



**TÜRKİYE CUMHURİYETİ
MARMARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**EL HAREKETLERİNİN GERÇEKLEŞTİRİLMESİ VE
GÖZLEMLENMESİ ESNASINDA KAYDEDİLEN EEG
SİNYALLERİNDEN DERİN ÖĞRENME TEMELLİ
SINIFLANDIRMA İLE AYNA NÖRON AKTİVİTESİNİN
DEĞERLENDİRİLMESİ**

**HÜSEYİN AKBULUT
YÜKSEK LİSANS TEZİ**

**BEDEN EĞİTİMİ VE SPOR ANABİLİM DALI
SPORDA BİLİŞİM TEKNOLOJİLERİ**

Doç. Dr. ADİL DENİZ DURU

2020-İSTANBUL



TÜRKİYE CUMHURİYETİ
MARMARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

EL HAREKETLERİNİN GERÇEKLEŞTİRİLMESİ VE
GÖZLEMLENMESİ ESNASINDA KAYDEDİLEN EEG
SİNYALLERİNDEN DERİN ÖĞRENME TEMELLİ
SINIFLANDIRMA İLE AYNA NÖRON AKTİVİTESİNİN
DEĞERLENDİRİLMESİ

HÜSEYİN AKBULUT
YÜKSEK LİSANS TEZİ

BEDEN EĞİTİMİ VE SPOR ANABİLİM DALI
SPORDA BİLİŞİM TEKNOLOJİLERİ


Doç. Dr. ADİL DENİZ DURU

2020-İSTANBUL

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışması ile elde edilmemiş bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Hüseyin AKBULUT



TEŞEKKÜR

Sunulan çalışmada emeği geçenlerden, anlattığı bir ders sırasında çalışmanın temellerini atan, sinirbilim ve bilişim uygulamaları konularında verdiği birçok dersiyle anlamamızı ve çalışmamızı kolaylaştıran ve çalışmanın her aşamasında yardımcı olan danışmanım Doç. Dr. Adil Deniz Duru'ya, beraber çalışabilme şansı elde etmek için yüksek lisans kararı verdiğim ve kabulüm sonrasında laboratuvarında istediğim gibi çalışmama izin veren Prof. Dr. Hasan Birol Çotuk'a, çalışmanın uygulanması için alınan izinlerde yardımcı olan ve Arel Üniversitesi Biyomedikal Mühendisliği laboratuvarlarını kullanmamıza izin veren Dr. Dilek Göksel Duru'ya, iki buçuk yıldan uzun bir süredir birçok araştırma ve analiz üzerinde tartıştığım ve çalışmada kullandığım ölçüm cihazları konusunda yardımları olan Selen Güney'e, aynı süreçte birçok çalışmada beraber görev aldığım değerli çalışma arkadaşlarım Savaş Akbaş, Murat Sükuti, Asuman Çevik, Kübra Tan ve sayamadığım diğer laboratuvar arkadaşlarıma, ve en önemlisi aileme eğitime ve çalışmaya olan katkılarından dolayı sonsuz teşekkürlerimi sunarım.

Hüseyin AKBULUT

Bu tez Marmara Üniversitesi Sağlık Bilimleri Enstitüsü Müdürlüğü'nün 15342631-302.01.08-E.2000148537 sayılı kararı ile Marmara Üniversitesi Uzaktan Eğitim Merkezi sitesinde dijital ortamda sunulmuştur.

İÇİNDEKİLER

Beyan.....	i
Teşekkür.....	ii
İçindekiler.....	iv
Kısaltmalar ve Simgeler Listesi.....	vii
Şekil Listesi.....	viii
Tablo Listesi.....	xi
Özet.....	1
Summary.....	2
1. BÖLÜM: GİRİŞ ve AMAÇ.....	3
2. BÖLÜM: GENEL BİLGİLER.....	6
2.1. Sinir Sistemi.....	6
2.1.1. Nöronlar.....	6
2.1.2. Gliyalar.....	7
2.1.3. Hemisfer.....	7
2.1.4. Aksiyonların Elektriksel Potansiyellerinin Ölçülmesi.....	8
2.1.5. Görme Sisteminin Anatomisi.....	9
2.1.6. Göz ve Beyin Bağlantısı.....	11
2.1.7. Hareketin Algısı.....	11
2.1.8. İnsanlarda Ayna Nöronlar.....	13
2.2. Makine Öğrenimi.....	19
2.2.1. Makine Öğrenimi Uygulamaları.....	19
2.2.1.1. Görev.....	20
2.2.1.2. Performans.....	20
2.2.1.3. Deneyim.....	20

