



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

NÖROBİLİM ANABİLİM DALI
NÖROBİLİM YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

DOĞAL DİL İŞLEME VE MAKİNE ÖĞRENİMİ; YÖNTEM VE
UYGULAMA ARAŞTIRMASI

Melisa Ceren ÇİMİLİ

Tez Danışmanı
Prof. Dr. Türker Tekin ERGÜZEL

İSTANBUL-2025

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

NÖROBİLİM ANABİLİM DALI
NÖROBİLİM YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

DOĞAL DİL İŞLEME VE MAKİNE ÖĞRENİMİ; YÖNTEM VE
UYGULAMA ARAŞTIRMASI

Melisa Ceren ÇİMİLİ

Tez Danışmanı
Prof. Dr. Türker Tekin ERGÜZEL

İSTANBUL-2025

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

Anabilim Dalı : Nörobilim Anabilim Dalı
Program : Nörobilim Yüksek Lisans Programı
Öğrenci No : 224202007
Öğrenci Adı Soyadı : Melisa Ceren ÇİMİLİ

Doğal Dil İşleme ve Makine Öğrenimi; Yöntem ve Uygulama Araştırması isimli çalışma aşağıdaki jüri tarafından 30 / 06 / 2025 tarihinde yapılan sınavda Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir.

Jüri Başkanı : Prof. Dr. Korkut ULUCAN İmza
(Marmara Üniversitesi)

Danışman : Prof. Dr. Türker Tekin ERGÜZEL İmza
(Üsküdar Üniversitesi)

Üye : Prof. Dr. Barış METİN İmza
(Üsküdar Üniversitesi)

ONAY

Bu tez, yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun tarih ve sayılı kararıyla kabul edilmiştir.

Prof.Dr. Türker Tekin ERGÜZEL
Enstitü Müdürü

ÖZET

DOĞAL DİL İŞLEME VE MAKİNE ÖĞRENİMİ; YÖNTEM VE UYGULAMA ARAŞTIRMASI

Dil öğrenimi ve üretimi, bir iletişim aracı olmanın da ötesinde dünyayı anlamlandıran bilişsel bir araç işlevine sahiptir. Doğal dil işleme (NLP) sistemleri, bilişsel dil süreçlerini derin öğrenme yöntemlerini kullanarak tekrardan yorumlamakta ve üretebilmektedir. Bunun da ötesinde, yapay zekâ teknolojisinin gelişmesiyle beraber, günümüzde “zihin okuma” olarak bilinen beyin-temelli dil tahmini mümkün hale gelmiştir. Bu çalışmada, doğal dil işlemenin nörobilimsel temelleri sistematik olarak ele alınmış ve doğal dil işleme görevlerinde kullanılan derin öğrenme yöntemleri kuramsal bir çerçevede incelenmiştir. EEG ve fMIR gibi non-invaziv nörogörüntüleme tekniklerinden elde edilen veriler ile eğitilen derin öğrenme modellerinin, katmanlar aracılığı ile nöronları simüle edebildiği ve dilin sözdizimsel ve anlamsal işlenmesinde insan beynindeki hiyerarşik dil işleme yapılarıyla paralellik gösterdiği bulunmuştur. Özellikle CNN, RNN ve Transformer tabanlı mimarilerin, kelime gömme, anlamsal analiz, makine çevirisi, duygu analizi ve sınıflandırması, soru yanıtlama ve kelime tahmini gibi doğal dil işleme görevlerinde yüksek performans gösterdiği bildirilmiştir. Bu bağlamda, doğal dil işleme sistemleri, hem beyin-bilgisayar arayüzlerinin altyapısını şekillendirerek gerçekçi dil üretiminde yeni bir paradigma sunmakta hem de insan beyninin ve bilişsel bozuklukların anlaşılmasında yeni kapılar aralamaktadır.

Anahtar Kelimeler: Doğal Dil İşleme, Makine Öğrenimi, Nörobilim, Derin Öğrenme Mimarileri, Yapay Zekâ

ABSTRACT

NATURAL LANGUAGE PROCESSING AND MACHINE LEARNING; METHOD AND APPLIED RESEARCH

Language acquisition and production function not only as tools for communication but also as cognitive instruments that shape our understanding of the world. Natural Language Processing (NLP) systems reinterpret and generate cognitive language processes using deep learning methods. Beyond that, advancements in artificial intelligence have made brain-based language prediction—commonly referred to as “mind reading”- increasingly possible. This study systematically explores the neuroscientific foundations of natural language processing and examines the deep learning methods used in NLP tasks within a theoretical framework. Deep learning models trained on data derived from non-invasive neuroimaging techniques such as EEG and fMRI have been found to simulate neurons through their layers and demonstrate parallels with the hierarchical language processing structures of the human brain in syntactic and semantic analysis. Notably, architectures based on CNNs, RNNs, and Transformers have shown high performance in various NLP tasks such as word embedding, semantic analysis, machine translation, sentiment analysis and classification, question answering, and word prediction. In this context, NLP systems not only shape the infrastructure of brain-computer interfaces by offering a new paradigm in realistic language generation, but also open new doors to understanding the human brain and cognitive disorders.

Keywords: Natural Language Processing, Machine Learning, Neuroscience, Deep Learning Architecture, Artificial Intelligence

TEŐEKKÜR

Tez danıőmanlıđımı yapan Prof. Dr. Tőrker Tekin ERGÜZEL'e teőekkőr ederim. Her an bilgi ve tecrübelerine baővurabildiđim, bana alanımı sevdiren ve öđreten saygıdeđer hocam Doç. Dr. Burak ERDENİZ'e teőekkörü borç bilirim.

Ek olarak, çalıőma süresince karőılaőtıđım tüm zorluklarda yanımda olan ve hayatımın tüm evresinde beni destekleyen kıymetli aileme özellikle Dr. Alaaddin ÇİMİLİ ve Dr. Ebru Burcu ÇİMİLİ GÖK'e, mesleki anlamda bana her zaman motivasyon sađlayan arkadaőım Psk. Dan. Ufuk ERDEM'e sonsuz teőekkürlerimi sunarım.

BEYAN FORMU

Bu çalışmadaki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi, görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, yararlandığım kaynaklara bilimsel normlara uygun olarak atıfta bulunduğumu, tezimin kaynak gösterilen durumlar dışında özgün olduğunu, tarafımdan üretildiğini ve Üsküdar Üniversitesi Sağlık Bilimleri Enstitüsü Tez Yazım Kılavuzuna göre yazıldığını beyan ederim

10.06.2025

Melisa Ceren Çimili

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
BEYAN FORMU	iv
İÇİNDEKİLER	v
TABLolar DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
RESİMLER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ	1
2. GENEL BİLGİLER	4
2.1. Literatür Çalışmaları	4
3. DOĞAL DİL İŞLEMENİN NÖROANATOMİK TEMELLERİ	8
3.1. İnsan Beynindeki Doğal Dil Öğrenme Süreçleri.....	8
3.2. Nörogörüntüleme ve Beyin Fizyolojisi Ölçümleri.....	10
3.3. Dil İşleme Modelleri	11
3.4. Anlamsal ve Sözdizimsel Dil Süreçleri.....	32
4. DOĞAL DİL İŞLEME VE MAKİNE ÖĞRENİMİ	39
4.1. Yapay Sinir Ağlarının Temel Bileşenleri.....	42
4.2. Evrişimli Sinir Ağları.....	44
4.3. Tekrarlayan Sinir Ağları	52
4.4. Transformer Mimarisi	62
4.5. Aktivasyon Fonksiyonları	66
5. GEREÇ VE YÖNTEM	82
6. PROBLEMLER, SINIRLILIKLAR VE GÜNCEL GELİŞMELER	84

6.1. Problemler ve Sınırlılıklar	84
6.2. Güncel Gelişmeler.....	87
7. SONUÇ VE ÖNERİLER.....	91
KAYNAKLAR.....	92
EKLER.....	128
Ek 1. ÖZGEÇMİŞ.....	128



TABLolar DİZİNİ

	<u>Sayfa</u>
Tablo 1: ILSVRC Yarışması'nı kazanan bazı CNN mimarileri.....	50
Tablo 2: Derin mimarilerde ReLU ve Softmax aktivasyon fonksiyonu kullanımı .	78
Tablo 3: GELU aktivasyon fonksiyonunun kullanıldığı mimariler.....	81



ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1: Wernicke Arki, 1874.	13
Şekil 2: Lichtheim Evi.....	14
Şekil 3: Lichtheim'in birçok noktadan oluşan kavram modeli. (Lichtheim, 1885).15	15
Şekil 4: Geschwind'in Klasik Modeli	16
Şekil 5: Afazik hastalarda karar verme ağacı.	18
Şekil 6: Dejerine'nin Saf Kelime Körlüğü diyagramı.....	19
Şekil 7: Dilin işlevsel anatomisinin Çift-Yönlü Yolak Modeli.....	23
Şekil 8: 'Ne' ve 'nerede' için ikili işleme şeması.....	24
Şekil 9: Konuşma tanımada seri ve paralel modeller	26
Şekil 10: Çift-Yönlü Yolak Modeli'nin fonksiyonel anatomisi için bir çerçeve.....	27
Şekil 11: Konuşma üretiminin geri besleme kontrolü modeli.....	29
Şekil 12: Sol hemisferin anatomik ve sitoarkitektonik detayları.....	31
Şekil 13: Dil korteksleri arasındaki yapısal bağlantılar	32
Şekil 14: Ivakhnenko ve Lapa tarafından eğitilen ağ mimarisi	39
Şekil 15: Neokognitronun hiyerarşik ağ yapısı. (Fukushima, 1988).....	40
Şekil 16: Biyolojik nöron ve yapay nöron	43
Şekil 17: Yapay nöronda ağırlıklar ve sapma.	44
Şekil 18: Beş katmanlı CNN mimarisi.....	46
Şekil 19: 9×9 RGB görüntü üzerinde 2D evrişimin gösterimi.....	47
Şekil 20: Relu kullanılan düzleştirme katmanı ve maksimum havuzlama.	48
Şekil 21: CNN'lerde havuzlama, düzleştirme, tam bağlantı ve çıktı katmanı.....	49
Şekil 22: Tekrarlayan sinir ağlarında çıktının t defa girdi olarak gönderilmesi....	53
Şekil 23: Üç zaman adımı için zaman içinde açılmış çift yönlü RNN yapısı.	55
Şekil 24: Herhangi bir t anında genel LSTM hücresinin diyagramı.....	57
Şekil 25: LSTM ve GRU gösterimi.	59
Şekil 26: Önerilen Kodlayıcı-Kod Çözücü RNN modelinin illüstrasyonu	60
Şekil 27: İngilizce'den Fransızca'ya çeviri için Kodlayıcı-Kod Çözücü RNN.....	61
Şekil 28: Transformer model mimarisi.....	62
Şekil 29: Yapay nöronda aktivasyon fonksiyonu	67
Şekil 30: Basamak fonksiyonu ve Doğrusal fonksiyon.....	68
Şekil 31: Sigmoid aktivasyon fonksiyonu ve türevi (Kılıçarslan vd., 2021)	70

Şekil 32: ReLU ve LReLU aktivasyon fonksiyonları ve türevleri.....	73
Şekil 33: Swish aktivasyon fonksiyonu ve birinci türevleri.	74
Şekil 34: Çok katmanlı sınıflandırma için Softmax aktivasyon fonksiyonu	76
Şekil 35: Bir diziye uygulanan Softmax aktivasyon fonksiyonu	77
Şekil 36: GELU, ReLU ve ELU aktivasyon fonksiyonları karşılaştırması.	80



RESİMLER DİZİNİ

	<u>Sayfa</u>
Resim 1: Leborgne ve Lelong'un beyin görselleri	12
Resim 2: H.C.'nin koronal düzlemde alınan beyin görüntüleri	20
Resim 3: Kelimelerin akustik, görsel ve anlamsal temsilinin hesaplandığı ağlar ...	22



SİMGELER VE KISALTMALAR DİZİNİ

NLP: Doğal Dil İşleme

fMRI: Fonksiyonel Manyetik Rezonans Görüntüleme

EEG: Elektroensefalografi

MEG: Manyoensefalografi

ERP: Olay İlişkili Potansiyeller

SPN: Konuşma Üretim Ağı

SPT: Silvian Parietal-Temporal

STG: Superior Temporal Girus

STL: Superior Temporal Lob

STS: Superior Temporal Sulkus

HG: Heschl Girus

PT: Planum Temporal

IFG: Inferior Frontal Girus

BA: Broca Alanı

CNN: Evrişimli Sinir Ağları

RNN: Tekrarlayan Sinir Ağları

LTSM: Uzun Kısa-Sürelili Bellek

1. GİRİŞ

İnsan ve yapay zekâ iş birliği düşünüldüğü zaman en çok akla gelen soru, zihin okumanın gerçekten mümkün olup olmadığıdır. Literatüre baktığımız zaman birçok araştırmacı, zihin okumanın gerçekçiliğini çözümlmek adına sinirbilim yöntemlerinden yararlanarak duyuşal ve motor temsiller oluşturmuş; bu temsiller aracılığıyla düşünme, algı ve hareket kabiliyetinin altında yatan sistemi incelemişlerdir. Temel algısal görevleri çözmeye yönelik hesaplama çerçeveleri sunan yaklaşımlar, üst düzey temsillerin yeniden yapılandırılması teknolojisinin önünü açmıştır.

Fedorenko ve Thompson-Schill, (2014) göre, dil belirli bir bölgeye lokalize değildir ve dilin işlevini dağılmış bir beyin alanı ağı desteklemektedir. Dil ağı, esnek ve farklı girdi modalitelerine yanıt olarak “yeniden işlenebilir” özellik taşımaktadır. Bilginin beyindeki kodlanma şekli ile algısal ve bilişsel durumlarını beyin aktivitesini görüntüleyerek çözmek, sinirbilimin en temel amaçlarından biridir (Haynes & Rees, 2006). Beyin aktivitesini görüntülemek açısından alınan kayıtlar, avantaj ve sınırlamaları baz alınarak invaziv ve non-invaziv olmak üzere ikiye ayrılır. İnvaziv kayıtlar, elektrotların cerrahi prosedürler yoluyla beyin dokusunun içine (Derin Beyin Kaydı; DBS) veya doğrudan beyin yüzeyine (Elektrikortikografi; ECoG) yerleştirilmesi ile elde edilen kayıtları içerirken, Non-invaziv kayıtlar, cerrahi bir müdahale içermeyen Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) ve Elektroensefalografi (EEG) gibi yöntemlerin kullanılmasını içermektedir (Waldert, 2016).

İnvaziv ve non-invaziv kayıtlar bazı avantaj ve dezavantajlara sahiptir. İnvaziv kayıtlar, daha yüksek çözünürlük ve daha az bozulmuş sinyaller sağlayarak belirli beyin bölgelerinin daha ayrıntılı izlenmesine olanak sağlarken; non-invaziv kayıtlar, elektromanyetik gürültü gibi çevresel faktörlerden etkilenmeye daha yatkın olup invaziv tekniklere oranla daha düşük çözünürlük ve daha bozuk sinyallere sebep olabilir. Bu sebepten invaziv kayıtlar beyne daha derin nüfuz ederek nöral mekanizmaların daha hassas şekilde araştırılmasını sağlayan nöronların tek tek incelenmesine olanak sağlar. Bununla birlikte, invaziv kayıtların kapsama alanı daha sınırlı olup, risk ve komplikasyon

taşıyan ameliyatları gerektirmektedir. Non-invazif yöntemler, invaziv yöntemlerin aksine, tüm beyin boyunca büyük ölçekli nöral aktiviteyi izlemeye daha uygun olup kapsama alanı daha genişir ve ameliyat gerektirmediği için risk ve maliyetleri daha azdır (Quiroga, 2019).

Non-invaziv kayıtlar aracılığı ile sürekli dilin anlamsal olarak yeniden yapılandırılması, sürekli dilin kodunun fMRI veya manyetoensefalografi (MEG) sinyalleri gibi kayıtlar aracılığı ile çözülmesini ifade etmektedir (Tang vd., 2023). Doğal konuşma, insan serebral korteksini döşeyen anlam haritaları ortaya çıkarmakta olup dilin anlamı semantik sistem adı verilen beyin bölgelerinde temsil edilmektedir. FMRI verilerinin voksel bazında modellenmesiyle birlikte korteks boyunca anlamsal seçiciliği sistematik olarak haritalandırmak, ayrıntılı anlamsal haritaların oluşturulmasını sağlamaktadır. Diğer bir ifadeyle, her bir alanda hangi temsilin nasıl işlendiği, non-invaziv kayıtlar ile ortaya konmaktadır (Huth vd., 2016). Anlamsal sistemin nasıl organize edildiğini anlamak, bilgisayar ve diğer cihazların zihinle kontrol edilebilmesi için kullanılacak beyin-bilgisayar arayüzlerinin geliştirilmesine olanak sağlamaktadır (Tang vd., 2023).

Özetle, insan duyuşsal ve motor kabiliyetlerinin altında yatan hesaplama ilkelerinin anlaşılabilmesi için bilişsel sinirbilim ve makine öğrenimi disiplinler arası iş birliğinin devam etmesi oldukça önemlidir. İnvaziv olmayan kayıtların Beyin-Bilgisayar Arayüzleri ile hesaplanmaları, üst düzey bilişsel temsillerin kodunun çözülmesini ve yeniden yapılandırılabilmesini sağlamaktadır. Beyin-Bilgisayar arayüzlerinin altyapısını şekillendirerek gerçekçi dil üretiminde yeni bir paradigma sunmaktadır. Nörobilim çerçevesinde dil işleme ve üretiminin nöral mekanizmalarını anlamamıza yardımcı olmaktadır. Klinik anlamda ise ağır felci veya nörolojik bozukluğu olan bireylerin iletişim yeteneğini geliştirebilecek rehabilitasyon yöntemleri üretilebilmesi için oldukça önemlidir. Bu çalışma, hem NLP alanında çalışan araştırmacılara biyolojik temeller sayesinde daha gerçekçi bir perspektif sağlamak, hem de nörobilim alanında çalışan araştırmacılara makine öğrenimi yöntemlerinin beyin işlevlerini anlamada nasıl kullanılacağını göstermek açısından öneme sahiptir.

Türkçe literatüre bakıldığı zaman, doğal dilin işlenmesi (natural language processing; NLP) ve modellenmesinde yapay zekâ alanında büyük ilerlemeler gerçekleşmektedir. Fakat güncel modeller büyük ölçüde yapay temsil odaklı geliştirilmekte ve insan beynindeki dil işleme süreçleri çoğu zaman göz ardı edilmektedir. Bu tezin amacı, doğal dil işlemenin nöroanatomik temellerini ve doğal dil işleme görevlerinde kullanılan derin öğrenme yöntemlerini sistematik biçimde bir araya getirerek gelecekteki çalışmalar için yol gösterici bir kaynak oluşturmaktır.



2. GENEL BİLGİLER

2.1. Literatür Çalışmaları

İşitsel imgelemenin temsillerini keşfetmek, bilişsel süreçlerin nöral temellerini anlamak için önemlidir. Bunzeck vd. (2005), fMRI tekniğini kullanarak, karmaşık seslerin zihinsel imgelemenin altında yatan sinirsel mekanizmaları araştırmış ve işitsel imgeleme esnasındaki beyin aktivitesinin spatiotemporal modelini incelemişlerdir. Çalışmaları, zihinsel imgelem ve karmaşık seslerin algılanmasının anlamlı nöral korelasyonlara dayandığını ve dış uyaran yokluğunda bile hayal edilen sesin birden fazla modalite arasında bilgi entegrasyonu içerebileceğini ortaya koymuştur. Bu çalışmayla birlikte, işitsel işleme bozukluğu gibi duyuşsal algı ve hayal gücünü içeren nörolojik rahatsızlıklarla ilgili potansiyel rehabilitasyon sonuçları doğmuştur.

Mitchell vd. (2008), beynin, somut isimlerin nöral temsillerini tahmin edebilmek adına ilişkili gözlemlenen fMRI verilerinin kombinasyonlarını kullanarak bir hesaplama modeli geliştirmişlerdir. Geliştirdikleri model, sadece belirli bir eğitim setine bağlı kalmayıp, eğitim seti dışındaki kelimeler için de fMRI aktivasyonunu doğru bir şekilde tahmin edebilmiş, duyuşsal-motor işlevlere karşılık gelen farklı aktivasyon modellerine de ayırtılabilmıştır. Bu çalışmayla birlikte somut isimlerin zihinsel temsillerinin hakkında içgörü sağlayan bir hesaplama çerçevesi ortaya koyulmuştur.

Nishimoto vd. (2011), film izleme esnasındaki beyin aktivitelerini analiz ederek, beynin karmaşık ve doğal görüntüleri nasıl temsil edip işlediğine bir öngörü ortaya koymuşlardır. fMRI yöntemi kullanarak, beyin verilerinden görsel deneyimlerin kodunu çözmüş ve yeniden yapılandırmak hesaplama modeli önermişlerdir. Beynin tutarlı görsel deneyimler için duyuşsal girdileri nasıl entegre ettiğini ve anıların nasıl saklanıp geri alındığını inceleyen bu çalışma, beyin-bilgisayar arayüzlerinin görsel deneyimleri yeniden yapılandırmada ne kadar önemli bir rol oynadığını vurgulamaktadır.

Bir başka çalışmada, doğal görüntülerin yeniden yapılandırılması adına Bayesian kod çözme modelleri kullanılmıştır. Naselaris vd. (2009) çalışmalarında, katılımcıların doğal görüntüleri izlerken fMRI görüntüleri alınmış, yeniden yapılandırılan görüntülerin görsel dünya ile tutarlı olup olmadığı incelemiştir. Bayesian Algoritması kullanılarak yeniden yapılandırılmış bu görüntülerin, orijinal görüntülere oldukça yakın oldukları gözlenmiştir. Bu yeniden yapılandırma tekniği, duyuşsal ve görsel bozukluğu olan bireylerin, beyin-bilgisayar ara yüzleri sayesinde işlevlerini geri kazandırabilecek nöral protezlerin geliştirilmesi açısından önemli rol oynamıştır.

Dil ağının dinamik doğasını anlamak, dilin sinirsel temeline ilişkin anlayışı geliştirerek dil bozukluklarına daha etkili müdahaleler getirilmesini sağlamak için oldukça önemlidir. Fedorenko vd. (2010), FMRI yöntemi ile ROI tanımlama tekniğini birleştirerek, geleneksel yöntemlere kıyasla dil alanlarının daha hassas bir şekilde incelenmesini sağlamışlardır. Bu çalışmaları ile, beyin tümörü hastalarında dilin yeniden düzenlenebilmesi ve dil becerilerinin korunabilmesi için kişiselleştirilmiş cerrahi müdahale stratejilerini güçlendirmek amaçlanmıştır.

Martin vd. (2014), sesli ve sessiz okuma görevlerini gerçekleştiren Epileptik hastalardan alınan ECoG kayıtlarının kullanarak, açık ve örtük konuşmanın ortak bir nöral temsili paylaşım paylaşmadığını araştırmışlardır. Çalışmada sesli ve sessiz okuma görevleri, kendi kendine üretilen konuşmanın spektrot temporal işitsel özelliklerinin yeniden yapılandırılması amacıyla kullanılmıştır. Bu çalışmayla birlikte, yüksek gama (70 – 150 Hz) nöral kod çözme modelinin hem açık hem de örtülü konuşmayı ortak bir nöral temsil üzerinden yapılandırdığını ortaya koymuşlardır.

Konuşma sesleri, serebral korteksteki vokal yol hareketlerini kodlayan bir ara temsil kullanarak sentezlenebilmektedir (Anumanchipalli vd., 2019). Katılımcılardan elde edilen veriler kullanılarak genişletilen bir sinir ağı modeli, paylaşılan kinematik durum uzayının, katılımcılar arasında aktarılabilir olduğunu ortaya koymaktadır. Bu bulgular, paralize olmuş hastaların doğal konuşmalarını geri kazanmalarına yönelik beyin-bilgisayar arayüzü teknolojisinin gelişmesi için önemli bir adımdır.

Katılımcıların beyin aktiviteleri MEG kullanılarak kaydedilirken daha önce tanımlanmış bir dizi cümleyi hayal etmeleri istenilen çalışmada (Dash vd., 2020) hayal edilen ve konuşulan ifadelerin kodunu çözenin uygulanabilirliği araştırılmıştır. Bulgular, bir önceki çalışmaları destekler nitelikte olup, dil üretimi gibi karmaşık süreçler için makine öğrenimi tekniklerinin potansiyelini vurgulamaktadır.

Makin vd. (2020), nöral aktiviteyi metinsel çıktıya çevirebilen bir Beyin-Bilgisayar arayüzü sistemi geliştiren çalışmalarında, katılımcılar doğal metin pasajlarını okuyup anlarken kaydedilen fMRI verileri kullanmışlardır. Kodlayıcı kısım bu fMRI verilerini yüksek boyutlu bir temsille kodlamayı öğrenirken, kod çözücü kısım temsili metne çevirmeyi öğrenmiştir. Kod-kod çözücü bu model, hem beynin dili nasıl temsil edip işlediğine dair kanıtlar sunmuş, hem de dil veya motor bozukluğu olan bireylere yardımcı bir teknoloji geliştirilmesinde önemli rol oynamıştır.

Moses vd. (2021), ağır felçli ve konuşamayan katılımcıların motor korteksine intrakraniyal mikroelektrot dizisi yerleştirilerek nöral aktiveyi incelemiş ve makine algoritmaları kullanılarak konuşmanın kodunu çözebilen bir nöroprotez sistemi geliştirmişlerdir. Nöroprotez sistemi sayesinde, felç sebebi ile ağır konuşma engeli olan kişilerin çevreleri ile etkili iletişim kurabilmeleri ve yaşam kalitelerini önemli bir şekilde arttırmaları sağlanmıştır.

Katılımcıların doğal metin pasajlarını okuyup anlarken ki beyin aktivitesini fMRI ile ölçen Caucheteux ve King (2022), frontal ve temporal loplar gibi semantik ve sözdizimsel işlemeye dahil olan bölgeleri incelemiş, beyin aktivitesi kalıpları ile NLP modellerinin iç temsilleri ile karşılaştırma yapmışlardır. Sonuçlar, NLP modellerinin, insan beyninin sahip olduğu esnek ve nüanslı dil algılama yeteneklerini henüz yakalayamadıklarını ortaya koymuştur. Çalışma, yapay zekâ ve sinirbilim arasındaki disiplinler arası iş birliği sayesinde doğal dil yeteneklerinin altında yatan hesaplamaların daha iyi anlaşılabilirliğini vurgulamıştır.

İlgi çekici bir başka çalışma, el yazısını bir ara temsil olarak kullanarak sinirsel aktiviteyi doğrudan metin çıktısına çevirebilen bir Beyin-Bilgisayar arayüzü sisteminin geliştirilmesini içermektedir. Willett vd. (2021) çalışmalarında, katılımcıların yazı yazmayı hayal ettikleri esnada alınan intrakraniyal ECoG kayıtlarını, bu nöral sinyalleri derin bir sinir ağı modelini eğitmek için kullanmışlardır. Model, ECoG sinyallerinin kodunu çözebilmiş ve bunları katılımcıların yazmayı hayal ettikleri belirli karakterlere ve kelimelere çevirebilmiştir. Doğrudan konuşmaya gerek duymadan iletişimi sağlayan bu model, locked-in sendromu veya amiyotrofik lateral skleroz (ALS) gibi ciddi motor bozukluğu olan bireylerin rehabilitasyonu için önem arz etmektedir.

Sürekli dilin anlamsal olarak yeniden yapılandırılması adına güncel bir çalışma, Tang vd. (2023) tarafından yürütülmüştür. Bu çalışma, invaziv olmayan beyin kayıtlarına odaklanarak sürekli konuşmanın anlamsal içeriğini yeniden yapılandırabilen bir Beyin-Bilgisayar Arayüzü sistemi geliştirilmek amaçlanmıştır. Araştırmacılar, katılımcıların konuşmaları dinlerken ve hayal ederken toplanan fMRI verilerini kullanarak yeni bir hesaplama çerçevesi tasarlamışlardır. Oluşturdukları model, duyusal veya motor temsillerin ötesinde soyut, üst düzey bilişsel temsillerin de yeniden yapılandırılabilir olduğunu ortaya koymuştur.

3. DOĞAL DİL İŞLEMENİN NÖROANATOMİK TEMELLERİ

3.1. İnsan Beynindeki Doğal Dil Öğrenme Süreçleri

İnsanlar, doğuştan gelen bir dil öğrenme kapasitesine sahiptir ve bu yeti, bebeklik döneminden itibaren çevresel dil girdilerini işlemeye başlamalarıyla devreye girmektedir. Bilişsel açıdan dil edinimi hem içgüdüsel mekanizmalarla hem de deneyime dayalı öğrenme süreçleriyle şekillenmektedir. Nativist kuram, insan beyninin dil öğrenimine yönelik doğuştan gelen özel bir donanımla yapılandığını savunmaktadır (Chomsky, 2014). Bu görüş, çocukların sınırlı dil girdisiyle bile karmaşık dil kurallarını öğrenebilmesini, beynin güçlü örüntü tanıma ve genelleme yeteneklerine dayandırmaktadır. Buna karşın empirist ve kullanım-temelli yaklaşımlar, dil bilgisinin esasen çevreden gelen girdilerin istatistiksel özellikleri doğrultusunda edinildiğini ileri sürmektedir (Tomasello, 2009). Nitekim, 8 aylık bebeklerin, sürekli konuşma akışı içerisinde olasılık temelli ipuçlarını kullanarak hece dizileri arasından kelimeleri ayırt edebildikleri gösterilmiştir (Saffran vd., 1996).

Bebekler, yaşamlarının ilk yılında maruz kaldıkları dil girdilerini değerlendirirken, beynin istatistiksel öğrenme kapasitesini kullanarak sık tekrarlanan ses dizilerini “kelime” olarak sınıflandırmayı başarmaktadırlar (Kuhl, 2010). Bununla birlikte, dil edinimi yalnızca pasif istatistiksel işleme indirgenemez; sosyal etkileşim bu süreçte belirleyici bir rol üstlenmektedir. Araştırmalar, bebeklerin dil öğreniminde sosyal ipuçlarına duyarlı olduklarını ve yalnızca televizyon gibi etkileşimsiz ortamlarda yeni ses kategorilerini öğrenemediklerini ortaya koymuştur (Kuhl, 2010). Bu bulgular, dil öğrenme süreçlerinin insan beyninde sosyal bağlam aracılığıyla etkinleştirildiğini öne süren "sosyal geçit" hipotezini desteklemektedir (Kuhl, 2007). Sonuç olarak, bilişsel açıdan dil öğrenimi; örüntü tanıma, dikkat, bellek ve sosyal biliş gibi çok sayıda bilişsel sürecin dinamik etkileşimiyle yürüyen karmaşık bir edinim sürecidir.

Dil öğreniminin sinirsel temelleri, beyin gelişimi ve plastisite bağlamında ele alınabilir. Kritik dönem hipotezine göre, insan beyninin dil öğrenimine en açık olduğu

dönem çocukluk yıllarıdır (Johnson & Newport, 1989; Lenneberg, 1967). Bu dönemde beynin yüksek plastisite göstermesi sayesinde bireyler birinci dili anadil düzeyinde edinme becerisi sergilemektedir.

Bebek beyninin dil girdisiyle karşılaşması, nörofizyolojik düzeyde ölçülebilir değişiklikler yaratmaktadır. Yenidoğanlar, tüm fonetik ayrımları algılayabilme kapasitesiyle dünyaya gelmektedirler; ancak bir yıl içerisinde yalnızca maruz kaldıkları dile özgü sesleri ayırt etme konusunda uzmanlaşmaktadırlar. Bu süreçte, duyuşal korteks ile dil ağı arasındaki bağlantıların deneyime dayalı olarak güçlendiğı gösterilmiştir (Kuhl, 2010). EEG/ERP çalışmalarında, bebeklerin farklı dillere özgü seslere farklı elektriksel yanıtlar verdikleri ve bu erken dönemdeki beyin tepkilerinin, sonraki dil gelişimiyle ilişkili olduğı gösterilmiştir (Kuhl, 2010). Örneğın, 6 aylıkken hem ana dili hem de yabancı dillerin fonemlerini iyi ayırt eden bebeklerin, 2-3 yaşlarında daha gelişmiş sözcük dağarcıklarına sahip oldukları saptanmıştır. Bu da erken dönemde ortaya çıkan nöral adaptasyonların ileriye dönük dil gelişimini desteklediğini göstermektedir. Ayrıca, genetik etkenler de bu süreçte belirleyici olabilmektedir. FOXP2 geninde meydana gelen mutasyonun, kalıtsal bir dil bozukluğuna neden olduğı bulgusu, dil ediniminin genetik bir temele de sahip olduğunu ortaya koymaktadır (Kozan, 2010).

Dil öğrenimine ilişkin nörofizyolojik süreçler yalnızca çocuklukla sınırlı değildir; ergenlik ve yetişkinlikte de beyin plastisitesi belirli ölçüde devam etmektedir. İkinci dil edinimi, öğrenim yaşıyla ilişkili olarak beyinde farklı yapısal ve işlevsel örüntüler oluşturabilmektedir. Erken yaşta ikinci dili öğrenen bireylerin, her iki dili Broca alanında örtüşen bölgelerde işlediğı; ancak yetişkinlikte ikinci dili öğrenenlerde, ikinci dilin Broca alanında anadilden daha ayırık bir bölgede temsil edildiğı saptanmıştır (Kim vd., 1997). FMRI temelli bu çalışmada, geç yaşta edinilen ikinci dilin sol frontal kortekste anadilden farklı bir alanda etkinlik gösterdiği; erken yaşta edinilen dillerin ise aynı alanda işlenebildiğı rapor edilmiştir. Buna karşılık, Wernicke alanı ve genel temporal bölge etkinliklerinin, dil öğrenim yaşı fark etmeksizin benzerlik gösterdiği bulunmuştur. Bu durum, kritik dönem sonrasında özellikle üretim ve aşamalı işleme bileşenlerinde nörofizyolojik örgütlenmenin farklılık gösterebileceğine işaret etmektedir.

Yapısal beyin plastisitesi üzerine yapılan çalışmalar, dil öğreniminin beyinde kalıcı etkiler yarattığını ortaya koymuştur. Mechelli vd. (2004), ikinci bir dil öğreniminin sol alt parietal kortekste gri madde yoğunluğunu artırdığını ve bu yapısal değişikliğin, bireyin ikinci dil yeterliliği arttıkça daha da belirginleştiğini göstermiştir. Bu bulgular, yüksek düzeyde ikinci dil yeterliliğine sahip bireylerde, dil öğreniminin beyin yapısal organizasyonunu deneyime bağlı olarak değiştirebildiğini göstermektedir.

Sonuç olarak, insan beyinde dil öğrenme süreçleri, doğuştan gelen bilişsel eğilimlerin çevresel girdilerle etkileşimiyle biçimlenmektedir. Bu süreçte, belirli sinirsel ağlar etkin hâle gelirken, edinim süreci boyunca bu ağlarda hem işlevsel hem de yapısal düzeyde deneyim temelli değişiklikler gözlemlenmektedir.

3.2. Nörogörüntüleme ve Beyin Fizyolojisi Ölçümleri

Dil öğreniminin beyin üzerindeki yansımalarını incelemek ve dil işleme yeterliliğini dolaylı biçimde değerlendirmek amacıyla nörogörüntüleme tekniklerinden yararlanılmaktadır. EEG ve olay ilişkili beyin potansiyelleri (event-related brain potentials; ERPs), beyin dil uyarılarına verdiği yanıtları milisaniyelik zaman çözünürlüğüyle ölçme imkânı sunmaktadır. ERP bileşenlerinden biri olan N400 dalgası, anlamsal olarak uyumsuz kelimelere karşı ortaya çıkan negatif yönlü bir elektriksel aktiviteyi ifade eder ve bireyin anlamsal işleme kapasitesi hakkında bilgi vermektedir (Kutas & Hillyard, 1980). Örneğin, “Ali kahvaltıda bir kitap yedi” gibi anlamsal olarak uygunsuz bir cümlede, yaklaşık 400 milisaniye sonra EEG kayıtlarında tipik bir N400 yanıtı gözlemlenmektedir. Bu bileşenin genliği, sözcüğün bağlama ne derece uymadığıyla ilişkilidir. İkinci dil bağlamında, N400 bileşeninin zamanla azalması, bireyin o dildeki anlamsal işleme kapasitesini daha otomatik hâle getirdiğini göstermektedir. Benzer şekilde, P600 adı verilen pozitif yönlü ERP bileşeni, dilbilgisel olarak hatalı ya da karmaşık cümlelerin işlenmesi sırasında ortaya çıkar ve beyin sözdizimsel ihlalleri çözümü çabasını yansıtmaktadır. ERP yöntemleri, ikinci dili öğrenen bireylerin beyin tepkilerini ana dil konuşucularıyla karşılaştırmak için yaygın biçimde kullanılmaktadır. Örneğin, Morgan-Short vd. (2012) tarafından gerçekleştirilen bir çalışmada, yetişkinlere yapay bir dil öğretildikten sonra, gramer hatalarına verdikleri P600 tepkilerinin zamanla

anadil konuşmacılarına benzemeye başladığı gözlemlenmiştir. Bu bulgu, ERP verilerinin dil öğrenimindeki ilerlemeyi objektif olarak izleyebildiğini göstermektedir.

