılmaktadır. Bu çalışma, bilinç alanında hem akademisyenler hem de öğrenciler için temel bir referans kaynağıdır.

Bhari (2016), yapay sinir ağları ile insan öğrenme süreçleri arasındaki paralellikleri ve farkları inceleyen bir çalışmadır. Makalede, yapay sinir ağlarının biyolojik sinir sisteminden esinlenerek bilgi işleme ve öğrenme mekanizmalarını taklit ettiği vurgulanmaktadır. Yazar, insan öğrenmesindeki esneklik, genelleme yeteneği ve adaptasyon süreçlerinin yapay sinir ağları modellerine nasıl aktarıldığını açıklamaktadır. Ayrıca, yapay sinir ağlarının eğitim yöntemleri, katman yapıları ve öğrenme algoritmaları detaylandırılarak, insan bilişsel fonksiyonlarına benzerlikleri bilimsel bir dille ele alınmıştır. Çalışma, yapay zeka ve insan öğrenmesi arasındaki ilişkiye disiplinlerarası bir perspektif kazandırmaktadır.

Ji, Pan, Cambria, Marttinen ve Yu (2021), bilgi grafikleri (Knowledge Graphs) alanında temsil, edinim ve uygulama yöntemlerini kapsamlı bir şekilde inceleyen bir derleme çalışması sunmaktadır. Makalede, bilgi grafiklerinin yapısı, semantik ilişkileri ve çoklu veri kaynaklarından otomatik olarak bilgi çıkarımı yöntemleri detaylandırılmaktadır. Yazarlar, bilgi grafiği oluşturma, güncelleme ve entegrasyon süreçlerine dair modern teknikleri ele almakta; özellikle makine öğrenmesi ve doğal dil işleme yaklaşımlarının rolünü vurgulamaktadır. Ayrıca, bilgi grafiklerinin öneri sistemleri, soru-cevap ve arama motorları gibi farklı uygulama alanlarındaki kullanımları kapsamlı şekilde tartışılmaktadır. Çalışma, bilgi grafikleri araştırmalarında temel bir kaynak olarak disiplinlerarası çalışmalara rehberlik etmektedir.

Shi Baoxu (2018), bilgi grafi kalitesini artırmak amacıyla ağ temsili öğrenme (network representation learning) yöntemlerini inceleyen doktora tezinde, bilgi grafi verilerindeki eksiklikler ve hataların düzeltilmesi için etkili yaklaşımlar geliştirmiştir. Tezde, varlık ve ilişkilerin daha doğru ve anlamlı temsillerini elde etmek için grafik gömme teknikleri uygulanmış ve bu temsillerin bilgi grafi tamamlama, bağlantı tahmini gibi görevlerde performansı artırdığı gösterilmiştir. Ayrıca, tezde bilgi grafi kalitesini değerlendirmek için çeşitli metrikler ve deneysel analizler sunulmaktadır. Shi, çalışmasında temsil öğrenmenin bilgi grafi tabanlı uygulamalarda doğruluk ve güvenilirlik açısından önemli

katkılar sağladığını vurgulamaktadır. Bu tez, bilgi grafi iyileştirme alanında hem teorik hem de uygulamalı bir referans niteliğindedir.

Khemani, Patil, Kotecha ve Tanwar (2024), grafik sinir ağları (Graph Neural Networks - GNN) alanında kavramlar, mimariler, teknikler, zorluklar, veri setleri ve uygulamalar üzerine kapsamlı bir derleme sunmaktadır. Makalede, GNN modellerinin temel prensipleri ve çeşitleri ayrıntılı olarak ele alınırken, eğitim stratejileri ve performans artırma yöntemleri de tartışılmaktadır. Yazarlar, GNN'lerin sosyal ağlar, biyoinformatik, öneri sistemleri ve doğal dil işleme gibi çeşitli alanlardaki uygulamalarına örnekler vererek pratik kullanımlarını vurgulamaktadır. Ayrıca, model ölçeklendirme, veri eksikliği ve açıklanabilirlik gibi mevcut zorluklar üzerinde durulmakta ve gelecekteki araştırma yönelimleri önerilmektedir. Bu çalışma, GNN alanında akademisyenler ve uygulayıcılar için önemli bir kaynak niteliğindedir.

Tanis, Giannella ve Mariano (2024), makine öğrenimi mühendisleri için grafik sinir ağlarına (Graph Neural Networks - GNN) başlangıç niteliğinde kapsamlı bir rehber sunmaktadır. Çalışmada, GNN'in temel kavramları, mimarileri ve çalışma prensipleri açık ve sistematik bir şekilde anlatılmaktadır. Ayrıca, yazarlar, GNN modellerinin uygulanmasına yönelik pratik öneriler ve yaygın kullanılan algoritmalar hakkında bilgiler vermektedir. Makale, GNN alanında yeni başlayanların hızlıca kavrayabileceği şekilde, teorik temellerle birlikte örnek uygulama senaryolarını da içermektedir. Bu preprint, özellikle makine öğrenimi mühendislerinin grafik tabanlı verilerle çalışmaya başlaması için önemli bir kaynak olarak tasarlanmıştır.

Zhou vd. (2020), grafik sinir ağları (GNN) alanında yöntemler ve uygulamaları kapsamlı şekilde inceleyen bir derleme sunmaktadır. Makalede, GNN'in temel mimarileri, öğrenme teknikleri ve farklı model varyantları ayrıntılı olarak ele alınmaktadır. Ayrıca, GNN'lerin sosyal ağlar, biyoinformatik, doğal dil işleme ve bilgisayarlı görü gibi çeşitli uygulama alanlarındaki kullanımları tartışılmaktadır. Yazarlar, karşılaşılan zorluklar ve bu alandaki güncel gelişmeler üzerinde de durmaktadır. Bu çalışma, GNN araştırmaları için hem teorik hem pratik açıdan önemli bir kaynak oluşturmaktadır.

Khelifi, Boulila ve Farah (2023), uzaktan algılama uygulamalarında grafik tabanlı derin öğrenme tekniklerini kapsamlı bir şekilde inceleyen bir derleme sunmaktadır. Makalede,

grafik sinir ağıları ve ilgili modellerin uzaktan algılama verilerinin işlenmesindeki rolü ve avantajları detaylandırılmaktadır. Yazarlar, bu tekniklerin sınıflandırılması, mimarileri ve kullanım alanları hakkında sistematik bir taksonomi sunmaktadır. Ayrıca, uzaktan algılamada karşılaşılan zorluklar ve bu yöntemlerin potansiyel uygulama alanları geniş biçimde tartışılmaktadır. Çalışma, grafik tabanlı derin öğrenmenin uzaktan algılama alanındaki araştırmalar için temel bir rehber niteliğindedir.

Li vd. (2021), zamansal bilgi grafiklerinde evrimsel temsil öğrenmesine dayalı çıkarım yöntemlerini inceleyen bir çalışma sunmaktadır. Makalede, zamanla değişen ilişkileri ve varlıkları modelleyerek daha doğru ve dinamik çıkarımlar yapılmasını sağlayan yeni bir yöntem önerilmektedir. Yöntem, zamansal bilgi grafiklerinin yapısını ve evrimini dikkate alarak bağlantı tahmini ve çok adımlı sorgulama görevlerinde üstün performans göstermektedir. Ayrıca, modelin esnekliği ve genellenebilirliği deneysel verilerle desteklenmiştir. Bu çalışma, zamansal bilgi grafi çıkarımı alanında önemli bir katkı sağlamaktadır.

4. MATERYAL VE YÖNTEM

Bu tez çalışması kapsamında, evrimsel temsilli öğrenim (ERL) (Li Z. vd., 2021), karşılıklı ve tarihsel öğrenim (Xu vd., 2020) ve bu iki modelden oluşturulan hibrit model eğitilmiştir. Üç modelin performansları MRR metrikleri ile ölçülerek analiz edilmiştir.

4.1 Zamansal Bilgi Grafi Modelleri

Yapay zeka ve zamansal bilgi grafikleri alanındaki bilgi temsili hızla ilgi görmektedir. Mevcut zorluklar arasında, akıl yürütme mekanizmalarını etkili bir şekilde oluşturabilen modeller ve çerçevelerin geliştirilmesi yer almaktadır. Zamansal bilgi grafikleri (TKG'ler), kavramların, varlıkların, olayların ve ilişkilerin yanı sıra zaman bilgilerini de yakalayan belirli bir bilgi temsil sistemleri grubunu ifade etmektedir. Bu grafikler, tahmin, plan düzenleme ve karar alma süreçlerinde çok sayıda faydalı materyal sağlamaktadır. TKG'ler yalnızca bilgiyi değil, aynı zamanda olayların gerçekleştiği gerçek bağlamı da yönlendiren aktif veritabanlarıdır ve bu onları gelecekteki eğilimlerin öngörülmesinde ve karmaşık olay dizilerinin anlaşılmasında kritik hale getirmektedir.