2.2.1.3.1. Gözetimsiz öğrenim algoritmaları.....	20
2.2.1.3.1. Gözetimli öğrenim algoritmaları.....	21
2.2.2. Derin Öğrenme.....	21
2.2.2.1. Konvolüsyonel Sinir Ağları.....	23
2.2.1.1. Konvolüsyon + ReLU.....	24
2.2.1.2. Havuzlama.....	25
2.2.1.3. Tam Bağlantılı Katmanlar.....	26
3. BÖLÜM: GEREÇ ve YÖNTEM.....	27
3.1. Araştırma Grubu.....	27
3.2. Araştırma Yöntemi.....	27
3.3. Araştırmanın Çalışma Alanı.....	28
3.4. Araştırma Uygulanan Testler ve Ölçümler.....	28
3.5. Analiz.....	29
3.5.1. Zaman-Frekans Analizi.....	30
3.5.2. Zaman-Frekans Çıktısı Gram Matrisi.....	31
3.6. Veri seti.....	34
3.7. Derin Ağ Yapıları.....	35
4. BÖLÜM: BULGULAR.....	37
4.1. Hareketin Uygulanması.....	37
4.1.1. Zaman-Frekans Görüntüleri.....	37
4.1.2. Zaman-Frekans Gram Matrisleri.....	39
4.1.3. Konvolüsyonel Sinir Ağları Çıktıları.....	41
4.2. Hareketin Gözlemlenmesi.....	48
4.2.1. Zaman-Frekans Görüntüleri.....	48
4.2.2. Zaman-Frekans Gram Matrisleri.....	50
4.2.3. Konvolüsyonel Sinir Ağları Çıktıları.....	52

4.3. Hareketin Uygulanması ve Gözlemlenmesi Setleri Yapay Sinir Ağları	
Çıktıları.....	56
5. BÖLÜM: TARTIŞMA ve SONUÇ.....	60
KAYNAKÇA.....	70
EKLER	



Kısaltma ve Simgeler Listesi

EEG: Elektroensefalografi

MEG: Manyetoensefalografi

TMS: Transkraniyal Manyetik Uyarım

PET: Pozitron Emisyon Tomografisi

fMRG: Fonksiyonel Manyetik Rezonans Görüntüleme

LGN: Lateral Genikulat Çekirdeği

MST: Medial Superior Temporal

AN: Ayna Nöronlar

PMD: Dorsal Premotor Korteks

SPL: Superior Parietal Lobçuk

IPL: Inferior Parietal Lobçuk

IFG: Inferior Frontal Girus

PMV: Ventral Premotor Korteks

STS: Superior Temporal Sulkus

KSA: Konvolüsyonel Sinir Ağları

ReLU: Düzleştirilmiş Doğrusal Birim Katmanı

Şekil Listesi

Şekil 1: Aksiyon potansiyellerinin yarattığı elektro-manyetik alanın elektrot aracılığıyla ölçülmesi

Şekil 2: Sensorimotor korteks ve motor korteks

Şekil 3: İnsanlarda ayna nöron mekanizması

Şekil 4: Meta-analiz sonucunda hareket gözlemi için ulaşılan anlamlı BOLD (fMRG) değişimi sonuçları

Şekil 5: Mu ritim desenkronizasyonu

Şekil 6: İlk derin ağ mimarisi

Şekil 7: Örnek bir konvolüsyonel sinir ağları yapısı

Şekil 8: Azami ve ortalama havuzlama örnekleri

Şekil 9: Katılımcıların uyguladığı ve gözlemlediği hareketlerden örnek görüntüler

Şekil 10: 64 kanallı EEG seti

Şekil 11: Katılımcının gerçekleştirdiği hareket esnasında kaydedilen video kayıtlarından örnek görüntü dizisi

Şekil 12: Katılımcının gözlemlediği hareket esnasında kaydedilen video kayıtlarından örnek görüntü dizisi

Şekil 13: Bir Morlet dalgacığı ve farklı frekans temsilleri için Morlet dalgacıkları

Şekil 14: 256 Hz ile kaydedilen EEG sinyallerinden epileptik nöbet sırasında ve iki epileptik nöbet arasında kaydedilen 1000 zaman noktasında hesaplanan matris temsili

Şekil 15: 500 Hz ile kaydedilen EEG sinyallerinden Cz elektrotunun 1 katılımcının ilk seride bireyin sabit duruş bölümünde ve hareket başlangıcında kaydedilen 250 zaman noktasında hesaplanan matris temsili

Şekil 16: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, A bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 17: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, B1 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 18: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, B2 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 19: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, C1 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 20: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, C2 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 21: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, D bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 22: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, A bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