FMRI, dil görevleri sırasında beyin hangi bölgelerinin etkinleştiğini yüksek uzamsal çözünürlükle göstermektedir. FMRI araştırmaları, ikinci bir dilde uzmanlaşmanın beyin aktivasyon örüntülerinde değişime yol açtığını ortaya koymuştur. Örneğin, Perani vd. (1998), başlangıç düzeyinde olan bireylerle akıcı konuşmacıları karşılaştırdıklarında, akıcı konuşan bireylerin daha odaklı ve verimli beyin aktivasyonuna sahip olduğunu; yeni başlayanların ise daha geniş ve yaygın beyin bölgelerini aktive ettiğini rapor etmişlerdir. Bu durum, dilde yetkinliğin artmasıyla birlikte bilişsel işlemlerin sinirsel düzeyde daha düşük maliyetle gerçekleştirilebildiğini göstermektedir.

Son olarak, dil öğreniminin beyin yapısında yol açtığı kalıcı değişiklikleri incelemek için yapısal MRI tekniklerinden faydalanılmaktadır. Mechelli vd. (2004), iki dil bilen bireylerin beyin taramalarında, sol alt parietal kortekste gri madde yoğunluğunda artış gözlemleyerek, dil öğreniminin beyinde yapısal değişimlere neden olabileceğini ortaya koymuşlardır.

Genel olarak, dil becerilerinin değerlendirilmesinde hem davranışsal performans ölçümleri hem de beyin tabanlı nörofizyolojik göstergeler bir arada kullanılmaktadır. Bu bütüncül yaklaşım, dil öğreniminin yalnızca çıktıya dayalı başarı düzeyini değil, aynı zamanda bu sürecin altında yatan bilişsel ve sinirsel mekanizmaları da kapsamlı biçimde anlamaya olanak tanımaktadır.


3.3. Dil İşleme Modelleri

3.3.1. Wernicke-Lichtheim-Geschwind modeli

Dil işlemenin nörolojik temelleri denildiği zaman akla ilk olarak temel tıp kitaplarında görülen ve giriş derslerinde öğretilen “Broca” ve “Wernicke” alanları gelmektedir. Tarihsel açıdan bakıldığında zaman Paul Broca'nın gözlemleri sitoarkitektonik

ve miyeloarkitektonik haritalardan çok daha öncesine dayanmaktadır (Keller vd., 2009a). Broca'nın tanımının makroskobik olmasından dolayı klasik görüşler kesin bir kanıttan ziyade belirsizliklere ve tartışmalara yol açmış olup günümüze kadar birçok farklı şekilde adlandırılmıştır. Litaratürde “Wernicke–Lichtheim–Geschwind modeli” (Hagoort, 2013, 2014, 2017), “Wernicke-Lichtheim modeli” (Fridriksson vd., 2018; R. E. Graves, 1997), “Wernicke-Geschwind modeli” (Anderson vd., 1999; Zhang vd., 2010), “Broca–Wernicke–Lichtheim–Geschwind modeli” (Geranmayeh vd., 2014; Poeppel & Hickok, 2004) ve “Lichtheim–Broca–Wernicke modeli” (Pickering & Garrod, 2014) olmak üzere farklı adlandırmalar “klasik model” olarak geçmektedir. Ancak en güncel kullanıma sahip olan klasik model, Tremblay ve Dick, (2016) “Geschwind Aromalı” şeklinde aktarımda bulunduğu “Geschwind Modeli”dir (Weiller vd., 2011).


Klasik modelin temeli, 19. yüzyılda Paul Broca'nın (Broca, 1961; Broca, 2006'da çevrilmiş ve yeniden üretilmiştir) 51 yaşında bir erkek hastasının nöropatolojik ve davranışsal verilerini ilk kez raporlaması ile atılmıştır. Broca'nın ilk gözlemlerinde zihinsel yeteneklerinde anormal bir durum gözlenmeyen fakat konuşma dilinde ciddi bir bozukluk olan hastasında, yıllar içerisinde “sağ alt ekstremitede ve sol yüz kaslarında ilerleyici sol serebral yarımküre lezyonuna işaret eden tek taraflı felç” geliştirmiştir (Keller vd., 2009b). Otopsi analizinin sonucunda Broca, sol inferior frontal kortekste lezyon tespit etmiş ve sol IFG'nin ikinci ve üçüncü kıvrımlarını “dil ifade etme yetisinin merkezi” şeklinde tanımlamıştır (Ben Shalom & Poeppel, 2008; Tremblay & Dick, 2016). Resim 1'de Paul Broca'nın ilk iki afazik hastası Leborgne ve Lelong'un beyinlerine ait görseller verilmiştir.



Resim 1: Leborgne ve Lelong'un beyinlerine ait görseller.

(A) Leborgne'nun beyninin yanal görünümü (B) Leborgne'nun beyindeki lezyonun yakın çekimi
(C) Lelong'un beyninin yanal görünümü (D) Lelong'un beyindeki lezyonun yakın çekimi
(Dronkers vd., 2007)

1874 yılında dil ile ilgili tüm işlemlerin Broca Alanı'nda gerçekleşmeyeceğini düşünen Carl Wernicke, ifade yeteneği açısından sağlıklı olan fakat konuşulan dili anlamakta zorluk çeken iki hastayı gözlemlemiştir (Tremblay & Dick, 2016). Wernicke (1874) ark (Wernicke's arc) figüründe (Şekil 1), sylvian fissür çevresinde “gyral convolution” olduğundan söz etmiştir ve bu alanı “Wernicke Alanı” olarak adlandırmıştır (Ahmad vd., 2024). Sol yarım küredeki superior temporal girusun arka üçte birinde yer alan bölgedeki lezyonlar sebebi ile meydana gelen dil anlamadaki eksiklikleri Wernicke Afazisi olarak raporlamıştır (Ben Shalom & Poeppel, 2008; Nasios vd., 2019; Wernicke, 1874, 1969). Wernicke ve Broca bölgesinin ilişkilendirme lifleri (associative fibers) ile (Şekil 1'deki noktalı yay) bağlandığını göstererek Wernicke modelini ortaya koymuştur (Pearche, 2001).




Şekil 1: Wernicke Arki, 1874.

(C) Merkezi sulkus (central sulcus); (F) Frontal lob; (O) Oksipital lob; (S) Sylvian fissür; (T) Temporal lob; (a) İşitsel merkez (auditory centre); (b) Broca bölgesi

1885 yılına gelindiğinde, Tremblay ve Dick'in (2016) deyimiyle Ludwig Lichtheim, devrim niteliğinde bir yaklaşımda bulunarak beyin bölgelerinin işlevsel olarak uzmanlaşmasını savunmuştur. Lichtheim, Broca ve Wernicke'nin önerilerini göz önünde bulundurarak beyin bölgeleri arasındaki iletişimi sağlayacak nöroanatomik yollar bulmak adına afazi unsurlarını ayrıntılı bir şekilde tanımlayarak “bağlantı” kavramını önermiştir (Ben Shalom & Poeppel, 2008). Girdi/çıkış sistemine dayalı bu nöral sistemi “ev” şeması ile sunmuştur (Şekil 2). Ev modelinde kelime sesi hakkında bilginin “Wernicke

Bölgesi”nde (A) depolandığını, konuşmanın planlanmasına ve programlamasına ise “Broca Bölgesi”nin hizmet ettiğini ve bu iki bölgeyi bağlayan tüm bölgelerin anlamsal işlemlerde görev aldığını bildirmiştir (Lichtheim, 2006;1885).




Şekil 2: Lichtheim Evi.

(A) İşitsel görüntü merkezi (centre of auditory image); (B) Kavram merkezi (concept/Begriffe/center); (M) Motor görüntü merkezi (centre of motor image); (a) akustik girdi (acoustic input) ; (m) motor çıktı (motor output); (1) Kortikal motor afazisi (cortical motor aphasia) ; (2) Kortikal Duyusal afazi (cortical sensory aphasia) ; (3) İletim afazisi (conduction aphasia); (4) Transkortikal motor afazi (transcortical motor aphasia) ; (5) Subkortikal motor afazi (subcortical motor aphasia); (6) Transkortikal duyusal afazi (transcortical sensory aphasia); (7) Subkortikal duyusal afazi (subcortical sensory aphasia). (Lichtheim, 2006;1885).

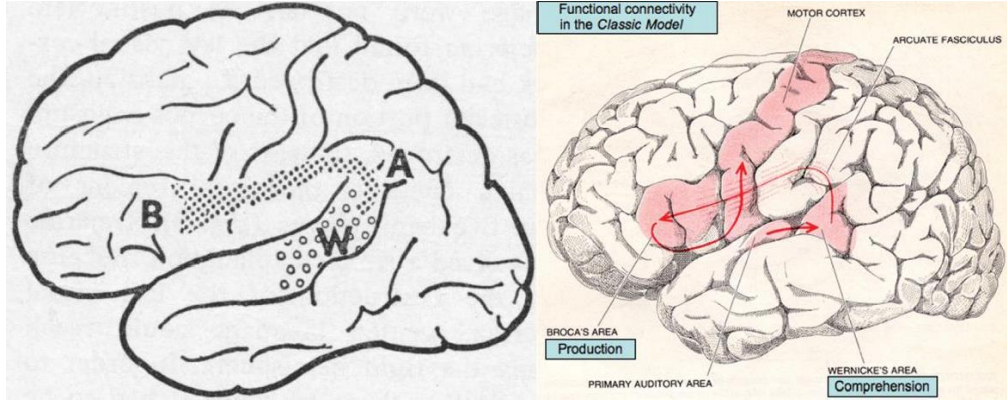
Eling'in (2011) aktarımıyla, Lichtheim anılarında kendisi için asıl meselenin “iki yeni duyusal afazi türünün, subkortikal ve transkortikal formların keşfi” olduğunu belirtmiştir. Fakat, Lichtheim'in beklentisinin aksine, makalesinin en ses getiren kısmın iki yeni duyusal afazi türü değil de “kavramsal merkez” (B) ve bu merkez ile ilişkili yollarda bağlantı kopuklukları olabileceği görüşü olmuştur. Kavramsal merkez, Wernicke'in modeli ile aradaki en önemli fark olarak görülmüştür. Wernicke (1874), kavramsal merkez bölgesini fazla kısıtlı bulduğunu ve somut nesne alanından kelime kavramına doğru olan aktivasyon akışının B-M ve B-A-M olmak üzere çift bir yoldan geçtiğini bildirerek Lichtheim'in görüşlerine karşı çıkmıştır (Eling, 2011). Makalesinin başında bu merkezleri fazla açıklama yapmadan tanıtan Lichtheim, makalesinin ilerleyen bölümlerinde kavramsal “işlevin tek bir noktada lokalize olduğuna inanmadığını, ancak

tüm duyusal kürenin birleşik eyleminden kaynaklandığına inandığını” bildirmiş ve B noktasının birçok noktaya dağıldığı bir diyagram ile modelini tekrardan uyarlamıştır (şekil 3). Çok geçmeden Wernicke bu bölgelerdeki sürecin dil üretimi ile ilgili olduğunu ve afazi teriminin doğruluğunu kabul etmiş, Lichtheim’in terimlerini kullanmadan “dil merkezleri” kavramı gibi kendi terimleri ile tartışmıştır (Eling, 2011; Weiller vd., 2011; Wernicke, 1885).



Şekil 3: Lichtheim'in birçok noktadan oluşan kavram modeli. (Lichtheim, 1885).

20. yüzyılda klasik model, davranışsal nörolog Norman Geschwind'in daha önceki Broca, Wernicke ve Lichtheim'in modellerini tekrardan canlandırması ile son halini almıştır. Geschwind'e göre (Geschwind, 1965, 1970, 1974) bu modelde, ana hatlarıyla kelime sesleri ilk etapta birincil işitsel kortekse, yazılı kelimelerden gelen bilgiler ise birincil görsel korteks yoluyla angular girusa aktarılır. İkinci aşamada, bu kelimelerin anlamlarını çıkarmak amacıyla bilgi Wernicke bölgesine gönderilir. Wernicke bölgesi ile Broca alanı, beyaz madde yolu olan yay biçimindeki liflerle birbirine bağlıdır (Tremblay & Dick, 2016) ve Wernicke bölgesinden gelen kelime anlamları bu arkuat fasikülüs ile Broca bölgesine iletilir. Son olarak kelime anlamlarının Broca bölgesinde morfemlere dönüştürülmesi ve ardından motor kortekse iletilmesi ile konuşma üretilmiş olur (Nasios vd., 2019). Geschwind Modeli'ne bakıldığı zaman, dil alanlarının Sylvian yarığına bitişik olduğu dikkat çekmektedir ve beynin bu kısmının perisylvian korteks olarak adlandırılmaktadır (Hagoort, 2013).



Şekil 4: Geschwind'in Klasik Modeli.

Sol: Geschwind'in orijinal çiziminde insan beyninin sol hemisferinin yan yüzeyi gösterilmiştir. Motor korteksin alt ucunda bulunan bölge (B) Broca Alanı olarak; Açık dairelerin bulunduğu temporal kortekste bulunan bölge (W) Wernicke Alanı olarak; ikisini bağlayan kapalı dairelerin olduğu bölge (A) ise Arkuat fasikülüs olarak resmedilmiştir (Geschwind, 1970). Sağ: Geschwind'in modelinden uyarlanmış olup, dil işleminin gerçekleşme aşamaları kırmızı oklarla gösterilmiştir (Ben Shalom ve Poeppel, 2007).

Geschwind (1970) Broca alanının, yüz, dudaklar, dil, ses telleri gibi motor temsilleri bulunduran kortikal bölgenin yakınında bulunmasının konuşmanın artikülasyon biçiminde kodlanması açısından kuralları içermesini mantıklı bulduğunu bildirmiştir. Bununla birlikte, işitme kortikal temsilin yanında bulunan Wernicke alanının da duyulan dilin desenlerini tanımlamak açısından önemli rol oynadığı görüşündedir. İlave olarak, Wernicke alanında meydana gelen bir lezyonun, sadece konuşulan değil aynı zamanda yazılı dilin anlamlandırılmasında bozukluğa sebep olarak Broca alanında üretilen konuşmanın karmaşık bir çıktıya sebep olacağı konusunda Wernicke'nin görüşlerine katıldığını belirtmiştir.

3.3.1.1. Geschwind'in bazı dil bozuklukları hakkındaki görüşleri

Geschwind'in modelinin temellerinin oluşmasında, afazi kavramlarının yeri büyüktür. Geschwind (1970), yavaş konuşmanın ve zayıf bir artikülasyon ile ortaya çıkan konuşma üretiminin Broca tipi afazinin karakteristik özelliklerinden olduğunu düşünmektedir. Geschwind'e göre, Broca tipi afaziye sahip bireyler, sadece fonemler

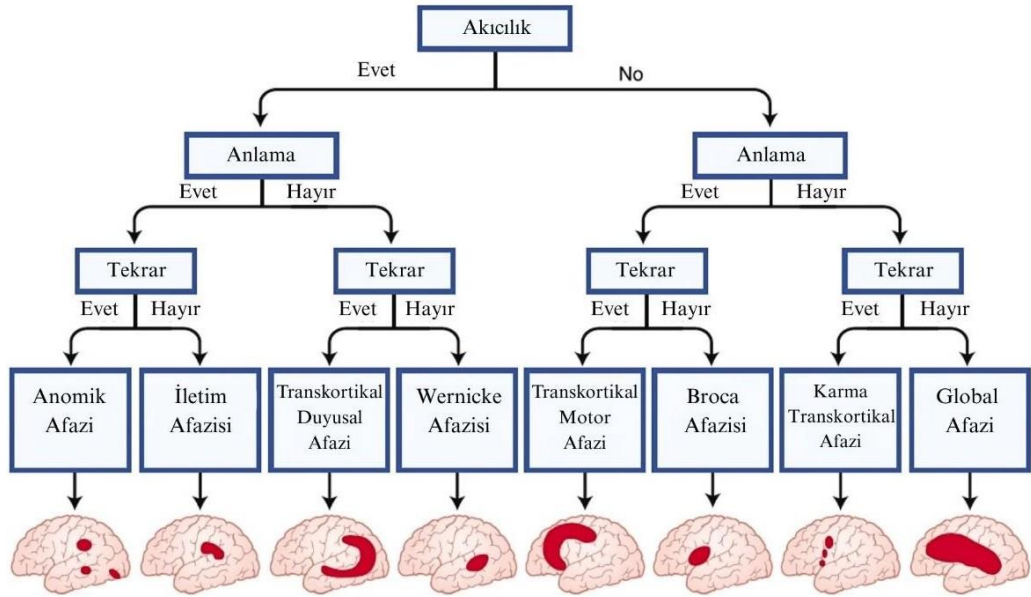
düzeyinde bir bozukluğa sahip değil, aynı zamanda İngilizce cümleler üretme, küçük gramer kelimeleri ve ekleri düzeyinde de anormalliklere sahiptirler. İlâveten, duydukları cümleleri tekrar etmeleri istendiğinde de aynı bozuklukları devam ettirmektedirler. Diğer yandan, yazılan ve konuşulan dili anlamak konusunda herhangi bir bozukluk göstermemektedirler. Geschwild makalesinde (1970) bu durumu, hava durumu sorulduğu zaman hastanın sorulan soruyu anladığı fakat cevap üretmesi istenildiğinde “Kapalı. (Overcast.)” diyebildiği örnekle göstermiştir. Hastadan konuşmanın devamında cümle üretmesi istenildiğinde ise “Hava... kapalı. (Weather ... overcast.)” şeklinde İngilizce’de “olmak” fiilinin geniş zamanda kullanım biçimi olan “is” fiilini kullanmadan cümle üretimi gerçekleştirmiştir. Ayrıca Geschwild, Broca bölgesinin motor kortekse yakınlığı sebebi ile Broca afazisi olan hastaların vücudunun sağ tarafında felç yaşadığı şeklinde gözlemlerini bildirmiştir.

Geschwild’e göre (1970) Wernicke afazisinin karakteristik özellikleri Broca afazisinden önemli derece farklılıklar göstermektedir. Wernicke afazisine sahip hastalar, çoğu zaman normalin üstünde bir hızla konuşma çıktısı oluşturmakta ve bu zahmetsiz bir şekilde gerçekleşmektedir. Fakat konuşma çıktıları anlamsız olmakla birlikte birçok parafazi (kelime üretim hatası; paraphasia) içermektedir. Geschwild makalesinde (1970) bu durumu, “Ben diğerindeydim ve onlar departman bulduktan sonra ben de bu taraftaydım.” (I was over in the other one, and then after they had been in the department, I was in this one) cümlesi ile örneklendirmiştir. Cümleye bakıldığı zaman tümce yapısının düzgün olduğu fakat anlamsal olarak eksikliklerin olduğu görülmektedir. Wernicke afazisinin Broca afazisinden ayrılan bir başka yönünü ise bu afazi tipine sahip hastalarda genellikle Wernicke bölgesindeki lezyona bağlı olarak felç yaşanmaması şeklinde ifade etmiştir.

Makalesinde saf kelime sağırlığından (Pure word deafness) bahseden Geschwild (1970), bu dil bozukluğunun Wernicke’nin teorisi ile dikkat çekici şekilde uyuştuğunu bildirmiştir. Fakat saf kelime sağırlığına sahip hastaların duyulan dili anlamada sıkıntı yaşamalarına rağmen yazılı dili algılamakta bir sorun yaşamadıklarını belirtmektedir. Bu sendrom, Wernicke alanının korunmasına rağmen hasarın sol temporal lobun daha

derinlerinde yer alması ve bu hasarın sonucunda callosal bağlantılarının yok olması ile sağ işitsel alandan gelen bilginin Wernicke alanına ulaşamaması sebebi ile oluşmaktadır.

İletim afazinin (Conduction Aphasia) karakteristik özelliklerine bakıldığı zaman, Geschwind (1970), konuşulan dilde hem anlama hem de üretimi açısından herhangi bir bozukluk görülmediğini fakat konuşmanın içerisinde tekrar bozukluğu görüldüğünü ve “the” “if” gibi küçük dilbilgisi gramer kelimelerinde belirgin bir bozulma olduğunu belirtmektedir. İletim afazisinde Broca ve Wernicke alanları korunmaktadır fakat iki bölgeyi birbirine bağlayan arkuat fasikülüsde lezyon bulunmaktadır. Geschwind’in örneklendirmesi ile hasta “başkanlık sıralaması” (presidential succession) gibi bir ifadeyi başarılı bir şekilde tekrar edebilirken “o burada.” (He is here.) gibi bir ifadeyi tekrar ederken başarısız olmaktadır. Şekil 5’te afaziler, özellikleri ve lokasyonları gösterilmiştir.




Şekil 5: Afazik hastalarda karar verme ağacı.

(Cauquil-Michon vd., (2011) ilustrasyonundan Türkçe'ye uyarlanmıştır.)

Saf kelime körlüğü (Pure alexia; cécité verbale pure) ilk defa 1892’de Dejerine’nin otopsi gözlemleri sonucunda tanımlanmıştır. Dejerine’nin hastası olan Monsieur C’nin sağ görme alanında bozulma gerçekleşmiştir. Dil üretimi ve anlaşılabilirlik açısından herhangi bir bozukluğu olmayan Monsieur C, anlayamadığı kelimeleri

kopyalayabilmiş ama kısa bir süre önce yazdığı cümleleri okuyamaz hale gelmiştir. Otopsi sonuçlarında Dejerine, hastasının sol görsel korteksinin yok olduğunu ve korpus kallozumunda hasar olduğunu (şekil 6) gözlemlemiştir (Dejerine, 1892). Sol görsel korteksteeki hasar sebebiyle yazılı dilin sadece sağ yarım kürede gerçekleşebildiğini fakat korpus kallozumdaki lezyon sebebi ile bilginin sol yarımküredeki konuşma bölgelerine iletilmemesi sebebiyle yazılı dilin anlamdan yoksun kaldığını bildirmiştir (Dejerine, 1892; Geschwind, 1970). Dejerine (1891), Angular girusta oluşan hasar sonucunda hastanın harflerin akustik sembollerini çağrıştıramaması veya içsel konuşmasında duyduğu harflerin görsel imajını canlandıramaması sebebiyle bu bölgeyi “harflerin optik imaj merkezi” olarak tanımlamıştır (Damasio, 1983).




Şekil 6: Dejerine'nin Saf Kelime Körlüğü diyagramı.

Orijinal kullanımı ile “Optik sinirlerin intraserebral yolunun ve sol kıvrımın bağlantılarının şematik diyagramı”. Dejerine, görselde genikulat cisimleri ve optik bantları vurgulamıştır. İlaveten, Quadrigeminal tüberküleri corpus callosum'un şemasında göstermiştir. (Dejerine, 1892).

Dejerine'nin saf aleksi hakkındaki görüşlerinden etkilenen Geschwind ve Fusillo (1966), agrafisi olmayan (agraphia) aleksi hastasını incelemişlerdir. İnme geçiren hastaları H.C., kısa bir süre sonra kelime hafızasında bozukluk yaşamaya başlamıştır. İlerleyen süreçte bu bozukluk geçse bile okuma zorluğu devam etmiştir. Yapılan otopsi sonucunda Geschwind ve Fusillo, beynin sol hipokampal bölgesinde hasar olduğunu ve korpus kallozum ile sol görsel korteksin arka ucunun yok olmasının hastada bu bozukluğa

sebebi olduğunu bildirmişlerdir. Bu sendroma sahip başka vakalar da inceleyen Geschwind (1970), posterior serebral arterin korpus kallozum ve görsel korteksin arka ucunun yanında hipokampal bölgeyi de beslediğinden bahsetmiştir. Geschwind ve Fusillo (1966), konuşulan renk adının görülen renkle eştirilememesine sebep olan renk adlandırma bozukluğunun da agrafisi olmayan aleksi ile ilişkili olduğunu belirtmişlerdir. Birkaç ay boyunca gözlemledikleri hastaları H.C., nesnelere doğru tanımladığı durumlarda bile renk tanımada bozukluk göstermiştir. H.C.’nin koronal düzlemde alınan soldaki görüntü diliminde (resim 2), spleniumun sol tarafta tamamen yok olduğu ve sol temporal ve oksipital kortekslerin medial yüzeylerinde önemli derecede hasar olduğunu gözlemlemişlerdir. Sağdaki görüntü dilimi (resim 2), spleniumun gerisinden alınmış olup, lezyonların sol görsel kortekse ve sol lateral ventrikülün etrafındaki beyaz maddeye kadar uzandığı belirtilmiştir (Damasio, 1983).



Resim 2: H.C.’nin koronal düzlemde alınan beyin görüntüleri.


(Geschwind ve Fusillo, 1966)

Geschwind vd. (1968), ilk olarak Goldstein (1914) tarafından transkortikal afazi olarak tanımlanan “konuşma alanının izolasyonunu” (isolation of the speech area), Wernicke’nin teorisi ile tekrardan açıklamışlardır. Karbon monoksit zehirlenmesi sonucunda beyin hasarı gerçekleşen hastalarını yaklaşık 9 sene boyunca gözlemlemişlerdir. Hastanın dil yetisine bakıldığı zaman dili anlama ve önerme içeren cümle üretme konusunda bozukluk olduğu görülmüştür. Öbür yandan hasta, işitsel olarak duyduğu cümleleri tekrarlama ve tamamlamakta herhangi bir sorun yaşamadığı gibi sözel öğrenme yeteneğini korumaya devam etmiştir. Örneğin hastaya “Bu bir gül mü?” (Is this a rose?) şeklinde bir soru sorulduğunda “Güller kırmızı, menekşeler mavi, şeker tatlı ve sen de öylesin” (Roses are red, violets are blue, sugar is sweet, and so are you.) şeklinde

tamamlayabilmektedir. Otopsi incelemesinin sonucunda, hastanın Wernicke ve Broca alanlarının ve hipokampal bölgenin korunduğunu fakat konuşma alanını çevreleyen bölgelerdeki beyaz maddenin yok edildiğini tespit etmişlerdir. Korunan bölgelerin, doğru tekrarları ve sözel öğrenme yeteneğinin normal düzeyde devam etmesini desteklerken; lezyonların, diğer dil bölgelerinden gelen dil girdilerinin konuşma alanlarına ulaşmasını ve herhangi bir çağrışım uyandırmasını engellediğini ve bu sebepten önerme içeren cümleler kuramadığı bildirilmiştir (Geschwind, 1970; Geschwind vd., 1968)

3.3.1. Price dil modeli

Klasik modelin dil işleme ile ilgili temel görüşlerinden sonra ilgili beyin bölgelerini detaylandırmak adına bir dizi çalışma yapılmaya başlanmıştır. Ben Shalom ve Poeppel (2008), Price'ın (2000) modelinden “klasik modelin modern torunu” olarak bahsetmişlerdir. Price modelinde özellikle kelimelerin akustik analizine, görsel analizine ve anlamsal temsile odaklanmış olup çalışmalarında bilişsel psikolojiye fMRI ve pozitron emisyon tomografisi (PET) gibi tekniklerin, afazilerin anlaşılması ve konuşma üretiminin temellerini anlamak açısından işlevsel olduklarına dikkat çekmiştir. Resim 3'te Price'ın modeline (2000) göre kelimelerin akustik analizinin, görsel analizinin ve anlamsal temsiline hesaplandığı ağlar verilmiştir.



Resim 3: Kelimelerin akustik, görsel ve anlamsal temsiline hesaplandığı ağlar.

(Ben Shalom ve Poeppel, 2007).


Price'a (2000) göre konuşma, klasik görüşlerdeki gibi tek bir lokalize alanda üretilmez. "Prefrontal kortekste ortaya çıkan lezyonlar, hedef kelimeyle anlamsal olarak ilişkili kelimeleri üretme yeteneğini bozarken, sözel anlama yetisini etkilemez" (Price vd., 1997). Konuşma üretimi, premotor, motor ve tamamlayıcı motor alanları (supplementary motor area) ile işitsel ve duyuşsal bölgeleri de içeren dağıtılmış bir konuşma üretim ağı (speech production network; SPN) ile desteklenmektedir (Narayana vd., 2020). Konuşmanın planlanması, izlenmesi ve uygulanması için koordine bir ağ çalışması gerekmektedir.

Konuşma seslerinin akustik-fonetik işlenmesi ilk olarak sol yarımküredeki posterior superior temporal kortekste gerçekleşmektedir. Klasik görüşte bu işlemenin lokasyonu superior temporal girus olarak belirtilse de Price, asıl lokasyonun superior temporal sulkus olduğunu öne sürmüştür (Ben Shalom & Poeppel, 2008; Price, 2000). Posterior inferior temporal korteks ve ventral oksipito-temporal korteks (vOT), kelimelerin görsel analizinin gerçekleştiği ağı içermektedir. Özellikle ortografik işleme için özellikle sol posterior fusiform girusun önemini vurgulamıştır (Price, 2012). Ventral oksipito-temporal korteksin, yazılı kelimelerin görsel özelliklerini işleyerek temsillerini oluşturmak ve bu temsillerin diğer dil işleme bölgelerine iletilmesini sağlamakla görevli olduğunu önermiştir. Anlamsal işlemenin ise anterior inferior temporal korteksi ve parietel angular girusu içeren bir ağda gerçekleştiğini bildirmiştir. Anlamsal bilginin en ilişkili olduğu bölgelerin sol ekstra silviyan temporal korteksler olduğunu önermiştir (Price vd., 1997). Ben Shalom ve Poeppel'e (2008) göre, anlamsal temsillere yaptığı vurgu Price'ın modelinin en önemli noktalarından birisidir.

3.3.3. Hickok ve Poeppel'in Çift-Yönlü Yolak Modeli

Hickok'a (2009) göre, konuşulan dil, düşünce malzemesiyle aynı değildir ve bir kavramı ifade etmek için belirsizlikleri içeren birçok yol vardır. Bu belirsizliği Hickok'un örneği ile açıklarsak İngilizce dilindeki "we went to the bank at noon" cümlesi "bank" kelimesinin birden fazla anlam içermesi sebebi ile finansal bir işlem için "öğlen bankaya

gittik” şeklinde anlaşılacağı gibi piknik yapmak için “nehir kenarına gidildiği” anlamına da gelmektedir. Hickok bu belirsizliğin konuşma sinyali ile ilgili bir durum olduğu ve dil düşüncelerinin akustik kodlara dönüştürülecek araçlar olduğunu düşünmektedir. Konuşma algısını ve dil işlemeyi farklı bir açıdan ele alan Hickok ve Poeppel Çift-Yönlü Yolak Modeli’ni (Dual-Stream Model) önermişlerdir (Hickok vd., 2000a; Hickok & Poeppel, 2004). Bu model (Şekil 7) temel çerçevesi ile, ventral yolak temporal lobun üst ve orta bölümlerini içermekte olup ses-anlam eşleşmesini, dorsal yolak posterior planum temporal lob ile posterior frontal lobu birbirine bağlamakta olup işitsel-motor entegrasyonunu desteklemektedir (Friederici, 2011). Konuşma işleme organizasyonu, konuşmanın anlaşılabilmesi ve tekrar üretilebilmesi olarak iki tür ana işleve dayanmaktadır. Konuşmanın anlaşılabilmesi için ilk olarak akustik konuşma girdilerinin kavramsal-semantic temsillere bağlanması gerekmektedir. İkinci olarak, konuşmanın yeniden üretilebilmesi için akustik konuşma bilgisi motor konuşma sistemine bağlanabilmelidir (Hickok, 2012).

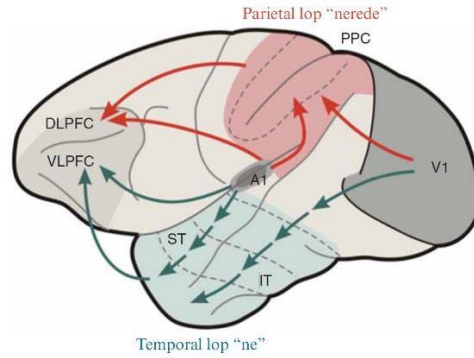


Şekil 7: Dilin işlevsel anatomisinin Çift-Yönlü Yolak Modeli.

pIFG: posterior inferior frontal girus; **PM:** premotor; **SPT:** silvian parietal-temporal; **STG:** superior temporal girus; **STS:** superior temporal sulcus; **aMTG:** anterior middle temporal girus; **aITS:** anterior inferior temporal sulcus; **pMTG:** posterior middle temporal girus; **pITS:** posterior inferior temporal sulcus. (Hickok ve Poeppel’den (2007) Türkçe’ye uyarlanmıştır.)

Hickok ve Poeppel, işitsel ve görsel işleme arasında kurdukları analogi ile modellerini önermişlerdir (Ben Shalom & Poeppel, 2008). Modellerinin temeli, Mishkin

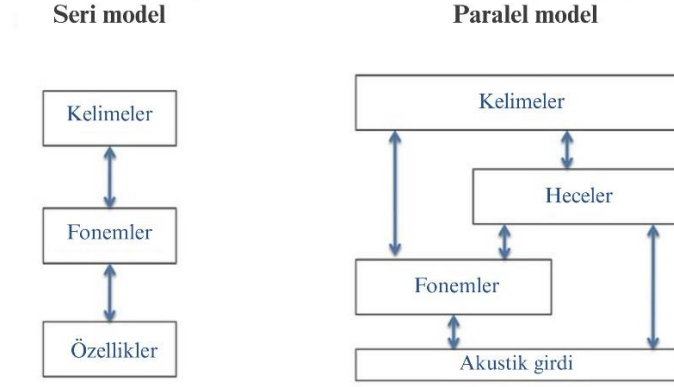
vd.'nin (1983) görsel sistem için önerdiği ve Rauschecker'in (1998) işitsel sistem için önerdiği “ne” ve “nerede” şemalarına (Şekil 8) dayanmaktadır. Mishkin vd.'nin (1983) görsel sistem akışlarının her ikisi de birincil görsek korteks V1'de başlamaktadır ve V1 den çıkan bilgi, “ne” akışı için ventral yola, “nerede” akışı için dorsal yola yönlendirilmektedir (Rauschecker & Tian, 2000). Ventral yolun parçası olan V4'teki nöronlar görsel nesne temsillerinin renk ve boyutunu seçmekte (Zeki, 1983) görev alırken, dorsal yolun parçası olan V5 nöronları hareketin yönünü ayırt etmede (Movshon & Newsome, 1996) görev almaktadır. Daha önceki çalışmalarda, V4 alanındaki nöronların görsel nesne temsilleri için kritik öneme sahip inferotemporal alanlara (Desimone, 1991); V5 alanındaki nöronların ise görsel mekânsal işleme için parietal kortekse (Sakata & Kusunoki, 1992) yansıtma yapmakta görev aldıklarından bahsedilmiştir (Rauschecker & Tian, 2000). İşitsel işlemedeki “ne” akışının görsel işlemedeki akış ile tutarlı olarak temporal yolun karmaşık nesne desenlerinin tanınmasına hizmet ettiği, fakat “nerede” akışının posterior parietal yol ile sensör-motor rolünü üstlendiği savunulmuştur. Bu projeksiyon yönlerine göre ana iki yol, postero-dorsal ve antero-ventral yol olarak adlandırılmıştır (Rauschecker, 1998; Rauschecker & Scott, 2009). Ventral yol, anterior temporal lob (ATL), orta temporal girus ve alt temporal sulkusun dahil olduğu “çoklu iki taraflı rota” içermektedir ve görevi leksikal kavramsal temsilleri duyuşal veya fonolojik temsiller ile eşleştirmektir (Hickok & Poeppel, 2007; Weiller vd., 2011).



Şekil 8: ‘Ne’ ve ‘nerede’ için ikili işleme şeması.

V1: birincil görsek korteks; A1: birincil işitsel korteks; IT: inferior temporal bölge; ST: superior temporal bölge; PPC: posterior parietal korteks; VLPFC: ventrolateral prefrontal korteks; DLPFC: dorsolateral prefrontal korteks. (Rauschecker ve Scott'tan (2009) Türkçe'ye uyarlanmıştır.)


Dil işleme hakkındaki tartışmalardan birisi STG'nin rolü ve hangi yarımkürede aktivasyon gözlendiği ile ilgilidir. İlk hipotezler, Wernicke (1870) dönemine dayanmakta olup kanıtlar dil anlama bozukluklarının genellikle sol üst temporal girus (STG) lezyonları ile bağlantılı olduğu yönündedir. İlerleyen dönemde yapılan çalışmalar, sol STG'nin yıkımının dilin anlaşılmasından ziyade konuşma üretimine katkıları olduğu yönündedir (Basso vd., 1977; Blumstein vd., 1977; Miceli vd., 1980). Sonraki nörogörüntüleme çalışmaları, üst temporal lopta (STL) bilateral ve büyük ölçüde simetrik aktivasyonların gerçekleştiğini raporlamışlardır (Binder vd., 1994, 2000; Price vd., 1997; Zatorre vd., 1996). Hickok'a (2009) göre, fonolojik işleme için superior temporal sulkus (STS) kritik öneme sahip bir bölgedir. Konuşma işlemenin amacı, fonolojik bilgileri kullanarak kavramsal-semantik temsillere erişmektir. Çift-Yönlü Yolak Modeli, dağılmış kavramsal temsiller ile fonolojik temsiller arasında eşleşmeyi sağlayan bir hesaplama arayüzü görevi görmektedir. Fonolojik süreçlerde rol alan STS'nin kritik bölümü, Heschl girusunun ön yanal yönü ile Sylvian füssürün en arka ucu arasında sınırlandırılmıştır. Bununla birlikte, Hickok ve Poeppel (2000, 2004, 2007), konuşmanın bilateral olduğu görüşüne katıldıklarını fakat iki yarımkürenin simetrik olarak aynı özellikleri göstermediklerini savunmaktadırlar. Onlara göre, bu asimetrinin temel farklarından birisi zamansal-spektral çözünürlüktür. Sol yarımküre zamansal çözünürlük için, sağ yarımküre ise spektral çözünürlük için seçiciliği tetiklemektedir (Hickok, 2009; Zatorre vd., 2002). Diğer bir temel farklılık, Zamanda Asimetrik Örnekleme (Asymmetric Sampling in Time) hipotezine göre, örnekleme hızıdır. Örnekleme hızı açısından sol yarımküre (25-50 Hz) sağ yarımküreden (4-8 Hz) daha hızlı olduğu bildirilmiştir (Poeppel, 2003). Bu işlev asimetrisindeki temel nokta olarak konuşma tanınmanın sestem anlama eşleşmesinde her iki yarımkürede de en az bir tane olmak üzere paralel yollar (Şekil 9) içermesi vurgulanmıştır (Hickok & Poeppel, 2007).