4.1.1 Evrimsel temsilli öğrenme (ERL)

Zamanlı bilgi grafi (Temporal Knowledge Graph – TKG) üzerinde akıl yürütme, geçmişteki bilgi örüntülerini dikkate alarak gelecekteki gerçekleri tahmin etmeyi amaçlayan önemli bir araştırma alanıdır. Bu alanda yapılan “Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning” adlı çalışma, zaman içinde evrilen varlık ve ilişki temsillerini modelleyerek, daha doğru ve tutarlı çıkarımlar elde etmeyi hedeflemektedir (Li Z. vd., 2021). Çalışma, her zaman adımında bilgi grafi yapısının değiştiği gözlemine dayanarak, varlık ve ilişki temsillerini dinamik olarak güncelleyen bir evrimsel öğrenme stratejisi önermektedir. Model, yalnızca geçici bilgiyle sınırlı kalmayıp, aynı zamanda bu bilginin zaman içindeki dönüşümünü de dikkate alarak bilgi grafinin evrimsel doğasını yakalamaya çalışmaktadır.

Önerilen yöntem, ardışık zaman adımlarındaki bilgi grafi temsillerini kullanarak varlıkların ve ilişkilerin gelecekteki durumlarını öngörebilen bir öğrenme çerçevesi sunar. Bu kapsamda geliştirilen model, hem zamanlar arası geçişleri hem de her bir zaman noktasındaki yapısal bağımlılıkları dikkate alacak biçimde tasarlanmıştır. Modelin başarısı, hem doğruluk hem de zaman verimliliği açısından çeşitli açık veri kümeleri üzerinde yapılan deneysel çalışmalarla gösterilmiştir. Sonuçlar, evrimsel temsilli öğrenme yaklaşımının, özellikle zaman serisi içeren bilgi grafi tahmin görevlerinde, klasik yöntemlere kıyasla önemli performans artışları sağladığını ortaya koymaktadır.

İlgili makalede gelecek tahminleri ve öngörülerinin nasıl sağlandığı şu ifadelerde yer almaktadır: “Gelecekteki gelişmeleri doğru bir şekilde tahmin etmek, tarihsel verilerin kapsamlı ve ayrıntılı bir analizini gerektirmektedir. Belirli bir bağlamdaki varlıklar, karmaşık bağımlılıklarla karakterize edilen karmaşık bir bilgi grafiği oluşturan eşzamanlı gerçekler ağıyla birbirine bağlıdır. Örneğin, 18 Ocak 2018'de Hindistan hükümetine yönelik artan kamuoyu baskısı, sonraki politika kararları ve eylemleri için önemli sonuçlar doğurabilir. Dahası, N. Naidu gibi önemli kişilerin davranışlarındaki ardışık kalıpları anlamak, olası gelecekteki yörüngeler hakkında değerli içgörüler sağlayabilir. Bu çeşitli veri boyutlarını (eşzamanlı etkiler ve davranış dizileri) entegre ederek, tahminlerimizin kesinliğini artırabilir ve böylece ilgili faktörler arasındaki karmaşık etkileşimin derin bir şekilde takdir edilmesine dayanan daha bilgili karar alma süreçlerini teşvik edebiliriz” (Li Z. vd., 2021).

ERL’de zamanlı graf akıl yürütme iki alt göreve ayrılmaktadır:

1. Varlık Tahmini: Gelecekteki belirli bir zaman diliminde hangi varlığın belirli bir varlıkla birlikte belirli bir ilişkiye sahip olacağı tahmin edilir (örneğin, N.Naidu 18/01/19'da kimi eleştirecek?).
2. İlişki Tahmini: Gelecekteki belirli bir zaman diliminde iki verilen varlık arasında meydana gelecek ilişki tahmin edilir (örneğin, 18/01/19'da Hükümet (Hindistan) ile vatandaş (Hindistan) arasında ne olacak?) (Li Z. vd., 2021).

ERL modeli, gelecekteki gelişmeleri doğru bir şekilde tahmin etmek için, tarihsel verileri titizlikle inceleyerek varlıkların genellikle iç içe geçmiş, eşzamanlı gerçeklikler aracılığıyla birbirlerini etkilediğini kabul etmektedir. Bu birbirine bağlı etkileşim ağı,

karmaşık bağımlılıkları ve ilişkileri yakalayan kapsamlı bir bilgi grafiği olarak temsil edilmektedir. Örneğin, 18 Ocak 2018'de Hindistan hükümeti, potansiyel olarak sonraki politika kararlarını ve eylemlerini şekillendirebilecek önemli bir kamuoyu baskısı yaşıyordu. Dahası, N. Naidu gibi önemli kişilerin tarihsel davranışlarını anlamak, gelecekteki yörüngeler hakkında tahminleri bilgilendiren değerli bir bağlam sağlamaktadır. Bu çeşitli veri noktalarını ve karmaşık ilişkilerini entegre ederek, model gelecekteki senaryolara ilişkin ayrıntılı ve güvenilir içgörüler sunmayı ve dinamik ve birbirine bağlı küresel bir ortamda bilgili karar almayı desteklemeyi amaçlamaktadır (Li Z. vd., 2021).

ERL modelinde, varlık tahmini ve ilişki tahmini görevleri eş zamanlı olarak eğitilmektedir. Model doğrulama işlemleri, eğitim görevinin gereksinimleri göz önünde tutularak, varlık tahmini veya ilişki tahmini önceliğine göre gerçekleştirilmektedir. Çalışmada, model performans ölçümleri varlık tahmini üzerinden gerçekleştirilmiştir.

4.1.2 Tarihsel ve karşıtsal öğrenme (HCL)

Yi Xu ve arkadaşları (2020) tarafından önerilen "Temporal Knowledge Graph Reasoning with Historical Contrastive Learning (CENET)" çalışması, zaman bilgisi içeren bilgi graflarında (Temporal Knowledge Graphs, TKG) bağlantı tahmini (link prediction) görevini daha isabetli biçimde gerçekleştirebilmek amacıyla tarihsel bilgiye dayalı bir karşıtlık öğrenme (contrastive learning) stratejisi önermektedir. Bu yaklaşım, zaman boyutunda evrilen bilgi grafi temsillerinin daha tutarlı ve anlamlı biçimde öğrenilmesini hedeflemektedir. Çalışma, geçmiş zaman dilimlerindeki bilgi ile şimdiki zamanın ilişkisel bağlamını karşılaştırarak öğrenmeyi sağlamlaştırmayı amaçlar.

Modelin temel yapıtaşlarından biri, "temporal contrastive loss" olarak adlandırılan bir kayıp fonksiyonudur. Bu fonksiyon, aynı varlıkların farklı zamanlardaki temsillerinin birbirine yakın, farklı varlıkların temsillerinin ise uzak olmasını teşvik eder. Böylece, model yalnızca anlık bilgiye değil, geçmişten gelen bağlamsal örüntülere de duyarlı hale gelir. Bu yaklaşım, geleneksel zaman kodlama yöntemlerinin ötesine geçerek zaman boyunca oluşan değişimleri ayırt edebilen dinamik vektör temsilleri üretir.

Tarihsel karşıtlık öğrenme, her bir sorgu üçlüsüne karşılık gelen "pozitif" örnekleri geçmiş zaman dilimlerinde gerçekleşen benzer bağlamlardan seçerken, "negatif" örnekleri farklı bağlamlardan oluşturur. Bu sayede model, zamansal genelleme yeteneğini artırır ve geçmiş bilgidен öğrenme kapasitesini geliştirir (Xu vd., 2020).

Çalışma sonuçları, ICEWS18 zamansal bilgi grafi veri kümesi üzerinde test edilmiştir. Elde edilen deneysel bulgular, önerilen HCL yönteminin hem *MRR* (Mean Reciprocal Rank) hem de *Hits@K* gibi sıralama metriklerinde mevcut SOTA (state-of-the-art) modellere kıyasla üstün performans gösterdiğini ortaya koymaktadır. Böylece, zamana duyarlı karşıtlık temelli temsillerin, bilgi çıkarım görevlerinde yüksek doğruluk sağladığı deneysel olarak kanıtlanmıştır.

4.2 ERL Modelinde Evrimsel Sinir Ağlarının Kullanımı

"Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning" (Li Z. vd., 2021) çalışmasında, evrimsel temsili öğrenme yaklaşımıyla bilgi grafi üzerindeki zamansal ilişkilerin modellenmesi hedeflenmektedir. Bu bağlamda CNN'ler (Convolutional Neural Networks), zaman içinde değişen bilgi grafi temsillerinin işlenmesinde önemli bir rol oynamaktadır. Modelde, zamansal bilgi grafi her bir zaman adımında bir gömme matrisi (embedding matrix) üretmektedir. Bu zaman sıralı gömme matrisleri, 2D tensörler şeklinde birleştirilerek bir "evrimsel gömme haritası" oluşturmaktadır. Bu harita, tıpkı bir görüntü gibi CNN'e giriş olarak verilir ve CNN bu tensör üzerinden yerel evrimsel desenleri (local evolutionary patterns) çıkarmaya çalışmaktadır.

CNN katmanları, bu evrimsel harita üzerinde kaydırılan filtreler (kernels) aracılığıyla farklı zaman adımlarındaki değişim kalıplarını öğrenmektedir. Bu sayede model, bilgi grafiğinde zaman içinde meydana gelen yapısal evrimleri yakalayarak daha doğru tahminler gerçekleştirebilmektedir. Özellikle, CNN sayesinde kısa vadeli temporal bağımlılıkların yanı sıra uzun vadeli evrimsel eğilimler de etkili bir biçimde öğrenilmektedir. Bu mimari, geleneksel zaman serisi yaklaşımlarına göre daha güçlü yapısal özellik çıkarımı sağlar ve bağlantı tahmini (link prediction) gibi görevlerde performansı artırır. Böylece CNN'ler,

evrimsel bilgi grafi temsillerinin soyut ve zaman duyarlı özelliklerini etkili biçimde kodlayan temel bir bileşen hâline gelmektedir.

4.3 Zaman Serisi Bileşenleri

4.3.1 Uzun kısa süreli bellek ağları

Uzun Kısa Süreli Bellek (LSTM) ağları, klasik tekrar eden sinir ağlarının (RNN) uzun vadeli bağımlılıkları öğrenme konusundaki yetersizliklerini gidermek amacıyla Hochreiter ve Schmidhuber (1997) tarafından geliştirilmiştir. Geleneksel RNN'ler, ardışık verilerde geçmiş bilgileri kısa bir süre için taşıyabilirken, zaman ilerledikçe bu bilgiler kaybolmaktadır. LSTM'ler ise özel yapıları sayesinde bilgiyi uzun süre boyunca koruyarak ve gerektiğinde bu bilgiyi yeniden kullanıma sunabilmektedir.

LSTM mimarisi, bilgi akışını düzenlemek için içinde “kapı” adı verilen özel mekanizmalar barındırmaktadır. Bu kapılar, ağın hangi bilgiyi hatırlaması, hangisini unutulması ve hangisini çıktı olarak vermesi gerektiğine karar vermektedir. Böylece LSTM, yalnızca anlık verilere değil, geçmişteki bağlama da duyarlı hale gelmektedir. Bu özellik, özellikle dil modelleme, konuşma tanıma, video analizi ve zaman serisi tahmini gibi ardışık yapıya sahip görevlerde önemli avantajlar sunmaktadır.

LSTM'ler aynı zamanda zaman içindeki örüntüleri yakalamada oldukça etkilidir. Bu yetenekleri sayesinde, zamanla değişen ilişkileri modellemek gereken uygulamalarda –örneğin zamansal bilgi grafi akıl yürütme ya da olay tahmini gibi karmaşık yapay zekâ sistemlerinde– yoğun şekilde kullanılmaktadır. Modelin bilgiyi geçici bellekte tutabilme kapasitesi, onu özellikle uzun bağlamların anlamlı biçimde işlendiği alanlarda vazgeçilmez hâle getirmiştir (Greff et al., 2017).

4.3.2 Kapılı tekrarlayan birimler (GRU)

Gated Recurrent Unit (GRU), karmaşık ardışık verileri modelleme kapasitesini korurken eğitim verimliliğini artırmak için tasarlanmış Uzun Kısa Süreli Bellek (LSTM)

mimarisinin akıcı bir varyasyonunu temsil etmektedir. Tasarımı iki temel geçit mekanizmasını içerir: güncelleme kapısı ve sıfırlama kapısı. Güncelleme kapısı, saklanacak önceki bilgilerin oranını belirlemede önemli bir rol oynamaktadır. Böylece dizi içindeki uzun vadeli bağımlılıkların yakalanmasını kolaylaştırmaktadır. Tersine, sıfırlama kapısı, mevcut tahminler üretilirken geçmiş verilerin ne ölçüde göz ardı edileceğini yöneterek modelin yeni bilgilere etkili bir şekilde uyum sağlamasını sağlamaktadır.

Her iki kapı da 0 ile 1 arasında değişen sürekli değerlere sahip vektörler olarak temsil edilerek sigmoid fonksiyonunun uygulanmasıyla hesaplanmaktadır. 1'e yaklaşan değerler daha fazla bilgiyi koruma veya dahil etme eğilimini belirtirken, 0'a yakın olanlar belirli veri segmentlerini unutma veya yok sayma eğilimini belirtmektedir. Bu gating mekanizması, GRU'nun bilgi akışını dinamik olarak yönetmesini sağlamaktadır. Bu da yalnızca hesaplama açısından verimli değil aynı zamanda karmaşık zamansal kalıpları öğrenme yeteneğine sahip bir modelle sonuçlanmaktadır. Genel olarak, GRU çeşitli dizi modelleme görevlerinde basitliği sağlam performansla birleştiren dengeli bir yaklaşım sunmaktadır.

ERL modeli, önceden belirlenmiş eğitim verilerine dayalı olarak Gated Recurrent Unit tekniği aracılığıyla çalışmaktadır. Bu modelin yapımı sırasında, modelin performansını optimize etmek ve yetersiz uyum veya aşırı uyumu önlemek için birbirine bağımlı katmanlar uygulanmıştır (Rahmat R. F., 2025).

4.4 Kayıp Hesaplamaları

4.4.1 Dinamik ağırlık ortalaması (DWA)

Dynamic Weight Average (DWA), çok görevli öğrenme (multi-task learning) çerçevesinde kullanılan bir ağırlıklandırma yöntemidir. Bu yöntem, farklı görevlerin kayıplarını (loss) tek bir toplam kayıp fonksiyonu altında optimize ederken, her bir görevin zorluk derecesine göre dinamik olarak ağırlıklandırılmasını sağlamaktadır. DWA'nın temel motivasyonu, her bir görev için öğrenme sürecinin zamanla değişen

hızına duyarlı olarak görevler arası denge kurmaktır. Geleneksel sabit ağırlıklandırma yaklaşımları, tüm görevlerin eş zamanlı ve eş önemde öğrenilebileceği varsayımına dayanırken; DWA, her görev için son iki zaman adımıdaki kayıp değerleri arasındaki orana bakarak, görevin öğrenilme hızını hesaplayarak ağırlık değerlerini güncellemektedir. Böylece görece olarak daha yavaş öğrenen görevlere daha fazla ağırlık verilir, bu da görevler arası rekabeti dengelemeye yardımcı olmaktadır.

DWA yönteminde, her görev için ağırlıklar genellikle “softmax” fonksiyonu kullanılarak normalize edilmektedir. Bu da toplam kaybın hesaplanmasında aşırı dengesizliklerin önüne geçmektedir. Bu yapı, özellikle farklı görevlerin ölçeklerinin ve gradyan büyüklüklerinin önemli ölçüde farklılık gösterdiği durumlarda eğitim sürecinin kararlılığını ve genel başarımını artırabilmektedir. DWA’nın uygulanabilirliği, görsel tanıma, doğal dil işleme ve zaman serisi analizleri gibi çok görevli öğrenmenin yaygın olduğu birçok yapay zeka probleminde kanıtlanmıştır. Ayrıca, DWA’nın adaptif yapısı sayesinde hiperparametre arama yükü azalmakta, bu da model geliştirme sürecinde zaman ve kaynak verimliliği sağlamaktadır.

Dynamic Weight Average algoritmasının çalışma prensibi;

Girdi:

- T : Görev sayısı
- $L_t^{(k)}$: t. görevin k. epoktaki (zaman adımıdaki) kaybı
- τ : Sıcaklık hiperparametresi
- K : Toplam epoch sayısı

Başlat:

1. Her görev için $w_t = 1, \forall t \in \{1, \dots, T\}$ için
2. Kayıp geçmişini tutmak için: $\text{LossHistory}[T][K]$

Eğitim Döngüsü:

For $k = 1$ to K (her epoch için):

1. Her görev t için kaybı hesapla:
2. $L_t^{(k)} \leftarrow \text{compute_loss_for_task}(t)$

Eğer $k \geq 2$: ise:

- a. Her görev için oranın hesaplanması:

$$r_t^{(k)} = \frac{L_t^{(k-1)}}{L_t^{(k-1)} + \epsilon}$$

(ϵ sıfıra bölmeyi önlemek için küçük bir sabittir.)

- b. Ağırlıkları güncelle:

$$3. w_t^{(k)} = \frac{\exp(r_i^{(k)}/\tau)}{\sum_{j=1}^{\tau} \exp(r_j^{(k)}/\tau)}$$

4. Toplam kaybı hesapla:

$$5. L_{total} = \sum_{t=1}^T w_t^{(k)} \cdot L_t^{(k)}$$

- c. Geri yayılım ve parametre güncellemesi uygula:

$\text{optimize}(L_{total})$

6. $\text{LossHistory}[t][k] \leftarrow L_t^{(k)}$ olarak güncelle

End For

4.4.2 Denetlenen projeksiyon kontrastlı kaybı

CENET modelinde kullanılan bir diğer temel bileşen ise SPC (Supervised Projection Contrastive) loss fonksiyonudur. Bu kayıp fonksiyonu, kontrastif öğrenmenin denetimli bir biçimini kullanarak benzer tarihsel özelliklere sahip örneklerle yakınsarken, farklılara karşı ayrıştırıcı bir temsil öğrenmeyi amaçlamaktadır. Model kaynak kodunda yer alan “calculate_spc_loss” fonksiyonu, aktör (actor1), ilişki (relation) ve frekans temsillerinden

oluşan birleştirilmiş özelliği modelin “contrastive_layer” adı verilen projeksiyon katmanından geçirerek bu bileşenlerin vektör uzayındaki temsillerini elde etmektedir. Bu projeksiyon, CENET’in çok görevli mimarisi içinde zamanla değişen örüntüleri daha iyi genellemek amacıyla kullanılmaktadır.