Şekil 9: Konuşma tanımada seri ve paralel modeller.

(Hickok'dan (2009) Türkçeye uyarlanmıştır.)

Hickok ve Poeppel'e göre (2007), işitsel-motor entegrasyonu esasen gelişime dayanmaktadır ve konuşmayı öğrenmek temelde motor öğrenme görevidir. Konuşma seslerini öğrenme, üretme ve konuşmayı tekrarlamak için ses örneklerini kodlayan ve koruyan bir sinir mekanizması olması gerekmektedir. Klasik modellere kadar gidildiği zaman, duyusal-motor bağlantısı için arkuat fasikülüs önerilmiştir (Geschwind, 1971). Çift-yönlü yolak modelindeki dorsal yolak, fonolojik çalışma belleğinde görev almaktadır. Bununla birlikte, işitsel-motor entegrasyonunu destekleyerek işitsel konuşma sinyallerinin motor komutlara çevrilmesini sağlar ve bu artikülasyon oluşumu için önemlidir (Hickok, 2009). Hickok ve Poeppel (2007), işitsel-motor entegrasyonunun birincisi konuşma segmentlerini ikincisi ise segment dizilerini içeren en az iki seviyeye sahip olduğunu önermişlerdir. Segmental düzeydeki süreçler, konuşma seslerini üretmeyi öğrenmede rol oynamaktadır. Fonetik becerilerin edinilebilmesi için dil, dudak ve ses telleri gibi artikülatorlerin hareket koordinasyonunu sağlamak segmental düzeydeki süreçlerin görevidir. Segment dizileri seviyesindeki süreçler, ses dizilerinin beyinde ve konuşma organlarında birlikte nasıl işlendiğini ifade etmektedir. Segment dizilerini doğru bir şekilde algılamak ve üretmek, yeni kelime dağarcığı edinilmesi sürecini desteklemektedir. İlaveten, bu süreçler, gerçek konuşma esnasında artikülator hareketlerini gerçek zamanlı koordine ederek akıcı ve anlaşılır ses dizilerinin üretilmesini sağlamaktadır. Diğer bir deyişle, "konuşma dizilerinin çevrimiçi olarak yönlendirilmesinde" rol oynamaktadır (Hickok ve Poeppel, 2007).



Şekil 10: Çift-Yönlü Yolak Modeli'nin fonksiyonel anatomisi için bir çerçeve.

pIFG: posterior inferior frontal girus; **dPM:** sol pre-motor; **SPT bölgesi:** Sylvian parietel-temporal alan; **STG:** superior temporal girus; **pITL:** posterior inferior temporal lop; **noktalı alan:** fonem düzeyindeki temsilleri destekleyen bölge. (Hickok ve Poeppel,'den (2004) Türkçeye uyarlanmıştır.)

Dorsal yolak, sol yarımküreye baskındır ve süreç, STS ve STG içindeki işitsel kortikal bölgelerde başlamaktadır. Konuşma seslerinin akustik fonolojik temsilleri bu bölgelerde kodlanır ve bilgi, sylvian parietel-temporal alana (Alan SPT) iletilir. Alan SPT, duyuşsal ve motor konuşma temsilleri arasındaki dönüşümü hesaplayan işitsel-motor entegrasyon sistemi için kritik bir bölge olarak tanımlanmıştır (Hickok, 2012) ve Parietal ve temporal loblar arasındaki sylvian yarığının posterior sınırında, planum temporalin (PT) içinde yer almaktadır. Alan SPT, İşitsel algı ve motor artikülasyon arasında bağlantı kurmaktadır ve işitsel kortikal bölgelerden aldığı duyuşsal kodları konuşma artikülasyonlarına yönlendirilmek üzere motor planlara dönüştürmekte görevlidir. Hickok vd. (2003), hem duyuşsal hem de motor tepki özelliklerine sahip yetenekli

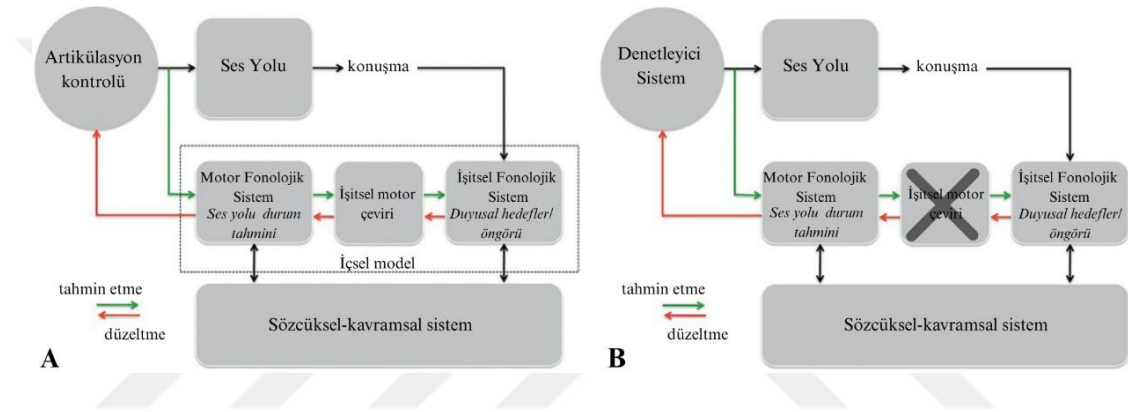
piyanistlerden işitsel bölgeleri belirlemek amacıyla yeni melodileri dinlemelerini ve bu melodileri mırıldanarak veya klavyede çaldıklarını hayal ederek yeniden üretmelerini istemişlerdir. Yapılan fMRI çalışmasının sonucunda, Alan SPT'nin mırıldanma koşulunda çalma koşulundan daha fazla aktif olduğu tespit edilmiştir. Bu bakımdan, Alan SPT'yi, ses yolu için sensörimotor arayüz devresinin parçası olarak gördüklerini bildirmişlerdir (Hickok ve Poeppel, 2007). Lezyon kanıtlarının da bu görüş ile tutarlı olduğu ve iletim afazisindeki lezyon dağılımının Alan SPT ile örtüştüğü gözlemlenmiştir (Buchsbaum vd., 2011; Hickok, 2012). Dorsal yolakta rol oynayan bir diğer bölge sol inferior frontal girustur (IFG). IFG, Alan SPT'nin entegratif rolünü tamamlamaktadır ve konuşmanın motor planlaması ve üretiminde görev almaktadır. İşitsel girdinin artikülatör motor komutlara dönüştürülmesi, sol IFG içerisindeki pars opercularis ve pars triangularis sayesinde gerçekleşmektedir. Son olarak sol premotor korteks, motor planların artikülasyon için gerekli kas hareketleri ile koordine edilmesine katkıda bulunmaktadır. Konuşmanın akıcı bir şekilde gerçekleşmesi adına sol IFG ve Alan SPT ile iş birliği içerisinde çalışmaktadır (Fridriksson vd., 2016; Hickok, 2012).

3.3.3.1. Geri besleme kontrolü ve öngörünü kodlama

Hickok'a (2012) göre, sinir sisteminin duyuşal ve motor komutları geçmişteki öğrenilmiş deneyimler ile birleştirmesi ve duyuşal girdi ile motor çıktıyı gerçek zamanlı olarak entegre etmesi sonucunda gelecekteki eylem ve durumlar hakkında tahminlerde bulunarak en doğru artikülasyonu oluşturması için bir hesaplama mekanizması gerekmektedir. Bu hesaplama mekanizmasında geri besleme kontrolü (state feedback control; SFC) ve öngörücü kodlama (predictive coding) bütüncül olarak işlev göstermektedir.

Çift-Yönlü Yolak Modeli'ne göre, geri besleme kontrolü, dorsal yolaktaki konuşma çıktısının izlenerek çıktıdaki hataların tespit edilmesi ve hızlı bir şekilde düzeltilmesi sürecini ifade etmektedir. Geri besleme koordinasyonu için Alan SPT, pIFG ve lateral PM korteks birlikte çalışmaktadır ve bu kontrol sayesinde en doğru artikülasyon elde edilir. Öngörücü kodlama, işitsel girdi ve motor durumlar ile ilgili ileriye dönük tahminlerde bulunularak konuşma algısını ve eylemini kolaylaştırma sürecini ifade

etmektedir. Öngörücü kodlama hem ventral hem de dorsal yolakta gerçekleşmekte olup iki yolakta farklı işlevlere hizmet etmektedir. Ventral yolak, gelen işitsel bilgiler hakkında algısal tahminlerde bulunarak konuşma seslerinin etkili bir biçimde çözümlenmesini amaçlamaktadır. İleriye dönük tahminlerde bulunması konuşma anlayışının gelişmesini sağlamaktadır. Dorsal yolaktaki öngörücü kodlama ise temelde motor kontrol süreçlerini desteklemektedir. Konuşma hareketlerinin duyuusal sonuçlarını tahmin etmek, hata düzeltmeyi ve konuşma üretimini kolaylaştırmaktadır (Hickok, 2012; Hickok & Poeppel, 2015).



Şekil 11: Konuşma üretiminin geri besleme kontrolü modeli.

A. Geri besleme kontrolünün psikodilbilim ve nörodilbilim literatürlerinden konuşma modelleri ile birleştirilmiş çerçevesi. B: İletim afazisinin önerilen kaynağı: işitsel-motor çeviri sistemindeki hasar. (Hickok ve Poeppel'den (2015) Türkçe'ye uyarlanmıştır.)

“İşitsel-fonolojik ağa gelen girdiler, konuşma eylemlerinin işitsel hedeflerini tanımlar. Bir motor konuşma birimi (ensemble) aktive olmaya başladığında, öngörülen işitsel sonuçları işitsel hedefe göre kontrol edilebilir. Eğer eşleşirlerse, o birim aktive olmaya devam eder ve hedefi vuracak bir artikülasyonla sonuçlanır. Bir uyumsuzluk varsa, doğru motor üniteyi etkinleştirmek için bir düzeltme sinyali üretilebilir.” (Hickok, 2012).


Son olarak, Hickok (2012) bu modelin iletim afazisindeki semptom örüntülerini açıklayabileceğinden bahsetmiştir. Hickok'a göre, Alan SPT'de gerçekleşen bir lezyon

hem öngörücü kodlamayı hem de geri beslemeli kontrolü bozmaktadır. Bu sistemlerin bozulması, işitsel hedeflerin aktivasyonu korunsa bile hataların tespit edilmesini zorlaştırmaktadır ve hata tespiti gerçekleşse bile düzeltme sinyali doğru bir şekilde çevrilmesini engellemektedir. Diğer bir deyişle, Alan SPT'deki bozulma, iletim afazisinin karakteristik bir özelliği olan tekrarlı şekilde kendini düzeltme girişimlerine sebep olmaktadır.

3.3.4. Friederici dil modeli

Friederici'ye (2002) göre, cümle işleme üç aşamadan oluşmaktadır. İlk aşamada, cümle yapısının kelime kategorisi bilgisi temel alınmaktadır. İkinci aşamada, cümledeki eylem ve eylemi kimin nasıl gerçekleştirdiği gibi sözdizimsel ve anlamsal ilişkiler hesaplanmaktadır. Anlamanın kolay bir şekilde gerçekleşebilmesi için sözdizimsel ve anlamsal bilgilerin uyumlu bir yorumlamaya yol açması oldukça önemlidir. Bu bilgilerin uyumlu olmadığı durumlarda ise üçüncü bir aşamaya ihtiyaç duyulmaktadır. Bu aşamada, işlemenin gerçekleşebilmesi için, dünya bilgisi ve bağlam gibi farklı bilgi türlerinin değerlendirilmesi ve entegre edilmesi gerekmektedir. Çalışmasında üçüncü aşamadan dilbilimsel prozodi olarak bahseden Friederici (2011), bu işleme sistemi sayesinde cümlenin tematik odağını ve ifadenin soru mu yoksa bildiri cümlesi mi olduğunu analiz ederek sözdizimsel ve anlamsal süreçlerinin düzenlenebileceğini vurgulamaktadır.

Beyin temelli dil çalışmalarının gelişmesi açısından, beyindeki bilişsel işlevlerin fMRI ile görüntülenmesinden başlayarak, gri madde ve beyaz madde lif yollarının in vivo olarak görüntülenmesini sağlayan EEG, MEG ve MRI metodolojileri sayesinde dil çalışmalarında önemli bir ilerleme kaydedilmiştir (Friederici, 2011). Yapılan çalışmalar sonucunda, IFG'de bulunan Broca alanının, STG'de bulunan Wernicke alanının, orta temporal girusun (MTG) bazı kısımlarının ve parietal lobdaki inferior parietal ve açılal girusunun dil ile ilgili olduğu belirlenmiştir. İlâveten, bu bölgelerin mikroanatomik alt bölgeleri bulunmaktadır (şekil 12).




Şekil 12: Sol hemisferin anatomik ve sitoarkitektonik detayları.

(Friederici, 2011)

İşlevsel bir yoruma göre (Saur vd., 2008, 2010), ventral yol, triangularis (BA 45) ve pars orbitalisi (BA 47) birbirine bağlamaktadır ve ses-anlam eşlemesi (mapping sound-to-meaning) denilen duyduğumuz sesleri zihnimizdeki temsilleri ile ilişkilendirmekte rol oynamaktadır. Dorsal yol ise temporal lobdan premotor kortekse, premotor korteksten de pars opercularise (BA 44) gitmektedir ve sestem artikülasyona (sound-to-articulation) duysal-motor eşlemeyi desteklemektedir. Friederici vd. (2006), dil işleme sürecine dahil olan iki yolağı tanımlamışlardır. Dorsal yolak, IFG'deki pars opercularisi (BA 44) arkuat fasikulus (AF) ve superior longitudinal fasikulus (SLF) aracılığı ile posterior temporal kortekse bağlamaktadır. Ventral yolak ise, frontal operkulumu (FOP) uncinat fasciculus (UF) aracılığıyla anterior temporal kortekse bağlamaktadır. Dorsal yol, karmaşık cümle yapılarında bitişik olmayan parçalar arasındaki bağlantıları anlamaktan sorumluyken, ventral yol, bir dizideki bitişik öğelerin kombinasyonunu desteklemektedir.

Bu görüşler ve yapılan intraoperatif derin stimülasyon çalışmalarından yola çıkarak Friederici (2011), dil işlemeye dahil olan 2 dorsal yolak ve 2 ventral yolak (Şekil

13) olduğu fikrini önermiştir. Ventral Yolak I, frontal korteksi (BA 45) aşırı lif kabul sistemi (EFCS) aracılığı ile temporal kortekse bağlamaktadır. Ventral Yolak II, frontal operkulumu (FOP) unsinat fasikül (UF) aracılığı ile temporal kortekse bağlamaktadır. Dorsal Yolak I, temporal korteksi premotor kortekse bağlamakta olup seslerin motor süreçlerle eşleştirilmesini desteklemektedir. Dorsal Yolak II, temporal korteksi BA 44'e bağlayarak üst düzey dil süreçlerinin yürütülmesinde rol oynamaktadır (Friederici, 2011).



Şekil 13: Dil korteksleri arasındaki yapısal bağlantılar.

İki dorsal yol ve iki ventral yolun şematik görünümü. (Friederici, 2011).

3.4. Anlamsal ve Sözdizimsel Dil Süreçleri

3.4.1. Akustik-fonolojik analiz

Duyusal girdiyi dilsel bilgiyle bütünleştirerek karmaşık bilişsel mekanizmaların incelenmesini sağlayan Akustik-Fonolojik Analiz, konuşulan dilin anlaşılmasında oldukça önemli bir rol oynamaktadır (Frederici, 2011). Seslerin hem soyut temsillerinin hem de fiziksel özelliklerinin incelenmesi, dil kurallarının belirlenebilir olmasını ve

karşılaştırılmasını sağlarken aynı zamanda da dilin beyindeki işleme süreçlerine dair teoriler geliştirilmesi yönündeki araştırmaların önünü açmaktadır (Mai vd., 2024; Pisoni & Luce, 1987).

Friederici'ye (2011) göre, işitsel korteks ve komşu bölgeler, akustik-fonolojik analiz çalışmaları için en uygun nöral bölgelerdir. İşitsel korteks ve komşu bölgelerdeki alt bölgeleri belirlemek amacıyla insan olmayan primatlar üzerinden elde edilen verilerden yola çıkılarak Heschl Girus'da (Heschl's Girus; HG) çekirdek, belt ve parabelt bölgeleri tanımlanmıştır (Rauschecker & Scott, 2009; Scott & Johnsrude, 2003). İnsan beyinde Transvers Temporal Girus olarak da bilinen HG, temporal lobun üst yüzeyinde, sylvian fissürü içerisinde ve yukarı postcentral girusun karşısında bulunmaktadır. HG'de temporal lobun üst yüzeyinde Birincil İşitsel Korteks (Primary Auditory Cortex; PAC) yer almakta olup BA 41 ve BA 45'i içermektedir. İlaveten Planum Temporale (PT), Planum Plare (PP) ve STG'den STS'ye uzanan HG'ye komşu üç bölge akustik analizde önemli rol oynamaktadır. PT posterior, PP ise HG'nin anterolateralinde yer almaktadır.

Konuşmayı anlamının nöroanatomik temellerinin açıklanması açısından birincil olarak konuşma ve konuşma dışı akustik sinyaller arasındaki ayrımı incelemek ve işlem akışının gerçekleştiği yerleri belirlemek önemlidir. Heschl Girus (HG), tüm ses türleri tarafından aktive edilebilmektedir (Johnsrude vd., 2002) ve birincil işitsel analizin gerçekleştiği bölgedir. Binder vd. (2000) fMRI kullandıkları çalışmalarında, lateral temporal korteksin işlevsel organizasyonunu incelemek için katılımcıları yapılandırılmamış gürültü, frekans modülasyonlu tonlar (frequency-modulated tones; FM), tersine çevrilmiş konuşma, sahte kelimeler ve gerçek kelimeler dahil edilmiş çeşitli uyarılara maruz bırakmışlardır. Çalışmanın sonucunda, özellikle HG'nin çevresindeki PT ve Sordolateral STG'nin gürültüye kıyasla FM tonlarına daha güçlü yanıtlar verdiğini ortaya koymuşlardır. STS merkezli bölgeler ise sahte sözcükler (pseudoword) ve tersine çevrilmiş konuşma için FM tonlarından daha fazla aktivasyon göstermiştir. Binder vd. (2000), bu sonuçlarından yola çıkarak aktivasyondaki farklılığın dilsel anlamından ziyade akustik özelliklerinden kaynaklandığını öne sürmüşlerdir.

Doğal çevremizde hem zamansal hem de spektral olarak karmaşık olan ve zaman içerisinde gelişen çoklu frekanslardan oluşan karmaşık seslere sıklıkla rastlanmaktadır. Beyin, işitsel sahne analizi (auditory scene analysis; ASA) adı verilen süreç aracılığı ile doğal çevreden gelen spekrotemporal kalıpları geçmiş deneyimlerle karşılaştırır ve ayırır. Griffiths ve Warren (2002), PT'yi, bu kalıpların ayrıştırılmasını ve eşleştirilmesini kolaylaştıran ve bilgiyi daha üst kortikal alanlara yönlendiren bir "Hesaplama Merkezi" olarak adlandırmaktadırlar. Aynı zamanda bu hesaplama merkezi, algılanan akustik kaynakların tanımlanmasını ve konumlanmasını sağlamaktadır. İlaveten, PT'deki aktivite, daha fazla konum sunuldukça uzamsal olarak spesifik nöral birimlerin adaptasyon sayısından etkilenmekte ve artmakta olup, aktivitenin artması için genel olarak seslere odaklanmış dikkat gerekli değildir (Deouell vd., 2007).

Fonem, "bir kelimeyi diğerinden ayırmaya yardımcı olan en küçük fonetik birim veya tek bir temel ses olarak algılanan benzer konuşma sesleri kümesi" olarak tanımlanmaktadır (Inc, 1998). Örneğin İngilizcedeki [weight] kelimesinin yazılışı 6 harften oluşmaktadır. Konuşma dili olarak baktığımızda < eigh > 4 harflidir fakat /ae/ tek sesinden oluşmaktadır. Fonem olarak incelediğimizde ise /w/ /ae/ /t/ olmak üzere 3 fonemi vardır. Başka bir örnekte ise [cat] ve [fat] kelimeleri 3'er harflidir. /c/ ve /f/ sesleri ise iki kelimenin farklı anlamlara kavuşmasını sağladıkları için fonem olarak kabul edilmektedir (Karakas, 2017). Konuşmanın hiyerarşik ağlarda çok aşamalı olarak nasıl işlendiğini araştıran nörogörüntüleme çalışmalarının sonucunda, akustik olarak eşleşen fakat anlaşılabilen kontrol seslerine kıyasla fonemlerin sol anterolateral superior temporal kortekste yüksek hassasiyet gözlenmiştir (Obleser vd., 2007). İlaveten, anlaşılabilirlikten bağımsız olarak karmaşık seslerin işlenmesinde PT'nin akustik analizatör olarak görev aldığı gözlenmiştir. Fonem dizilimlerinin beyinde nasıl temsil edildiğini inceleyen bir çalışmada, sıralı düzen korunurken bilgilerin konuşma birimlerine nasıl dönüştürüldüğünü kodlama ve kod çözme kullanarak analiz edilmiştir (Gwilliams vd., 2022). Çalışmaya göre beyin, en son duyulan yaklaşık üç konuşma sesini paralel olarak sürekli kodlamaktadır. Duyusal girdi kaybolduğu zaman veya sözcükler belirsiz olduğunda beyin kelime tanıma başarılı bir şekilde gerçekleşene kadar fonem temsillerini sıralı olarak korumaya devam etmektedir. Ayrıca çalışmacılar, bağlama dayalı öngörülebilir fonemlerin daha erken aktif hale geldiklerini gözlemlemişlerdir.

3.4.2. Sözdizimsel süreçler

Psikodilbilimde, insanların tümce anlama sırasında dili nasıl işlediği tartışmalı bir konudur. Frazier (1987), sözdizimsel bilginin birden fazla aşamada işlenmesi ile cümle çözümlemenin gerçekleşeceğini öne sürmektedir. Başlangıçta, kelimeler anlamları dikkate alınmadan kelime kategorisi bilgisine (dilbilgisi) dayalı temel bir sözdizimsel yapı oluşturulmaktadır. İkinci aşamada ise, “Kimin kime ne yaptığı” gibi tematik roller atayarak tümcenin anlamsal olarak işlenmesi için varlıklar arası ilişki kurulmaktadır. Diğer bir deyişle, bu seri sözdizim öncelikli modeller (Serial Syntax-First Models), dilbilgisel bilginin anlamsal bilgidan bağımsız olarak ilk önce işlendiğini öne sürmektedir (Forster, 1981). Son olarak, ilk aşamadaki sözdizimsel yapı ikinci aşamadaki anlamsal beklentilerle örtüşmezse, uyumsuzlukları gidermek adına beyin yeniden analiz yapmaktadır.

Seri sözdizim öncelikli modellere meydan okuyan etkileşimli ve kısıtlama tatmini (Interactive and constraint-satisfaction) modelleri, tümcenin anlaşılması için sözdizimsel ve anlamsal bilginin başlangıçtan itibaren eş zamanlı olarak etkileşime girdiğini öne sürmektedir (Malaia & Newman, 2015). Bu modelde, bilginin iki türü de belirsizlikleri gidermek ve anlam oluşturmak için sürekli bir etkileşim halindedir. Model, en makul yoruma ulaşmak için sözdizimi ve anlambilim alanlarından gelen kısıtlamaları kullanarak dinamik olarak entegre etmektedir.

Friederici'ye (2011) göre, sözdizim öncelikli modellerde ilk sözdizimsel çözümleme gerçekleştikten birkaç yüz milisaniye sonra tümcenin dilbilgisel yapısının atanmasını içeren sözdizimsel süreçler gerçekleşmektedir ve bu düşük zamansal çözünürlük sebebiyle işlem aşamalarının fMRI kullanılarak ayrıştırılması zordur. Doğal tümcelerin ilk ya da sonraki aşamalarını hedef almak üzere sözdizimsel ihlaller eklemek, bu zorluğun üstesinden gelmenin bir yoludur. Kelime kategorisi ihlalleri, yerel tümce yapılarının oluşumunu engeller ve ilk aşamayı bozmaktadır. Dilbilgisel ilişki ihlalleri ise sonraki aşamaları etkilemektedir. İşlem aşamalarını incelemenin bir diğer yolu ise anlamsal bağlamdan yoksun yapay gramerler kullanılmasıdır. Bununla birlikte, sözdizimi öncelikli modeller, tümce anlama mimarisine ilişkin zamansal ve uzamsal bilgiler

saplamak adına ERP'leri dikkate alan modellerden destek almaktadır (Bornkessel & Schlesewsky, 2006; Friederici, 2002). fMRI sinirsel olayların nerede gerçekleştiği yönünde hassas bir mekânsal bilgi sağlarken, ERP'ler olaylar hakkında zamansal ayrıntılı bilgi sağlamaktadır. Her ne kadar fMRI'nin düşük zamansal çözünürlüğü, kelime ihlalleri kategorisi bilgisine verilen ERP yanıtlarında ortaya konulan erken ve geç etkilerin ayırt edilmesini engellese de belirli beyin lezyonlarına sahip hastaların yanıtlarını içeren ERP çalışmalarının ve sağlıklı katılımcılardan elde edilen MEG lokalizasyon çalışmalarının birleştirilmesi kelime ihlallerinin lokalizasyonu hakkında bilgi sağlayabilmektedir (Friederici, 2011).

ERP'ler, uyarının başlangıcından yaklaşık 400 ms sonra zirveye ulaşan ve anlamsal bilginin işlenmesiyle tutarlı bir şekilde dalgalandığı gözlemlenen N400 olarak adlandırılan bir negatif bileşen içermektedir (Kutas & Federmeier, 2000). Nobre ve McCarthy (1995), kelime tiplerinin değiştiği bir kelime okuma içeren görevler esnasında, dirençli nöbetlere sahip hastaların anterior medial temporal lobun (AMTL) intrakranial derin kayıt verilerini analiz ettiklerinde, kollateral sulkus ve anterior fusiform girus bölgelerindeki neokorteksleri N400'ün hem işlevsel olarak hem de uzaysal olarak farklı üreticilerden (generators) kaynaklanabileceğini öne sürmüşlerdir. Bununla birlikte alan potansiyellerinin nöral üreticileri (neural generators) olarak kollateral sulkus ve anterior fusiform girus bölgesindeki neokorteksi önermişlerdir. McCarthy vd. (1995) tarafından ERP kullanılarak yapılan bir başka kelime okuması içeren çalışmada, parsiyel epilepsi (fokal nöbet) teşhisi konulmuş hastalara, yarısı normal bir şekilde sonlandırılmış diğer yarısı ise anlamsal olarak anormal bir kelime ile sonlandırılmış cümleler bir video monitörünün ortasından ardışık olarak sunulmuştur. Sonuçlara bakıldığı zaman, anormal kelimelerin amigdalanın bitişiğindeki AMTL'de ve hipokampusun önünde bilateral olarak saç derisinden kaydedilen N400 e benzer şekilde negatif bir alan potansiyeli oluşturdukları gözlenmiştir. Bununla birlikte, parahipokampal girusların üzerinde ve kollateral sulkusun yakınında bulunan subdural elektrotlarda ise pozitif bir alan potansiyeli gözlenmiştir.

Simos vd. (1997), McCarthy vd.'nin (1995) daha önceki çalışmalarına ithafen, N400 tepkisinin manyetik eşdeğerine sebep olan kaynakları yerelleştirmek amacıyla

standart MEG analiz tekniklerini ve MRI kullandıkları bir cümle okuma paradigması kullanmışlardır. Sağlıklı yetişkinlere, yarısı “He dried his hands with a towel” (Ellerini bir havluyla kuruladı) cümlesindeki “towel” (havlu) gibi uygun bir kelimeyle, diğer yarısı ise “He dried his hands with a hammer” (Ellerini bir çekiç ile kuruladı) cümlesindeki “hammer” (çekiç) gibi uygunsuz kelime ile biten cümleler göstermişlerdir. Çalışmanın sonucunda, N400 tepkisi belirgin olarak sol yarım küre üzerinde kaydedilen uyarılmış manyetik alanlarda (Evoked Magnetic Field; EMF) ve aynı anda Fz ve Pz noktalarından kaydedilen ERP’lerde gözlenmiştir. Sol yarım kürede anlamsal olarak uyumsuz kelimelere karşı tepki kaydedilmiş olup, çoğu beyin aktivitesinin posterior temporal neokortekste, özellikle superior temporal sulcusa yakın orta temporal girus etrafında, temporo-parietal kesişim yakınında yoğunlaştığı gözlenmiştir.

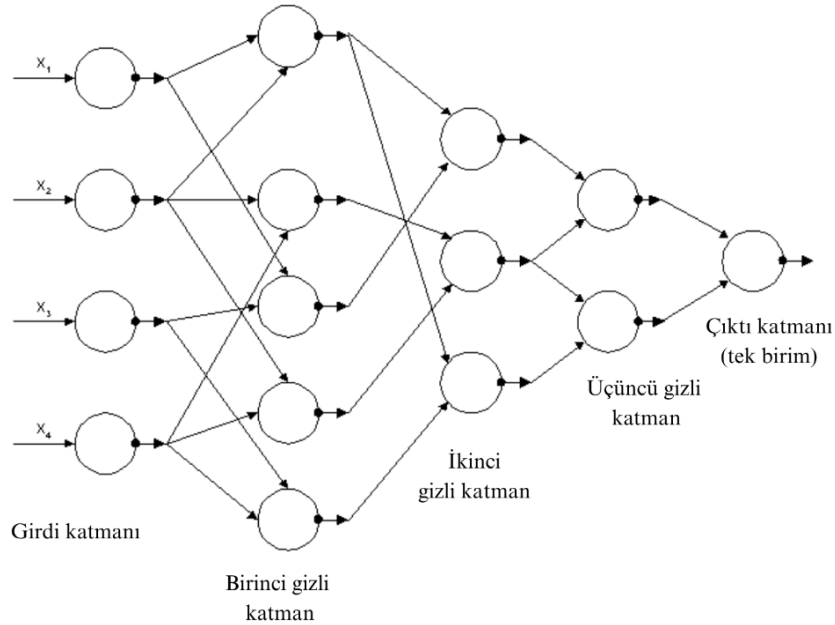
Friederici vd. (2003) çalışmalarında, hem erken sol anterior negatiflik ve geç sentero-parietal pozitiflik (Centro-parietal positivity; CPP) (P600) yanıtı veren anormal cümlelerdeki sözdizimsel işlemenin hem de N400 yanıtı veren sözcüksel-anlamsal bilgi işlenmesinin beyin lokasyonlarını belirlemek amacıyla olaya bağlı fMRI (even-related fMRI) paradigması kullanmışlardır. Anadili Almanca olan sağlıklı katılımcılara, doğru (örn; Das hemd wurde gebügelt; The shirt was ironed), sözdizimsel ihlal içeren (örn: Die Bluse wurde am gebügelt; The blouse was on ironed) ve anlamsal ihlal içeren (örn: Das Gewitter wurde gebügelt; The thunderstorm was ironed) cümleler dinletilmiştir. Hem sözdizimsel hem de anlamsal doğru cümlelerin işlenmesi, genel hat olarak temporo-frontal ağ üzerinden gerçekleşmektedir. Ayrıntılara bakıldığı zaman hem sözdizimsel hem de anlamsal süreçlerde STG’de iki taraflı olarak aktivasyon artışı gözlenmiştir. Sözdizimsel doğru cümlelere bakıldığı zaman, STG’nin sol ön kısmında ve Broca alanına bitişik sol posterior frontal operkulumda aktivasyon artışı olmuştur. Ayrıca, sol bazal gangliyonlar, sözdizimsel işlemede önemli rol oynamaktadır. Bazal gangliyon fonksiyonu bozulmuş hastaların, özellikle kaudat nükleus, putamen ve globus palliduslarının P600 bileşenine yol açan düzenlenmiş sözdizimsel mekanizmalar ile anlamlı bir ilişki içerisinde olduğu gözlemlenmiştir (Friederici vd., 2003). Bir diğer aktivasyon gözlenen bölge de sol IFG’dir. Anterior IFG sözdizimsel belleği desteklerken; Pars opercularisin inferior tarafı ve ventral premotor korteksin sınırındaki derin frontal operkulum, sözdizimsel yapı oluşturma süreçlerini desteklemektedir (Friederici vd., 2000). Anlamsal doğru cümlelerin işlenmesine bakıldığı zaman, sözdizimsel işlemeden

farklı olarak STG'nin orta bölümünde ve insular kortekste iki taraflı olarak aktivasyon artışı saptanmıştır. İlaveten sol temporal bölgelerin (Grodzinsky, 2000) anlamsal işlemede rol oynadığına değinilmiştir. Hem sözdizimsel hem de anlamsal ihlal içeren cümlelerin işlenmesine bakıldığı zaman doğru cümle işleminde olduğu gibi STG'nin iki tarafında da güçlü bir aktivasyon gözlemlenmiştir. Sol STG'nin posterior bölümüne uzanan aktivasyona rastlanmıştır. Bu aktivasyonun anlamsal koşullarda sözdizimsel ihlale oranla daha büyük ölçekte olduğuna dikkat çekilmiştir. Sözdizimsel ihlallerde ise, anlamsal ihlallerin aksine, daha çok sol STG'nin anterior bölümünde aktivasyon artışı olmuştur. Sözdizimsel ihlallere özgü aktivasyonlar sol posterior frontal operkulumda, özellikle de insular kortekse doğru uzanan inferior precentral girusda gözlemlenmiştir. Ayrıca, sol bazal ganglionların putamenlerinde sözdizimsel ihlallere özgü yüksek aktivasyon tespit edilmiştir. Anlamsal ihlal koşulunda, sözdizimsel ihlale kıyasla, STG'nin orta bölümünde çift taraflı olarak daha güçlü aktivasyon gerçekleştiği tespit edilmiştir. Anlamsal ihlale özgü aktivasyon ise sağ inferior premotor kortekste ve iki taraflı olarak anterior insulada kaydedilmiştir.

4. DOĞAL DİL İŞLEME VE MAKİNE ÖĞRENİMİ

Makine öğrenimi, insanların duyuşal girdi sinyallerini işleyerek öğrenmesini taklit etmek üzere tasarlanmış bir hesaplamalı algoritmadır (El Naqa & Murphy, 2015). Doğal dil işleme (Natural Language Processing, NLP) alanı, bilgisayarların insan dilini anlamasını ve üretmesini amaçlayan bir disiplin olup son yıllarda makine öğrenmesindeki (machine learning; ML), özellikle de derin öğrenme (deep learning) yöntemlerindeki gelişmelerle birlikte NLP alanında büyük bir ilerleme katedilmiştir.


Bilinen ilk derin ağ mimarisi, 1965 yılında Ivakhnenko ve Lapa tarafından eğitilmiştir (Ivakhnenko & Lapa, 1965). Bu ağ modelinde, özellik çıkarımı yapabilmek adına polinom aktivasyon fonksiyonları (polynomial activation functions) kullanılmıştır. En iyi özelliğin seçilerek bir sonraki katmana aktarıldığı bu ağ modelinin eğitiminde geri yayılım (backpropagation) kullanılmamış, bunun yerine birbirinden bağımsız en küçük kareler ile ilerlenmiştir. Şekil 14'te görüldüğü gibi bu ağlar, azalan ve sonlanan bir mimariye sahiplerdir.



Şekil 14: Ivakhnenko ve Lapa tarafından eğitilen ağ mimarisi.

(Dettmers,'den (2015) Türkçe'ye uyarlanmıştır; <https://developer.nvidia.com/blog/deep-learning-nutshell-history-training/>)

1979 yılına gelindiği zaman Fukushima (1980), ilk evrişimli ağ olarak bilinen “neokognitron” adını verdiği sinir ağı modelini önermiştir. Neocognitron (Şekil 15), çok sayıda havuzlama katmanı (pooling layer) ve evrişim katmanından (convolutional layer) oluşan ve bitişik katmanındaki hücreler arasında değişken bağlantılara sahip olan bir hiyerarşik ağ olarak tanımlanmıştır. Öğrenme sürecinde, giriş desenine ait önemli özellikler daha düşük aşamadaki hücreler tarafından çıkarılarak kademeli olarak genel özelliklere entegre edilmektedir. Bu yöntem sayesinde neokognitron, örüntü tanıma (pattern recognition) kazanabilmektedir (Fukushima, 1988).