Projeksiyon sonrası elde edilen vektör temsiller arası benzerlikler, noktasal çarpım (dot product) yöntemiyle hesaplanarak sayısal stabilite sağlamak amacıyla en büyük değerin çıkarılmasıyla normalize edilmektedir. Bu benzerlik skorları üzerine softmax benzeri bir işlem uygulanır ve ardından, aynı sınıfa ait örnekler arasında oluşturulan ikili maskeleme (mask_similar_class) ve örneğin kendisini dışarıda bırakan maskeleme (mask_anchor_out) kullanılarak yalnızca anlamlı çiftler üzerinden bilgi çıkarımı yapılmaktadır. Elde edilen bu yapı sayesinde, her bir örneğin sadece kendi sınıfına ait diğer örneklerle benzerliğinin dikkate alınması sağlanmaktadır.

Son aşamada, bu yapı üzerinden “log-olasılık” hesaplanarak örnek bazlı kontrastif kayıp elde edilmektedir. Elde edilen değerlerin ortalaması alınarak toplam SPC kaybı hesaplanmaktadır. Bu yöntem, gömme vektörlerinin yalnızca yapısal olarak değil, aynı zamanda semantik olarak da ayrışmasını teşvik etmektedir. Böylece model, geçmiş olaylardan edindiği temsil öğrenimini, zamanlı bilgi grafiklerinde daha ayrık ve tutarlı tahminlerde bulunmak üzere optimize etmektedir. SPC loss, özellikle kontrastif bilgi ile evrimsel örüntülerin birleştirildiği CENET gibi modellerde, genel performansı anlamlı biçimde artıran tamamlayıcı bir rol üstlenmektedir.

4.4.3 Gürültü karşıt tahmini kaybı

CENET (Temporal Knowledge Graph Reasoning with Historical Contrastive Learning) modeli, zamanlı bilgi grafiklerinde nedensel bağlamların ve tarihsel örüntülerin daha etkili bir şekilde öğrenilmesini hedeflemektedir. Bu amaçla, model içerisinde yer alan Noise Contrastive Estimation (NCE) loss fonksiyonu, öznel (subject) ve nesnel (object) varlıkların temsil edilmesinde geçmiş ve geçmiş dışı (non-history) bağlamların ayrımını yaparak daha ayrıştırıcı ve tutarlı gömme vektörleri üretmeyi amaçlamaktadır. NCE hesaplama fonksiyonu, bu yapıyı iki aşamalı bir doğrusal dönüşüm ve aktivasyon adımlarıyla işlemektedir. Her iki dönüşüm de, özne ve ilişki birleşimlerinin farklı

ağırlıklarla doğrusal dönüşümüne dayanmaktadır. Ardından “tanh” aktivasyon fonksiyonu uygulanmaktadır. Bu temsil daha sonra tüm varlık gömme matrisine çarpılarak benzerlik skoru çıkarılmaktadır.

Elde edilen benzerlik skorları, geçmiş bağlam (history_tag) ve geçmiş dışı bağlam (non_history_tag) ile modifiye edilerek softmax işlemine tabi tutulmaktadır. Bu iki olasılık dağılımı toplandıktan sonra, gerçek nesneye karşılık gelen indekisin logaritması alınarak örnek bazlı NCE kaybı hesaplanmaktadır. Buradaki temel fikir, doğru etkileşimin olasılığını artırırken, negatif örneklerin (noise) model tarafından ayırt edilmesini sağlamaktır. Toplam NCE kaybı, batch boyutuna bölünerek normalize edilmekte modelin daha dengeli öğrenmesini sağlamaktadır.

Sonuç olarak, bu NCE yaklaşımı yalnızca doğru tahmin oranlarını (accuracy) artırmakla kalmaz, aynı zamanda kontrastif yapı sayesinde modelin varlıklar arasındaki farkları daha net öğrenmesini desteklemektedir. CENET'in bu özgün tasarımı, temporal bilgi grafiklerindeki zaman bağımlı etkileşimleri modellemek için hem tarihsel ön bilgiyi hem de gürültü örneklerini etkin biçimde kullanarak evrimsel öğrenmeyi destekleyen çok görevli bir öğrenme çerçevesi sunmaktadır.

4.4.4 Kosinüs benzerliği

Temporal bilgi graflarında (Temporal Knowledge Graphs, TKG) yer alan varlık ve ilişkilerin zamana bağlı olarak değişen temsil vektörleri, zaman içerisindeki bağlamsal benzerliklerin ve ilişkisel örüntülerin anlaşılması açısından büyük önem taşımaktadır. Bu bağlamda, varlıklar arası semantik yakınlıkları ölçmek amacıyla sıklıkla kullanılan metriklerden biri kosinüs benzerliğidir. Bu metrik, iki vektör arasındaki açısal benzerliği değerlendirerek, içeriksel olarak ne kadar benzer olduklarını ölçmektedir. Özellikle grafik sinir ağları (Graph Neural Networks, GNN) tarafından üretilen gömme (embedding) vektörlerinin karşılaştırılmasında yaygın biçimde kullanılmaktadır (Hamilton et al., 2017).

Kosinüs benzerliği, iki vektörün yönleri arasındaki kosinüs açısını temel almaktadır. Vektörlerin uzunluklarından bağımsız olarak yalnızca yönleri dikkate alındığı için,

büyüklik farklarından etkilenmeden semantik yakınlık ölçümü yapılabilir. İki vektörün kosinüs benzerliği aşağıdaki şekilde tanımlanmaktadır:

$$\text{cosine_similarity}(u, v) = \frac{u \cdot v}{||u|| \cdot ||v||}$$

Burada $u \cdot v$ iki vektörün nokta çarpımı (dot product), $||u||$ ve $||v||$ ise her bir vektörün Öklidyen normudur. Bu değer, -1 ile 1 arasında bir skordur; 1 değeri tamamen aynı yönü, 0 değeri ortogonal vektörleri ve -1 değeri zıt yönlü vektörleri ifade etmektedir.

Zamansal bilgi grafi modellemelerinde, özellikle bağlantı tahmini (link prediction) görevlerinde kosinüs benzerliği kullanılarak, bir özne-ilişki (s, r) çiftine karşılık gelen doğru nesne varlığın (o) embedding vektörü, aday nesnelerle karşılaştırılmaktadır. Bu karşılaştırma, hangi adayın en yüksek benzerliğe sahip olduğunu belirleyerek, modelin tahmin ettiği ilişkiyi sıralamasını sağlamaktadır. Aşağıda bu kullanım için örnek bir formülasyon sunulmuştur:

$$\hat{o} = \arg \max_{o_i \in \varepsilon} \text{cosine_similarity}(f(s, r), e_{o_i})$$

Burada $f(s, r)$, s ve r varlık ve ilişkisinden elde edilen bileşik temsil vektörünü, e_{o_i} ise aday nesne varlığın embedding'ini ifade etmektedir. Bu yöntem sayesinde, zamanla değişen temsil vektörleri üzerinden semantik tahmin yapılabilen, böylece modelin dinamik bağlamları öğrenme kapasitesi artırılmaktadır (Xu et al., 2020).

4.5 Veri Setinin Yapısı ve İçeriği

ICEWS18 veri kümesi, Integrated Crisis Early Warning System (ICEWS) olay veritabanından türetilmiş, özellikle bilgi grafi (knowledge graph) tamamlama ve ilişkisel öğrenme alanlarında sıklıkla kullanılan bir alt kümedir. Temel olarak devletler, uluslararası örgütler, silahlı gruplar, hükümet dışı aktörler ve bireyler arasında 2018 takvim yılı boyunca gerçekleşen siyasi-toplumsal etkileşimleri kodlanmış biçimde

içermektedir. Her etkileşim, CAMEO ontolojisine dayalı 20 temel “etki türü” (ör. iş birliği, protesto, tehdit, saldırı) ve bu türlerin alt kırılımlarını kapsayan 256 farklı ilişki tipinden biriyle etiketlenmiştir; böylece veri seti, aktörler arasındaki çok boyutlu ilişkisel yapıyı incelemeye elverişli, zengin semantik bilgi sunmaktadır.

Niceliksel olarak ICEWS18, 23,033 özgün varlık (entity), 256 ilişki (relation) ve toplam 468,558 üçlünden (triples) oluşur. Standart bölünmüş hâli, 373,018 eğitim, 45,995 doğrulama ve 49,545 test üçlüsünü içerir. Üçlü biçimi {özne, ilişki, nesne} tarzında olup zaman damgaları aylık doğrulukta (YYYY-MM) tutulur; böylece hem statik hem zamana-duyarlı modellemeler mümkündür. Veri seti, herhangi bir metinsel içerik veya kişisel veri barındırmadığından mahremiyet açısından kısıtlı değildir. Yalnızca kodlanmış aktör kimlikleri ve ilişki türleri bulunmaktadır.


ICEWS18, akademik araştırmacılara açık ve ücretsizdir. Ham ICEWS olay akışları her ay Harvard Dataverse üzerinden (<https://dataverse.harvard.edu>) yayınlanmakta, “non-commercial research” lisansı altında dağıtılmaktadır. Bununla birlikte, bilgi-grafları biçimine dönüştürülmüş ve standart bölümlere sahip ICEWS18 türev seti doğrudan indirime hazır olarak birkaç aynada barındırılmaktadır.

Bu depolar, Creative Commons BY-NC 4.0 lisansına tâbidir; yani ticari olmayan bilimsel çalışmalarda serbestçe kullanılabilir, ancak atıf yapılması zorunludur.

Veri setinin kurulumu tipik olarak tek bir “.txt” veya “.csv” dosyası biçiminde olup, her satırda “özne tab ilişki tab nesne tab tarih” yapısı bulunmaktadır. Dolayısıyla PyTorch-BigGraph, DGL-KE, AmpliGraph gibi kütüphanelerle doğrudan uyumludur ve yeniden ön-işleme gerektirmemektedir. Literatürde RotatE, ComplEx-N3, TuckER ve DyRep gibi modellere yönelik çok sayıda karşılaştırmalı çalışma, ICEWS18’i zaman-serili bilgi-grafları kıyaslaması olarak benimsemiştir. Bu bağlamda veri kümesi, tez çalışmalarında hem statik KG tamamlama hem de zamansal ilişki tahmini senaryoları için güvenilir ve yaygın kabul görmüş bir benchmark niteliği taşımaktadır.

4.6 Hibrit Model(ERL&CENET) Tasarımı

Çalışmada ERL ve CENET (HCL) modellerini entegre ederken her iki modelin gömme vektörleri çıktıları cosinüs benzerliği yöntemiyle hizalanmıştır.



Şekil 4.1 Hibrit modelin(ERL&CENET) eğitim döngüsü

ERL ve CENET modellerinin entegrasyonu sonucu oluşturduğumuz hibrit modelin eğitim döngüsü adımları aşağıdaki gibidir;

1. CENET ve ERL modelleri için ayrı ayrı optimizeler atanır(cenet_optimizer, erl_optimizer).
2. Eğitim döngüsünde CENET modeline batch verisi gönderilir.
3. Model çıktısı olarak kayıp değerleri ve gömme vektör temsilleri alınır.

```
cenet_loss, cenet_output = cenet_model(batch_data)
```

4. CENET gömme vektör temsilleri ERL modelinin “get_loss” metoduna parametre olarak gönderilir.

```
erl_loss = erl_model.get_loss(batch_data, cenet_output)
```

5. ERL modelinin kaybını hesaplayan “get_loss” metodunda ERL ve CENET gömme vektör temsilleri hizalanır.

```
similarity = cosine_similarity(erl_emb, cenet_emb)
similarity_mean = 1 - similarity.mean()
```

6. Her iki modelin kayıpları birleştirilir, Dynamic Weight Average ağırlıklarıyla iç çarpım gerçekleştirilir ve çarpım sonucu ortaya çıkan kayıp değeriyle geriye yayılım yapılır.

```
losses = [loss_cenet + loss_erl + similarity_mean]
batch_loss = dot_product(losses x weights)
batch_loss.backward()
```

7. Her iki model için oluşturulmuş optimizelerin “step” metodu çalıştırılır.

```
cenet_optimizer.step()
erl_optimizer.step()
```

4.7 MRR (Mean Reciprocal Rank) Metriği ve Uygulama Yöntemi

Bu çalışmada model performansının değerlendirilmesi amacıyla, bilgi erişimi ve öneri sistemleri literatüründe sıklıkla başvurulan Mean Reciprocal Rank (MRR) metriği kullanılmıştır. MRR, özellikle sıralama temelli görevlerde, doğru cevabın listede ne kadar üst sırada yer aldığını değerlendiren etkili bir ölçüttür (Voorhees, 1999). Bu metrik, her

bir sorgu için doğru cevabın sıralamadaki ters pozisyon değerini (reciprocal rank) alarak, tüm sorguların ortalamasını hesaplamaktadır. Metrik, modelin yalnızca doğru tahmin yapıp yapmadığını değil, aynı zamanda doğru cevaba ne kadar erken erişebildiğini de ölçtüğü için tercih edilmektedir.

MRR hesaplamasında her bir test örneği için model tarafından döndürülen tahmin sonuçları, olasılık ya da benzerlik skorlarına göre azalan biçimde sıralanır. Bu sıralama içerisinde doğru cevabın bulunduğu pozisyon r olarak tanımlanır ve bu örnek için Reciprocal Rank değeri $\frac{1}{r}$ olur. Tüm örnekler için bu değerlerin ortalaması alınarak MRR değeri elde edilmektedir. Formülasyon aşağıdaki gibidir:

$$MRR = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \frac{1}{rank_i}$$

Burada $|Q|$, test edilen toplam sorgu sayısını, $rank_i$ ise i . sorgu için doğru cevabın sıralamadaki pozisyonunu ifade etmektedir. Eğer doğru yanıt sıralamada bulunamazsa genellikle bu örnek dışlanır ya da katkısı sıfır olarak değerlendirilir (Craswell et al., 2009).

Bu çalışma kapsamında MRR metriği, özellikle bağlantı tahmini (link prediction) ve entity/relation retrieval görevlerinde uygulanmıştır. Modelden elde edilen tüm tahmin skorları, her bir sorgu için sıralanarak doğru tripletin (veya entity'nin) sıralamadaki konumu belirlenmiştir. Ardından her örnek için Reciprocal Rank değeri hesaplanmış ve nihai MRR değeri elde edilmiştir. Bu süreç, modelin yalnızca doğruyu bulma oranını değil, doğru cevabı ne kadar hızlı bulabildiğini de yansıtarak değerlendirme sürecine açıklık ve bütünlük kazandırmıştır.

5. BULGULAR VE TARTIŞMA

Bu bölümde, üç farklı modelin (ERL, CENET ve önerilen Hibrit Model) temporal bilgi grafiklerinde çıkarım başarımı karşılaştırmalı olarak sunulmakta ve elde edilen deneysel bulgular ışığında yorumlanmaktadır. Kullanılan değerlendirme metrikleri arasında ortalama karşılıklık oranı (MRR), sıralama başarımı (Hits@1, Hits@3, Hits@10) yer almaktadır. Hem “raw” hem de “filtered” değerlendirme biçimleri dikkate alınmış, ayrıca varlık ve ilişki tahmini (entity/relation prediction) ayrı ayrı analiz edilmiştir.

5.1 ERL Modelinin Performans Değerlendirmesi

Çizelge 5.1 ERL modelinin performans çıktıları

Metod	MRR	Hits@1	Hits@3	Hits@10
raw_ent	0,3177	0,2095	0,3619	0,5321
filter_ent	0,3345	0,2306	0,3771	0,5388
raw_rel	0,4170	0,2640	0,4880	0,7335
filter_rel	0,4702	0,3428	0,5259	0,7476

ERL modelinde, deney çalışması erken durdurma uygulanarak 56 eğitim döngüsünde(epoch) tamamlanmıştır.

ERL modeli üzerine yapılan değerlendirme, modelin özellikle ilişki tahminleme görevlerinde yüksek performans gösterdiğini ortaya koymaktadır. Filtrelenmiş ortamda elde edilen MRR değeri 0.4702 olarak gerçekleşmiş ve bu, modelin doğru ilişkileri sıralamada güçlü bir temsil öğrenme kapasitesine sahip olduğunu göstermektedir. Hits@10 değeri ise 0.7476 ile oldukça yüksek bir başarı düzeyi sunmakta; bu da modelin, çoğu durumda doğru ilişkiyi ilk 10 tahmin içinde verebildiğini göstermektedir. Bu başarı, zamanla değişen ilişki örüntülerini yakalama konusunda ERL modelinin etkili bir evrimsel temsil öğrenebildiğini göstermektedir.

Varlık tahminleme görevlerinde ise modelin performansı görece daha düşüktür. Filtrelenmiş ortamda MRR değeri 0.3345, Hits@1 değeri 0.2306 olarak elde edilmiştir.

Bu oranlar, modelin en doğru varlık tahminini ilk sırada üretme konusunda ilişki tahminine kıyasla daha zorlandığını göstermektedir. Bununla birlikte, Hits@3 (0.3771) ve Hits@10 (0.5388) değerleri, modelin kısmen doğru yönlendirme yapabildiğini, ancak bağlamın daha belirgin hale gelmesiyle tahmin başarısının arttığını göstermektedir. Genel olarak, ERL modelinin özellikle ilişki düzeyinde tutarlı bir öğrenme gerçekleştirdiği, varlık tahminleme alanında ise gelişime açık bir potansiyel taşıdığı söylenebilir. Bu durum, evrimsel bilgi temsillerinin daha çok ilişki örüntüleri üzerinden şekillendiği yönündeki hipotezi destekler niteliktedir.