Şekil 15: Neokognitronun hiyerarşik ağ yapısı. (Fukushima, 1988).

Geri yayılım, ilk olarak 1960’larda kullanılmaya başlasa da Linnainmaa’nın 1970 yılında yazdığı yüksek lisans tezinde Fortran koduyla tekrardan oluşturularak (Linnainmaa, 1976) güncel halini almıştır. 1985 yılında ise geri yayılım, “nöron benzeri birimlerden oluşan ağlar için yeni bir öğrenme prosedürü” olarak açıklanmış (Rumelhart vd., 1986) ve kullanılmaya başlanılmıştır. İlk pratik kullanımı ise 1989 yılında gerçekleştirilmiştir (LeCun vd., 1989). LeCun vd. (1989), ABD posta servisi tarafından sağlanan el yazısı ile yazılmış posta kodu rakamlarının tanınması için geri yayılım ve evrişimli sinir ağlarını (convolutional neural network; CNN) beraber kullanmışlardır.

Hochreiter ve Schmidhuber'a (1997) göre, bilgilerin uzun zaman aralıklarında tekrarlı geri yayılımla depolanmasının öğrenilmesi çok uzun zaman almaktadır. Geleneksel türdeki tekrarlayan sinir ağlarının (recurrent neural network; RNN) sınırlamalarını gidermek amacıyla Uzun Kısa Süreli Bellek (Long Short-Term Memory; LSTM) mimarisini öne sürmüşlerdir. LSTM mimarisinin en temel yeniliği, dil modelleme ve konuşma tanıma gibi uzun ve karmaşık dizilerde bilgilerin korunmasını ve düzenlenmesini sağlamasıdır.

2006 yılına gelindiğinde, Hinton vd. (2006), "çok katmanlı yapay sinir ağlarının" (multilayer artificial neural networks; MANN) daha nitelikli bir şekilde eğitilebileceği fikrini öne sürmüş, bunun üzerine ilk kez Derin Öğrenme kavramı kullanılmaya başlanmıştır. Derin öğrenmenin "öznitelik çıkarımını kendisinin yapabilmesi", derin öğrenmeyi makine öğreniminden ayıran en temel fark olarak bildirilmiştir (Dayan & Yılmaz, 2022).

NLP'de makine öğrenmesi başlangıçta ayrıştırma ağaçları, metin sınırlandırma, dil modeli oluşturulma gibi görevlerde kullanılırken, derin öğrenme kavramı ile birlikte daha karmaşık görevler mümkün hale gelmiştir. Modern NLP görevlerinde kullanılan derin öğrenme temelli ilk atılımlarından biri kelime gömme (word embedding) tekniklerinin geliştirilmesidir. Kelime gömme, bilgi getirme (information retrieval), anlamsal analiz (semantic analysis), bağıllık ayrıştırması (dependency parsing), makine çevirisi (machine translation) ve soru yanıtlama (question-answering; QA) gibi NLP görevlerinde güçlü bir araç olarak kullanılmaktadır (Wang vd., 2019). Yaygın olarak bilinen bir kelime gömme tekniği, Mikolov vd. (2013) tarafından geliştirilen Word2Vec algoritmasıdır. Word2Vec, kelimelerin anlamsal ve sözdizimsel anlamlarını yakalamak amacıyla vektör temsilleri oluşturur ve kelimeler arasındaki anlamsal benzerlikleri ölçmek, eş anlamlı kelimeleri tespit etmek ve ilgili kelimeleri önermek gibi görevleri gerçekleştirebilmektedir (Fink, 2023). Bu görevleri gerçekleştirmek için iki katmanlı bir sinir ağı kullanılmaktadır. Dildeki benzerlikleri ve ilişkileri yakalamayı sağlayan bu fikir, daha kompleks ağ mimarilerinin (Network Architecture) temelini oluşturmuştur.


2017 yılında ise “Attention is all you need” başlıklı çalışma ile Transformer mimarisi ortaya çıkmış ve NLP’de devrim yaratmıştır (Vaswani vd., 2017). Transformer mimarisi, RNN/LTSM ve CNN yapılar olmadan diziler üzerinde daha hızlı ve etkili bir öğrenme gerçekleştirebileceğini göstermiştir. Bu mimari, gelişen teknolojiyle beraber modern yapay zekâ sistemlerinin temel taşı haline gelmiştir.

4.1. Yapay Sinir Ağlarının Temel Bileşenleri

İnsan beyni, örüntü tanıma, motor kontrolü, tahmin yürütme ve algılama gibi görevleri tamamlayabilmek için yapısal bileşenlerini organize edebilecek ve doğrusal olmayan, oldukça karmaşık ve paralel işlemler gerçekleştirebilecek şekilde tasarlanmıştır. Beynin karmaşık süreçleri hesaplama yeteneğine duyulan hayranlık, yapay sinir ağları (YSA) için ilham kaynağı olmuştur. İnsan beynindeki otonom birimler olan nöronlar, iç ve dış uyaranlardan gelen bilgileri işler, depolar ve iletir. Yapay sinir ağları, insan sinir hücrelerinin bir taklidi olan yapay nöronlardan oluşan tasarlanmış makinelerdir (Montesinos López vd., 2022).

4.1.1. Nöron

İnsan beyinde nöronlar, iç ve dış uyaranlardan aldıkları bilgi ve vücuttaki elektriksel sinyalleri ve motor komutları iletmekten sorumlu temel birimlerdir. Nöronlar, dentrit, akson, gücre gövdesi (soma), miyelin kılıftan oluşmaktadır. Dentritler, diğer nöronlardan aldıkları bilgileri toplamak ve hücre gövdesinde iletmekten sorumludur. Hücre gövdesi, bir nöronun merkezi kısmıdır ve hücrenin DNA’sını barındıran çekirdeği içerir. Dentritlerden gelen sinyaller, hücre gövdesi aracılığı ile entegre edilir ve bir çıkış sinyali üretilip üretilmeyeceğine burada karar verilir. Aksonlar, hücre gövdesinden gelen elektriksel impulsları diğer nöronlara ileten uzun ince uzantıdır. Aksonların yapısı, sinyal iletimini hızlandıran miyelin kılıfla kaplı olup diğer nöronlarla iletişim kurmak amacıyla nörotransmitterleri serbest bırakan akson uçları ile sona erer. Nörotransmitterlerin serbest bırakıldığı akson terminalleri ve diğer nöronun dentriti arasındaki küçük boşluk sinaps olarak adlandırılmaktadır. Yapay nöronların (perceptron) işlevi, biyolojik nöronda olduğu gibi, bilginin girdi olarak alınması, işlenmesi ve bir sonraki işlem için diğer nöronlara gönderilmek üzere sonuç çıktısı üretilmesidir (Şekil 16).



Şekil 16: Biyolojik nöron ve yapay nöron.

4.1.2. Ağırlıklar

Sistemin davranışlarını kontrol eden değerlere parametreler (parameters) denilmektedir. Ağırlık (weight) terimi, iki nöron arasındaki bağlantının ne derece güçlü olduğunu veya her bir özellik veya girdinin tahmini ne derece etkileyeceğini belirleyebilen sayısal bir parametreyi ifade etmektedir. Diğer bir deyişle ağırlık (w_i), tüm özelliklerin toplama işleminden önce özellik (x_i) ile çarpılan katsayıdır.


Bazı gelişmiş mimarilerde, ağırlıklara farklı önem düzeyleri de atanabilir (Tong, 2024). Eğitimler esnasında, önemli olduğu düşünülen girdilere daha yüksek değerli ağırlıklar atanır. Pozitif bir ağırlık, atandığı özelliğin değerini arttırırken tahminin de değerini arttırır; özellik negatif bir ağırlık aldıysa, özelliğin değerini arttırmak tahminin değerini azaltır. Sinir ağı tarafından ağırlığın değeri sıfır olarak verilirse, bu girdi veya özelliğin önemsiz olduğu anlamına gelir (Goodfellow vd., 2016).

Bir a girdisine w_1 ağırlığı atandığı zaman, düğümden sonraki girdi $a * w_1$ olarak ifade edilmektedir.

4.1.3. Sapma

Çevremizdeki dünyada önyargı (bias) kelimesi, “gerçeklerin tarafsız değerlendirilmesinin aksine önceden oluşturulmuş fikirlere dayalı yargı” anlamına gelmektedir (Campolo vd., 2017). Çoğu makine öğrenim tekniğinin dünya gözlemlerini taklit etmesine benzer şekilde, sistemler bu kavramı da taklit etmiş ve sapma (bias; b) kavramı ortaya çıkmıştır (Hellström vd., 2020). Yapay sinir ağının mimarisinde sapma, ağırlık katsayılı girdilerin aralığını değiştirmek adına girdilerin ağırlıklı toplamına eklenerek eğitilebilen matematiksel parametreyi ifade etmektedir ve “dönüşümün son doğrusal bileşeni”dir. (Yılmaz, 2021). Bu parametre, aktivasyon fonksiyonuna etki ederek ağırlık verilerdeki kalıpları daha esnek modellemesine katkıda bulunmaktadır.

Matematiksel olarak x_1, x_2, \dots, x_n girdilerine ve w_1, w_2, \dots, w_n ağırlıklarına sahip bir nöron için: $z = x_1 * w_1 + x_2 * w_2 + \dots x_n * w_n + b$ şeklinde ifade edilmiş olacaktır. Şekil 17’de yapay nörona ağırlıkların ve sapmanın bir temsili görülmektedir.



Şekil 17: Yapay nörona ağırlıklar ve sapma.

4.2. Evrişimli Sinir Ağları


Evrişimli Sinir Ağları (Convolutional Neural Network; CNN), ilk olarak LeCun vd. tarafından LeNet-5 adlı ilk CNN mimarisinin tanıtıldığı “Backpropagation Applied to Handwritten Zip Code Recognition” makalesinde el yazısında karakter tanıma gibi görsel tanıma görevleri için geliştirilmiştir. CNN’ler ilk olarak bilgisayarlı görü

(computer vision; CV) görevlerinde kullanılsa da zamanla makine çevirisi (Gehring vd., 2017) veya soru yanıtlama (Wu vd., 2017) gibi NLP görevlerinde, popüler olan diğer yöntemlere kıyasla, önemli bir hız artışı sunmaları sebebi ile büyük ilgi görmüştür (Mareček vd., 2020).

CNN mimarisinin temellerini anlamak adına ilk olarak görüntü işlemenin (image processing) öğrenme paradigmalarından bahsetmek gerekir. Görüntü işleme iki temel paradigmaya sahiptir: denetimli öğrenme (supervised learning) ve denetimsiz öğrenme (unsupervised learning). Denetimli öğrenme, genellikle vektör olarak temsil edilen önceden etiketlenmiş girdiler aracılığı ile bir modelin eğitilmesini içermektedir. Temel amaç, öğrenme esnasında verilen örnekler için çıktı değerini doğru bir şekilde hesaplanarak modellerin genel sınıflandırma hatasını minimuma indirmektir. Denetimsiz öğrenmenin farkı, eğitim setinde herhangi bir etiketlenmiş girdinin bulunmamasıdır. Denetimsiz öğrenmede ağın başarısı, ilişkili bir maliyet fonksiyonunu azaltabilmesine veya artırabilmesine bağlı olarak belirlenmektedir. CNN'ler, "öğrenme yoluyla kendisini optimize edebilen nöronlardan" oluşmaktadır ve girdi ham vektörlerden nihai çıktıya kadar tek bir ağırlık ile ifade edilmektedir (O'Shea & Nash, 2015)

4.2.1. Genel mimari

CNN katmanları, girdinin yükseklik (height) ve genişlik (width) gibi uzamsal boyut (spatial dimensionality) ve derinlik (depth) özelliklerine göre üç boyutta düzenlenmiş nöronlardan oluşmaktadır. Derinlik, aktivasyon hacminin üçüncü boyutunu ifade etmektedir. CNN'ler, evrişim (convolution), düzleştirme (rectified linear unit), havuzlama (pooling) ve tam bağlantı (fully connection) katmanlarının istiflenmesi sonucu oluşmaktadır (şekil 18.)



Şekil 18: Beş katmanlı CNN mimarisi.

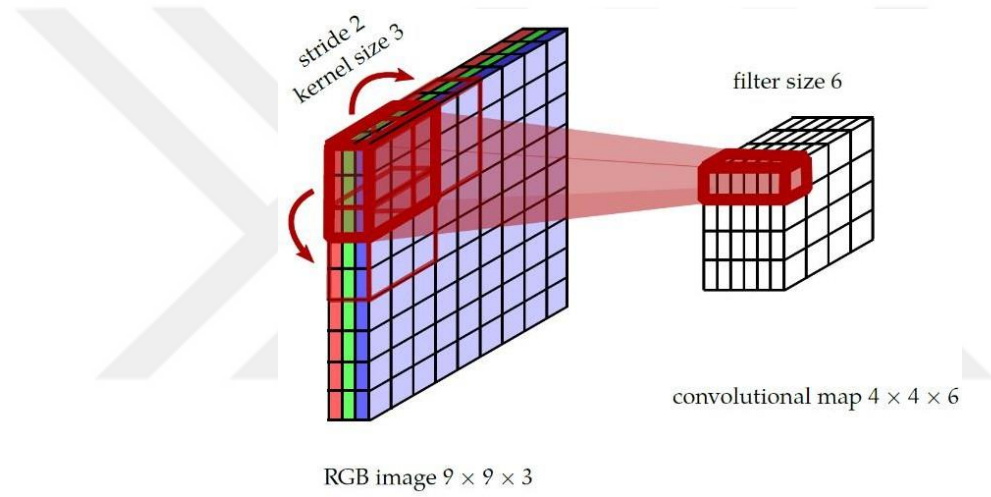
(O'shea ve Nash'den (2015) Türkçe'ye uyarlanmıştır.)

CNN'lerin temel işlevselliği dört adımla şu şekilde verilmiştir (O'shea ve Nash, 2015):

1. Görüntünün piksel değerleri girdi katmanı ile saklanmaktadır.
2. Evrişimli katmanda, her nöron çıktısı, ağırlıklar ile girdi hacmine bağlı bölge arasındaki skaler çarpımın hesaplanması yoluyla belirlenmektedir. Üretilen aktivasyon çıktısına genellikle ReLU fonksiyonu uygulanarak sıfırdan küçük değerlerin sıfır değerine eşitlenmesi amaçlanmaktadır.
3. Havuzlama katmanı, verilen girdinin uzamsal boyutları boyunca basitçe aşağı örnekleme işlemi gerçekleştirerek, bu aktivasyon içindeki parametre sayısını daha da azaltmaktadır.
4. Tam bağlantı katmanları, standart yapay nöral ağlara benzer şekilde görevleri yerine getirmektedir ve sınıflandırma için kullanılacak sınıf puanları, aktivasyonlardan üretilmeye çalışılmaktadır. Performansı artırmak için bu katmanlar arasında ReLU kullanılabileceği önerilmektedir.

4.2.2. Evrişim Katmanı

Katman parametreleri, genellikle uzamsal boyutları küçük olan ancak girdinin tüm derinliği boyunca uzanan öğrenilebilir çekirdeklerin (learnable kernels) kullanımına odaklanmaktadır. Bir CNN katmanı, filtre sayısı (filter size) ve pencere boyutu (window size) olmak üzere iki ana hiperparametreye sahiptir. Pencerenin hareket ettiği adım boyutunu ise kaydırma adımı (stride) belirlemektedir (Mareček vd., 2020). Önceki katmandan gelen veriler evrişim katmanına ulaştığı zaman, bir filtrenin girdi hacminin yüksekliği ve genişliği boyunca kaydırılmasıyla aktivasyon haritası elde edilmektedir (Şekil 19). Çıktı hacmi, derinlik boyunca yığılan aktivasyon haritaları kullanılarak üretilmektedir (Yılmaz, 2021).



Şekil 19: 9x9 RGB görüntü üzerinde 2D evrişimin gösterimi.

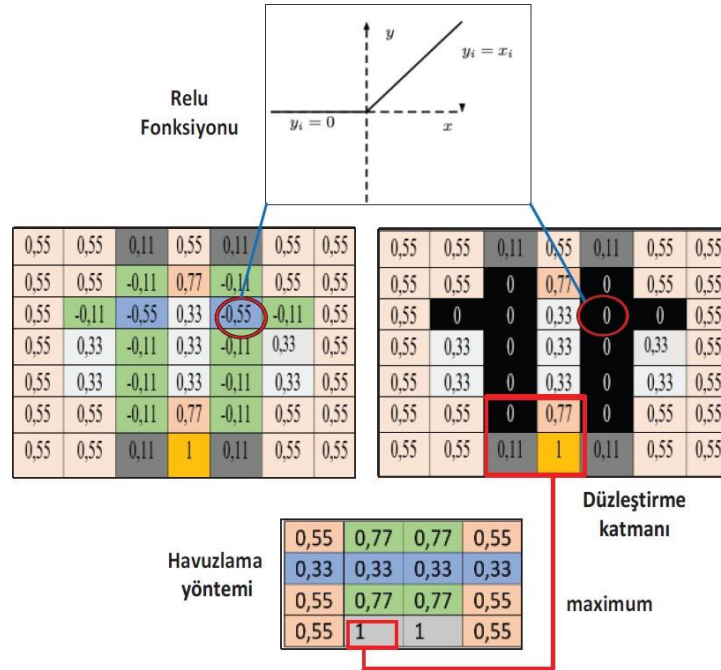
(Kaydırma adımı 2, çekirdek boyutu 3 ve filtre sayısı 6'dır. (Marecek vd., 2020).

Görüntüler gibi büyük girdilerin standart yapay sinir ağları ile eğitilmesi, tamamen bağlantılı yapıları sebebiyle zorlayıcıdır ve bu durum aşırı büyük modellerin ortaya çıkmasına sebep olmaktadır. Bu sorunu çözmek için evrişimli katmanlar, yalnızca kendisinde önceki katmanın küçük yerel bir bölgesine, yani alıcı alana (receptive field) bağlanmaktadır. Girdi hacminin $64 \times 64 \times 3$ (yükseklik, genişlik, derinlik) verildiği bir örnekte, görüntünün işlenmesi için standart bir sinir ağı kullanılması durumunda 12.288 tane parametre olması gerekmektedir. CNN kullanıldığı durumlarda ise, modeldeki tam girdi hacmi, derinlik boyutu boyunca dosyalanmış kompakt bir sınıf puanları hacmine sıkıştırılmaktadır ve her nöron toplam 108 ağırlık içermektedir. Çıktıların evrişimli

katmanda optimize edilmesi, modelin karmaşıklığını önemli derecede azaltmaktadır. Bir bölge özelliğinin belirli bir uzamsal bölgede hesaplanmasının yararlı olması durumunun diğer bölgelere genellenmesi varsayımına parametre paylaşımı (parameter sharing) denilmektedir (O’Shea & Nash, 2015).

4.2.3. Havuzlama katmanı

Havuzlama katmanları, görüntü işleme esnasında temsilin boyutunu kademeli olarak azaltarak parametre sayısını ve modelin karmaşıklığını da azaltmayı amaçlayan katmanlardır. Bilgi tekrarını azaltmak amacıyla maksimum havuzlama tekniği kullanılmaktadır. Bu teknik, evrişim katmanındakine benzer şekilde, kayan bir pencere şeklinde ilerleyerek her pencerenin maksimum değerlerini alıp tek bir vektöre indirgemektedir. Marecek vd. (2020) evrişimi, “genellikle filtrelerin gizli özelliklere karşılık geldiği girdi tensörü üzerindeki gizli özelliklerin çıkarımı” şeklinde yorumlamışlardır. Maksimum havuzlamanın ise “pencere üzerinde uygulanan yumuşak varoluşsal bir kantitatiför” olduğunu bildirmişlerdir.

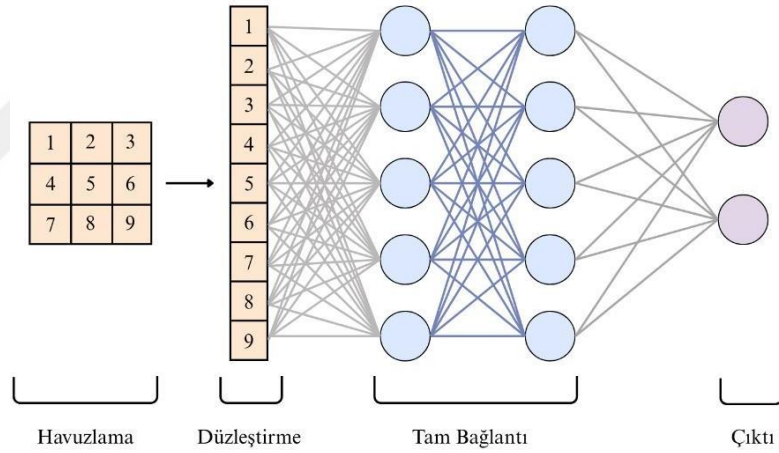


Şekil 20: Relu kullanılan düzeltilme katmanı ve maksimum havuzlama.

(Akın & Şahin, 2024).

4.2.4. Tam bağlantı katmanı

Tam bağlantı katmanı, ağın çıktısı olarak kullanılacak sınıf puanlarının hesaplandığı katmandır. Çıktı hacminin boyutları $1 \times 1 \times n$ şeklinde olup, çıktı sınıflarının sayısı olan n bu katmanda değerlendirilmektedir. Tam bağlantı katmanlarında nöron bağlantıları, geleneksel yapay sinir ağı formlarındaki nöronların düzenlenme biçimine benzetilmektedir. Katmandaki tüm nöronlar, önceki katmandaki nöronlar ile bir bağlantıya sahiptir ve katman ve hiperparametreler için normal parametre değerleri görülmektedir (Şekil 21). Girdi hacmindeki parametrelerin ve aksiyonların bir fonksiyonu olan dönüşümler bu katmanda gerçekleştirilmektedir (Patterson & Gibson, 2017).



Şekil 21: CNN'lerde havuzlama, düzleştirme, tam bağlantı ve çıktı katmanı.

Bazı CNN mimarilerinde ağın sonunda birden fazla tam bağlantı katmanı kullanılmaktadır. Bunun bir örneği AlexNet olup iki tam bağlantı katmanına sahiptir ve sonunda Softmax katmanı bulunmaktadır (Patterson & Gibson, 2017). Tablo 1'de ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge; ILSVRC) yarışmasını kazanan CNN mimarileri ve özellikleri verilmiştir:

Tablo 1: ILSVRC Yarışması'nı kazanan bazı CNN mimarileri

Mimari	Özellik	ILSRC	Kaynak
AlexNet	İlk kez GPU ile eğitilen derin CNN mimarisidir. Derin öğrenme devrimini başlatmıştır.	2012	Krizhevsky vd., 2012
ZF Net	Dekonvolüsyonel ağın görselleştirme kavramını tanıtmıştır. Filtre boyutlarını ve adımları optimize etmiştir.	2013	Zeiler & Fergus, 2014
GoogLeNet	Kod adı "Inception" olan bir varyasyonunda 22 katman bulunmaktadır.	2014	Szegedy vd., 2015
VGGNet	Ağın derinliğini arttırmanın iyi performans için kritik bir faktör olduğunu göstermiştir.	2014	Simonyan & Zisserman, 2015
ResNet	"Skip connections" ile çok derin ağların eğitilmesini mümkün kılmıştır (1.200 katmana kadar).	2015	(K. He vd., 2016a)

4.2.5. NLP ile ilgili çalışmalar

Kim (2014) çalışmasında, cümle düzeyinde sınıflandırma görevleri için hiperparametre ayarlaması çok az olan ve statik vektörlere sahip sade bir CNN modeli kullanmıştır. Çalışmanın mimarisine bakıldığı zaman, giriş vektörleri için kelime gömme tekniği kullanılmıştır. Her cümledeki kelimeler, kelime çantası modeli (bag-of-words; Mikolov vd., 2013) ile eğitilen 300 boyutlu Word2Vec vektörlerle temsil edilmiştir. İlave olarak çalışmada, rasgele gömme (random embedding), önceden eğitilmiş ve modelle birlikte güncellenen fine-tuned gömme ve önceden eğitilmiş ama eğitim esnasında sabit kalan statik gömme (static embedding) kullanılmıştır. Evrişim katmanında, her biri 100 özellik haritasına sahip olan farklı boyutlara sahip (3,4 ve 5) filtre penceresi kullanılmıştır. Havuzlama katmanında, özellik haritası için en yüksek değere sahip özelliği yakalamak amacıyla max-overtime işlemi (Collobert vd., 2011) uygulanmıştır. Bir sonraki aşama olarak, havuzlama katmanından gelen çıktılar, olasılık dağılımı olan tam bağlantılı katmana ve Softmax katmanına aktarılmıştır. Çalışmada, duygu analizi görevi için MR (Movie Review) veri seti (Pang & Lee, 2004) ve STS1/STS2 (Stanford Sentiment Treebank) veri setleri (Socher vd., 2013) ve CR (Customer Reviews) veri seti (Hu & Liu, 2004); soru tipi sınıflandırma görevi TREC veri seti (X. Li & Roth, 2002);

özellik tespiti görevi için Subj veri seti (Pang & Lee, 2005) ve görüş kutupluluğu alt görevi için MPQA veri seti (Wiebe vd., 2005) kullanılmıştır. Bu çalışma ile, tek katmanlı CNN kullanılarak daha az parametrelili ve daha hızlı eğitim gerçekleştirilebileceği gösterilmiştir.

Kalchbrenner vd. (2014), farklı uzunluklardaki girdi cümlelerindeki kısa ve uzun mesafeli ilişkileri açıkça yakalamak adına Dinamik Evrişimli Sinir Ağı (Dynamic Convolutional Neural Network; DCNN) olarak adlandırdıkları bir evrişimli sinir ağı önermişlerdir. Modelin mimarisine bakıldığı zaman, DDCN katmanları, bir evrişim işlemi ve ardından bir havuzlama işlemi ile oluşturulmuştur. Kelime gömme katmanında cümledeki her kelime bir vektörle temsil edilmektedir. Evrişim katmanında, tek boyutlu evrişim (one-dimensional convolution) ve klasik Zaman Gecikmeli Sinir Ağı (Time-Delay Neural Network; TDNN; Hinton, 1990; Waibel vd., 1989) kullanılmıştır. DCNN'leri geleneksel CNN'lerden ayrılan en büyük özelliği, geniş evrişim katmanlarını dinamik k -Max havuzlama katmanları ile değiştirebilen bir mimari modellenmiş olmasıdır. Standart max-havuzlama, her özellik haritasından en büyük değeri alırken k -max havuzlama, k tane en büyük değeri özelliklerin sırasını koruyarak seçmektedir. Ağda, en üstte bulunan evrişim katmanından sonra uygulanmaktadır. Ara evrişim katmanlarında k sabit değildir; katman derinliğine ve cümle uzunluğuna bağlı olarak k değeri dinamik olarak değişmektedir. Evrişim sonucuna dinamik k -max havuzlama uygulandıktan havuzlanmış matrisin her bir satırına bir sapma (b) değeri ve matrisin tamamına doğrusal olmayan fonksiyon uygulanmaktadır. Girdi cümlesine uygulanan evrişim, dinamik k -max havuzlama ve doğrusal olmayan fonksiyon işlemlerinin tekrarlanması sonucunda artan derinlikte bir ağ ve artan dereceden özellik haritaları elde edilmektedir. Katlama katmanı (folding layer), bu özellik haritalarının boyutunu yarıya indirmektedir ve sırayla komşu değerler toplanarak bilgi yoğunlaştırılmaktadır. Son olarak, tam bağımlı katmanda çıktılar sabit uzunlukta bir vektöre dönüştürülmüş ve bu vektöre sınıflandırma için Softmax uygulanmıştır. Çalışma dört deneyden oluşmaktadır. İlk iki deneyde, duygu tahmini görevi için Stanford Sentiment Treebank içindeki MR veri setinin kullanılmıştır. Üçüncü deneyde, soru tipi sınıflandırma görevi için TREC veri seti kullanılmıştır. Son olarak dördüncü deney, Go vd. (2009) tarafından bildirilen prosedür takip edilerek Twitter gönderilerindeki duyguların emojiye bakılarak olumlu veya olumsuz olarak etiketlenmesini içermektedir. Çalışmanın sonucunda, DCNN, ilk üç

deneyde mükemmel performans gösterirken son deneyde %25'ten fazla hata azaltımı sağlamıştır. Kalchbrenner vd.'nin (2014) bu çalışması, NLP'de uzun veya kısa cümlelerin önemli bilgiler kaybedilmeden sıralı bir şekilde işlenebileceğini göstermiştir.

4.3. Tekrarlayan Sinir Ağları


Juergen Schmidhuber'in açıklamasıyla Tekrarlayan Sinir Ağları (Recurrent Neural Network; RNN), prensipte bir bilgisayarın hesaplayabileceği her şeyi hem sıralı hem de paralel olarak hesaplayabilen ağlardır. Geleneksel bilgisayarlardan farkı, duyuşal girdi akışını bir dizi motor çıktıya çevirmeyi ömür boyu öğrenebilen bir geri besleme ağı olan insan beynine benzemesidir (akt: Patterson ve Gibson, 2017). RNN'ler, bir dizi girdi vektörünü alarak bunları tek tek modellemektedir ve zaman boyutunu (time dimension) modellemek en ayırt edici özelliği olarak görülmektedir. RNN'lerin mimarisi, girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı katmanından (output layer) oluşmaktadır. RNN'ler, her nöronun önceki girdi hakkındaki bilgileri saklayan belleğe (memory) sahiptir ve bu birimler gizli durum (hidden state) olarak adlandırılmaktadır. RNN'lerin tasarlanma amacı, gizli durumları koruyarak sıralı verileri işlemektedir (Tsantekidis vd., 2022). Her bir zaman adımında (time step) gizli durumun korunma denklemi şu şekilde verilmiştir (Mienye vd., 2024):

$$h_t = \sigma_h(W_{xh}x_t + W_{hh}h_{t-1} + b_h)$$

Denklemden t, zaman adımını; h_t , gizli durumu; x_t , girdi vektörünü; W_{xh} , girdi katmanı ve gizli katman arasındaki ağırlık matrisini; W_{hh} , tekrarlayan bağlantı için ağırlık matrisini; b_h sapma vektörünü ifade etmektedir. σ_h ise aktivasyon fonksiyonunu olarak bildirilmiştir. Her bir zaman adımını t'deki çıktının denklemi şu şekilde verilmiştir (Mienye vd., 2024):

$$y_t = \sigma_y(W_{hy}h_t + b_y)$$

Denklemden W_{hy} gizli katman ve çıktı katmanı arasındaki ağırlık matrisini; b_y , sağma vektörünü, σ_y ise çıktı katmanı için aktivasyon fonksiyonunu ifade etmektedir. Şekil 22'de çıktının t defa girdi olarak gönderilmesi gösterilmiştir.



Şekil 22: Tekrarlayan sinir ağlarında çıktının t defa girdi olarak gönderilmesi.

Diyagramda x_t bir tür girdiyi, h_t gizli katmanı, y_t ise çıktıyı ifade etmektedir. NLP görevlerinde, cümledeki kelimeler veya dizideki karakterler x_t olarak beslenebilmekte ve y_t ile sonuçlanmaktadır. RNN'lerin buradaki amacı, çıktıyı test verileriyle karşılaştırmak ve hata oranı bilgisini elde etmektir (Tarwani & Edem, 2017). Daha sonrasında, Zaman İçinde Geri Yayılım (Back Propagation Through Time; BPTT) (Mesnil vd., 2015; Williams & Zipser, 1995) tekniği ile ağıın geriye doğru kontrolü sağlanarak hata oranına göre ağırlıklar ayarlanabilmekte ve daha verimli bir öğrenme sağlanabilmektedir.

RNN'lerin en büyük yeteneği, önceki girdileri hatırlayıp bir dizideki bir sonraki kelimeyi tahmin ederek yeniden yapılandırabilmesidir. Bu özellikleri sayesinde RNN, el yazısı tanıma (handwriting recognition) (A. Graves vd., 2009), konuşma tanıma (speech recognition) (Sak vd., 2014), makine çevirisi (machine translation) (Hermanto vd., 2015) ve kelime anlamı belirginleştirme (word sense disambiguation; WSG) (Karwa & Chandak, 2014) gibi doğal dil işleme görevlerini başarı ile gerçekleştirebilmektedir.

RNN'ler genel olarak bağlamı ifadenin başından itibaren işleyerek ifadenin sonundaki kelimelerin daha doğru tahmin edilmesini sağlayabilmektedir fakat bu tüm RNN'ler için geçerli değildir. Basit RNN'ler sadece birkaç adım önceki bilgiyi işlemekle sınırlı olup uzun cümle ve paragraflarda yeterli başarıyı sergileyememektedir (Tarwani & Edem, 2017). BPTT veya Gerçek Zamanlı Tekrarlayan Öğrenme (real-time recurrent learning; RTRL) (Robinson, 1987) esnasında ağırlıkların büyüklüğüne bağlı olarak, geri yayılan hatanın zamansal evrimi üstel olarak değişmektedir. Bu durum patlayan gradyan

ve kaybolan gradyan problemlerine sebep olmaktadır (Hochreiter & Schmidhuber, 1997). Bu problemler sebebi ile RNN'lerin aşağıda verilen türleri geliştirilmiştir:

- Çift Yönlü RNN (Bidirectional RNN; BRRN)
- Uzun Kısa Süreli Bellek (Long Short-Term Memory; LTSM)
- Kapılı Tekrarlayan Birimler (Gated Recurrent Unit; GRU)
- Kodlayıcı-Kod Çözücü Model (Encoder-Decoder Model)

4.3.1. Çift yönlü RNN

Çift Yönlü RNN'ler (Bidirectional RNN; BRRN), ilk olarak, RNN'lerin düzenli yapılarından kaynaklanan sınırlamaları aşmak amacıyla Schuster ve Paliwal (1997) tarafından önerilmiştir. Standart bir RNN, gelecek durum (pozitif zaman) hakkında çıkarım yaparken geçmiş durum (negatif zaman) çıktılarına göz önüne almaktadır ve bilgi tek yönlü bir akış sergilemektedir. BRNN'ler ise, geçmiş zaman, şimdiki zaman ve gelecek zaman olmak üzere üç zamanı da göz önünde bulundurur. BRNN'lerde "ileri durumlardan (forward states) çıkan çıktılar, geri durumların (backward states) girdilerinden bağımsızdır" ve bunun tersi de geçerlidir. Bu üç zamansal yapı, Şekil 23'te görülen açılmış yapıya yol açmaktadır. BRNN'lerin eğitimi tek yönlü RNN ile aynı algoritma kullanılarak eğitilebilmektedir ve bu şekilde eğitildiği zaman genel ileri beslemeli bir ağa açılmaktadır. Fakat, zaman içinde geri yayılım (BPTT) ile kullanıldığı zaman durum ve çıktıların güncellemesi birer birer yapılamaz ve bu sebepten ileri ve geri geçiş prosedürü daha karmaşık hale gelmektedir. BRNN'lerin çalışma prosedürü aşağıdaki üç adımda özetlenmiştir (Schuster ve Paliwal, 1997):

1) İleri geçiş (forward pass)


Bir zaman dilimi $1 \leq t \leq T$ için tüm girdi verilerini BRNN üzerinden çalıştırın ve tahmin edilen tüm çıktıları belirleyin.

- a) Sadece ileri durumlar ($t = 1$ 'den $t = T$ 'ye) ve geri durumlar ($t = T$ 'den $t = 1$ 'e) için ileri geçiş yapın.
- b) Çıktı nöronları için ileri geçiş yapın.

2) Geri geçiş (backward pass)

İleri geçişte kullanılan $1 \leq t \leq T$ zaman dilimi için hedef fonksiyonu türevinin kısmını hesaplayın.

- a) Çıktı nöronları için geri geçiş yapın.
 - b) Sadece ileri durumlar ($t = T$ 'den $t = 1$ 'e) ve geri durumlar ($t = 1$ 'den $t = T$) için geri geçiş yapın.
- 3) Ağırlıkları güncelleme



Şekil 23: Üç zaman adımı için zaman içinde açılmış çift yönlü RNN yapısı.

Graves ve Schmidhuber (2005) çalışmalarında, fonem sınıflandırma (phoneme classification) görevinde kullanılmak üzere BRNN'lerin bir alt türü olan çift yönlü LSTM'lerin (BLSTM) öğrenme algoritmasını değiştirerek tam gradyanlı versiyonunu sunmuşlardır. Çalışma için verileri seti olarak TIMIT Akustik-Fonetik Sürekli Konuşma Korpusu (Garofolo vd., 1993) kullanılmıştır. Çalışmanın sonucunda, çift yönlü ağların tek yönlü ağlara kıyasla çok daha iyi performans gösterdiğini bildirmişlerdir. İlaveeten, bağlamsal bilginin konuşma işleme için önemine vurgu yapmışlardır. Graves ve Schmidhuber'in bu çalışması, BRNN ile LSTM'lerin uzun vadeli bağımlılıkları öğrenme becerisini birleştiren ilk çalışmalardan biri olma özelliğini taşımaktadır.