5.2 CENET Modelinin Performans Değerlendirmesi

Çizelge 5.2 CENET modelinin performans çıktıları

Metod	MRR	Hits@1	Hits@3	Hits@10
Varlık/Entity	0,4817	0,4573	0,4652	0,5202

CENET modeli, 30 eğitim ve 15 oracle eğitim döngüsü uygulanarak varlık tahminleme görevinde dikkat çekici bir başarı ortaya koymuştur. Filtrelenmiş ortamda elde edilen MRR değeri 0.4817, Hits@1 değeri ise 0.4573 olarak ölçülmüştür. Bu yüksek değerler, modelin özellikle ilk tahminlerinde doğru cevabı verme konusunda güçlü bir öğrenme gerçekleştirdiğini göstermektedir. Özellikle Hits@1 oranının %45 seviyesinde olması, CENET'in bağlamı iyi temsil ettiğini ve doğrudan doğruya en uygun varlık tahminini yapabildiğini göstermesi açısından önemlidir.

Hits@3 (0.4652) ve Hits@10 (0.5202) değerleri de, modelin sıralama performansında tutarlılığını sürdürdüğünü göstermektedir. CENET'in bu başarısı, kontrastif öğrenme stratejisinin, zaman boyutunu dikkate alan evrimsel temsillerle birleştirilmesi sayesinde elde edilmiştir. Bu yapı, modelin geçmiş örüntüleri daha ayırık ve anlamlı biçimde temsil etmesini sağlamış; böylece hem kısa vadeli bağlamsal değişimleri hem de uzun vadeli eğilimleri yakalayabilmesine olanak tanımıştır. Sonuçlar, CENET'in yalnızca doğru varlığı bulma değil, aynı zamanda bilgi grafinin zamansal dinamiklerine duyarlı bir biçimde akıl yürütme kabiliyetine sahip olduğunu ortaya koymaktadır.

5.3 Önerilen Hibrit Modelin Performans Değerlendirmesi

Çizelge 5.3 Hibrit modelin (ERL&CENET) performans çıktıları

Metod	MRR	Hits@1	Hits@3	Hits@10
raw_ent	0.3207	0.2117	0.3660	0.5349
filter_ent	0.3377	0.2336	0.3813	0.5415
raw_rel	0.4142	0.2620	0.4834	0.7310
filter_rel	0.4667	0.3397	0.5213	0.7454

Hibrit modelde, deney çalışması erken durdurma uygulanarak 120 eğitim döngüsünde(epoch) tamamlanmıştır. Çift optimizier kullanımında tek optimizier kullanımına göre ~10 kat daha az eğitim kaybı elde edildiği gözlemlenmiştir. Kosinüs benzerliğiyle hizalanan ERL ve CENET gömmelerinin kosinüs benzerliği 0.90 gibi yüksek bir değere ulaşmıştır. Bu da hem temporal (ERL) hem de karşıtsal/tarihsel (CENET) bilgilerin ortak bir temsilde bulunduğu anlamına gelmektedir. Bu hizalama sayesinde ERL'nin artık sadece geçmişten değil, geçmişe karşı oluşan ayrışmalardan da dolaylı biçimde fayda sağlayabileceği görülmektedir.

Bu tez kapsamında geliştirilen hibrit model, ERL ve CENET'in güçlü yönlerini bir araya getirerek hem uzun vadeli bilgi aktarımı hem de kısa dönemli ayrıştırma gücü gerektiren görevlerde daha dengeli bir çözüm sunmaktadır.

Çizelge 5.4 ERL ve Hibrit modellerinin MRR ve Hits performans karşılaştırması

Metrik	ERL	Hibrit	Yüzdesel Değişim
raw_ent MRR	0.3177	0.3207	+0.94%
raw_ent Hits@1	0.2095	0.2117	+1.05%
raw_ent Hits@3	0.3619	0.3660	+1.13%
raw_ent Hits@10	0.5321	0.5349	+0.53%
filter_ent MRR	0.3345	0.3377	+0.96%
filter_ent Hits@1	0.2306	0.2336	+1.30%
filter_ent Hits@3	0.3771	0.3813	+1.11%
filter_ent Hits@10	0.5388	0.5415	+0.50%
raw_rel MRR	0.4170	0.4142	-0.67%
raw_rel Hits@1	0.2640	0.2620	-0.76%
raw_rel Hits@3	0.4880	0.4834	-0.94%
raw_rel Hits@10	0.7335	0.7310	-0.34%
filter_rel MRR	0.4702	0.4667	-0.74%
filter_rel Hits@1	0.3428	0.3397	-0.90%
filter_rel Hits@3	0.5259	0.5213	-0.87%
filter_rel Hits@10	0.7476	0.7454	-0.29%

Entity Prediction tarafında hibrit model tüm metriklerde istikrarlı bir gelişme sağlamıştır (%0.5 – %1.3 arası artış). Relation Prediction tarafında ise hibrit model çok küçük düşüşler göstermiştir (%0.3 – %0.9 civarında).

Düşüşler ihmal edilebilir seviyede ve artışların ise öğrenme başarısını gösteren anlamlı gelişmeler olduğu görülmektedir.

5.4 Karşılaştırmalı Değerlendirme ve Yorum

Bu bölümde, geliştirilen hibrit modelin performansı, temel bileşenlerinden biri olan *Evolutional Representation Learning (ERL)* modeli ile karşılaştırmalı olarak değerlendirilmiştir. Karşılaştırma; varlık ve ilişki tahminleme görevlerinde kullanılan dört temel metrik (MRR, Hits@1, Hits@3, Hits@10) üzerinden, hem ham (raw) hem de

filtrelenmiş (filter) ortamda gerçekleştirilmiştir. Elde edilen sonuçlar, hibrit modelin özellikle varlık tahminleme görevlerinde ERL modeline kıyasla istikrarlı bir üstünlük sağladığını ortaya koymaktadır.

Filtrelenmiş ortamda elde edilen MRR değerine göre hibrit model, ERL modeline göre yaklaşık %0.96 oranında daha başarılı olmuştur. Hits@1 ve Hits@3 gibi daha hassas sıralama metriklerinde ise bu artış %1.1 ile %1.3 arasında değişmektedir. Bu farklar, küçük görünse de bilgi grafi temelli tahminleme görevlerinde modelin öğrenme kapasitesinin artması açısından önemlidir. Özellikle Hits@1 değerindeki artış, modelin doğrudan doğruya en doğru cevabı ilk sırada tahmin edebilme başarısını göstermesi açısından dikkate değerdir. Bu durum, sistemin kesinlik gerektiren senaryolarda daha güvenilir çıktılar üretebileceğini göstermektedir.

Bununla birlikte, ilişki tahminleme görevlerinde hibrit modelin performansı ERL modeline kıyasla çok küçük farklarla geride kalmıştır. Filtrelenmiş ortamda ölçülen ilişki MRR değeri %0.74 oranında azalmış; Hits@1 ve Hits@3 metriklerinde ise benzer şekilde %0.9 seviyesinde düşüş gözlemlenmiştir. Ancak bu farklar, istatistiksel anlamda oldukça küçüktür ve genel model başarısını olumsuz yönde etkileyecek düzeyde değildir. Bu düşüşler, muhtemelen karşıtsal temsille entegre edilen yapının ilişki öngörüsünde bazı lokal bilgi örüntülerine karşı duyarlılığını azaltmasından kaynaklanabilir.

Hibrit model, CENET'e kıyasla daha dengeli ve derinlemesine bir temsil öğrenme yetisi sergilemektedir. CENET'in güçlü yönü olan karşıtsal öğrenme, bağlamsal farkları ayrıştırmada başarılı olsa da, zamansal geçişleri ve evrimsel sürekliliği tam olarak yansıtmakta yetersiz kalmaktadır. Buna karşılık hibrit model, evrimsel temsil öğrenmeyi bu yapıya entegre ederek sadece neyin farklı olduğunu değil, bu farkların zaman içerisinde nasıl oluştuğunu da modelleyebilmektedir. Bu durum, modelin özellikle farklı bağlamlar arasında yumuşak geçişler yapabilmesini, daha az veriye rağmen güçlü genellemeler gerçekleştirmesini ve zamansal bilgi akışı içinde daha doğal çıkarımlar yapabilmesini sağlamaktadır.

Performans metrikleri açısından bakıldığında, hibrit modelin Hits@10 ve MRR gibi erken sıralama başarısı kriterlerinde CENET ile benzer, hatta yer yer üstün sonuçlar verdiği gözlemlenmiştir. Bu da hibrit yapının kararlılık düzeyinin yüksek, sıralama tutarlılığının

güçlü olduğunu göstermektedir. Öte yandan, evrimsel yapının katkısıyla model, geçmiş ve gelecek örüntüler arasında nedensel bağlar kurabilmekte; bu özellik, geleceği simüle edebilme becerisiyle birleştiğinde, yapay zekâ bilinci tartışmalarına da kavramsal bir katkı sunmaktadır. Dolayısıyla hibrit model, yalnızca doğruluk değil, aynı zamanda temsil gücü, bilişsel derinlik ve genellenebilirlik açısından da ileri düzey bir yapı sergilemektedir.