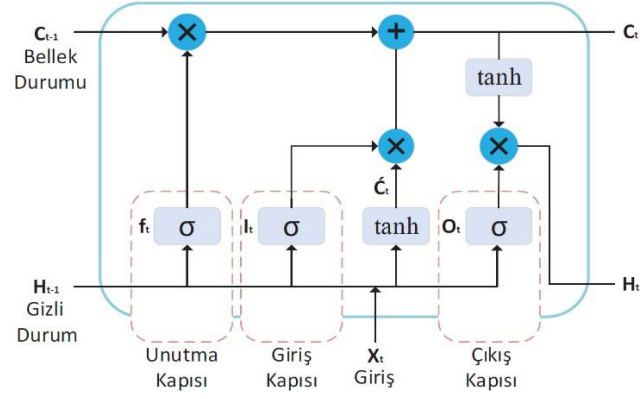
Sundermeyer vd. (2014), BRNN mimarisini kullanarak kelime tabanlı (word-based) ve ifade tabanlı (phrase-based) olmak üzere iki farklı çeviri modeli sunmuşlardır. Çalışma, IWSLT 2013 veri seti kullanılan Almanca→İngilizce çeviri modellemesi, DARPA BOLT projesinin Arapça→İngilizce ve Çince→İngilizce çeviri modellemesi olmak üzere üç ana görevden oluşmaktadır. Tüm çeviri deneylerinde Jane araç seti (Vilar vd., 2010) kullanılmıştır. Deneylerin büyük çoğunluğu IWSLT 2013 ile yapılmış olup, sonuçları doğrulamak adına DARPA BOLT ile ek deneyler gerçekleştirilmiştir. Çalışmanın sonucunda, IWSLT 2013 Almanca→İngilizce sisteminde, %1,6'ya kadar BLEU ve

%1,7'ye kadar TER kazançları gözlemlendiği bildirilmiştir. Sundermeyer vd.'nin bu çalışması, istatistiksel makine çevirisi (statistical machine translation; SMT) sistemlerinde BRNN mimarisini kullanan ilk çalışmalardan biri olarak görülmektedir.

4.3.2. Uzun Kısa Süreli Bellek

Uzun Kısa Süreli Bellek (Long Short-Term Memory; LSTM), geri yayılım esnasında ortaya çıkan kaybolan gradyanlar problemini aşmak amacı ile Hochreiter ve Schmidhuber (1997) tarafından geliştirilmiştir. LSTM'nin mimarisine bakıldığı zaman bellek hücreleri (memory cells) ve kapı birimlerinden (gate units) oluştuğu görülmektedir.

Bellek hücreleri, hücre durumu (cell state) olarak da adlandırılmaktadır ve C_{t-1} ile gösterilmektedir. Her bellek hücrelerinin merkezinde, tekrarlı şekilde öz-bağlı bir doğrusal birim (self-connected linear unit) olan sabit hata karuseli (constant error carousel; CEC) bulunmaktadır. Bellek hücreleri vasıtasıyla aktivasyon ve hata sinyalleri, bellek hücreleri vasıtasıyla ağda sonsuza kadar dolaşmaktadır ve CEC ile önemli bilgilerin depolanması sağlanmaktadır. Unutma kapısı (forget gate) ve girdi kapısı (input gate) tarafından modüle edilmektedir. Unutma kapısı, f_t ile gösterilir ve bellek hücrelerinin hangi bilgileri koruyup hangilerini unutacağına karar veren mekanizmadır. Gers vd. (2000) tarafından standart LSTM modeline eklenmiştir. Her hücre durumu için, bir önceki katmandan gelen gizli durum (h_{t-1}) ve güncel bilgi (x_t) aktivasyon fonksiyonundan geçmektedir ve 0 ile 1 arasında bir değer oluşmaktadır. Değer 1 çıkarsa bilgi depolanmaktadır; 0 çıkarsa bilgi silinmektedir. Girdi kapısı (I_t), unutma kapısından gelen korunmuş bilgilerin ve yeni girdi verilerinin iletiminden sorumludur. Hücre durumu C_{t-1} 'in Aday Bellek C_t 'ye güncellenmesine yardımcı olur. Çıktı kapısı (output gate; O_t), hücre durumuna, girdi durumuna ve gizli duruma bağlı olup çıktı verisinin hesaplanmasından ve iletilmesinden sorumludur (Gers vd., 2000, 2002; Hochreiter & Schmidhuber, 1997). Şekil 24'te herhangi bir t anındaki LSTM hücrelerinin diyagramı verilmiştir.



Şekil 24: Herhangi bir t anında genel LSTM hücresinin diyagramı.

(Akın ve Şahin, 2024).

Tarwani ve Edem'e (2017) göre, NLP'de ağı LSTM eklenmesi, tüm bağlamın girdinin başından sonuna kadar hatırlanmasını sağlayan bir birim eklemek gibidir. 10 kelimedenden oluşan bir cümlede 11. Kelime tahmin edilmek istenildiğinde, RNN'ler tarafından 10 kelimenin tümü işlenilmekte ve her adımdaki ağırlıklar LSTM tarafından kaydedilmektedir. Bu işlem sonucunda 11. Kelimenin tahmin edilme olasılığı belirlenebilmektedir.

Hem bağlamdan bağımsız (context-free) hem de bağlama duyarlı (context-sensitive) doğal dil öğreniminde LSTM'lerin dikkate alınması gereken bir güç olduğu bildirilmiştir (Gers vd., 2000, 2002; Van Houdt vd., 2020). Doğal dil işlemede diyalog sistemleri (dialog systems) LSTM'nin kullanım alanlarından biridir. Ryu vd. (2017) diyalog sistemlerinde alan dışı (out-of-domain; OOD) cümleleri tanımlayabilmek adına alan içi (in-domain; ID) cümle verilerini eğittikleri iki LSTM katmanı içeren yeni bir sinirsel cümle gömme yöntemi önermişlerdir. Yöntemleri, önceki gelişmiş modellerden çok daha yüksek tahmin oranları elde etmiştir.


LSTM'lerin bir diğer uygulaması, varlık belirsizliğinin (entity disambiguation) giderilmesidir. Örneğin, bağlam göze alındığı zaman algoritmalar "Apple bu bahar üç yeni iPad modelini piyasaya sürecektir." cümlesindeki "Apple" kelimesinin meyveyi değil de şirketi ifade ettiğini varlık belirsizliğinin giderilmesi yöntemi ile algılayabilmektedir (Van Houdt vd., 2020). Sun vd. (2017), söz ve varlık arasındaki anlamsal ilişkiyi ölçerek

varlık belirsizliğini gideren bir hesaplama mimarisi geliştirmişlerdir. İki LSTM ağı içeren mimari, cümle bağlamlarını öğrenmede iyi performans göstermiştir.

Kanjo vd. (2019), duygu tespiti ve izlenmesi için ilk kez fizyolojik sinyaller (örneğin EEG ve GSR), çevresel veriler ve konum sensörü verilerinin analizini gerçekleştirmişlerdir. Veri setini, akıllı telefonlar ve giyilebilir cihazlar üzerinden toplamışlardır. Çalışmada, tüm verilerin analizi için CNN-LSTM mimarisine dayanan bir hibrit yaklaşım sergilemişlerdir. Çalışmanın sonucunda, çok sayıda sensör girişi kullanılan derin öğrenme yaklaşımlarının duygu sınıflandırmada etkili olduğunu ve hibrit mimarilerin geleneksel modellere oranla daha iyi performans gösterdiğini bildirmişlerdir.

4.3.3. Kapılı tekrarlayan mimariler

Kapılı Tekrarlayan Birimler (Gated Recurrent Unit; GRU) ilk kez Cho vd.'nin (2014) çalışmasında tanıtılmıştır. GRU, LSTM'lere benzer şekilde klasik RNN'lerdeki kaybolan gradyanlar problemini çözmek amacıyla geliştirilmiştir ve uzun süreli bağımlılıkları öğrenme konusunda iyi performans sergilediği bildirilmiştir. Temel mimari olarak LSTM'lere benzer şekilde bilgiyi modüle eden kapılı bir mekanizmaya sahiptir ve iki kapısı vardır: güncelleme kapısı (update gate) ve sıfırlama kapısı (reset gate). Fakat LSTM'lerin aksine, GRU'da ayrı bellek hücreleri yoktur (Şekil 25). Güncelleme kapısı, birimin aktivasyonu veya bağlamı ne kadar güncelleyeceğine kadar vermektedir. Diğer bir deyişle, LSTM'deki unutmaya ve girdi kapısına benzer şekilde bilgilerden hangisinin unutulmasına ve hangisinin bir sonraki adıma aktarılmasına karar vermektedir. Sıfırlama kapısı, bilginin ne kadarının unutulup ne kadarının hatırlanacağına karar vermekte görevlidir (Cho vd., 2014). GRU'ların mevcut durum ve yeni hesaplanan durum arasında doğrusal bir toplam alma prosedürü açısından LSTM'ye benzetildiği halde durumun maruz kalma derecesini kontrol eden bir mekanizması bulunmamaktadır. Bu sebepten her defasında durumun tamamına maruz kaldığı bildirilmiştir (Chung vd., 2014).



Şekil 25: LSTM ve GRU gösterimi.

(a) i , f , ve o sırasıyla girdi, unutmaya ve çıktı kapılarını temsil etmektedir. c ve \tilde{c} sırasıyla bellek hüresini ve aday bellek hüresini belirtmektedir. (b) r ve z sırasıyla sıfırlama ve güncelleme kapılarıdır. h ve \tilde{h} ise aktivasyon ve aday aktivasyondur (Chung vd., 2014).


Chung vd. (2014) çalışmalarında, polifonik müzik modelleme ve konuşma sinyali modelleme görevlerinde sofistike tekrarlayan birimlerin iki varyantı olan LSTM ve GRU mimarilerini kullanmışlardır. Çalışmanın sonucunda, GRU'nun CPU süresinde yakınsama açısından ve parametreleri güncelleme ve genelleme açısından LSTM'ye oranla daha iyi performans gösterdiğini bildirmişlerdir.

Khano vd. (2023), duygu analizinde VosViewer, LSTM ve GRU'yu temel alan bir çalışma yürütmüşlerdir. VosViewer (Visualization of Similarities Viewer), metin madenciliği, bibliyometri alanında veri erişimi, bir belgede kullanılan eş-kelimelerden çıkarım yapma ve eş-kelime analizi (co-word analysis) esnasında kullanılarak çeşitli belgelerin içeriğini, eğilimini ve kalıplarını anlamayı hedefleyen bir yazılımdır. Bu çalışmada LSTM, RNN'lerin uzun vadeli bağımlılık (long-term dependence) sorununu çözmek için tercih edilirken GRU'lar yüksek verimliliği ve basit yapısı sebebiyle tercih edilmiştir. Hibrit bir LSTM-GRU'nun, ilgili verileri saklamayı ve tahmin etmeyi daha iyi öğrenebileceği bildirilmiştir. Bu hibrit modelin ilk aşamasında girdi verileri LSTM katmanından alınarak bir ağırlık değeri oluşturulmaktadır. Bir sonraki adımda, LSTM katmanından gelen veriler ağırlık değeri üretilerek GRU katmanından geçmektedir. Çıktı nöronları GRU katmanındaki verileri alarak uygun ağırlıklara dönüştürülür. Sonraki adımda, çıktı ve başlangıç değerlerinin karşılaştırılması yoluyla maliyet fonksiyonu hesaplanmaktadır. Son olarak, maliyet fonksiyonunun minimum noktasına ulaştığı zaman, gerçek değerler ile tahmin edilen değerler arasındaki fark göz önünde

bulundurularak ağırlıklar tekrardan ayarlanmaktadır. Çalışmada hibrit LSTM-GRU mimarisi, Python kullanılarak uygulanmıştır.

4.3.4. Kodlayıcı-kod çözücü model


Kodlayıcı-Kod Çözücü Model (Encoder-Decoder Model) ilk olarak Cho vd. (2014) tarafından önerilmiştir. Aynı zamanda diziden diziye modeli (Sequence to Sequence; Seq2Seq) modeli olarak da adlandırılmaktadır. Önerilen mimari temelde iki RNN'den oluşmaktadır: kodlayıcı RNN ve kod çözücü RNN. Kodlayıcı, değişken uzunluktaki bir kaynak dizisini sabit uzunlukta bir vektöre dönüştürmekle görevlidir. Kod çözücü ise bu vektör temsili değişken uzunluktaki bir hedef dizisine geri dönüştürme işlevinde görevlidir. İki ağı hem bellek kapasitesini hem de eğitimi kolaylaştırmak amacıyla Cho vd. (2014), gizli birim olarak GRU kullanılmasını önermişlerdir (Şekil 26).



Şekil 26: Önerilen Kodlayıcı-Kod Çözücü RNN modelinin illüstrasyonu (Cho vd., 2014).

Cho vd. (2014), kodlayıcı-kod çözücü RNN modelini ve yenilikçi gizli birimi İngilizce'den Fransızca'ya çeviri görevinde değerlendirmişlerdir. Farklı dillerdeki cümle çiftleri, ağı girdilerini oluşturmaktadır. Modelin çalışma prensibi cümle işleme görevi ile açıklandığı zaman kodlayıcı, girdi cümlesindeki kelimeleri sırayla işlemekle görevlidir. Bir sonraki adımda, önceki gizli durum ve mevcut kelime kullanılarak yeni bir

gizli durum olan bağlam vektörü (context vector) üretilmektedir. Girdi dizisindeki tüm bilgiler, bağlam vektöründe özetlenmektedir ve çıktının üretilmesi için kod çözücüye iletilmektedir. Son olarak kod çözücü, önceki çıktıyı ve mevcut gizli durumu göz önünde bulundurarak sıradaki kelimeyi tahmin etmektedir. Şekil 27’de, cümledeki kelimelerin sırasıyla nasıl işlendiği gösterilmiştir. Tarwani ve Edem (2017), kelime sunumunun daha doğru bir şekilde elde edilebilmesi için kelime gömme katmanı kullanılması gerektiğini bildirmişlerdir. Genellikle GloVE veya Word2Vec algoritması olan kelime gömme katmanları, bir dizideki benzer kelimelerin birbiriyle ilişkilendirilmesinde rol oynayan ağırlıklı bir matris oluşturulmasını sağlamaktadır. Böylece kelimeler daha iyi temsillere sahip olmaktadır ve ağırlık çıkarım yapması gereken veride azalma gerçekleşmektedir (Tarwani & Edem, 2017).



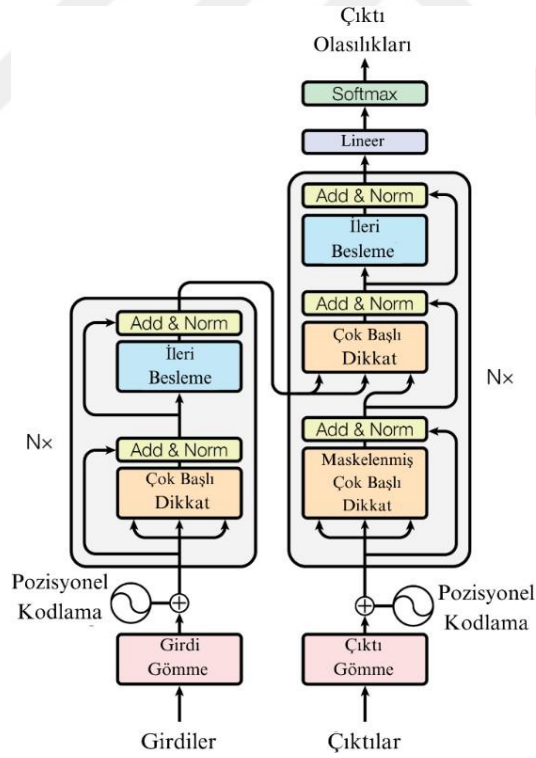
Şekil 27: İngilizce'den Fransızca'ya çeviri için Kodlayıcı-Kod Çözücü RNN.

(Tarwani ve Edem, 2017).

Kodlayıcı-kod çözücü modeller, sabit boyutlu bağlamsak vektör içermeleri sebebi ile uzun cümlelerde bilgi kaybına yol açmak gibi sınırlılıklara sahiptirler. Bu problem, ilerleyen çalışmalarda (Bahdanau vd., 2016) dikkat mekanizmasının (attention mechanism) tanıtılmasıyla birlikte çözülmüştür.

4.4. Transformer Mimarisi

Transformer mimarisi, sıralı veri işlemede geleneksel RNN'ler yerine dikkat mekanizması (attention) kullanan bir mimaridir. Vaswani vd. (2017), metindeki tüm kelimelerin birbirleriyle ilişkilerine aynı anda bakarak paralel işlem yapabilen dikkat katmanlarını tanıtmışlardır. Bu mimaride her kelime, diğer kelimelere öz-dikkat (self-attention) yoluyla bağlamsal olarak ağırlıklar atamaktadır; böylece cümlenin herhangi bir uzak konumdaki sözcüğüyle etkileşimi, bellekte zincirleme aktarım olmadan doğrudan modellenmektedir. Transformer mimarisi (Şekil 28), uzun dizileri paralel bir şekilde hesapladığı (parallel computing) için daha hızlı eğitilmektedir. Bu özelliğiyle beraber RNN'lerin verileri sıralı olarak işlemesi sebebi ile uzun dizilerin yavaş işlenmesi ve diziler uzadıkça RNN'lerin uzak kelimeleri ilişkilendirmede yaşadığı zorluk çözülmüştür.



Şekil 28: Transformer model mimarisi.

Add & Norm: Artık katman bağlantısı ve ardından katman normalizasyonu anlamına gelmektedir. (Vaswani vd.'den (2017) Türkçe'ye uyarlanmıştır).

Transformer, kodlayıcı (encoder) ve kod çözücü (decoder) bileşenlerinden oluşan bir yapıya sahiptir: Kodlayıcı, giriş cümleyi bağlamsal vektörlere dönüştürmekle görevlidir; çözücü ise bu vektörlerden istenen çıktıyı (örneğin çeviri cümlesini) meydana getirmektedir. Paralel hesaplama avantajı sayesinde bu mimari, çok büyük veri setlerinde verimli şekilde eğitime olanak tanıyarak derin ve geniş modellerin oluşturulmasına imkân sağlamıştır.

Takip eden yıllarda Transformer tabanlı sayısız model önerildi ve hemen her NLP görevinde önceki tüm yaklaşımların performansını geride bırakmıştır. Özellikle dil modelleri alanında, Transformer mimarisinin uyarlanmasıyla ortaya çıkan devasa ölçekli modeller, insan benzeri dil üretimi ve anlama konusunda çarpıcı başarılar sergilenmiştir. Bu modeller genellikle üç ana stratejiden birini kullanır: (1) Salt kodlayıcı (encoder) tabanlı modeller, (2) Salt çözücü (decoder) tabanlı modeller veya (3) Hem kodlayıcı hem çözücü bileşenlerini birlikte kullanan melez mimariler. Transformer tabanlı en etkili NLP modellerinden bazıları BERT, GPT serisi ve T5 transformerlardır.

4.4.1. BERT

Google araştırmacıları tarafından geliştirilen ve Devlin vd. (2019) tarafından sunulan BERT, yalnızca çift yönlü kodlayıcı Transformer katmanlarından oluşan bir mimariye sahiptir. “Çift yönlü” ifadesi, modelin eğitilirken hem sol hem sağ bağlamı eşzamanlı olarak değerlendirdiği anlamına gelmektedir. BERT, büyük ölçekli metin korpusları üzerinde öz-denetimli (self-supervised) öğrenme ile eğitilmiştir ve iki temel ön eğitim görevi kullanmaktadır: (i) Maskeli dil modelleme (Masked Language Modeling; MLM): Cümle içerisindeki bazı kelimeler maskelenir ve modelden bu boşlukları doğru kelimelerle tahmin etmesi beklenir; (ii) Sonraki cümle tahmini (Next Sentence Prediction; NSP): İki cümlenin metinde ardışık olup olmadığını tahmin etme. Bu sayede BERT, dilin yapısı ve anlamsal dağılımı hakkında zengin bir temsil öğrenmektedir. Daha sonra, bu ön eğitimli model, belirli NLP görevlerine (metin sınıflandırma, ad öbek tanıma, soru-cevap vb.) ince ayar (fine-tuning) yapılarak kolayca uyarlanabilir hale gelmektedir (Devlin vd., 2019).

BERT'in getirdiği yenilik, evrensel dil temsillerinin tek bir ön eğitimle öğrenilmesidir: Az miktarda görev verisiyle birçok farklı dil görevinde üstün performans sağlamaktadır (Devlin vd., 2019). BERT ve türevleri, SQuAD gibi okuduğunu anlama testlerinde insan seviyesine yaklaşan sonuçlar üretmiş ve GLUE gibi dil anlama benchmark'larında o zamana kadar elde edilen en yüksek skorları yakalamıştır. BERT'in başarısı, derin bağlamsal temsil (deep contextual representation) kavramını NLP alanında standart hâle getirmiş ve çok sayıda türevinin (Türkçe BERT, çok dilli BERT, distilBERT vb.) üretilmesine öncülük etmiştir.

4.4.2. GPT serisi

GPT (Generative Pre-trained Transformer) modelleri, OpenAI tarafından geliştirilen ve yalnızca çözücü (decoder) kısmını kullanan, metin üretimine odaklı modellerdir. İlk GPT versiyonu Radford vd., (2018) tarafından tanıtılmış; GPT-2 (Radford vd., 2019) ve GPT-3 (Brown vd., 2020) sürümleriyle asıl ününü kazanmıştır.

GPT mimarisi, tek yönlü (unidirectional) bir dil modeli gibi davranmaktadır: Girilen bir metin parçasının devamındaki kelimeyi olasılıksal olarak tahmin ederek metin üretmektedir. Model, giriş olarak bir kelime dizisi olarak ardışık şekilde sonraki kelimeyi tahmin ederek üretimini sürdürmektedir (Radford vd., 2018). GPT-2, yaklaşık 1,5 milyar parametreye sahip olup internet metinleri üzerinde eğitildiğinde tutarlı ve uzun metinler üretebildiği gösterilmiştir. Tek bir görev için fine-tuning gerektirmeden çoklu görevleri yüksek başarı ile gerçekleştirebilmiştir (Radford vd., 2019). Bunu takiben GPT-3, 175 milyar parametrelili devasa bir model olarak tanıtılmıştır. GPT-3'ün yeniliği, zero-shot, one-shot (Fei-Fei vd., 2006) ve few-shot öğrenme yeteneklerinin çok gelişmiş olmasıdır: Model, herhangi bir özel ince ayar yapılmadan, yalnızca doğal dilde verilen talimatlar veya birkaç örnek gösterilerek birçok NLP görevini gerçekleştirebilmektedir (Brown vd., 2020). Örneğin GPT-3'e "Fransızcadan İngilizceye çeviri yap" şeklinde bir yönlendirme verildiğinde, model bu özel görevi görmemiş olsa bile doğru çeviriyi üretebilir. Bu durum, modelin eğitiminde gördüğü muazzam veri içinde çeşitli görev örüntülerini gömülü biçimde öğrendiğini göstermektedir. GPT-3 ve benzeri büyük modeller, metin

üretiminde insan benzeri tutarlılık ve uzunlukta içerikler oluşturabilmekte, makale, program kodu veya diyaloglar üretme kapasitesine ulaşmaktadır.

Bu seri, kısa süre önce GPT-4 (OpenAI vd., 2024) gibi daha da gelişmiş sürümlerle devam etmiş ve hem metin hem görüntü girdilerini işleyebilen multimodal yetenekler kazanmıştır. GPT serisi, dil modelleme alanında olasılıksal metin üretimi paradigmasının zirvesi olarak kabul edilmekte ve insan benzeri yaratıcı dil çıktıları üretmesiyle dikkat çekmektedir.

4.4.3. T5

T5 (Text-to-Text Transfer Transformer) Google Brain ekibi (Raffel vd., 2023) tarafından geliştirilmiş ve tanıtılmıştır. T5'in temel felsefesi, her NLP görevini bir metinden metine dönüşüm (text-to-text transfer) problemi olarak ele almaktır. Model, tam bir Transformer kodlayıcı-kod çözücü mimarisine sahiptir. T5, BERT benzeri bir ön eğitim aşamasından geçmektedir; ancak burada eğitim hedefi, cümleleri çeşitli şekillerde yeniden yazmaktır. Örneğin, yazım hatalarını düzeltme, soruya yanıt üretme, çeviri yapma veya özetleme gibi farklı görevler, hepsi “girdi metnini çıktı metnine dönüştürme” formatında ele alınır. T5, 750 GB'lık devasa bir metin veri kümesi (Colossal Clean Crawled Corpus; C4) üzerinde eğitilmiş ve bu sayede genel dil bilgisini içselleştirmiştir. Modelin en güçlü yönü, farklı görevleri tek bir birleşik mimariyle gerçekleştirebilmesidir: Aynı T5 modeli, uygun biçimde hazırlanan metin girdileriyle hem çeviri hem özetleme hem de metin sınıflandırma gibi görevlerde performans sergileyebilmektedir. Bu yaklaşım, farklı görevler için ayrı modeller yerine tek bir görev-agnostik model kullanmanın mümkün ve verimli olduğunu göstermiştir. T5, pek çok dil anlama ve üretme benchmark'ında o güne dek elde edilen en iyi sonuçları almış; örneğin uzun metinleri anlamlı ve tutarlı özetler hâline getirme veya sorulara bağlama uygun yanıtlar verme konularında öncülük etmiştir. T5'den sonra araştırmacılar, NLP'deki “her problemi metinden metine problem” olarak düşünmeye yönlendirilmiş ve görev-agnostik yaklaşımların gücü net biçimde vurgulanmıştır (Raffel vd., 2023).

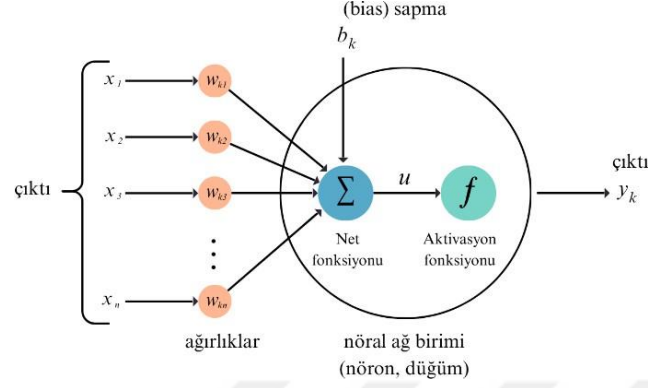
4.4.4. NLP ile ilgili çalışmalar

Tang vd. (2023), fMRI ile ölçülen beyin aktivitelerinden yola çıkarak sürekli konuşmanın anlamsal içeriğini yeniden yapılandırabilen (semantic reconstruction) bir Beyin-Bilgisayar Arayüzü sistemi geliştirmeyi amaçlamışlardır. Çalışmanın mimarisine bakıldığı zaman, kodlayıcı, kod çözücü ve cümle gömme/CLIP modellerinden oluşan transformer mimarisinin kullanıldığı görülmektedir. Kodlayıcı, beyin sinyallerinden semantik temsil çıkarımı için kullanılmıştır. Ön işleme tutulan fMRI verilerine lineer regresyon ve MLP yöntemleri uygulanarak dil modelinin “gömme uzayına” yansıtma yapılmıştır. Kod çözücü bölümde, beyin aktiviteleri ve GPT-2 modelinin iç temsilleri hizalanacak şekilde eşleştirilmiştir. FMRI verileri, GPT-2'nin ara katmanlarına eşleştirilen vektöre dönüştürülmüştür. Bu temsil, GPT-2 ile çözümlenerek semantik olarak anlamlı cümleler üretilmiştir. Modelin semantik açıdan ne derece yakın çıktılar verdiğini değerlendirmek amacıyla, Sentence-BERT ve CLIP gömme yöntemleri kullanılarak hedef cümle ve tahmin edilen cümle karşılaştırılmıştır. Çalışmada NLP ilişkili görev olarak, semantik cümle yeniden yapılandırma, anlamsal benzerlik işleme, çok modlu hizalama ve zero-shot/few shot genelleme görevleri kullanılmıştır. Çalışma ile birlikte, beyin sinyallerinden dil modeli temsillerine doğrudan bir geçiş sağlanmıştır.

4.5. Aktivasyon Fonksiyonları

Bir nöronun çıktısına uygulanan matematiksel işlem, derin öğrenmede aktivasyon fonksiyonunu (activation function) ifade etmektedir (Şekil 29). Derin öğrenme için aktivasyon fonksiyonları kritik önem taşımaktadır. Aktivasyon fonksiyonları, karmaşık fonksiyonları yaklaşık hale getirerek sinir ağlarının karmaşık ilişkileri modellemesine yardımcı olmaktadır. Karmaşık veri temsillerini öğrenmesini sağlayarak ağları ses ve görüntü tanıma görevlere hazır hale getirmektedir. İlaveten, aktivasyon fonksiyonu olmadan sinir ağları, doğrusal regresyon modeli gibi davranmaktadır (Basirat & Roth, 2018; Lederer, 2021). Geri yayılım esnasında gradyanlar aktivasyon fonksiyonundan etkilenirler ve eğitim hızı ve etkinliği aktivasyon fonksiyonu seçimi ile yakından ilişkilidir (Hammad, 2024). Aktivasyon fonksiyonları, öğrenme sürecini daha sağlıklı

hale getirmek, hesaplama maaliyetini azaltmak ve doğruluk performansını artırmak amacıyla geliştirilmiştir (Kılıçarslan vd., 2021).



Şekil 29: Yapay nöronunda aktivasyon fonksiyonu.

Öncelikle giriş verileri ağırlıklar ile çapılarak sinir hücresine aktarılır ve sapma eklenerek net fonksiyon hesaplanır ve işlem sonucu oluşan ifadeye u denildiğinde;

$$u = \sum w * x + b$$


olmaktadır. Aktivasyon fonksiyonunun u değerine uygulanması sonucunda $f(u)$ oluşur ve çıktı:

$$f(u) = f(\sum w * x + b) = y_k$$

olarak ifade edilmektedir. Bu çıktı ağıdaki bir sonraki katmana iletilmektedir.

Kısmi türev işlemi, özellikle makine öğrenmesindeki problemlerin yaklaşımında hatayı geriye yayarak minimize etmek amacıyla kullanılmaktadır. En basit iki fonksiyon olarak basamak (step) fonksiyonu ve doğrusal (linear) fonksiyonundan (Şekil 30) bahsedilmektedir. Basamak fonksiyonu, ikili değer almaktadır fakat türevi öğrenmeyi temsil etmediği için yapay sinir ağlarının ara katmanlarında tercih edilmemektedir. Doğrusal fonksiyon, türevi alınabilir bir fonksiyondur fakat türevinin alınabilmesi öğrenmenin gerçekleştiği anlamına gelmemektedir. Türev sonucunda sabit bir değer elde

edildiği için öğrenme gerçekleşmez ve bu sebepten ara katmanlarda tercih edilmemektedir (Yılmaz, 2021).



Şekil 30: Basamak fonksiyonu ve Doğrusal fonksiyon.

Sinir ağlarının optimizasyonu ve eğitimi için aktivasyon fonksiyonları anahtar bileşen görevi üstlenmektedir. Doğal dil işleme, sınıflandırma, nesne tespiti ve segmentasyon gibi alanlarda kullanılmak üzere derin öğrenme mimarilerinin farklı katmanlarında uygulanmaktadır (Nwankpa vd., 2018). Sigmoid, ReLU, Swish, Softmax ve GELU aktivasyon fonksiyonları, doğal dil işleme görevlerinde en sık karşılaşılan fonksiyonlar olarak görülmektedir.

4.5.1. Sigmoid aktivasyon fonksiyonu

Bağımsız değişkenleri sonsuz bir aralıktan alıp 0 ile 1 arasında değerler üreten ve ikili sınıflandırma problemlerinde kullanılan makineler, sigmoid fonksiyonu olarak adlandırılmaktadır (Patterson ve Gibson, 2017). Derin öğrenme mimarilerinde öğrenme sürecini gerçekleştirmek amacıyla tercih edilen geri yayılım algoritması, güncelleme işlemini mimarideki parametrelerin türevlerini alarak gerçekleştirir. Doğrusal aktivasyon fonksiyonlarında türev alındığı zaman sabit bir değer sonucu alınmaktadır ve bu sebepten geri yayılım algoritması derin öğrenme süreçlerini gerçekleştirememektedir. Bu problem, türev alabilen ve doğrusal olmayan sigmoid fonksiyonlarının geliştirilmesine sebep olmuştur (Kılıçarslan vd., 2021).


Sigmoid aktivasyon fonksiyonu ‘‘S’’ harfine benzer bir grafiğe sahiptir ve türevlenebilir olduğu için birden fazla varyasyon içermektedir. Lojistik fonksiyon (logistic funtion), lojistik regresyon modellerini vurgular ve makine öğreniminde en yaygın olarak kullanılan sigmoid fonksiyonudur (Hammad, 2024). Logistic-Sigmoid aktivasyon fonksiyonu şu şekilde verilmiştir:

$$\begin{aligned}\sigma_{Logistic}(x) &= \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \\ &= \frac{-1 + (1 + e^x)}{1 + e^x} \\ &= 1 - \sigma_{Logistic}(-x)\end{aligned}$$

$$\begin{aligned}\frac{d}{dx} \sigma_{Logistic}(x) &= \frac{d}{dx} \frac{e^x}{1 + e^x} = \frac{e^x(1 + e^x) - e^x e^x}{(1 + e^x)^2} \\ &= \frac{e^x[(1 + e^x) - e^x]}{(1 + e^x)^2} \\ &= \frac{1}{(1 + e^x)} \frac{e^x}{(1 + e^x)} \\ &= \left[1 - \frac{e^x}{(1 + e^x)}\right] \frac{e^x}{(1 + e^x)} \\ &= (1 - \sigma_{Logistic}(x)) \sigma_{Logistic}(x).\end{aligned}$$

Logistik-Sigmoid fonksiyonunda Şekil 31’da görüldüğü gibi girdi pozitif hale geldikçe, eğri 0.5 değerinden başlayıp yavaşça yükselip ve 1’e yakınsamaktadır; girdi negatif hale geldikçe yavaşça alçalmakta ve 0’a yakınsamaktadır. Fonksiyon sonsuz derecede pürüzsüzdür ve sınırlıdır. Türevi, en yüksek ve en düşük değer aldığı noktalarda 0’a yakınsamaktadır. Bu sığra yakınsayan yerlerde öğrenme gerçekleşmez ve buna kaybolan gradyan problemi (vanishing gradient problem) denilmektedir. Fonksiyon üstel hesaplamalar içerdiği için toplama çıkarma gibi basit işlemlerden daha fazla kaynak

gerektirir ve daha maliyetlidir. Bu sebeplerden, ikili sınıflandırma problemlerini modellemek için faydalı olsa da çok sayıda parametreye sahip ağlarda eğitim sürecinin yavaşlamasına sebep olabilmektedir (Hammad, 2024).



Şekil 31: Sigmoid aktivasyon fonksiyonu ve türevi (Kılıçarslan vd., 2021)

Sigmoid aktivasyon fonksiyonu, doğal dil işleme görevlerinde CNN katmanlarında kullanılmaktadır. Örneğin, duygu polaritesi (sentiment polarity) ve bir özelliğin varlığı veya yokluğu gibi ikili sınıflandırmalarda genellikle çıktı katmanında kullanılarak çıktıları 0 ile 1 arasında sıkıştırmakta ve girilen her metin için pozitif veya negatif olasılıklar üretebilmektedirler (Mesran vd., 2024).

Mercioni ve Holban (2020) çalışmalarında, nesne sınıflandırma görevinde performans iyileştirme sağlayabilen sigmoid gibi çeşitli aktivasyon fonksiyonlarının tartışmışlardır. Çalışmada, CIFAR-10 ve CIFAR-100 veri setlerini (Krizhevsky & Hinton, 2009), LeNet-5 (Lecun vd., 1998) Network in Network (NiN) (Lin vd., 2014), ve ResNeT34 (K. He vd., 2016b) mimarilerinde; IMDB ve FastText crawl 200d 2M veri setlerini (Mikolov vd., 2017) Reuters'da 3 NLP görevi için özel mimarilerde; The 2018 Data Science Bowl veri setini anlamsal segmentasyon görevi için U-Net (Fully Connected Convolutional Network) mimarisinde kullanmışlardır. Sigmoid fonksiyonu, çıktı katmanlarında, özellikle ikili sınıflandırma görevinde tercih edilmiştir (Mercioni ve Holban, 2020).

Bir başka çalışmada (Chen, 2024), ceza mahkemeleri hukukundaki cezalandırma standartları üzerinden suç tahmini üzerine yasal bilgi tabanı tasarlanmıştır. Suç enstrümanındaki önemli olay örgüsü unsurlarına saha iyi erişebilmek adına BERT ön eğitim modeli (Y. Li vd., 2024) kullanılırken, ikinci katmanında doğrusal regresyon (Kubáček & Wimmer, 2016), sınıflandırma katmanında ise Sigmoid aktivasyon fonksiyonu kullanılmıştır.