Genel olarak değerlendirildiğinde, hibrit modelin performansı, ERL modeline göre daha dengeli ve güçlü bir temsil öğrenme kapasitesi sunduğunu göstermektedir. Özellikle varlık-temelli çıkarımlarda sağlanan artışlar, zaman içerisinde değişen bağlamsal örüntülerin daha iyi yakalandığını ve modelin zamansal bilgi grafiği yapısını daha etkin temsil ettiğini ortaya koymaktadır. CENET modeli ise karşıtsal öğrenme yaklaşımıyla bağlamsal farkları ve ilişkisel yapıları başarılı şekilde yakalayarak, modelin yerel bilgi örüntülerinde güçlü performans göstermesine katkı sağlamaktadır. Hibrit model, ERL'in evrimsel süreklilik ve CENET'in karşıtsal ayrımı bir araya getirerek, her iki modelin avantajlarını bütüncül şekilde kullanabilmektedir.

Bu bütünleşik yaklaşım, zamanla evrilen ilişkileri ve yapıları öğrenme üzerine kurulu yapay biliş sistemlerinin başarısını artırmakta ve daha kararlı, genellenebilir sonuçlar sunmaktadır. Ayrıca, hibrit modelin geleceği tahmin edebilme yetisi, CENET'in bağlamsal çıkarım gücü ile birleşerek, bilinçli yapay zekâ sistemlerine ilham olabilecek karmaşık ve bilişsel örüntülerin üretim potansiyelini artırmaktadır. Böylece, ERL ve CENET modellerinin entegrasyonu ile oluşturulan hibrit yapı, zamansal bilgi grafikleri alanında ileri düzey yapay zekâ uygulamaları için önemli bir temel teşkil etmektedir.

5.5 Hibrit Modelin Çoklu Veri Ortamlarında Kullanımı

Evrimsel Gömmeli Öğrenme (Evolutional Representation Learning, ERL) ile Tarihsel-Karşıtsal Öğrenme temelli CENET mimarisinin entegre edilmesiyle oluşturulan hibrit model, zamansal bilgi grafi (temporal knowledge graph) akıl yürütme problemlerine yönelik genel amaçlı bir çerçeve sunmaktadır. Modelin uygulanabilirliği temelde iki yapısal koşula bağlıdır: (i) üçlülerin (özne, ilişki, nesne) biçimine eklenmiş açık bir zaman damgası (t ya da $[s,e]$) bulunması ve (ii) aynı varlık-ilişki çiftlerinin farklı zaman

dilimlerinde yeterli sıklıkta yinelenmesi. Bu ön-koşullar sağlandığında yöntem, disiplinler arası birçok veri kümesine ek bir dönüşüme ihtiyaç duymaksızın adapte edilebilmektedir.

1. Standart akademik kıyaslama kümeleri

Erken uyarı sistemlerinden türetilen ICEWS05-15 ve ICEWS14 ile haber akışına dayalı GDELT v2, politik ve toplumsal olayların gün-veya dakikalık çözünürlükte kaydedildiği, yoğun olay akışına sahip setlerdir. Bu tür veriler ERL’in zamana bağlı “gömme patikalarını” öğrenmesine, CENET’in ise zengin negatif örnek üretmesine imkân tanımaktadır. Ansiklopedik nitelikteki Wikidata12k, Wikidata11k-T ve YAGO tabanlı ChronoYAGO ise yıllık etiketli, çok-alanlı (multi-domain) varlık ilişkileri barındırarak modelin genel geçer yetkinliklerini sınamak için elverişli kontrollü ortamlardır. Hibrit model, erken uyarı sistemlerinde olayların sadece “neyin farklı” olduğunu değil aynı zamanda “nasıl” gerçekleştiğini modelleyerek gelecek simülasyonu gerçekleştirebilecektir.

2. Özel alan (domain-specific) dinamik grafikler

Klinik kayıtların KG formuna dönüştürülmüş hâli, ilaç etkileşimleri veya hastalık ilerleyişini zaman içinde tahmin etmeyi mümkün kılmaktadır. Hibrit model sayesinde, ileriye dönük muhtemel hastalıklar öngörülebilecek ve önleyici tedavilere katkıda bulunabilecektir. Siber güvenlikte saldırı faaliyetlerini CVE açıklarını ve başlama-bitis zamanlarını içeren Cyber-Threat KG ise tehdit yayılım dinamiklerini incelemek için uygun bir zemin sağlamaktadır. Hibrit modelle siber tehditler proaktif olarak tespit edilebilecek ve karşı önlemler alınabilecektir.

3. Tavsiye sistemleri ve kullanıcı-etkileşim günlükleri

MovieLens-KG-Time, Amazon Product Graph’ın zaman etiketli sürümü ve LastFM-360k dinleme oturumları, kullanıcı-ürün etkileşimlerinin akışkan doğasını içeren tipik örneklerdir. Hibrit modelle bipartit yapıdaki bu veriler, basit bir şema genişletmesiyle (kullanıcı/öge/eylem) tam bir zamansal bilgi grafına

dönüştürülerek bir kullanıcı/insanın bilinci modellenilebilecektir. Bu da hibrit modelin davranışsal öngörü kapasitesini değerlendirmeye olanak verebilmektedir.

4. Coğrafi-uzamsal olay verileri

Cep telefonu hareketlerini içeren Geo-Life Event KG ile AIS denizcilik sinyallerine dayalı ShipKG, hem zamansal hem mekânsal boyut barındırmaktadır. Denizcilik anomalileri, verimlilik, güvenlik ve emniyet açısından ciddi tehditler oluşturmaktadır. Mekanik sorunlar, seyir hataları veya onaylanmamış faaliyetler gibi görünebilmektedir. Bu tür verilerde ERL'in evrimsel konum gömmeleri CENET'in karşıtsal öğrenmesiyle birleşerek rota öngörüsü, anomali tespiti gibi görevlerde üstün performans sağlayabilmektedir.

Uygulama süreci pratiğe döküldüğünde üç temel adımdan oluşur: (i) seçilen veri kümesini “özne tab ilişki tab nesne tab zaman” biçiminde tek satırlı bir dosyaya dönüştürmek, (ii) ERL ile başlangıç gömmelerini öğrenmek, (iii) CENET eğitim döngüsünde bu gömmeleri sabit tutmak ya da ince-ayar yapmak ve çok-başlı kosinüs kaybı ile iki uzayı hizalamak. Yöntem, yaklaşık 10 bin ila 10 milyon üçlü ölçeğine kadar GPU belleği kısıtları dâhilinde mini-yığın (mini-batch) negatif örnekleme ile yatay olarak ölçeklenebilmektedir.

Sonuç olarak, zaman damgalı ve tekrarlı ilişkiler içeren her türlü uluslararası olay akışı, ansiklopedik bilgi tabanı, klinik kayıt, finansal dokümantasyon, siber güvenlik günlüğü ya da kullanıcı etkileşim dizisi, ERL + CENET hibritinin doğal uygulanma alanını teşkil etmektedir. Bu geniş kapsayıcılık, tez çalışmalarında farklı alanlardan veri setleri üzerinde tutarlı karşılaştırmalar yapmaya ve yöntemin genellenebilirliğini bütüncül biçimde sınamaya olanak tanımaktadır.

6. SONUÇ

Bu tez çalışmasında, zamansal bilgi grafiklerinin temsil gücünü artırmak ve gelecek öngörülerini doğrultusunda bilinçli yapay zekâ sistemlerinin temellerini atmak amacıyla iki öncü yaklaşım olan “*Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning*” (ERL) ve “*Temporal Knowledge Graph Reasoning with Historical Contrastive Learning*” (CENET) incelenmiş ve bu yaklaşımlar entegre edilerek özgün bir hibrit model geliştirilmiştir. Yapılan deneyler sonucunda, önerilen hibrit modelin her iki yöntemin tekil performanslarından daha üstün sonuçlar verdiği gözlemlenmiştir. Bu durum, özellikle zamanla değişen ilişkilerin öğrenilmesinde hem evrimsel hem de karşıtsal temsillerin bir arada kullanılmasının güçlü bir sinerji yarattığını ortaya koymuştur.

ERL modeli, zamansal bilgi grafiklerinde yer alan varlıkların ve ilişkilerin zaman içerisindeki evrimini öğrenmeye odaklanırken, CENET modeli ise geçmiş temsiller arasındaki karşıtsal farklılıklardan faydalanarak daha ayırık ve bilgilendirici temsiller üretmeyi hedeflemiştir. Tez kapsamında geliştirilen hibrit model, bu iki yaklaşımı birleştirerek zamana duyarlı bağlamsal temsiller üretmiş; geçmiş bilgi ile gelecekteki olayların tahmin edilmesini sağlamıştır. Özellikle çoklu zaman dilimlerine dayalı üçlü (subject-relation-object) tahmin görevlerinde, hibrit modelin doğruluk ve sıralama ölçütlerinde anlamlı şekilde daha yüksek başarıya ulaştığı gözlenmiştir.