Amin vd. (2022), varlık ismi tanıma (named entity recognition; NER) ve duygu analizi (sentiment analysis) gibi metin sınıflandırma görevlerini gerçekleştirmek adına Bi-LSTM-CRF modeli kullanmışlardır. Büyük veri setlerini hızlı ve verimli bir şekilde eğitebilmek adına hesaplamaları CUDA hızlandırılmış kütüphaneler içeren NVIDIA tabanlı GPU üzerinde gerçekleştirmişlerdir. Tüm hiperparametreleri SGD (Stochastic Gradient Decent) optimizörü ile sabitleyerek, Sigmoid, SoftMax, SoftPlus gibi aktivasyon fonksiyonlarını karşılaştırmışlardır. NER görevinde %95,17 doğruluk oranına ulaşan Sigmoid fonksiyonunun maksimum doğruluk ve minimum kayıp değerleri nedeniyle kullanım için en uygun fonksiyon olduğunu bildirmişlerdir.

Doğal dil işleme alanındaki son gelişmelerde Sigmoid aktivasyon fonksiyonu, gömme tekniklerinde kullanılmaya başlanılmıştır. Del Gaizo vd. (2024), koroner arter baypas greft (coronary artery bypass graft; CABG) ameliyatı ile ilişkili morbidite riskini ölçmek için lojistik regresyon tabanlı bir risk hesaplayıcısı kullanmışlardır. Cerrahi notlardan sonuç tahmini performansını arttırmak adına, metin içerisine gömülü sayısal değerleri hesaplamak adına “sigmoid-liner-log” fonksiyonunu kullanmışlardır.

4.5.2. ReLU aktivasyon fonksiyonu

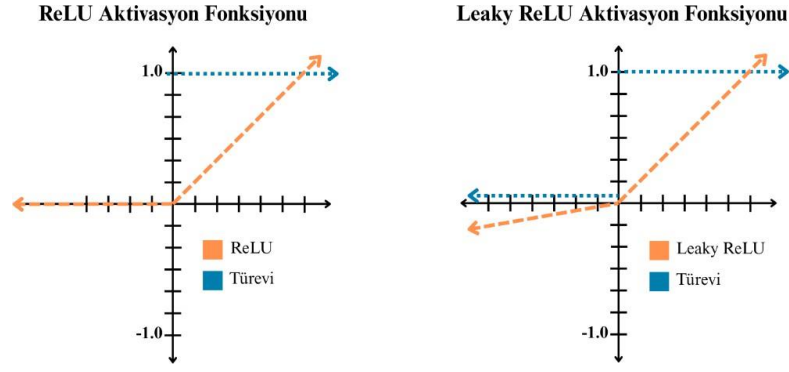
Sigmoid fonksiyonlarında ortaya çıkan kaybolan gradyanlar problemine çözüm bulmak amacıyla ReLU (Rectified Linear Unit; Doğrultulmuş Doğrusal Birimler) fonksiyonları geliştirilmiştir (Kılıçarslan vd., 2021). ReLU fonksiyonları, pozitif değer aldığı noktalarda doğrusal fonksiyonlara benzemektedir fakat negatif değerlerde sıfır çıktısı vermesi sebebiyle doğrusal fonksiyonlardan ayrılır. Diğer bir deyişle, girdi belirli

bir eşik değerinin üzerine çıktığı zaman bağımlı değişken ile liner bir ilişki kurulmaktadır: $f(x) = \max(0, x)$ (Patterson ve Gibson, 2017). ReLU aktivasyon fonksiyonu şu şekilde verilmiştir (Hammad, 2024):

$$\begin{aligned}\sigma_{ReLU}(x) &= \max(0, x) \\ &= \frac{x + |x|}{2} \\ &= \begin{cases} x, & x \geq 0, \\ 0, & x < 0, \end{cases} \\ \frac{\partial}{\partial x} \sigma_{ReLU}(x) &= \begin{cases} 1, & x > 0, \\ 0, & x < 0, \end{cases}\end{aligned}$$

ReLU aktivasyon fonksiyonları, sınır ağlarına non-lineerlik getirmesi sebebi ile karmaşık ilişkilerin modellenmesine olanak tanımaktadır ve sigmoid aktivasyonun aksine ağız gizli katmanlarında uygulanmaktadır. Fonksiyon aralığı $[0, \infty)$ 'dur ve ağız öğrenme ve temsil yeteneğini genişletmek adına kritik bir öneme sahip olduğu bildirilmiştir. Sigmoid fonksiyonlarına oranla daha basit bir matematiksel işlem içermektedir. Bu sebepten hesaplama performansı daha yüksektir (Hammad, 2024).

ReLU, pozitif değerlerde türevlenebilir bir fonksiyondur ve gradyanlar hem büyük hem de tutarlıdır (Goodfellow vd., 2016) fakat negatif alanlarda türevinin alınamaması sebebi ile öğrenme süreci yavaşlamaktadır. ReLU aktivasyon fonksiyonunun aktivasyonun sıfır olduğu örneklerde gradyanların ölmesi problemine çözüm bulamaması sebebiyle LReLU (Leaky Rectified Linear Units) fonksiyonu ortaya çıkmıştır (Şekil 32). LReLU aktivasyon fonksiyonunda, değerlerin negatif olduğu bölümde küçük değerlere sahip bir fonksiyon tasarlanmıştır. Bu sayede fonksiyonun $(-\infty, \infty)$ aralığında değer alması ve türevi alındığında eğitim oranının daha aktif hale gelmesi sağlanmıştır (Hammad, 2024).



Şekil 32: ReLU ve LReLU aktivasyon fonksiyonları ve türevleri.

ReLU aktivasyon fonksiyonu, basit bir hesaplama içermesi ve doğrusal olmayan yapısı sebebiyle, görüntü işleme (CV), duygu analizi ve metin sınıflandırması gibi görevlerde eğitimi hızlandırmaktadır (Kumnunt & Sornil, 2020; Mareček vd., 2020). NLP görevlerinde özellikle CNN, LTSM ve RNN mimarilerinde kullanılmaktadır.

Kumnunt ve Sornil (2020), sosyal medya mesajları üzerinden depresyonu tespit etme görevi için CNN-LTSM modelinin CNN katmanlarında ReLU aktivasyon fonksiyonunu kullanmışlardır. Sonuçlarda ReLU aktivasyon fonksiyonunun Sigmoid ve Tanh aktivasyon fonksiyonlarına kıyasla %83,1'lik bir F1 puanı ile güçlü bir performans gösterdiğini raporlamışlardır. Bu görüşleri Nwankpa vd.'nin (2018) ReLU, Sigmoid ve Tanh aktivasyon fonksiyonlarını tartıştıkları çalışmayı kanıtlar niteliktedir.

Agarap (2019), Adam (Kingma & Ba, 2017) optimizasyon algoritmasını kullanarak MNIST (LeCun, 1998), FashionMNIST (Xiao vd., 2017) ve Wisconsin Diagnostic Breast Cancer (WDBC) (Wolberg vd., 1995) sınıflandırmasında DL-ReLU ve DL-Softmax modellerinin tahmin performansını tartışmıştır.


AlexNet, üç maksimum havuzlama katmanı ile iç içe geçmiş beş konvolüsyon katmanından ve ardından iki tam bağlı katmanından oluşmaktadır (Mareček vd., 2020). AlexNet'ten önce de CNN'ler oldukça bilinir olduğu halde ReLU aktivasyon fonksiyonlarının (Hahnloser vd., 2000) kullanılmasıyla beraber ağların derinliği artmıştır.

4.5.3. Swish aktivasyon fonksiyonu

Swish aktivasyon fonksiyonu şu şekilde tanımlanmaktadır (Avenash & Viswanath, 2019);

$$\sigma_{Swish}(x) = x \cdot \sigma_{Sigmoid}(\beta x)$$

Buradaki $\sigma_{Sigmoid}(x) = (1 + \exp(-x))^{-1}$ sigmoid fonksiyonu olup β sabit veya eğitilebilir bir parametre olarak bildirilmiştir. Şekil 33'te swish aktivasyon fonksiyonundaki farklı β değerleri gösterilmiştir. $\beta = 1$ olduğu zaman, pekiştirmeli öğrenme (Reinforcement learning) için önerilen SiLU (Sigmoid Linear Unit) ile eşdeğer görülmektedir. $\beta = 0$ ise Swish, ölçeklendirilmiş doğrusal fonksiyon $\sigma(x) = \frac{x}{2}$ olmaktadır. $\beta \rightarrow \infty$ olduğu zaman, Sigmoid bileşeni neredeyse 0-1 fonksiyonuna dönüşmektedir ve Swish, ReLU fonksiyonuna yakınsamaktadır. β parametresinin eğitilebilir bir parametre olması, enterpolasyon (interpolation) derecesinin model tarafından kontrol edilebileceği anlamına gelmektedir (Hammad, 2024).



Şekil 33: Swish aktivasyon fonksiyonu ve birinci türevleri.

(Ramachandran vd., 2017).

Swish aktivasyon fonksiyonunun en önemli özelliği $x < 0$ olduğu durumlarda, nöronların inaktif hale geldiği ReLU'dan farklı olarak, öğrenmeye devam etmesidir. Swish'in düzgün ve monoton olmayan doğası, onu diğer aktivasyon fonksiyonlarından ayırmaktadır ve derin mimarilerde esnek ve etkili olmasını sağlamaktadır. Swish'in diğer

önemli özelliği, tüm mimari boyunca hem pozitif hem de negatif türev değerlerine sahip olabilmesidir. Swish'in türevi şu şekilde verilmiştir (Ramachandran vd., 2017);

$$\begin{aligned} f'(x) &= \sigma(\beta x) + \beta x \cdot \sigma(\beta x)(1 - \sigma(\beta x)) \\ &= \sigma(\beta x) + \beta x \cdot \sigma(\beta x) - \beta x \cdot \sigma(\beta x)^2 \\ &= \beta x \cdot \sigma(x) + \sigma(\beta x)(1 - \beta x \cdot \sigma(\beta x)) \\ &= \beta f(x) + \sigma(\beta x)(1 - \beta f(x)) \end{aligned}$$

β değeri, Şekil 32'de görüldüğü gibi, Swish'in birinci türevlerinin 0 ve 1'e yaklaşma hızını kontrol etmektedir. Swish fonksiyonları, öğrenme açısından daha yüksek performans gösterse de içerisinde sigmoid fonksiyonunu da içermesi sebebi ile ReLu'ya oranla daha yüksek hesaplama maliyetine sahiptir (Hammad, 2024).


Swish aktivasyon fonksiyonu, özellikle de parametrik bir varyantı olan P-Swish fonksiyonu, NLP veri setlerinde ve anlamsal segmentasyon görevlerinde monotonik olmayan ve pürüzsüz yapısı sebebiyle sigmoid ve ReLU gibi geleneksel fonksiyonlarından daha hızlı eğitim ve performans iyileştirmeleri göstermektedir (Alcaide, 2018; Mercioni & Holban, 2020).

Eger vd. (2019), Swish dahil olmak üzere toplamda 21 farklı aktivasyon fonksiyonunu 8 ayrı NLP görevinde üç farklı mimari kullanarak karşılaştırmışlardır. İlk paradigmada, film incelemesi sınıflandırması (movie review classification; MR), öznellik sınıflandırması (subjectivity classification; SUBJ), soru türü sınıflandırması (question type classification; TREC) ve cümlelerin belirli bir argümanı içerip içermediğini sınıflandıran (argument mining; AM) cümle görevlerinde çok katmanlı algılayıcı (multilayer perceptron; MLP) kullanılarak gerçekleştirilmiştir. Cümle temsili tekniği olarak 600 boyutlu Sent2Vec (Pagliardini vd., 2018) ve 4096 boyutlu InferSent (Conneau vd., 2018) kullanılmıştır. 3 vakadan 2'sinde Swish'in daha güvenilir olduğu bildirilmiştir. İkinci paradigmada, 20 Newsgroup (NG) ve Reuters-21578 (R8) olmak üzere iki belge sınıflandırma (document classification) görevi için CNN kullanılmıştır. Üçüncü

paradigma olarak, Pos etiketleme (POS tagging), bölümlere ayırma (chunking), NER, söylem ayrıştırma (discourse parsing) (Braud vd., 2017) ve argüman madenciliği içeren klasik sekans etiketleme (sequence tagging) görevlerinde RNN kullanılmıştır. İlk paradigmada, 3 vakadan 2'sinde Swish'in daha güvenilir olduğu bildirilmiştir. Diğer iki paradigma da göz önüne alındığında, gizli katmanlara dayanıklılık açısından Swish'in önde olduğu ve görevlerde en iyi ikinci performansı %91 oranla Swish'in gösterdiği raporlanmıştır.

4.5.4. Softmax aktivasyon fonksiyonu

Sinir ağlarında özellikle çok katmanlı sınıflandırma (multi-class classification) problemlerinde Softmax aktivasyon fonksiyonu kullanılmaktadır. Softmax aktivasyon fonksiyonuna (Şekil 34) sınıflandırıcıların çıktı katmanlarında sıklıkla rastlanmaktadır. Patterson ve Gibson'ın (2017) örneklendirmesiyle, çok sınıflı bir modelleme probleminde sınıflar arasındaki en iyi puan önemseniyorsa argmax () işlevine sahip bir softmax çıktı katmanı kullanılmaktadır. Fakat çıktı başına birden fazla sınıflandırma elde edilmek isteniliyorsa softmax yerine her sınıf için bağımsız bir olasılık veren sigmoid katmanı kullanılmaktadır. Bazı CNN mimarileri, ağın sonunda çoklu tam bağlantılı katmanlar kullanılır ve AlexNet, sonunda softmax katmanı bulunduran mimarilere örnek verilmiştir (Patterson ve Gibson, 2017).




Şekil 34: Çok katmanlı sınıflandırma için Softmax aktivasyon fonksiyonu.

Ağ, girdi katmanı, tam bağlantılı bir katman ve softmax çıktı katmanından oluşmaktadır (Hammad, 2024).

Softmax aktivasyon fonksiyonu, gerçek sayılardan oluşan bir girdi vektörünü olasılık dağılımına dönüştürmekle görevlidir. Softmax'ın hesaplaması şu şekilde verilmiştir (Hammad, 2024):

$$i = 1,2, \dots, n. \text{ için} \quad \sigma_{Softmax}(z_i) = a_i = \frac{e^{z_i}}{\sum_j e^{z_j}}$$

Softmax, girdi vektöründeki her öge için değerlerin $[0,1]$ aralığında olması ve toplamının 1 olması şeklinde olasılıklar atamaktadır. Şekil 35'teki grafikte, üç girdi (x , 0 , $-x$) için Softmax olasılıkları gösterilmiştir. Grafikte x , -3 ve 3 aralığında değişmektedir. x değerinin artmasıyla birlikte x girdisi ile ilişkili olasılığında arttığı ve 0 ve $-x$ girdilerinin olasılıklarının da buna göre ayarlandığı bildirilmiştir (Hammad, 2024).



Şekil 35: Bir diziye uygulanan Softmax aktivasyon fonksiyonu.

Ham girdi değerlerinin toplamı 1 olan olasılıklara dönüştürülmesi. (Hammad, 2024).

NLP görevlerinde softmax, çoğunlukla sınıflandırma problemlerine yönelik derin öğrenme çözümlerinin son katmanında kullanılmaktadır (Agarap, 2019). Mareček vd.'nin (2020) aktarımıyla ağ, temelde, girdi önceden bilinen sabit bir sete sınıflandırılmak istenilir. Bu göreve bir örnek, metnin türe göre sınıflandırılmasıdır (Y.-B. Lee & Myaeng, 2002). Diğer bir örnek, duygu analizi (sentiment analysis) ile metnin olumlu veya olumsuz olarak bir duygu taşıyıp taşımadığının sınıflandırılmasıdır (Pak & Paroubek, 2010; Pang vd., 2002). Bu görevlerde yaygın olarak sınıflandırma ağında, gerçekte sınıflandırmadan önce Softmax fonksiyonu ile tahmin dağılımı yapılır ve maximumu

alınmaktadır. Sınıflandırma yapılırken, RNN’ler gibi çok katmanlı sinir ağları kullanılmaktadır. Softmax aktivasyon fonksiyonu sadece sınıflandırma durumunda değil, otoregresif kod çözme (autoregressive decoding) ve dizi etiketleme (sequence labeling) durumlarında da kullanılmaktadır (Mareček vd., 2020). Tablo 2’de, ReLU ve Softmax fonksiyonlarının derin öğrenme mimarilerindeki yeri listelenmiştir (Nwankpa vd., 2018):

Tablo 2: Derin mimarilerde ReLU ve Softmax aktivasyon fonksiyonu kullanımı

Mimari	Gizli Katman	Çıktı Katmanı	Kaynak
AlexNet	ReLU	Softmax	Krizhevsky vd., 2012
NiN	No activation	Softmax	Lin vd., 2014
ZFNet	ReLU	Softmax	Zeiler & Fergus, 2014
VGGNet	ReLU	Softmax	Simonyan & Zisserman, 2015
SegNet	ReLU	Softmax	Badrinarayanan vd., 2017
GoogleNet	ReLU	Softmax	Szegedy vd., 2015
SqueezeNet	ReLU	Softmax	Golkov vd., 2016
ResNet	ReLU	Softmax	He vd., 2016
ResNeXt	ReLU	Softmax	Xie vd., 2017
MobileNets	ReLU	Softmax	Howard vd., 2017
SeNet	ReLU	Softmax	Fu vd., 2017

4.5.5. GELU aktivasyon fonksiyonu

“Yüksek performanslı” bir sinir ağı aktivasyon fonksiyonu olan GELU (Gaussian Error Linear Unit), Hendrycks ve Gimpel (2023) tarafından dropout (bırakma) gibi skolastik düzenleyicileri ReLU özellikleri ile birleştirme motivasyonu ile önerilmiştir. Hem ileri hem de geri yayılımda yineleme sayısı (repetition counting), tüm girdi yığınlarının tek bir eğitim tekrar sayısını ifade etmekte olup ağı daha yüksek doğruluk değerine sahip olması tekrar sayısının yüksekliği ile sağlanmaktadır (Yılmaz, 2021). Çok yüksek ve dikkat edilmeden seçilen tekrar sayıları ağı aşırı uyumuna sebep olmaktadır. Derin doğrusal olmayan sınıflandırıcılarda ortaya çıkan bu sorunu önlemek amacıyla katmanlara gürültü eklemek veya dropout uygulamak gibi standartlaştırma (standardization) teknikleri uygulanmıştır (Srivastava vd., 2014). Skolastik düzenleyiciler, ağı bir sözde topluluk (pseudoensemble) (Bachman vd., 2014) gibi

davranmaya zorlayarak doğruluk artışlarına sebep olmuşlardır. Fakat GELU'nun önerilmesinden önce hem doğrusal olmayan yöntemler hem de dropout bir nöronun çıktısını beraber belirleseler bile ayrı kalmışlardır (Hendrycks ve Gimpel, 2016). Dropout düzenlemesiyle bir nöronun girdileri skolastik olarak 0 ile çarpılarak rasgele bir nöron alt kümesi devre dışı bırakılmaktadır ve nöron çıktısı daha olasılıksal hale getirilmektedir. ReLU aktivasyonunda ise girdilerin değerlerine bağlı olarak 0 veya 1 ile çarpılmaktadır. GELU ise girdileri 0 ile 1 arasındaki değerlerle çarparak bu iki işlevi birleştirmektedir (Hammad, 2024). Hendrycks ve Gimpel (2016), GELU aktivasyon fonksiyonunu şu şekilde tanımlamışlardır:

$$\text{GELU}(x) = xP(X \leq x) = x\Phi(x) = x \cdot \frac{1}{2} [1 + \text{erf}(x/\sqrt{2})]$$


GELU yaklaşık şu şekilde ifade edilmiştir:

$$\sigma_{\text{GELU}}(x) \approx 0.5x (1 + \text{Tanh}[\sqrt{2/n} (x + 0.044715x^3)])$$

Her iki yaklaşımında doğruluğu çeşitli veri setlerinde değerlendirilmiş olup yeterince hızlı ve kolay uygulanabilir oldukları gözlenmiştir. GELU, kümülatif bir dağılım fonksiyonu olarak verilmiştir ve ortalama bir 0 ve varyans 1 olan normal dağılımdan gelen rastgele bir değişkenin x 'ten küçük veya eşit olma olasılığının x ile çarpımı olarak ifade edilmiştir. GELU'da x azaldıkça girdilerin bırakılma oranı daha yüksektir. Diğer bir deyişle, uygulanan dönüşüm skolastik olsa bile girdiye bağlıdır.

GELU, ReLU'nun kullandığı ikili fonksiyona karşı düzgün bir yaklaşım olması sebebiyle ReLU'yu yumuşatmanın bir yolu olarak görülmektedir. Fakat bazı farklılıklar bildirilmiştir. Girdiler ReLU'daki gibi işaretlerine göre değil, diğer girdilerden ne kadar büyük olduğuna göre ağırlıklandırılmaktadır. Şekildeki grafikte görüldüğü gibi, GELU, ReLU ve ELU'ların aksine (Şekil 36), konveks olmayan, pozitif alanda doğrusal olmayıp tüm noktalarda eğrilik gösteren ve monoton olmayan bir aktivasyon fonksiyonudur. GELU'nun bu özelliğinin karmaşık fonksiyonları diğerlerine oranla daha kolay bir şekilde yaklaştırmasına olanak sağladığı bildirilmiştir. Ek olarak, GELU'nun sıfır merkezli olmasının, ağırlıkların pozitif veya negatif yönde sürekli olarak güncellenmesi

riskini azalttığı ve öğrenme dinamiklerine daha istikrarlı bir biçimde katkıda bulunduğu belirtilmiştir (Hendrycks ve Gimpel, 2016; Hammad, 2004).



Şekil 36: GELU, ReLU ve ELU aktivasyon fonksiyonları karşılaştırması.

(sol) -3 ile 3 arasındaki x aralığı (sağ) birinci türevleri (Hammad, 2004).

GELU aktivasyon fonksiyonunun girdileri değerlerine göre ağırlıklandırmaktadır ve doğrusal olmayan bir yapıya sahiptir. GELU'nun bu öğrenme özelliği, derin sinir ağlarının dil verilerindeki ilişkileri ve ince kalıpları daha iyi yakalamasına (Hendrycks ve Gimpel, 2016) ve dil çevirisi gibi karmaşık görevlerde en son teknolojiye (state-of-the-art) sahip performans elde etmesine (Lee, 2023) olanak sağlamaktadır.

Son olarak, transformer tabanlı modellerin çoğunda GELU aktivasyon fonksiyonu benimsenmiştir (Devlin vd., 2019). GELU, transformer mimarilerinde genellikle kodlayıcı (encoder) ve kod çözücü (decoder) blokların içerisindeki doğrusal dönüşümlerden sonra uygulanmaktadır (Vaswani vd., 2017). GELU'nun hesaplamasının optimize edilmesini inceleyen araştırmalar, transformer tabanlı mimarilerde GELU'nun merkezi rolünü kabul etmiş, NLP sistemlerinde eğitimler ve çıkarımları hızlandırdığını bildirmişlerdir (Peltekis vd., 2024).

Tablo 3'te, GELU aktivasyon fonksiyonlarını kullanan NLP modellerinin bir listesi gösterilmektedir:

Tablo 3: GELU aktivasyon fonksiyonunun kullanıldığı mimariler

Mimari	Kaynak
GPT-1	Radford vd., 2018
BERT	Devlin vd., 2019
GPT-2	Radford vd., 2019
XLNet	Yang vd., 2020
RoBERTa	Liu vd., 2019
Megatron-LM	Shoeybi vd., 2020
ALBERT	Lan vd., 2020
GPT-3	Brown vd., 2020
ELECTRA	Clark vd., 2020
BART	Lewis vd., 2019
DeBERTa	He vd., 2021
Jurassic-1	Lieber vd., 2021
Megatron-Turing NLG	Smith vd., 2022
Chinchilla	Hoffmann vd., 2022
LaMDA	Thoppilan vd., 2022

5. GEREÇ VE YÖNTEM

Bu çalışma, doğal dil işlemenin nöroanatomik temelleri ve makine öğrenimi yöntemlerine dair literatürün sistematik bir şekilde incelenmesi yoluyla gerçekleştirilmiş bir derleme çalışmasıdır. Derleme süreci, ilgili alandaki temel ve güncel araştırmaların kapsanmasını hedeflemiştir.

Çalışmada yer alan literatür, 2025 yılına kadar yayınlanmış ağırlıklı olarak İngilizce dilindeki akademik kaynaklar arasından seçilmiştir. Bazı kaynaklar, ana kaynaktan bilgi edinmek amacıyla (örneğin, Broca, Wernicke ve Dejerine'in çalışmaları) Fransızca ve Almanca dillerinde incelenmiştir. Literatür taraması, PubMed, Scopus, ScienceDirect, IEEE Xplore, Google Scholar, SpringerLink, Wiley Online Library, Oxford Academic ve JStore veri tabanlarında gerçekleştirilmiştir. Makine öğreniminde kullanılan veri setleri GitHub üzerinden incelenmiştir. İlaveeten, literatür haritaları için ResearchRabbit yapay zekâ aracı ve kaynakça için Zotero yazılımı kullanılmıştır.

Literatür tarama sürecinde en sık kullanılan anahtar kelimeler şu şekildedir: “natural language processing”; “language processing in the brain”; “neuroanatomy of language processing”; “semantic reconstruction brain”; “neural basis of syntax/semantics processing”; “brain decoding”; “deep learning architectures”; “foundation of the machine learning”; “neuroimaging NLP”. Bu anahtar kelimeler Boolean operatörleri (“AND”, “OR”) ile birleştirilerek farklı kombinasyonlarla taramalar yapılmıştır.

Kaynak seçilirken, hakemli dergide yayınlanmış ve akademik nitelikte olması deneysel ya da kuramsal katkı sağlaması ve alıntılanma sayısı göz önüne alınmıştır. “GPT-4 Technical Report” gibi önemli fakat dergide yayınlanmamış çalışmalar hakemli dergi kriterinden muaf tutulmuştur. Popüler bilim veya akademik düzeyi yeterli olmayan kaynaklar ve yetersiz örneklem bilgisi veya metodoloji sunan deneysel çalışmalar literatür dışlama kriterleri olarak görülmüştür.

Taranan literatür, içerik analizi yöntemi ile incelenmiştir. Tematik başlıklar altında sınıflandırılmıştır. Bu başlıklar, çalışmanın alt bölümlerini oluşturmuştur. Her bir tema, ilişkili makalelerden elde edilen bulgularla desteklenmiş, örneklendirilmiştir.

Bu çalışma bir derleme niteliğinde olup herhangi bir bireysel deneysel veri içermemektedir. Bu nedenle etik kurul onayı gerektirmemektedir. Yazarın herhangi bir çıkar çatışması bulunmamaktadır.



6. PROBLEMLER, SINIRLILIKLAR VE GÜNCEL GELİŞMELER

Doğal dil işleme ile nörobilim arasındaki kesişim noktası, insan beyni ile yapay zekâ sistemleri arasında anlamlı bağlantılar kurarak her iki alanın da daha derinlemesine anlaşılmasını hedeflemektedir. Son yıllarda bu arayüzde kayda değer sayıda araştırma gerçekleştirilmiş, fakat beraberinde önemli sorunlar ve sınırlılıklar da gündeme gelmiştir. Öte yandan, bu alanda hızlı ve umut verici gelişmeler de yaşanmaktadır.

6.1. Problemler ve Sınırlılıklar

6.1.1. Korelasyon ve nedensellik ayrımı

NLP modelleri ile beyin aktivitesi arasındaki benzerliklere ilişkin çalışmalar genellikle korelasyonel bulgulara dayanmaktadır. Örneğin, bir Transformer modelinin belirli bir katmanı ile EEG'de gözlenen N400 etkisi arasında bir korelasyon saptanması dikkat çekicidir; ancak bu, modelin beyin çalışma biçimini birebir taklit ettiği anlamına gelmez. Embick ve Poeppel (2015), yalnızca korelasyon raporlamanın ötesine geçilerek açıklayıcı modellerin geliştirilmesi gerektiğini vurgulamaktadır. Başka bir ifadeyle, yapay bir model ile beyin dil işleme süreçleri arasında ilişki saptanması, hâlâ "nasıl" ve "neden" sorularını yanıtlamaktan uzaktır. Beyin farklı yollar izleyerek benzer çıktılara ulaşabilir ya da model, bambaşka temsiller aracılığıyla benzer sonuçlar üretebilir. Bu nedenle, NLP ve nörobilim arayüzündeki en temel sorunlardan biri, bulguların yorumlanmasında gereken ihtiyatlılıktır: Korelasyonlar umut verici olsa da nedensel eşdeğerlik anlamına gelmemektedir (Embick & and Poeppel, 2015). Henüz bir yapay modele küçük müdahaleler yapılarak beyin dil ağına öngörülebilir etkiler yaratma yönünde nedensel testler gerçekleştirilmemiştir; mevcut çalışmalar, genellikle mevcut modellerin pasif biçimde beyin verileriyle karşılaştırılmasıyla sınırlı kalmaktadır.

6.1.2. Model şeffaflığı ve yorumlanabilirlik

Modern derin öğrenme modelleri çoğunlukla "kara kutu" niteliği taşımaktadır. Bir modelin bir cümleyi nasıl temsil ettiğine ilişkin matematiksel bilgiler mevcut olsa da bu temsillerin insan tarafından kavranabilir açıklamalara dönüştürülmesi oldukça zordur. Nörobilimde de benzer bir zorluk söz konusudur: Beyindeki nöral kodlama süreçleri henüz bütünüyle çözülememiştir. Bu nedenle, iki karmaşık ve opak sistemi (biri beyin, diğeri yapay sinir ağı) karşılaştırmak, benzerlik veya farklılıkların kökenlerini anlamayı zorlaştırmaktadır. Nöral temsillerin anlamsal içeriği hâlâ açıklığa kavuşmamış olduğundan, bir modelin beyinle benzerlik göstermesinin ne anlama geldiği belirsiz kalmaktadır. Örneğin, GPT-2'nin beşinci katmanı ile EEG verileri arasında korelasyon saptandığında, bu katmanın neyi temsil ettiği ve EEG'deki bileşenin neye duyarlı olduğu hâlâ bilinmemektedir. Bu durum hem yapay zekâ hem nörobilim topluluğunda yorumlanabilirliğe yönelik çalışmaları teşvik etmektedir. Model tarafında, dikkat mekanizmaları ya da aktivasyon görselleştirmeleri yoluyla hangi bilginin nerede kodlandığını anlamaya yönelik araştırmalar yürütülmektedir. Beyin tarafında ise yapay modeller aracılığıyla beyin verisine anlam kazandırmaya çalışan encoding/decoding yaklaşımları geliştirilmektedir. Ancak her iki sistemin karmaşıklığı göz önüne alındığında, şeffaflık hâlâ ciddi bir sınırlılık olarak öne çıkmaktadır.

6.1.3. Veri uyumsuzluğu

Nörobilimsel veriler ile NLP modellerinin verileri yapısal olarak oldukça farklıdır. fMRI, EEG, MEG gibi tekniklerden elde edilen beyin verileri yüksek boyutlu, gürültülü ve sınırlı sayıda örnek içermektedir. Bir deneyde en fazla birkaç yüz cümle dinletilebilir ve sınırlı sayıda ölçüm alınabilir; çünkü insan katılımcılarla çalışmanın doğal sınırları vardır. Buna karşın, yapay modeller milyonlarca cümleyle eğitilmiştir. Bu dengesizlik, verinin NLP modellerine uygun biçimde uyarlandığı durumlarda bile metodolojik sorunlar doğurabilmektedir. Sıklıkla modelin aktivasyonlarından beyin aktivitesini lineer regresyon ile tahmin etmeye çalışan kodlayıcı modeller kullanılmaktadır (Mitchell vd., 2008; Huth vd., 2016). Ancak bu yaklaşımda modelin parametreleri sabit kalır ve yalnızca eşleme katsayıları öğrenilmektedir. Bu yöntemle yüksek korelasyon elde edilmesi, modelin beyinle aynı şekilde çalıştığını değil, yalnızca

eşlemenin başarılı yapıldığını gösterebilir. Ayrıca, beyin verileri bireyler arasında önemli değişkenlikler göstermektedir. Bir modelin bir kişideki dil aktivitesini doğru tahmin etmesi, başka bir bireyde genellenemeyebilir. Genellikle grup düzeyinde ortalamalar kullanılması ise bireysel farklılıkları maskeleymektedir. Bu tür metodolojik sınırlılıkların, daha geniş veri kümeleri ya da bireysel düzeyde derinlemesine ölçümlerle aşılması beklenmektedir.

6.1.4. Görev ve becerilerin kısıtlı tanımlanması

NLP modelleri dil görevlerini çoğunlukla dar kapsamlı biçimlerde işlemektedir. Oysa insan için dil, yalnızca bir bilgi aktarım aracı değil; düşünme, duyguları ifade etme ve toplumsal etkileşimde bulunma aracıdır. Modeller, dili büyük ölçüde metinsel diziler olarak işlerken, insanların dili bağlamsal ve amaç odaklı biçimde kullandıkları unutulmamalıdır. Örneğin insanlar bir diyalogu niyetleri anlamak için takip ederken, modeller henüz niyet gibi kavramları içsel olarak temsil edemez, yalnızca olasılıksal tahminleri üretmektedir. Bu da model ve insan beyninin hedef işlevlerinin farklı olduğu anlamına gelir. Arayüz araştırmalarında bu ayrım çoğu zaman göz ardı edilmektedir. Gerçekte, insan benzeri dil kullanımı testi yalnızca cümle eşleştirmesi ile sınırlı kalmamalı, daha zengin ve gerçekçi ortamlarda gerçekleştirilmelidir. Ancak bu tür deneyler oldukça zordur. Mevcut çalışmalar genellikle bir hikâyeye dinlenirken elde edilen beyin aktivitesi ile model çıktısının karşılaştırılması gibi sınırlı senaryolar içermektedir. Mizah ve mecaz gibi dilin bilişsel bileşenleri yapay modellerde yeterince temsil edilmediği için bu alanlar arayüz çalışmalarında büyük ölçüde boşlukta kalmaktadır. Kısacası, NLP ve nörobilim arayüzü hâlen sözdizimsel ve anlamsal işlemeyle sınırlı kalmaktadır.

6.1.5. Etik ve güvenlik endişeleri

Büyük dil modellerinin insan benzeri dil üretme yeteneği, yanlış bilginin yayılması ve önyargıların pekişmesi gibi etik sorunları da beraberinde getirmiştir (Bender vd., 2021). Nörobilimde ise beyin verisinin mahremiyeti ve bireyin zihinsel süreçlerine

izinsiz erişim gibi kaygılar mevcuttur. Bu iki alan birleştiğinde yeni etik sorunlar doğmaktadır. Örneğin, bir yapay model beyin sinyallerinden bireyin içsel konuşmalarını ya da düşüncelerini çözümleyebilirse, bu teknoloji nasıl denetlenmelidir? Henüz erken aşamada olmasına karşın, arayüz alanındaki gelişmeler bu tür zihinsel mahremiyet konularını giderek daha önemli hale getirmektedir. Örneğin Tang vd. (2023), fMRI beyin verisinden deneğin dinlediği bir hikâyeyi GPT-tabanlı bir model ile %80 doğrulukla yeniden yapılandırmayı başarmıştır. Bu etkileyici bilimsel başarı, aynı zamanda bireylerin zihinsel içeriklerinin rızaları dışında açığa çıkarılması ihtimaline dair endişeleri de artırmıştır. Dolayısıyla, arayüz alanındaki teknik ilerlemelerin etik boyutu da dikkate alınması gereken önemli bir sınırlılıktır.

6.2. Güncel Gelişmeler

NLP ve nörobilim arayüzü, yukarıda belirtilen metodolojik ve teorik sınırlamalara rağmen, son yıllarda son derece hızlı ilerleyen ve hem bilimsel hem teknolojik açıdan büyük umut vadeden bir alan hâline gelmiştir. Bu alandaki gelişmeler, hem daha önce uygulanması mümkün olmayan araştırma yöntemlerinin kullanımını mümkün kılmakta hem de dil işleme teknolojilerini ve nörobilim kuramlarını ileri taşımaktadır.

6.2.1. Beyin ilhamlı yapay modeller

Araştırmacılar, insan beyninin bilgi işleme mekanizmalarından ilham alarak yeni sinir ağı mimarileri geliştirmeye başlamışlardır. Örneğin, beyin çalışma belleği süreçlerinden esinlenerek, modellere nöromodülatör işlevleri ya da dinamik bellek modülleri entegre edilmektedir. Aynı şekilde, insan beyninin dil işleme sırasında geribildirim sinyalleri kullandığı bilgisinden hareketle, yalnızca ileri beslemeli Transformer yapılarının ötesine geçerek, karşılıklı dikkat mekanizmalarını içeren geri beslemeli modeller tasarlanmaktadır. Recurrent Memory Transformer gibi bazı yapılar, uzun bağlamlarda daha insana benzer biçimde bilgi tutma amacı gütmektedir. Bu tür gelişmeler, modellerin bilişsel planda daha gerçekçi ve biyolojik olarak daha uygun hale gelmesine katkı sağlayabilir. Benzer şekilde, çoklu modalite (multimodalite) ilkesine

dayanan modelleme yaklaşımları da öne çıkmaktadır. İnsan beyni, dili yalnızca metinsel değil, aynı zamanda görsel ve işitsel bağlamlarla birlikte işler. GPT-4 ve PaLM-E gibi modeller, metne ek olarak görsel ve işitsel girdilerle eğitilerek çoklu modaliteler arası entegrasyon yetisi kazanmaktadır. Bu modeller, örneğin bir görsel hakkında sorulan soruya yanıt verebilmekte veya görsel ipuçları ile dil bilgisini birleştirebilmektedir. Bu yönüyle insan zihnindeki çok boyutlu anlamsal bütünlüğe yaklaşmaktadırlar. Gelecekte dokunsal ya da başka duyuşsal modalitelerle eğitilen modellerin daha “bedenlenmiş” (embodied) bir dil anlayışı sergilemesi mümkündür. Bu, yalnızca NLP performansını artırmakla kalmayacak, aynı zamanda nörobilimsel karşılaştırmaların daha gerçekçi temeller üzerine oturtulmasını sağlayacaktır.

6.2.2. Beyin verisi ile model eğitimi

Yeni ortaya çıkan bazı araştırmalarda, yapay modeller doğrudan beyin verileri ile eğitilmekte ya da bu verilerle ince ayar yapılmaktadır. Örneğin, bazı dil modellerinin belirli bileşenleri, fMRI verilerindeki beyin aktivitesini tahmin edecek biçimde optimize edilmiştir. Bu yaklaşım, modelin temsil uzayının, beyin aktivite uzayıyla hizalanmasını hedeflemektedir (Merlin & Toneva, 2024). İlk bulgular, bu tür modellerin hem dil tahmini görevlerinde daha başarılı performans sergilediğini hem de beyin verileri ile daha yüksek korelasyon gösterdiğini ortaya koymaktadır. Bu durum, modelin hem bilişsel uygunluk hem dil işlevselliği açısından gelişimini sağlayan ilginç bir geri besleme döngüsüne işaret etmektedir. Brain-Score gibi girişimler, bir dil modelinin insan beynine ne derece benzer çalıştığını değerlendiren nörobilimsel ölçütler sunarak, model geliştirme sürecine biyolojik uygunluk temelli bir hedef kazandırmaktadır (Schrimpf vd., 2021). Yakın gelecekte, bir modelin mimarisi veya hiperparametreleri yalnızca NLP görev performansına göre değil, aynı zamanda beyinle uyumluluğuna göre de değerlendirilecektir. Bu durum, yapay zekâ araştırmalarına nörobilimsel optimizasyonun entegre edilmesi anlamına gelmektedir.

6.2.3. Zihin okuma ve beyin-bilgisayar arayüzü

NLP teknikleri, nörobilimin uygulamalı alanlarında da dönüştürücü yeniliklere olanak tanımaktadır. Özellikle beyin-bilgisayar arayüzü (Brain-Computer Interface, BCI) kapsamında, bireyin düşündüğü, duyduğu ya da söylemek istediği ifadeleri beyin sinyallerinden çözümleyebilmek amacıyla dil modelleri kullanılmaktadır. 2023 yılında Nature Neuroscience’da yayımlanan bir çalışmada, bir bireyin sessizce düşündüğü cümleler, fMRI verilerinden hareketle GPT tabanlı bir model aracılığıyla yüksek doğrulukla yeniden inşa edilmiştir (Tang vd., 2023). Bu çalışmada, beyin aktivitesinden çıkarılan özellikler bir dil modeline aktarılmış ve anlam açısından en uygun metin seçilerek “içerik tahmini” gerçekleştirilmiştir. Bunun sonucunda, katılımcı bir hikâyeyi yalnızca zihninden okurken, model, bu zihinsel içeriğe oldukça yakın metinler üretebilmiştir. Bu gelişme, kamuoyunda “zihin okuma” olarak nitelendirilmiş ve geniş ilgi uyandırmıştır. Benzer şekilde, konuşma yetisini kaybetmiş bireylerin (örneğin ALS hastaları) beyin sinyalleri gerçek zamanlı olarak metne dönüştürülebilmekte, dil modelleri bu sürece akıcılık ve tutarlılık kazandırmaktadır (Willett vd., 2023). Elektrokortikografi verisinden çıkarılan karakterler ya da kelimeler, dil modeli ile birleştirilerek tutarlı cümleler oluşturulmakta, böylece kişi yalnızca düşünerek ekrana yazı yazdırabilmekte ya da sentezlenmiş ses yoluyla iletişim kurabilmektedir. Bu tür BCI sistemlerinde büyük dil modelleri, beyin sinyalindeki gürültüyü azaltarak anlamlı ve doğal çıktılarının üretilmesini kolaylaştırmaktadır. Bu gelişmeler, özellikle felçli bireyler için devrimsel iletişim araçlarının geliştirilmesine olanak tanımaktadır.

6.2.4. Bilişsel hesaplamalı sinirbilim yaklaşımları

Teorik düzlemde, insan beyninde dilin nasıl temsil edildiğini anlamaya yönelik olarak yapay modellerin hipotez uzayı şeklinde kullanıldığı yeni araştırma yönelimleri gelişmektedir. Bilişsel hesaplamalı nörobilim olarak adlandırılan bu alanda, dilbilimciler ve bilişsel bilimciler, büyük dil modellerini insan dil davranışlarını test etmek amacıyla kullanmaktadır. Örneğin, insanların dilde yaptığı hatalar, ipuçlarına verdikleri tepkiler ya da cümle yapılarını işleme biçimleri, bu modeller aracılığıyla simüle edilmekte ve karşılaştırılmaktadır. Eğer model ile insan benzer çıktılar veriyorsa, modelin içsel işleyişi üzerinden insan zihnindeki süreçler hakkında çıkarım yapılabilmektedir. Bu yaklaşım, klasik nöropsikolojik lezyon çalışmalarına benzer biçimde "model lezyonlama" yöntemlerini de içermektedir. Örneğin bir modelin belirli bir katmanı devre dışı

birakıldığında anlamlılık bozuluyorsa, bu, insan beyninde benzer bir işlevin hangi bölgeyle ilişkili olabileceğine dair ipuçları sunabilir (Mahowald vd., 2024)s. Bu tür çalışmalar henüz erken aşamadır, ancak gelecekte entegre beyin-dil sistemlerinin oluşturulması yönünde önemli adımlar olarak değerlendirilmektedir.

6.2.5. Daha gerçekçi simülasyonlar

Güncel eğilimlerden biri, yapay modellerin daha gerçekçi dil öğrenme koşullarında test edilmesidir. Örneğin, simüle edilmiş bir ortamda yer alan yapay ajanlara hem görsel dünya hem dilsel girdiler sunularak, bu ajanların çevreyle etkileşim kurarken dil öğrenmeleri sağlanmaktadır (Hill vd., 2020). Bu tür çalışmalar, çocukların çevreyle etkileşim içinde dil edinmesini modellemeye yöneliktir. Model bir yandan nesnelere algılamakta, diğer yandan onların adlarını duymakta ve anlam ilişkileri kurmaktadır. Bu sayede, dil öğrenimi süreci insan benzeri bir çerçeveye taşınmaktadır. Bu yaklaşımlar, hem yapay modellerin daha insansı hale gelmesini hem de insan öğrenmesi hakkında yeni hipotezlerin geliştirilmesini mümkün kılmaktadır. Yakın dönemde Meta AI (Facebook AI) araştırmacıları, çocukların çevresel istatistiklere dayalı dil edinim süreçlerini taklit eden bir model geliştirerek, bu modelin beyin aktivasyonlarına benzer temsiller üretebildiğini bildirmiştir (Goldstein vd., 2022; Schrimpf vd., 2021). Bu tür "bebek model/bebek beyin" karşılaştırmaları, gelecekte dil edinim kuramlarını test etmek için güçlü bir yöntem sunabilir.

7. SONUÇ VE ÖNERİLER

Sonuç olarak, NLP ve nörobilim kesişiminde yer alan bu disiplinler arası alan, mevcut teorik ve pratik sınırlamalara rağmen, büyük bir ivmeyle gelişmekte ve hem insan beynini hem de yapay sistemleri daha derinlemesine anlama fırsatı sunmaktadır. Nihai hedef, dil yetisinin hem biyolojik hem yapay sistemlerde eksiksiz bir şekilde modellenmesi ve anlaşılmasıdır. Bu doğrultuda atılan her adım, insan-makine arasındaki bilişsel boşluğu kapatmaya katkı sağlamaktadır.



KAYNAKLAR

- Agarap, A. F. (2019). *Deep Learning using Rectified Linear Units (ReLU)* (No. arXiv:1803.08375). arXiv. <https://doi.org/10.48550/arXiv.1803.08375>
- Ahmad, A., Jagdhane, N., Ademmer, K., & Choudhari, K. (2024). Carl Wernicke of the Wernicke Area: A Historical Review. *World Neurosurgery*, 185, 225-233. <https://doi.org/10.1016/j.wneu.2024.02.103>
- Akın, E., & Şahin, M. E. (2024). Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*, 14(1), Article 1.
- Alcaide, E. (2018). *E-swish: Adjusting Activations to Different Network Depths* (No. arXiv:1801.07145). arXiv. <https://doi.org/10.48550/arXiv.1801.07145>
- Amin, M. S., Anselma, L., & Mazzei, A. (2022). The Role of Activation Function in Neural NER for a Large Semantically Annotated Corpus. *2022 International Conference on Emerging Trends in Electrical, Control, and Telecommunication Engineering (EECTE)*, 1-6. <https://doi.org/10.1109/EECTE55893.2022.10007317>
- Anderson, J. M., Gilmore, R., Roper, S., Crosson, B., Bauer, R. M., Nadeau, S., Beversdorf, D. Q., Cibula, J., Rogish, M., Kortencamp, S., Hughes, J. D., Gonzalez Rothi, L. J., & Heilman, K. M. (1999). Conduction Aphasia and the Arcuate Fasciculus: A Reexamination of the Wernicke–Geschwind Model. *Brain and Language*, 70(1), 1-12. <https://doi.org/10.1006/brln.1999.2135>
- Anumanchipalli, G. K., Chartier, J., & Chang, E. F. (2019). Speech synthesis from neural decoding of spoken sentences. *Nature*, 568(7753), 493-498. <https://doi.org/10.1038/s41586-019-1119-1>
- Avenash, R., & Viswanath, P. (2019). Semantic Segmentation of Satellite Images using a Modified CNN with Hard-Swish Activation Function: *Proceedings of the 14th*

- International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, 413-420.
<https://doi.org/10.5220/0007469604130420>
- Bachman, P., Alsharif, O., & Precup, D. (2014). *Learning with Pseudo-Ensembles* (No. arXiv:1412.4864). arXiv. <https://doi.org/10.48550/arXiv.1412.4864>
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495.
<https://doi.org/10.1109/TPAMI.2016.2644615>
- Bahdanau, D., Cho, K., & Bengio, Y. (2016). *Neural Machine Translation by Jointly Learning to Align and Translate* (No. arXiv:1409.0473). arXiv. <https://doi.org/10.48550/arXiv.1409.0473>
- Basirat, M., & Roth, P. M. (2018). *The Quest for the Golden Activation Function* (No. arXiv:1808.00783). arXiv. <https://doi.org/10.48550/arXiv.1808.00783>
- Basso, A., Casati, G., & Vignolo, L. A. (1977). Phonemic Identification Defect in Aphasia. *Cortex*, 13(1), 85-95. [https://doi.org/10.1016/S0010-9452\(77\)80057-9](https://doi.org/10.1016/S0010-9452(77)80057-9)
- Ben Shalom, D., & Poeppel, D. (2008). Functional Anatomic Models of Language: Assembling the Pieces. *The Neuroscientist*, 14(1), 119-127.
<https://doi.org/10.1177/1073858407305726>
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? [!\[\]\(209d2706cf6994add696a6951d663df9_img.jpg\)...Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency](#), 610-623.
<https://doi.org/10.1145/3442188.3445922>
- Binder, J. R., Frost, J. A., Hammeke, T. A., Bellgowan, P. S. F., Springer, J. A., Kaufman, J. N., & Possing, E. T. (2000). Human Temporal Lobe Activation by Speech and

- Nonspeech Sounds. *Cerebral Cortex*, 10(5), 512-528.
<https://doi.org/10.1093/cercor/10.5.512>
- Binder, J. R., Rao, S. M., Hammeke, T. A., Yetkin, F. Z., Jesmanowicz, A., Bandettini, P. A., Wong, E. C., Estkowski, L. D., Goldstein, M. D., Haughton, V. M., & Hyde, J. S. (1994). Functional magnetic resonance imaging of human auditory cortex. *Annals of Neurology*, 35(6), 662-672. <https://doi.org/10.1002/ana.410350606>
- Blumstein, S. E., Baker, E., & Goodglass, H. (1977). Phonological factors in auditory comprehension in aphasia. *Neuropsychologia*, 15(1), 19-30.
[https://doi.org/10.1016/0028-3932\(77\)90111-7](https://doi.org/10.1016/0028-3932(77)90111-7)
- Bornkessel, I., & Schlesewsky, M. (2006). The extended argument dependency model: A neurocognitive approach to sentence comprehension across languages. *Psychological Review*, 113(4), 787-821. <https://doi.org/10.1037/0033-295X.113.4.787>
- Braud, C., Lacroix, O., & Søgaard, A. (2017). *Cross-lingual and cross-domain discourse segmentation of entire documents* (No. arXiv:1704.04100). arXiv.
<https://doi.org/10.48550/arXiv.1704.04100>
- Broca, M. P. (1961). REMARQUES SUR LE SIÈGE DE LA FACULTÉ DU LANGAGE ARTICULÉ, SUIVIES D'UNE OBSERVATION D'APHÉMIE (PERTE DE LA PAROLE). *Bulletin et Memoires de la Societe anatomique de Paris*, 6, 330-357.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D., Wu, J., Winter, C., ... Amodei, D. (2020). Language Models are Few-Shot Learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901.

<https://proceedings.neurips.cc/paper/2020/hash/1457c0d6bfc4967418bf8ac142f64a-Abstract.html>

- Buchsbaum, B. R., Baldo, J., Okada, K., Berman, K. F., Dronkers, N., D'Esposito, M., & Hickok, G. (2011). Conduction aphasia, sensory-motor integration, and phonological short-term memory – An aggregate analysis of lesion and fMRI data. *Brain and Language*, *119*(3), 119-128. <https://doi.org/10.1016/j.bandl.2010.12.001>
- Bunzeck, N., Wuestenberg, T., Lutz, K., Heinze, H.-J., & Jancke, L. (2005). Scanning silence: Mental imagery of complex sounds. *NeuroImage*, *26*(4), 1119-1127. <https://doi.org/10.1016/j.neuroimage.2005.03.013>
- Campolo, A., Sanfilippo, M. R., Whittaker, M., & Crawford, K. (2017). *AI Now 2017 Report*. AI Now Institute at New York University.
- Caucheteux, C., & King, J.-R. (2022). Brains and algorithms partially converge in natural language processing. *Communications Biology*, *5*(1), 134. <https://doi.org/10.1038/s42003-022-03036-1>
- Cauquil-Michon, C., Flamand-Roze, C., & Denier, C. (2011). Borderzone Strokes and Transcortical Aphasia. *Current Neurology and Neuroscience Reports*, *11*(6), 570-577. <https://doi.org/10.1007/s11910-011-0221-z>
- Chen, J. (2024). Exploring the Legal Accuracy of Mathematical Models in Crime Sentencing Prediction in the Face of Criminal Procedure Law Practice Needs. *Applied Mathematics and Nonlinear Sciences*, *9*(1). <https://doi.org/10.2478/amns-2024-2479>
- Cho, K., Merriënboer, B. van, Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). *Learning Phrase Representations using RNN Encoder-*

- Decoder for Statistical Machine Translation* (No. arXiv:1406.1078). arXiv.
<https://doi.org/10.48550/arXiv.1406.1078>
- Chomsky, N. (2014). *Aspects of the Theory of Syntax, 50th Anniversary Edition*. MIT Press.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling* (No. arXiv:1412.3555). arXiv.
<https://doi.org/10.48550/arXiv.1412.3555>
- Clark, K., Luong, M.-T., Le, Q. V., & Manning, C. D. (2020). *ELECTRA: Pre-training Text Encoders as Discriminators Rather Than Generators* (No. arXiv:2003.10555). arXiv. <https://doi.org/10.48550/arXiv.2003.10555>
- Collobert, R., Com, C., Weston, J., Bottou, L., Org, B., Karlen, M., Karlen, M., Kavukcuoglu, K., & Kuksa, P. (2011). Natural Language Processing (Almost) from Scratch. *NATURAL LANGUAGE PROCESSING*.
<https://www.jmlr.org/papers/volume12/collobert11a/collobert11a.pdf?source>
- Conneau, A., Kiela, D., Schwenk, H., Barrault, L., & Bordes, A. (2018). *Supervised Learning of Universal Sentence Representations from Natural Language Inference Data* (No. arXiv:1705.02364). arXiv.
<https://doi.org/10.48550/arXiv.1705.02364>
- Damasio, A. R. (1983). Pure alexia. *Trends in Neurosciences*, 6, 93-96.
[https://doi.org/10.1016/0166-2236\(83\)90046-2](https://doi.org/10.1016/0166-2236(83)90046-2)
- Dash, D., Ferrari, P., & Wang, J. (2020). Decoding Imagined and Spoken Phrases From Non-invasive Neural (MEG) Signals. *Frontiers in Neuroscience*, 14.
<https://doi.org/10.3389/fnins.2020.00290>

- Dayan, A., & Yılmaz, A. (2022). Doğal dil işleme ve derin öğrenme algoritmaları ile makine dili modellemesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(3), Article 3. <https://doi.org/10.24012/dumf.1131565>
- Dejerine, J. J. (1891). Sur un cas de cécité verbale avec agraphie suivi d'autopsie. *Mémoires de la Société de Biologie*, 3, 197-201.
- Dejerine, J. J. (1892). Contribution à l'étude anatomopathologique et clinique des différents variétés de cécité verbale. *Mémoires de la Société de Biologie*, 4, 61-90.
- Deouell, L. Y., Heller, A. S., Malach, R., D'Esposito, M., & Knight, R. T. (2007). Cerebral Responses to Change in Spatial Location of Unattended Sounds. *Neuron*, 55(6), 985-996. <https://doi.org/10.1016/j.neuron.2007.08.019>
- Desimone, R. (1991). Face-Selective Cells in the Temporal Cortex of Monkeys. *Journal of Cognitive Neuroscience*, 3(1), 1-8. <https://doi.org/10.1162/jocn.1991.3.1.1>
- Dettmers, T. (2015, Aralık 16). *Deep Learning in a Nutshell: History and Training*. NVIDIA Technical Blog. <https://developer.nvidia.com/blog/deep-learning-nutshell-history-training/>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. İçinde J. Burstein, C. Doran, & T. Solorio (Ed.), *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)* (ss. 4171-4186). Association for Computational Linguistics. <https://doi.org/10.18653/v1/N19-1423>

- Eger, S., Youssef, P., & Gurevych, I. (2019). *Is it Time to Swish? Comparing Deep Learning Activation Functions Across NLP tasks* (No. arXiv:1901.02671). arXiv. <https://doi.org/10.48550/arXiv.1901.02671>
- El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? İçinde I. El Naqa, R. Li, & M. J. Murphy (Ed.), *Machine Learning in Radiation Oncology: Theory and Applications* (ss. 3-11). Springer International Publishing. https://doi.org/10.1007/978-3-319-18305-3_1
- Eling, P. (2011). Lichtheim's golden shot. *Cortex*, 47(4), 501-508. <https://doi.org/10.1016/j.cortex.2010.06.008>
- Embick, D., & Poeppel, D. (2015). Towards a computational(ist) neurobiology of language: Correlational, integrated and explanatory neurolinguistics. *Language, Cognition and Neuroscience*, 30(4), 357-366. <https://doi.org/10.1080/23273798.2014.980750>
- Fedorenko, E., Hsieh, P.-J., Nieto-Castañón, A., Whitfield-Gabrieli, S., & Kanwisher, N. (2010). New Method for fMRI Investigations of Language: Defining ROIs Functionally in Individual Subjects. *Journal of Neurophysiology*, 104(2), 1177-1194. <https://doi.org/10.1152/jn.00032.2010>
- Fedorenko, E., & Thompson-Schill, S. L. (2014). Reworking the language network. *Trends in Cognitive Sciences*, 18(3), 120-126. <https://doi.org/10.1016/j.tics.2013.12.006>
- Fei-Fei, L., Fergus, R., & Perona, P. (2006). One-shot learning of object categories. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(4), 594-611. <https://doi.org/10.1109/TPAMI.2006.79>

- Fink, M. A. (2023). From data to insights: How natural language processing and structured reporting advance data-driven radiology. *European Radiology*, 33(11), 7494-7495. <https://doi.org/10.1007/s00330-023-10242-w>
- Forster, K. I. (1981). Priming and the effects of sentence and lexical contexts on naming time: Evidence for autonomous lexical processing. *The Quarterly Journal of Experimental Psychology Section A*, 33(4), 465-495. <https://doi.org/10.1080/14640748108400804>
- Frazier, L. (1987). Sentence processing: A tutorial review. İçinde *Attention and performance 12: The psychology of reading* (ss. 559-586). Lawrence Erlbaum Associates, Inc.
- Fridriksson, J., den Ouden, D.-B., Hillis, A. E., Hickok, G., Rorden, C., Basilakos, A., Yourganov, G., & Bonilha, L. (2018). Anatomy of aphasia revisited. *Brain*, 141(3), 848-862. <https://doi.org/10.1093/brain/awx363>
- Fridriksson, J., Yourganov, G., Bonilha, L., Basilakos, A., Den Ouden, D.-B., & Rorden, C. (2016). Revealing the dual streams of speech processing. *Proceedings of the National Academy of Sciences*, 113(52), 15108-15113. <https://doi.org/10.1073/pnas.1614038114>
- Friederici, A. D. (2002). Towards a neural basis of auditory sentence processing. *Trends in Cognitive Sciences*, 6(2), 78-84. [https://doi.org/10.1016/S1364-6613\(00\)01839-8](https://doi.org/10.1016/S1364-6613(00)01839-8)
- Friederici, A. D. (2006). The Neural Basis of Language Development and Its Impairment. *Neuron*, 52(6), 941-952. <https://doi.org/10.1016/j.neuron.2006.12.002>
- Friederici, A. D. (2011). The Brain Basis of Language Processing: From Structure to Function. *Physiological Reviews*, 91(4), 1357-1392. <https://doi.org/10.1152/physrev.00006.2011>

- Friederici, A. D., Meyer, M., & von Cramon, D. Y. (2000). Auditory Language Comprehension: An Event-Related fMRI Study on the Processing of Syntactic and Lexical Information. *Brain and Language*, 74(2), 289-300. <https://doi.org/10.1006/brln.2000.2313>
- Friederici, A. D., Rüschemeyer, S.-A., Hahne, A., & Fiebach, C. J. (2003). The Role of Left Inferior Frontal and Superior Temporal Cortex in Sentence Comprehension: Localizing Syntactic and Semantic Processes. *Cerebral Cortex*, 13(2), 170-177. <https://doi.org/10.1093/cercor/13.2.170>
- Fu, J., Zheng, H., & Mei, T. (2017). Look Closer to See Better: Recurrent Attention Convolutional Neural Network for Fine-Grained Image Recognition. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4476-4484. <https://doi.org/10.1109/CVPR.2017.476>
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193-202. <https://doi.org/10.1007/BF00344251>
- Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural Networks*, 1(2), 119-130. [https://doi.org/10.1016/0893-6080\(88\)90014-7](https://doi.org/10.1016/0893-6080(88)90014-7)
- Gaizo, J. D., Sherard, C., Shorbaji, K., Welch, B., Mathi, R., & Kilic, A. (2024). Prediction of coronary artery bypass graft outcomes using a single surgical note: An artificial intelligence-based prediction model study. *PLOS ONE*, 19(4), e0300796. <https://doi.org/10.1371/journal.pone.0300796>
- Garofolo, J. S., Lamel, L. F., Fisher, W. M., Fiscus, J. G., & Pallett, D. S. (1993). DARPA TIMIT acoustic-phonetic continuous speech corpus CD-ROM. NIST speech disc

- 1-1.1. İçinde *NASA STI/Recon Technical Report N* (C. 93, s. 27403).
<https://ui.adsabs.harvard.edu/abs/1993STIN...9327403G>
- Gehring, J., Auli, M., Grangier, D., Yarats, D., & Dauphin, Y. N. (2017). Convolutional Sequence to Sequence Learning. *Proceedings of the 34th International Conference on Machine Learning*, 1243-1252.
<https://proceedings.mlr.press/v70/gehring17a.html>
- Geranmayeh, F., Brownsett, S. L. E., & Wise, R. J. S. (2014). Task-induced brain activity in aphasic stroke patients: What is driving recovery? *Brain*, 137(10), 2632-2648.
<https://doi.org/10.1093/brain/awu163>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, 12(10), 2451-2471.
<https://doi.org/10.1162/089976600300015015>
- Gers, F. A., Schraudolph, N. N., & Schmidhuber, J. (2002). Learning Precise Timing with LSTM Recurrent Networks. *Journal of Machine Learning Research*, 3(Aug), 115-143.
- GESCHWIND, N. (1965). DISCONNEXION SYNDROMES IN ANIMALS AND MAN1. *Brain*, 88(3), 585. <https://doi.org/10.1093/brain/88.3.585>
- GESCHWIND, N., & FUSILLO, M. (1966). Color-Naming Defects in Association With Alexia. *Archives of Neurology*, 15(2), 137-146.
<https://doi.org/10.1001/archneur.1966.00470140027004>
- Geschwind, N. (1970). The Organization of Language and the Brain. *Science*, 170(3961), 940-944. <https://doi.org/10.1126/science.170.3961.940>
- Geschwind, N. (1971). Aphasia. *New England Journal of Medicine*, 284(12), 654-656.
<https://doi.org/10.1056/NEJM197103252841206>

- Geschwind, N. (1974). Disconnexion Syndromes in Animals and Man. İçinde N. Geschwind (Ed.), *Selected Papers on Language and the Brain* (ss. 105-236). Springer Netherlands. https://doi.org/10.1007/978-94-010-2093-0_8
- Geschwind, N., Quadfasel, F. A., & Segarra, JoséM. (1968). Isolation of the speech area. *Neuropsychologia*, 6(4), 327-340. [https://doi.org/10.1016/0028-3932\(68\)90005-5](https://doi.org/10.1016/0028-3932(68)90005-5)
- Go, A., Bhayani, R., & Huang, L. (2009). Twitter Sentiment Classification using Distant Supervision. *CS224N Project Report, Stanford, 12*. <https://www-cs-faculty.stanford.edu/people/alecmgo/papers/TwitterDistantSupervision09.pdf>
- Goldstein, A., Zada, Z., Buchnik, E., Schain, M., Price, A., Aubrey, B., Nastase, S. A., Feder, A., Emanuel, D., Cohen, A., Jansen, A., Gazula, H., Choe, G., Rao, A., Kim, C., Casto, C., Fanda, L., Doyle, W., Friedman, D., ... Hasson, U. (2022). Shared computational principles for language processing in humans and deep language models. *Nature Neuroscience*, 25(3), 369-380. <https://doi.org/10.1038/s41593-022-01026-4>
- Goldstein, K. (1914). Einige Bemerkungen zu der Arbeit von Stertz: Die klinische Stellung der amnestischen und transkortikalen Aphasie usw. *Deutsche Zeitschrift für Nervenheilkunde*, 52(5-6), 504-514. <https://doi.org/10.1007/BF01649812>
- Golkov, V., Dosovitskiy, A., Sperl, J. I., Menzel, M. I., Czisch, M., Sämann, P., Brox, T., & Cremers, D. (2016). q-Space Deep Learning: Twelve-Fold Shorter and Model-Free Diffusion MRI Scans. *IEEE Transactions on Medical Imaging*, 35(5), 1344-1351. <https://doi.org/10.1109/TMI.2016.2551324>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning* (2. bs, C. 1). Cambridge: MIT press. <https://mitpress.mit.edu/9780262035613/deep-learning/>

- Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H., & Schmidhuber, J. (2009). A Novel Connectionist System for Unconstrained Handwriting Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(5), 855-868. <https://doi.org/10.1109/TPAMI.2008.137>
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5), 602-610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- Graves, R. E. (1997). The Legacy of the Wernicke-Lichtheim Model*. *Journal of the History of the Neurosciences*, 6(1), 3-20. <https://doi.org/10.1080/09647049709525682>
- Griffiths, T. D., & Warren, J. D. (2002). The planum temporale as a computational hub. *Trends in Neurosciences*, 25(7), 348-353. [https://doi.org/10.1016/S0166-2236\(02\)02191-4](https://doi.org/10.1016/S0166-2236(02)02191-4)
- Grodzinsky, Y. (2000). The neurology of syntax: Language use without Broca's area. *Behavioral and Brain Sciences*, 23(1), 1-21. <https://doi.org/10.1017/S0140525X00002399>
- Gwilliams, L., King, J.-R., Marantz, A., & Poeppel, D. (2022). Neural dynamics of phoneme sequences reveal position-invariant code for content and order. *Nature Communications*, 13(1), 6606. <https://doi.org/10.1038/s41467-022-34326-1>
- Hagoort, P. (2013). MUC (Memory, Unification, Control) and beyond. *Frontiers in Psychology*, 4. <https://doi.org/10.3389/fpsyg.2013.00416>
- Hagoort, P. (2014). Nodes and networks in the neural architecture for language: Broca's region and beyond. *Current Opinion in Neurobiology*, 28, 136-141. <https://doi.org/10.1016/j.conb.2014.07.013>

- Hagoort, P. (2017). The neural basis for primary and acquired language skills. İçinde E. Segers & P. van den Broek (Ed.), *Developmental Perspectives in Written Language and Literacy: In honor of Ludo Verhoeven* (ss. 17-27). John Benjamins Publishing Company.
<https://www.degruyterbrill.com/document/doi/10.1075/z.206.02hag/html>
- Hahnloser, R. H. R., Sarpeshkar, R., Mahowald, M. A., Douglas, R. J., & Seung, H. S. (2000). *Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit.*
- Hammad, M. M. (2024). *Artificial Neural Network and Deep Learning: Fundamentals and Theory* (No. arXiv:2408.16002). arXiv.
<https://doi.org/10.48550/arXiv.2408.16002>
- Haynes, J.-D., & Rees, G. (2006). Decoding mental states from brain activity in humans. *Nature Reviews Neuroscience*, 7(7), 523-534. <https://doi.org/10.1038/nrn1931>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016a). *Deep Residual Learning for Image Recognition.* 770-778.
https://openaccess.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html
- He, K., Zhang, X., Ren, S., & Sun, J. (2016b). *Deep Residual Learning for Image Recognition.* 770-778.
https://openaccess.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html
- He, P., Liu, X., Gao, J., & Chen, W. (2021). *DeBERTa: Decoding-enhanced BERT with Disentangled Attention* (No. arXiv:2006.03654). arXiv.
<https://doi.org/10.48550/arXiv.2006.03654>

- Hellström, T., Dignum, V., & Bensch, S. (2020). *Bias in Machine Learning—What is it Good for?* (No. arXiv:2004.00686). arXiv. <https://doi.org/10.48550/arXiv.2004.00686>
- Hendrycks, D., & Gimpel, K. (2023). *Gaussian Error Linear Units (GELUs)* (No. arXiv:1606.08415). arXiv. <https://doi.org/10.48550/arXiv.1606.08415>
- Hermanto, A., Adji, T. B., & Setiawan, N. A. (2015). Recurrent neural network language model for English-Indonesian Machine Translation: Experimental study. *2015 International Conference on Science in Information Technology (ICSITech)*, 132-136. <https://doi.org/10.1109/ICSITech.2015.7407791>
- Hickok, G. (2009a). The functional neuroanatomy of language. *Physics of Life Reviews*, 6(3), 121-143. <https://doi.org/10.1016/j.plrev.2009.06.001>
- Hickok, G. (2009b). The functional neuroanatomy of language. *Physics of Life Reviews*, 6(3), 121-143. <https://doi.org/10.1016/j.plrev.2009.06.001>
- Hickok, G. (2012a). The cortical organization of speech processing: Feedback control and predictive coding the context of a dual-stream model. *Journal of communication disorders*, 45(6), 393-402. <https://doi.org/10.1016/j.jcomdis.2012.06.004>
- Hickok, G. (2012b). The cortical organization of speech processing: Feedback control and predictive coding the context of a dual-stream model. *Journal of communication disorders*, 45(6), 393-402. <https://doi.org/10.1016/j.jcomdis.2012.06.004>
- Hickok, G., Buchsbaum, B., Humphries, C., & Muftuler, T. (2003). Auditory–Motor Interaction Revealed by fMRI: Speech, Music, and Working Memory in Area Spt. *Journal of Cognitive Neuroscience*, 15(5), 673-682. <https://doi.org/10.1162/jocn.2003.15.5.673>

- Hickok, G., & Poeppel, D. (2004). Dorsal and ventral streams: A framework for understanding aspects of the functional anatomy of language. *Cognition*, 92(1), 67-99. <https://doi.org/10.1016/j.cognition.2003.10.011>
- Hickok, G., & Poeppel, D. (2007). The cortical organization of speech processing. *Nature Reviews Neuroscience*, 8(5), 393-402. <https://doi.org/10.1038/nrn2113>
- Hickok, G., & Poeppel, D. (2015). Chapter 8—Neural basis of speech perception. İçinde M. J. Aminoff, F. Boller, & D. F. Swaab (Ed.), *Handbook of Clinical Neurology* (C. 129, ss. 149-160). Elsevier. <https://doi.org/10.1016/B978-0-444-62630-1.00008-1>
- Hickok, G., Poeppel, D., Hickok, G., Poeppel, D., Hickok, G., & Poeppel, D. (2000a). Towards a functional neuroanatomy of speech perception. *Trends in Cognitive Sciences*, 4(4), 131-138. [https://doi.org/10.1016/S1364-6613\(00\)01463-7](https://doi.org/10.1016/S1364-6613(00)01463-7)
- Hickok, G., Poeppel, D., Hickok, G., Poeppel, D., Hickok, G., & Poeppel, D. (2000b). Towards a functional neuroanatomy of speech perception. *Trends in Cognitive Sciences*, 4(4), 131-138. [https://doi.org/10.1016/S1364-6613\(00\)01463-7](https://doi.org/10.1016/S1364-6613(00)01463-7)
- Hill, F., Tieleman, O., Glehn, T. von, Wong, N., Merzic, H., & Clark, S. (2020). *Grounded Language Learning Fast and Slow* (No. arXiv:2009.01719). arXiv. <https://doi.org/10.48550/arXiv.2009.01719>
- Hinton, G. E. (1990). CONNECTIONIST LEARNING PROCEDURES1. İçinde Y. Kodratoff & R. S. Michalski (Ed.), *Machine Learning* (ss. 555-610). Morgan Kaufmann. <https://doi.org/10.1016/B978-0-08-051055-2.50029-8>
- Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>

- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hoffmann, J., Borgeaud, S., Mensch, A., Buchatskaya, E., Cai, T., Rutherford, E., Casas, D. de L., Hendricks, L. A., Welbl, J., Clark, A., Hennigan, T., Noland, E., Millican, K., Driessche, G. van den, Damoc, B., Guy, A., Osindero, S., Simonyan, K., Elsen, E., ... Sifre, L. (2022). *Training Compute-Optimal Large Language Models* (No. arXiv:2203.15556). arXiv. <https://doi.org/10.48550/arXiv.2203.15556>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications* (No. arXiv:1704.04861). arXiv. <https://doi.org/10.48550/arXiv.1704.04861>
- Hu, M., & Liu, B. (2004). Mining and summarizing customer reviews. *Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining*, 168-177. <https://doi.org/10.1145/1014052.1014073>
- Huth, A. G., de Heer, W. A., Griffiths, T. L., Theunissen, F. E., & Gallant, J. L. (2016). Natural speech reveals the semantic maps that tile human cerebral cortex. *Nature*, 532(7600), 453-458. <https://doi.org/10.1038/nature17637>
- Inc, M.-W. (1998). *Merriam-Webster's Manual for Writers and Editors*. Merriam-Webster.
- Ivakhnenko, A. G., & Lapa, V. G. (1965). *Cybernetic Predicting Devices*. Joint Publications Research Service [available from the Clearinghouse for Federal Scientific and Technical Information].
- Johnson, J. S., & Newport, E. L. (1989). Critical period effects in second language learning: The influence of maturational state on the acquisition of English as a

- second language. *Cognitive Psychology*, 21(1), 60-99.
[https://doi.org/10.1016/0010-0285\(89\)90003-0](https://doi.org/10.1016/0010-0285(89)90003-0)
- Johnsrude, I. S., Giraud, A. L., & Frackowiak, R. S. J. (2002). Functional Imaging of the Auditory System: The Use of Positron Emission Tomography. *Audiology and Neurotology*, 7(5), 251-276. <https://doi.org/10.1159/000064446>
- Kalchbrenner, N., Grefenstette, E., & Blunsom, P. (2014). *A Convolutional Neural Network for Modelling Sentences* (No. arXiv:1404.2188). arXiv.
<https://doi.org/10.48550/arXiv.1404.2188>
- Kanjo, E., Younis, E. M. G., & Ang, C. S. (2019). Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection. *Information Fusion*, 49, 46-56. <https://doi.org/10.1016/j.inffus.2018.09.001>
- Karakas, S. (2017). *Prof. Dr. Sirel Karakaş Psikoloji Sözlüğü: Bilgisayar Programı ve Veritabanı*. <https://www.psikolojisozlugu.com/phoneme-sesbirim>
- Karwa, R. R. n, & Chandak, M. B. (2014). Word Sense Disambiguation: Hybrid Approach with Annotation Up To Certain Level – A Review. *International Journal of Engineering Trends and Technology*, 18(7), 328-330.
<https://doi.org/10.14445/22315381/IJETT-V18P267>
- Keller, S. S., Crow, T., Foundas, A., Amunts, K., & Roberts, N. (2009a). Broca's area: Nomenclature, anatomy, typology and asymmetry. *Brain and Language*, 109(1), 29-48. <https://doi.org/10.1016/j.bandl.2008.11.005>
- Keller, S. S., Crow, T., Foundas, A., Amunts, K., & Roberts, N. (2009b). Broca's area: Nomenclature, anatomy, typology and asymmetry. *Brain and Language*, 109(1), 29-48. <https://doi.org/10.1016/j.bandl.2008.11.005>
- Khano, M. N. A., Saputro, D. R. S., Sutanto, S., & Wibowo, A. (2023). SENTIMENT ANALYSIS WITH LONG-SHORT TERM MEMORY (LSTM) AND GATED

RECURRENT UNIT (GRU) ALGORITHMS. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 17(4), 2235-2242.
<https://doi.org/10.30598/barekengvol17iss4pp2235-2242>

Kılıçarslan, S., Adem, K., & Çelik, M. (2021). An overview of the activation functions used in deep learning algorithms. *Journal of New Results in Science*, 10(3), Article 3. <https://doi.org/10.54187/jnrs.1011739>

Kim, K. H. S., Relkin, N. R., Lee, K.-M., & Hirsch, J. (1997). Distinct cortical areas associated with native and second languages. *Nature*, 388(6638), 171-174.
<https://doi.org/10.1038/40623>

Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. İçinde A. Moschitti, B. Pang, & W. Daelemans (Ed.), *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (ss. 1746-1751). Association for Computational Linguistics.
<https://doi.org/10.3115/v1/D14-1181>

Kingma, D. P., & Ba, J. (2017). *Adam: A Method for Stochastic Optimization* (No. arXiv:1412.6980). arXiv. <https://doi.org/10.48550/arXiv.1412.6980>

Kozan, O. (2010). Beyin Ve Dil: Araştırmaların 150 Yılı. *Dil Dergisi*, 147, 22-39.