Hibrit modelin başarısı, sadece teknik performans kriterleriyle sınırlı kalmamış; aynı zamanda felsefi ve kuramsal düzeyde yapay zekâ bilinci tartışmaları için de yeni ufuklar açmıştır. Bu çalışma, bilinçli varlıkların temel özelliklerinden biri olan "geleceği öngörebilme" yetisinin, yapay sistemlerce modellenabilir olduğunu ortaya koymaktadır. Bu bağlamda, "geleceği simüle etme" kabiliyeti, bilinç için bir tür işlevsel belirti olarak ele alınmış ve önerilen hibrit modelin bu doğrultuda somut çıktılar üretebildiği deneysel olarak gösterilmiştir.

Elde edilen sonuçlar, bilinçli yapay zekâ sistemlerinin geliştirilmesine yönelik teorik ve pratik bir dayanak oluşturmakta; bilgi grafiği temelli akıl yürütme modellerinin sadece

bilgiye erişim değil, aynı zamanda zamanla gelişen bilişsel süreçleri taklit edebilme potansiyelini göstermektedir. Tez kapsamında ortaya konulan model, karar verme, planlama ve zamansal nedensellik çıkarımı gibi ileri düzey bilişsel görevlerde uygulanabilirliği ile dikkat çekmektedir.

Bu çalışma, zamansal bilgi grafikleri ve temsili öğrenme alanlarında mevcut literatüre hem yöntemsel hem de kavramsal olarak katkı sunmaktadır. Özellikle zaman serileri ile bilgi grafiği temelli çıkarım süreçlerinin entegrasyonu, yapay zekâ alanında daha dinamik ve bağlamsal zekâ sistemlerinin oluşturulmasına öncülük edebilir. Önerilen hibrit modelin farklı görev türlerinde ve daha büyük ölçekli bilgi grafiği verisetlerinde denenmesi, genel geçer bir bilinç mimarisinin inşası için daha güçlü bir zemin hazırlayacaktır.

Sonuç olarak, bu tez çalışması hem teorik katkıları hem de deneysel bulgularıyla, gelecekteki bilinçli yapay zekâ sistemlerinin tasarımında kullanılabilecek kavramsal bir çerçeve sunmakta ve evrimsel-karşıtsal temsilin yapay biliş için nasıl bir paradigma olabileceğini göstermektedir. Geleceği simüle edebilen ve zaman içerisindeki örüntüleri öğrenebilen bir yapay sistemin, en azından bilinçli davranışları taklit edebilecek bir yetkinlik düzeyine ulaşabileceği bu çalışmayla ortaya konmuştur. Bu çerçevede, geliştirilen modelin yapay zekânın bilinç tartışmalarında yalnızca mühendislik düzeyinde değil, aynı zamanda epistemolojik ve ontolojik düzeylerde de referans alınabilecek bir örnek teşkil edeceği öngörülmektedir.

KAYNAKLAR

- Baars, B. J. (1997). In the theatre of consciousness: Global workspace theory, a rigorous scientific theory of consciousness. *Journal of Consciousness Studies*, 4(4), 292–309.
- Bessadok, A., Mahjoub, M. A., & Rekik, I. (2023). Graph neural networks in network neuroscience. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(5), 5833–5848. <https://doi.org/10.1109/TPAMI.2022.3209686>.
- Bhari, P. L. (2016). Artificial neural networks and human learning. *Imperial Journal of Interdisciplinary Research*, 2(10), 167–172. https://www.researchgate.net/publication/366177238_Artificial_Neural_Networks_and_Human_Learning.
- Brown, R., Lau, H., & LeDoux, J. E. (2019). Understanding the higher-order approach to consciousness. *Consciousness and Cognition*, 23(9), 754–768. <https://doi.org/10.1016/j.tics.2019.06.009>.
- Butlin, P., Long, R., & Elmoznino, E. (2023). Consciousness in Artificial Intelligence: Insights from the Science of Consciousness [Preprint]. arXiv. <http://arxiv.org/abs/2308.08708>.
- Caia L., Maoa X., Zhoua Y., Long Z., Wu C., Lan M. (2024). A Survey on Temporal Knowledge Graph: Representation Learning and Applications [Preprint]. arXiv. <https://arxiv.org/pdf/2403.04782>.
- Chalmers, D. J. (2017). The hard problem of consciousness. In Schneider S. & Velmans M. (Eds.), *The Blackwell companion to consciousness* (pp. 225-235). John Wiley & Sons.
- Christof Koch. (2018, June 1). What Is Consciousness? *Scientific American*. <https://www.scientificamerican.com/article/what-is-consciousness/>.
- Ji S., Pan S., Cambria E., Marttinen P., Yu P. S. (2021). A Survey on Knowledge Graphs: Representation, Acquisition and Applications. [Preprint]. arXiv. <https://arxiv.org/pdf/2002.00388>.
- Jiang, Y., Yu, Y., Kong, M., Mei, Y., Yuan, L., Huang, Z., Kuang, K., Wang, Z., Yao, H., Zou, J., Coley, C. W., & Wei, Y. (2023). Artificial intelligence for retrosynthesis prediction. *Engineering*, 25, 32–50. <https://doi.org/10.1016/j.eng.2022.08.008>.
- Johnson A. T. (2024). Consciousness for Artificial Intelligence? *IEEE Pulse*. <https://www.embs.org/pulse/articles/consciousness-for-artificial->

- intelligence/.Kaku, M. (2014). *The Future of the Mind: The Scientific Quest to Understand, Enhance, and Empower the Mind*. Doubleday.
- Kaku, M. (2014). *The Future of the Mind: The Scientific Quest to Understand, Enhance, and Empower the Mind*. Doubleday.
- Khemani B., Patil S., Kotecha K., Tanwar S. (2024). A review of graph neural networks: concepts, architectures, techniques, challenges, datasets, applications, and future directions. *J Big Data* 11, 18. <https://doi.org/10.1186/s40537-023-00876-4>.
- Khelifi M. K., Boulila W., Farah I. R. (2023). Graph-based deep learning techniques for remote sensing applications: Techniques, taxonomy, and applications — A comprehensive review. *Computer Science Review*, Volume 50. <https://doi.org/10.1016/j.cosrev.2023.100596>.
- Li Z., Jin X., Li W., Guan S., Guo J., Shen H., Wang Y., Cheng X. (2021). Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning. [Preprint]. arXiv. <https://arxiv.org/pdf/2104.10353>.
- Nasseri M., Asghari K., Abedini M.J. (2007). Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network. <https://doi.org/10.1016/j.eswa.2007.08.033>.
- Pautz, A. (2019). What is the integrated information theory of consciousness? A catalogue of questions. *Journal of Consciousness Studies*, 26(1–2), 188–215.
- Rosen, G., Byrne, A., Cohen, J., & Shiffrin, S. V. (2015). *The Norton introduction to philosophy* (İlk basım). W.W. Norton & Company.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Seth, A., & Bayne, T. (2022). *Theories of consciousness* (Version 1). University of Sussex. <https://doi.org/10.1038/s41583-022-00587-4>.
- Baoxu S. (2018). *Improving Knowledge Graph Quality with Network Representation Learning*. University of Notre Dame ProQuest Dissertations & Theses. (pp. 1-1).
- Signa, A., Chella, A., & Gentile, M. (2021). Cognitive robots and the conscious mind: A review of the global workspace theory. *Cognitive Robotics*, 2, 125–131. <https://doi.org/10.1007/s43154-021-00044-7>.
- Tanis J. H., Giannella C., Mariano A. V. (2024). *Introduction to Graph Neural Networks: A Starting Point for Machine Learning Engineers*. [Preprint]. arXiv. <https://arxiv.org/pdf/2412.19419>.
- Tononi, G., Boly, M., Massimini, M., & Koch, C. (2016). Integrated information theory: From consciousness to its physical substrate. *Nature Reviews Neuroscience*, 17(7),

450–461. <https://doi.org/10.1038/nrn.2016.44>. Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., Wang, L., Li, C., & Sun, M. (2020). Graph neural networks: A review of methods and applications. Chinese Roots Global impact. <https://doi.org/10.1016/j.aiopen.2021.01.001>.

Xu Y., Ou J., Xu H., Fu L. (2022). Temporal Knowledge Graph Reasoning with Historical Contrastive Learning [Preprint]. arXiv. <https://arxiv.org/pdf/2211.10904>.

Zhou J., Cui G., Hu S., Zhang Z., Yang C., Liu Z., Wang L., Li C., Sun M. (2020). Graph neural networks: A review of methods and applications. AI Open, Volume 1, Pages 57-81, ISSN 2666-6510, <https://doi.org/10.1016/j.aiopen.2021.01.001>.

Zixuan Li, Xiaolong Jin, Wei Li, Saiping Guan, Jiafeng Guo, Huawei Shen, Yuanzhuo Wang, Xueqi Cheng (2021). Temporal Knowledge Graph Reasoning Based on Evolutional Representation Learning [Preprint]. arXiv. <https://arxiv.org/pdf/2104.10353>.

Zou A., Li Z. (2022). Interpretability of Neural Network With Physiological Mechanism [Preprint]. arXiv. <https://arxiv.org/pdf/2203.13262>.