Krizhevsky, A., & Hinton, G. (2009). *Learning Multiple Layers of Features from Tiny Images*. <https://www.cs.utoronto.ca/~kriz/learning-features-2009-TR.pdf>

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25.
<https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>

- Kubáček, L., & Wimmer, G. (2016). Reparameterization of weakly nonlinear regression models with constraints. *Mathematica Slovaca*, 66(3), 731-744.
<https://doi.org/10.1515/ms-2015-0175>
- Kuhl, P. K. (2007). Is speech learning 'gated' by the social brain? *Developmental Science*, 10(1), 110-120. <https://doi.org/10.1111/j.1467-7687.2007.00572.x>
- Kuhl, P. K. (2010). Brain Mechanisms in Early Language Acquisition. *Neuron*, 67(5), 713-727. <https://doi.org/10.1016/j.neuron.2010.08.038>
- Kumnunt, B., & Sornil, O. (2020). Detection of Depression in Thai Social Media Messages using Deep Learning: *Proceedings of the 1st International Conference on Deep Learning Theory and Applications*, 111-118.
<https://doi.org/10.5220/0009970501110118>
- Kutas, M., & Federmeier, K. D. (2000). Electrophysiology reveals semantic memory use in language comprehension. *Trends in Cognitive Sciences*, 4(12), 463-470.
[https://doi.org/10.1016/S1364-6613\(00\)01560-6](https://doi.org/10.1016/S1364-6613(00)01560-6)
- Kutas, M., & Hillyard, S. A. (1980). Event-related brain potentials to semantically inappropriate and surprisingly large words. *Biological Psychology*, 11(2), 99-116.
[https://doi.org/10.1016/0301-0511\(80\)90046-0](https://doi.org/10.1016/0301-0511(80)90046-0)
- Lan, Z., Chen, M., Goodman, S., Gimpel, K., Sharma, P., & Soricut, R. (2020). *ALBERT: A Lite BERT for Self-supervised Learning of Language Representations* (No. arXiv:1909.11942). arXiv. <https://doi.org/10.48550/arXiv.1909.11942>
- LeCun, Y. (1998). THE MNIST DATABASE of handwritten digits.
<http://yann.lecun.com/exdb/mnist/>
<https://cir.nii.ac.jp/crid/1571417126193283840>
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code

- Recognition. *Neural Computation*, 1(4), 541-551.
<https://doi.org/10.1162/neco.1989.1.4.541>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
<https://doi.org/10.1109/5.726791>
- Lederer, J. (2021). *Activation Functions in Artificial Neural Networks: A Systematic Overview* (No. arXiv:2101.09957). arXiv.
<https://doi.org/10.48550/arXiv.2101.09957>
- Lee, M. (2023). *GELU Activation Function in Deep Learning: A Comprehensive Mathematical Analysis and Performance* (No. arXiv:2305.12073). arXiv.
<https://doi.org/10.48550/arXiv.2305.12073>
- Lee, Y.-B., & Myaeng, S. H. (2002). Text genre classification with genre-revealing and subject-revealing features. *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*, 145-150. <https://doi.org/10.1145/564376.564403>
- Lenneberg, E. H. (1967). The Biological Foundations of Language. *Hospital Practice*, 2(12), 59-67. <https://doi.org/10.1080/21548331.1967.11707799>
- Lewis, M., Liu, Y., Goyal, N., Ghazvininejad, M., Mohamed, A., Levy, O., Stoyanov, V., & Zettlemoyer, L. (2019). *BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension* (No. arXiv:1910.13461). arXiv. <https://doi.org/10.48550/arXiv.1910.13461>
- Li, X., & Roth, D. (2002). Learning question classifiers. *Proceedings of the 19th international conference on Computational linguistics - Volume 1*, 1-7.
<https://doi.org/10.3115/1072228.1072378>

- Li, Y., Wei, X., Yang, Q., Xiong, A., Li, X., Zou, Q., Cui, F., & Zhang, Z. (2024). msBERT-Promoter: A multi-scale ensemble predictor based on BERT pre-trained model for the two-stage prediction of DNA promoters and their strengths. *BMC Biology*, 22(1), 126. <https://doi.org/10.1186/s12915-024-01923-z>
- Lichtheim, L. (2006). On Aphasia (1885). İçinde Y. Grodzinsky & K. Amunts (Ed.), *Broca's Region* (s. 0). Oxford University Press. <https://doi.org/10.1093/acprof:oso/9780195177640.003.0020>
- Lieber, O., Sharir, O., Lentz, B., & Shoham, Y. (2021). Jurassic-1: Technical Details and Evaluation. *White Paper. AI21 Labs*, 1(9), 1-17.
- Lin, M., Chen, Q., & Yan, S. (2014). *Network In Network* (No. arXiv:1312.4400). arXiv. <https://doi.org/10.48550/arXiv.1312.4400>
- Linnainmaa, S. (1976). Taylor expansion of the accumulated rounding error. *BIT Numerical Mathematics*, 16(2), 146-160. <https://doi.org/10.1007/BF01931367>
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). *RoBERTa: A Robustly Optimized BERT Pretraining Approach* (No. arXiv:1907.11692). arXiv. <https://doi.org/10.48550/arXiv.1907.11692>
- Mahowald, K., Ivanova, A. A., Blank, I. A., Kanwisher, N., Tenenbaum, J. B., & Fedorenko, E. (2024). Dissociating language and thought in large language models. *Trends in Cognitive Sciences*, 28(6), 517-540. <https://doi.org/10.1016/j.tics.2024.01.011>
- Mai, A., Riès, S., Ben-Haim, S., Shih, J. J., & Gentner, T. Q. (2024). Acoustic and language-specific sources for phonemic abstraction from speech. *Nature Communications*, 15(1), 677. <https://doi.org/10.1038/s41467-024-44844-9>

- Makin, J. G., Moses, D. A., & Chang, E. F. (2020). Machine translation of cortical activity to text with an encoder–decoder framework. *Nature Neuroscience*, *23*(4), 575-582. <https://doi.org/10.1038/s41593-020-0608-8>
- Malaia, E., & Newman, S. (2015). Neural bases of syntax–semantics interface processing. *Cognitive Neurodynamics*, *9*(3), 317-329. <https://doi.org/10.1007/s11571-015-9328-2>
- Mareček, D., Libovický, J., Musil, Tomáš., Rosa, R., & Limisiewicz, T. (2020). *Hidden in the layers: Interpretation of neural networks for natural language processing*. Ústav formální a aplikované lingvistiky.
- Martin, S., Brunner, P., Holdgraf, C., Heinze, H.-J., Crone, N. E., Rieger, J., Schalk, G., Knight, R. T., & Pasley, B. N. (2014). Decoding spectrotemporal features of overt and covert speech from the human cortex. *Frontiers in Neuroengineering*, *7*. <https://doi.org/10.3389/fneng.2014.00014>
- McCarthy, G., Nobre, A. C., Bentin, S., & Spencer, D. D. (1995). Language-related field potentials in the anterior-medial temporal lobe: I. Intracranial distribution and neural generators. *Journal of Neuroscience*, *15*(2), 1080-1089. <https://doi.org/10.1523/JNEUROSCI.15-02-01080.1995>
- Mechelli, A., Crinion, J. T., Noppeney, U., O’Doherty, J., Ashburner, J., Frackowiak, R. S., & Price, C. J. (2004). Structural plasticity in the bilingual brain. *Nature*, *431*(7010), 757-757. <https://doi.org/10.1038/431757a>
- Mercioni, M. A., & Holban, S. (2020). P-Swish: Activation Function with Learnable Parameters Based on Swish Activation Function in Deep Learning. *2020 International Symposium on Electronics and Telecommunications (ISETC)*, 1-4. <https://doi.org/10.1109/ISETC50328.2020.9301059>

- Merlin, G., & Toneva, M. (2024). *Language models and brains align due to more than next-word prediction and word-level information* (No. arXiv:2212.00596). arXiv. <https://doi.org/10.48550/arXiv.2212.00596>
- Mesnil, G., Dauphin, Y., Yao, K., Bengio, Y., Deng, L., Hakkani-Tur, D., He, X., Heck, L., Tur, G., Yu, D., & Zweig, G. (2015). Using Recurrent Neural Networks for Slot Filling in Spoken Language Understanding. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 23(3), 530-539. <https://doi.org/10.1109/TASLP.2014.2383614>
- Mesran, M., Yahya, S. R., Nugroho, F., & Windarto, A. P. (2024). Investigating the Impact of ReLU and Sigmoid Activation Functions on Animal Classification Using CNN Models. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 8(1), Article 1. <https://doi.org/10.29207/resti.v8i1.5367>
- Miceli, G., Gainotti, G., Caltagirone, C., & Masullo, C. (1980). Some aspects of phonological impairment in aphasia. *Brain and Language*, 11(1), 159-169. [https://doi.org/10.1016/0093-934X\(80\)90117-0](https://doi.org/10.1016/0093-934X(80)90117-0)
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications. *Information*, 15(9), Article 9. <https://doi.org/10.3390/info15090517>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). *Efficient Estimation of Word Representations in Vector Space* (No. arXiv:1301.3781). arXiv. <https://doi.org/10.48550/arXiv.1301.3781>
- Mikolov, T., Grave, E., Bojanowski, P., Puhersch, C., & Joulin, A. (2017). *Advances in Pre-Training Distributed Word Representations* (No. arXiv:1712.09405). arXiv. <https://doi.org/10.48550/arXiv.1712.09405>

- Mishkin, M., Ungerleider, L. G., & Macko, K. A. (1983). Object vision and spatial vision: Two cortical pathways. *Trends in Neurosciences*, 6, 414-417. [https://doi.org/10.1016/0166-2236\(83\)90190-X](https://doi.org/10.1016/0166-2236(83)90190-X)
- Mitchell, T. M., Shinkareva, S. V., Carlson, A., Chang, K.-M., Malave, V. L., Mason, R. A., & Just, M. A. (2008). Predicting Human Brain Activity Associated with the Meanings of Nouns. *Science*, 320(5880), 1191-1195. <https://doi.org/10.1126/science.1152876>
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of Artificial Neural Networks and Deep Learning. İçinde O. A. Montesinos López, A. Montesinos López, & J. Crossa (Ed.), *Multivariate Statistical Machine Learning Methods for Genomic Prediction* (ss. 379-425). Springer International Publishing. https://doi.org/10.1007/978-3-030-89010-0_10
- Morgan-Short, K., Steinhauer, K., Sanz, C., & Ullman, M. T. (2012). Explicit and Implicit Second Language Training Differentially Affect the Achievement of Native-like Brain Activation Patterns. *Journal of Cognitive Neuroscience*, 24(4), 933-947. https://doi.org/10.1162/jocn_a_00119
- Moses, D. A., Metzger, S. L., Liu, J. R., Anumanchipalli, G. K., Makin, J. G., Sun, P. F., Chartier, J., Dougherty, M. E., Liu, P. M., Abrams, G. M., Tu-Chan, A., Ganguly, K., & Chang, E. F. (2021). Neuroprosthesis for Decoding Speech in a Paralyzed Person with Anarthria. *New England Journal of Medicine*, 385(3), 217-227. <https://doi.org/10.1056/NEJMoa2027540>
- Movshon, J. A., & Newsome, W. T. (1996). Visual Response Properties of Striate Cortical Neurons Projecting to Area MT in Macaque Monkeys. *Journal of Neuroscience*, 16(23), 7733-7741. <https://doi.org/10.1523/JNEUROSCI.16-23-07733.1996>

- Narayana, S., Parsons, M. B., Zhang, W., Franklin, C., Schiller, K., Choudhri, A. F., Fox, P. T., LeDoux, M. S., & Cannito, M. (2020). Mapping typical and hypokinetic dysarthric speech production network using a connected speech paradigm in functional MRI. *NeuroImage: Clinical*, 27, 102285. <https://doi.org/10.1016/j.nicl.2020.102285>
- Naselaris, T., Prenger, R. J., Kay, K. N., Oliver, M., & Gallant, J. L. (2009). Bayesian Reconstruction of Natural Images from Human Brain Activity. *Neuron*, 63(6), 902-915. <https://doi.org/10.1016/j.neuron.2009.09.006>
- Nasios, G., Dardiotis, E., & Messinis, L. (2019). From Broca and Wernicke to the Neuromodulation Era: Insights of Brain Language Networks for Neurorehabilitation. *Behavioural Neurology*, 2019(1), 9894571. <https://doi.org/10.1155/2019/9894571>
- Nishimoto, S., Vu, A. T., Naselaris, T., Benjamini, Y., Yu, B., & Gallant, J. L. (2011). Reconstructing Visual Experiences from Brain Activity Evoked by Natural Movies. *Current Biology*, 21(19), 1641-1646. <https://doi.org/10.1016/j.cub.2011.08.031>
- Nobre, A. C., & McCarthy, G. (1995). Language-related field potentials in the anterior-medial temporal lobe: II. Effects of word type and semantic priming. *Journal of Neuroscience*, 15(2), 1090-1098. <https://doi.org/10.1523/JNEUROSCI.15-02-01090.1995>
- Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). *Activation Functions: Comparison of trends in Practice and Research for Deep Learning* (No. arXiv:1811.03378). arXiv. <https://doi.org/10.48550/arXiv.1811.03378>

- Obleser, J., Zimmermann, J., Van Meter, J., & Rauschecker, J. P. (2007). Multiple Stages of Auditory Speech Perception Reflected in Event-Related fMRI. *Cerebral Cortex*, 17(10), 2251-2257. <https://doi.org/10.1093/cercor/bhl133>
- OpenAI, Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., Aleman, F. L., Almeida, D., Altenschmidt, J., Altman, S., Anadkat, S., Avila, R., Babuschkin, I., Balaji, S., Balcom, V., Baltescu, P., Bao, H., Bavarian, M., Belgum, J., ... Zoph, B. (2024). *GPT-4 Technical Report* (No. arXiv:2303.08774). arXiv. <https://doi.org/10.48550/arXiv.2303.08774>
- O'Shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks* (No. arXiv:1511.08458). arXiv. <https://doi.org/10.48550/arXiv.1511.08458>
- Pagliardini, M., Gupta, P., & Jaggi, M. (2018). Unsupervised Learning of Sentence Embeddings using Compositional n-Gram Features. *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)*, 528-540. <https://doi.org/10.18653/v1/N18-1049>
- Pak, A., & Paroubek, P. (2010). Twitter as a Corpus for Sentiment Analysis and Opinion Mining. İçinde *Proceedings of LREC* (C. 10).
- Pang, B., & Lee, L. (2004). *A Sentimental Education: Sentiment Analysis Using Subjectivity Summarization Based on Minimum Cuts* (No. arXiv:cs/0409058). arXiv. <https://doi.org/10.48550/arXiv.cs/0409058>
- Pang, B., & Lee, L. (2005). *Seeing stars: Exploiting class relationships for sentiment categorization with respect to rating scales* (No. arXiv:cs/0506075). arXiv. <https://doi.org/10.48550/arXiv.cs/0506075>

- Pang, B., Lee, L., & Vaithyanathan, S. (2002). *Thumbs up? Sentiment Classification using Machine Learning Techniques* (No. arXiv:cs/0205070). arXiv. <https://doi.org/10.48550/arXiv.cs/0205070>
- Patterson, J., & Gibson, A. (2017). *Deep Learning: A Practitioner's Approach*. O'Reilly Media, Inc.
- PEARCE, J. (2001). Aphasia and Wernicke's arc. *Journal of Neurology, Neurosurgery, and Psychiatry*, *70*(5), 699. <https://doi.org/10.1136/jnnp.70.5.699>
- Peltekis, C., Alexandridis, K., & Dimitrakopoulos, G. (2024). Reusing Softmax Hardware Unit for GELU Computation in Transformers. *2024 IEEE 6th International Conference on AI Circuits and Systems (AICAS)*, 159-163. <https://doi.org/10.1109/AICAS59952.2024.10595882>
- Perani, D., Paulesu, E., Galles, N. S., Dupoux, E., Dehaene, S., Bettinardi, V., Cappa, S. F., Fazio, F., & Mehler, J. (1998). The bilingual brain. Proficiency and age of acquisition of the second language. *Brain*, *121*(10), 1841-1852. <https://doi.org/10.1093/brain/121.10.1841>
- Pickering, M. J., & Garrod, S. (2014). Neural integration of language production and comprehension. *Proceedings of the National Academy of Sciences*, *111*(43), 15291-15292. <https://doi.org/10.1073/pnas.1417917111>
- Pisoni, D. B., & Luce, P. A. (1987). Acoustic-phonetic representations in word recognition. *Cognition*, *25*(1), 21-52. [https://doi.org/10.1016/0010-0277\(87\)90003-5](https://doi.org/10.1016/0010-0277(87)90003-5)
- Poeppel, D. (2003). The analysis of speech in different temporal integration windows: Cerebral lateralization as 'asymmetric sampling in time'. *Speech Communication*, *41*(1), 245-255. [https://doi.org/10.1016/S0167-6393\(02\)00107-3](https://doi.org/10.1016/S0167-6393(02)00107-3)

- Poeppl, D., & Hickok, G. (2004). Towards a new functional anatomy of language. *Cognition*, 92(1), 1-12. <https://doi.org/10.1016/j.cognition.2003.11.001>
- Price, C. J. (2000). The anatomy of language: Contributions from functional neuroimaging. *The Journal of Anatomy*, 197(3), 335-359. <https://doi.org/10.1046/j.1469-7580.2000.19730335.x>
- Price, C. J. (2012). A review and synthesis of the first 20 years of PET and fMRI studies of heard speech, spoken language and reading. *NeuroImage*, 62(2), 816-847. <https://doi.org/10.1016/j.neuroimage.2012.04.062>
- Price, C. J., Moore, C. J., Humphreys, G. W., & Wise, R. J. S. (1997). Segregating Semantic from Phonological Processes during Reading. *Journal of Cognitive Neuroscience*, 9(6), 727-733. <https://doi.org/10.1162/jocn.1997.9.6.727>
- Quiroga, R. Q. (2019). Plugging in to Human Memory: Advantages, Challenges, and Insights from Human Single-Neuron Recordings. *Cell*, 179(5), 1015-1032. <https://doi.org/10.1016/j.cell.2019.10.016>
- Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). *Improving Language Understanding by Generative Pre-Training*. <https://www.mikecaptain.com/resources/pdf/GPT-1.pdf>
- Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., & Sutskever, I. (2019). Language Models are Unsupervised Multitask Learners. *OpenAI Blog*, 8(1). <https://storage.prod.researchhub.com/uploads/papers/2020/06/01/language-models.pdf>
- Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Li, W., & Liu, P. J. (2023). *Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer* (No. arXiv:1910.10683). arXiv. <https://doi.org/10.48550/arXiv.1910.10683>

- Ramachandran, P., Zoph, B., & Le, Q. V. (2017). *Searching for Activation Functions* (No. arXiv:1710.05941). arXiv. <https://doi.org/10.48550/arXiv.1710.05941>
- Rauschecker, J. P. (1998). Cortical processing of complex sounds. *Current Opinion in Neurobiology*, 8(4), 516-521. [https://doi.org/10.1016/S0959-4388\(98\)80040-8](https://doi.org/10.1016/S0959-4388(98)80040-8)
- Rauschecker, J. P., & Scott, S. K. (2009). Maps and streams in the auditory cortex: Nonhuman primates illuminate human speech processing. *Nature Neuroscience*, 12(6), 718-724. <https://doi.org/10.1038/nn.2331>
- Rauschecker, J. P., & Tian, B. (2000). Mechanisms and streams for processing of “what” and “where” in auditory cortex. *Proceedings of the National Academy of Sciences*, 97(22), 11800-11806. <https://doi.org/10.1073/pnas.97.22.11800>
- Robinson, A. J. (1987). *The Utility Driven Dynamic Error Propagation Network*. University of Cambridge Department of Engineering.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Ryu, S., Kim, S., Choi, J., Yu, H., & Lee, G. G. (2017). Neural sentence embedding using only in-domain sentences for out-of-domain sentence detection in dialog systems. *Pattern Recognition Letters*, 88, 26-32. <https://doi.org/10.1016/j.patrec.2017.01.008>
- Saffran, J. R., Aslin, R. N., & Newport, E. L. (1996). Statistical Learning by 8-Month-Old Infants. *Science*, 274(5294), 1926-1928. <https://doi.org/10.1126/science.274.5294.1926>
- Sak, H., Senior, A., & Beaufays, F. (2014). *Long Short-Term Memory Based Recurrent Neural Network Architectures for Large Vocabulary Speech Recognition* (No. arXiv:1402.1128). arXiv. <https://doi.org/10.48550/arXiv.1402.1128>

- Sakata, H., & Kusunoki, M. (1992). Organization of space perception: Neural representation of three-dimensional space in the posterior parietal cortex. *Current Opinion in Neurobiology*, 2(2), 170-174. [https://doi.org/10.1016/0959-4388\(92\)90007-8](https://doi.org/10.1016/0959-4388(92)90007-8)
- Saur, D., Kreher, B. W., Schnell, S., Kümmerer, D., Kellmeyer, P., Vry, M.-S., Umarova, R., Musso, M., Glauche, V., Abel, S., Huber, W., Rijntjes, M., Hennig, J., & Weiller, C. (2008). Ventral and dorsal pathways for language. *Proceedings of the National Academy of Sciences*, 105(46), 18035-18040. <https://doi.org/10.1073/pnas.0805234105>
- Saur, D., Schelter, B., Schnell, S., Kratochvil, D., Küpper, H., Kellmeyer, P., Kümmerer, D., Klöppel, S., Glauche, V., Lange, R., Mader, W., Feess, D., Timmer, J., & Weiller, C. (2010). Combining functional and anatomical connectivity reveals brain networks for auditory language comprehension. *NeuroImage*, 49(4), 3187-3197. <https://doi.org/10.1016/j.neuroimage.2009.11.009>
- Schrimpf, M., Blank, I. A., Tuckute, G., Kauf, C., Hosseini, E. A., Kanwisher, N., Tenenbaum, J. B., & Fedorenko, E. (2021). The neural architecture of language: Integrative modeling converges on predictive processing. *Proceedings of the National Academy of Sciences*, 118(45), e2105646118. <https://doi.org/10.1073/pnas.2105646118>
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673-2681. <https://doi.org/10.1109/78.650093>
- Scott, S. K., & Johnsrude, I. S. (2003). The neuroanatomical and functional organization of speech perception. *Trends in Neurosciences*, 26(2), 100-107. [https://doi.org/10.1016/S0166-2236\(02\)00037-1](https://doi.org/10.1016/S0166-2236(02)00037-1)

- Shoeybi, M., Patwary, M., Puri, R., LeGresley, P., Casper, J., & Catanzaro, B. (2020). *Megatron-LM: Training Multi-Billion Parameter Language Models Using Model Parallelism* (No. arXiv:1909.08053). arXiv. <https://doi.org/10.48550/arXiv.1909.08053>
- Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition* (No. arXiv:1409.1556). arXiv. <https://doi.org/10.48550/arXiv.1409.1556>
- Simos, P. G., Basile, L. F. H., & Papanicolaou, A. C. (1997). Source localization of the N400 response in a sentence-reading paradigm using evoked magnetic fields and magnetic resonance imaging. *Brain Research*, 762(1), 29-39. [https://doi.org/10.1016/S0006-8993\(97\)00349-1](https://doi.org/10.1016/S0006-8993(97)00349-1)
- Smith, S., Patwary, M., Norick, B., LeGresley, P., Rajbhandari, S., Casper, J., Liu, Z., Prabhunoye, S., Zerveas, G., Korthikanti, V., Zhang, E., Child, R., Aminabadi, R. Y., Bernauer, J., Song, X., Shoeybi, M., He, Y., Houston, M., Tiwary, S., & Catanzaro, B. (2022). *Using DeepSpeed and Megatron to Train Megatron-Turing NLG 530B, A Large-Scale Generative Language Model* (No. arXiv:2201.11990). arXiv. <https://doi.org/10.48550/arXiv.2201.11990>
- Socher, R., Perelygin, A., Wu, J., Chuang, J., Manning, C. D., Ng, A., & Potts, C. (2013). Recursive Deep Models for Semantic Compositionality Over a Sentiment Treebank. *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*, 1631-1642. <https://doi.org/10.18653/v1/D13-1170>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, 15(1), 1929-1958.

- Sun, Y., Ji, Z., Lin, L., Tang, D., & Wang, X. (2017). Entity disambiguation with decomposable neural networks. *WIREs Data Mining and Knowledge Discovery*, 7(5), e1215. <https://doi.org/10.1002/widm.1215>
- Sundermeyer, M., Alkhoul, T., Wuebker, J., & Ney, H. (2014). Translation Modeling with Bidirectional Recurrent Neural Networks. İçinde A. Moschitti, B. Pang, & W. Daelemans (Ed.), *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (ss. 14-25). Association for Computational Linguistics. <https://doi.org/10.3115/v1/D14-1003>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). *Going Deeper With Convolutions*. 1-9. https://www.cv-foundation.org/openaccess/content_cvpr_2015/html/Szegedy_Going_Deeper_With_2015_CVPR_paper.html
- Tang, J., LeBel, A., Jain, S., & Huth, A. G. (2023). Semantic reconstruction of continuous language from non-invasive brain recordings. *Nature Neuroscience*, 26(5), 858-866. <https://doi.org/10.1038/s41593-023-01304-9>
- Tarwani, K. M., & Edem, S. (2017). Survey on Recurrent Neural Network in Natural Language Processing. *International Journal of Engineering Trends and Technology - IJETT*, 48(6). <https://doi.org/10.14445/22315381/IJETT-V48P253>
- Thoppilan, R., Freitas, D. D., Hall, J., Shazeer, N., Kulshreshtha, A., Cheng, H.-T., Jin, A., Bos, T., Baker, L., Du, Y., Li, Y., Lee, H., Zheng, H. S., Ghafouri, A., Menegali, M., Huang, Y., Krikun, M., Lepikhin, D., Qin, J., ... Le, Q. (2022). *LaMDA: Language Models for Dialog Applications* (No. arXiv:2201.08239). arXiv. <https://doi.org/10.48550/arXiv.2201.08239>

- Tomasello, M. (2009). The usage-based theory of language acquisition. İçinde *The Cambridge handbook of child language* (ss. 69-87). Cambridge Univ. Press.
<https://doi.org/10.1017/CBO9780511576164.005>
- Tong, J. (2024). Dual-Path Neural Network based on Deep Features and Transfer Learning for Bearing Fault Diagnosis. *International Journal of Mechanical and Electrical Engineering*, 3(2), 1-6. <https://doi.org/10.62051/ijmee.v3n2.01>
- Tremblay, P., & Dick, A. S. (2016). Broca and Wernicke are dead, or moving past the classic model of language neurobiology. *Brain and Language*, 162, 60-71.
<https://doi.org/10.1016/j.bandl.2016.08.004>
- Tsantekidis, A., Passalis, N., & Tefas, A. (2022). Chapter 5—Recurrent neural networks. İçinde A. Iosifidis & A. Tefas (Ed.), *Deep Learning for Robot Perception and Cognition* (ss. 101-115). Academic Press. <https://doi.org/10.1016/B978-0-32-385787-1.00010-5>
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53(8), 5929-5955.
<https://doi.org/10.1007/s10462-020-09838-1>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł. ukasz, & Polosukhin, I. (2017). Attention is All you Need. *Advances in Neural Information Processing Systems*, 30.
<https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>
- Vilar, D., Stein, D., Huck, M., & Ney, H. (2010). Jane: Open Source Hierarchical Translation, Extended with Reordering and Lexicon Models. İçinde C. Callison-Burch, P. Koehn, C. Monz, K. Peterson, & O. Zaidan (Ed.), *Proceedings of the Joint Fifth Workshop on Statistical Machine Translation and MetricsMATR* (ss.

- 262-270). Association for Computational Linguistics.
<https://aclanthology.org/W10-1738/>
- Waibel, A., Hanazawa, T., Hinton, G., Shikano, K., & Lang, K. J. (1989). Phoneme recognition using time-delay neural networks. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(3), 328-339. <https://doi.org/10.1109/29.21701>
- Waldert, S. (2016). Invasive vs. Non-Invasive Neuronal Signals for Brain-Machine Interfaces: Will One Prevail? *Frontiers in Neuroscience*, 10. <https://doi.org/10.3389/fnins.2016.00295>
- Wang, B., Wang, A., Chen, F., Wang, Y., & Kuo, C.-C. J. (2019). Evaluating word embedding models: Methods and experimental results. *APSIPA Transactions on Signal and Information Processing*, 8, e19. <https://doi.org/10.1017/ATSIP.2019.12>
- Weiller, C., Bormann, T., Saur, D., Musso, M., & Rijntjes, M. (2011). How the ventral pathway got lost – And what its recovery might mean. *Brain and Language*, 118(1), 29-39. <https://doi.org/10.1016/j.bandl.2011.01.005>
- Wernicke, C. (1874). *Der aphasische Symptomencomplex*.
- Wernicke, C. (1969). The Symptom Complex of Aphasia. İçinde R. S. Cohen & M. W. Wartofsky (Ed.), *Proceedings of the Boston Colloquium for the Philosophy of Science 1966/1968* (ss. 34-97). Springer Netherlands. https://doi.org/10.1007/978-94-010-3378-7_2
- Wiebe, J., Wilson, T., & Cardie, C. (2005). Annotating Expressions of Opinions and Emotions in Language. *Language Resources and Evaluation*, 39(2), 165-210. <https://doi.org/10.1007/s10579-005-7880-9>

- Willett, F. R., Avansino, D. T., Hochberg, L. R., Henderson, J. M., & Shenoy, K. V. (2021). High-performance brain-to-text communication via handwriting. *Nature*, 593(7858), 249-254. <https://doi.org/10.1038/s41586-021-03506-2>
- Willett, F. R., Kunz, E. M., Fan, C., Avansino, D. T., Wilson, G. H., Choi, E. Y., Kamdar, F., Glasser, M. F., Hochberg, L. R., Druckmann, S., Shenoy, K. V., & Henderson, J. M. (2023). A high-performance speech neuroprosthesis. *Nature*, 620(7976), 1031-1036. <https://doi.org/10.1038/s41586-023-06377-x>
- Williams, R. J., & Zipser, D. (1995). Gradient-Based Learning Algorithms for Recurrent Networks and Their Computational Complexity. İçinde *Backpropagation*. Psychology Press.
- Wolberg, W. H., Street, W. N., & Mangasarian, O. L. (1995). Image analysis and machine learning applied to breast cancer diagnosis and prognosis. *Analytical and Quantitative Cytology and Histology*, 17(2), 77-87.
- Wu, F., Lao, N., Blitzer, J., Yang, G., & Weinberger, K. (2017). *Fast Reading Comprehension with ConvNets* (No. arXiv:1711.04352). arXiv. <https://doi.org/10.48550/arXiv.1711.04352>
- Xiao, H., Rasul, K., & Vollgraf, R. (2017). *Fashion-MNIST: A Novel Image Dataset for Benchmarking Machine Learning Algorithms* (No. arXiv:1708.07747). arXiv. <https://doi.org/10.48550/arXiv.1708.07747>
- Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). *Aggregated Residual Transformations for Deep Neural Networks* (No. arXiv:1611.05431). arXiv. <https://doi.org/10.48550/arXiv.1611.05431>
- Yang, Z., Dai, Z., Yang, Y., Carbonell, J., Salakhutdinov, R., & Le, Q. V. (2020). *XLNet: Generalized Autoregressive Pretraining for Language Understanding* (No. arXiv:1906.08237). arXiv. <https://doi.org/10.48550/arXiv.1906.08237>

- YILMAZ, D. Ö. Ü. A. (2021). *DERİN ÖĞRENME*. Kodlab Yayın Dağıtım Yazılım Ltd.şti.
- Zatorre, R. J., Belin, P., & Penhune, V. B. (2002). Structure and function of auditory cortex: Music and speech. *Trends in Cognitive Sciences*, 6(1), 37-46. [https://doi.org/10.1016/S1364-6613\(00\)01816-7](https://doi.org/10.1016/S1364-6613(00)01816-7)
- Zatorre, R. J., Meyer, E., Gjedde, A., & Evans, A. C. (1996). PET Studies of Phonetic Processing of Speech: Review, Replication, and Reanalysis. *Cerebral Cortex*, 6(1), 21-30. <https://doi.org/10.1093/cercor/6.1.21>
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. İçinde D. Fleet, T. Pajdla, B. Schiele, & T. Tuytelaars (Ed.), *Computer Vision – ECCV 2014* (ss. 818-833). Springer International Publishing. https://doi.org/10.1007/978-3-319-10590-1_53
- Zeki, S. (1983). Colour coding in the cerebral cortex: The reaction of cells in monkey visual cortex to wavelengths and colours. *Neuroscience*, 9(4), 741-765. [https://doi.org/10.1016/0306-4522\(83\)90265-8](https://doi.org/10.1016/0306-4522(83)90265-8)
- Zhang, Y., Wang ,Chunxue, Zhao ,Xingquan, Chen ,Hongyan, Han ,Zaizhu, & and Wang, Y. (2010). Diffusion tensor imaging depicting damage to the arcuate fasciculus in patients with conduction aphasia: A study of the Wernicke–Geschwind model. *Neurological Research*, 32(7), 775-778. <https://doi.org/10.1179/016164109X12478302362653>

EKLER

Ek 1. ÖZGEÇMİŞ

1. Adı Soyadı: Melisa Ceren ÇİMİLİ

2. Yabancı Dili: İngilizce (B2); Fransızca (A2)

3. E-Posta:

4. İletişim:

5. Eğitim Durumu:

Lise	Konya Selçuklu Anadolu Lisesi	2011 - 2014
Lise	Sınav Akademi Koleji	2014 - 2015
Üniversite	İzmir Ekonomi Üniversitesi – Psikoloji (%100 İngilizce)	2016 - 2021
Yüksek Lisans	Üsküdar Üniversitesi Sağlık Bilimleri Enstitüsü Nörobilim Anabilim Dalı	2022- Devam ediyor

6. İş Tecrübesi:

Görev Ünvanı	Kurum	Yıl
Psikolog	Metta Psikoloji	10.2023 – 04.2024
Psikolog	İzmir Birim Disleksi	01.2022 – 06.2022
Psikolog / Eğitim Danışmanı	İzmir Psikoloji Enstitüsü	06.2021 – 08.2023

7. Staj Tecrübesi:

Görev Ünvanı	Kurum	Yıl
Stajyer Psikolog	İzmir Psikoloji Enstitüsü	09.2020 – 10.2021
Stajyer Psikolog	DEU Tıp Fakültesi Ruh Sağlığı ve Hastalıkları Anabilim Dalı	06.2019 – 09.2019
Stajyer Psikolog	DEU Tıp Fakültesi Biyofizik Anabilim Dalı	06.2018 – 07.2018

8. Akademik Çalışmalar:

“Projected Self-Location and Perspective in Dreams” (Poster). *Mind & Brain - 60th International Neuropsychiatric Congress; Deneysel-Bilişsel Psikoloji Sempozyumu 2021.*