Şekil 23: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, B1 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü ve B2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

Şekil 24: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, C1 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü ve C2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

Şekil 25: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, D bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

Şekil 26: A ve B1 karşılaştırmaları için tüm elektrotlar kullanılarak 9 katılımcı ile eğitilen ve rastgele seçimle verinin %20'si ile test edilen ağın eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 27: A ve C2 karşılaştırmaları için tüm elektrotlar kullanılarak 9 katılımcı ile eğitilen ve rastgele seçimle verinin %20'si ile test edilen ağın eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 28: GK ve B2 karşılaştırmaları için santral bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 29: GK ve B2 karşılaştırmaları için parieto-okspital bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test

Şekil 30: GK ve B2 karşılaştırmaları için orta santral bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 31: GK ve B2 karşılaştırmaları için oksipital bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 32: GK ve C2 karşılaştırmaları için tüm bölge elektrotları kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 33: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, E bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 34: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, F1 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 35: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, F2 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 36: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, G1 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 37: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, G2 bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 38: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, H bölümünde hesaplanan zaman-frekans görüntüsü

Şekil 39: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, E bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

Şekil 40: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, F1 bölümünde ve F2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüleri

Şekil 41: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, G1 bölümünde ve G2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüleri

Şekil 42: 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, H bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

Şekil 43: GK ve G2 karşılaştırmaları için tüm bölge elektrotları kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 44: E ve G2 karşılaştırmaları için santral bölge elektrotları kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 45: E ve G2 karşılaştırmaları için tüm elektrotlar kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 46: 9 katılımcının B2 ve C2 grupları zaman-frekans görüntüleri kullanılarak eğitilen hareket setinin, katılımcıların F2 ve G2 gruplarının orta santral bölge elektrotları ile test edilmesinde ulaşılan eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 47. 9 katılımcının B2 ve C2 grupları zaman-frekans görüntüleri kullanılarak eğitilen hareket setinin, katılımcıların F2 ve G2 gruplarının orta santral bölge elektrotları ile test edilmesinde ulaşılan eğitim ve test skorları ile eğitim ve test kayıpları

Tablo Listesi

Tablo 1: Göz kapalı, hareket ve gözlem setlerindeki görüntü sayıları

Tablo 2: Zaman-frekans çıktılarında kullanılan derin ağ katmanları

Tablo 3: Zaman-frekans çıktılarının Gram matrisleri için kullanılan derin ağ katmanları

Tablo 4: Hareket uygulaması deneylerinde GK durumu ile C2 ve B2 durumlarının karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 5: Hareket uygulaması deneylerinde farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 6: Hareket uygulaması deneylerinde farklı bölümlerin karşılaştırmaları için rastgele test yöntemi ile yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 7: Hareket uygulaması deneylerinde farklı bölümlerin karşılaştırmaları için zaman-frekans Gram matris görüntülerinde rastgele test yöntemi ile yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 8: Hareket gözlemi deneylerinde farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 9: Hareket gözlemi deneylerinde farklı bölümlerin karşılaştırmaları için rastgele test yöntemi ile yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 10: Hareket uygulaması ve gözlemlenmesi değerlendirmelerinde zaman-frekans Gram matris görüntülerinin farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 11: Hareket uygulaması ve gözlemlenmesi değerlendirmelerinde zaman-frekans görüntülerinin farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Tablo 12: Hareketin uygulandığı C2 ve gözlemlendiği G2 bölümlerinin ayrıştırılması için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

Özet

El hareketlerinin gerçekleştirilmesi ve gözlemlenmesi esnasında kaydedilen EEG sinyallerinden derin öğrenme temelli sınıflandırma ile ayna nöron aktivitesinin değerlendirilmesi

Öğrenci Adı: Hüseyin AKBULUT

Danışman Adı: Doç. Dr. Adil Deniz DURU

Amaç: Bireylerin başka bir insanın hareketini gözlemlediği esnada motor ve sensorimotor kortekste gözlemlenen nöronal aktivite, hareketi kendi uyguladığı sırada görülen aktiviteye benzer şekilde EEG'nin alfa (8-13 Hz) ve beta (14-25) frekans bantlarında gözlemlenir. Bu çalışmanın amacı, EEG sinyalleri kullanılarak katılımcıların top sıkma hareketini gerçekleştirdikleri ve gözlemledikleri durumların sınıflandırılmasıdır.

Gereç ve yöntem: Çalışmada EEG ölçümleri ile eş zamanlı olarak katılımcıların el hareketleri 1280x720 piksel, 60 Hz çözünürlükte videolara kaydedildi ve elde edilen görüntüler değerlendirilerek EEG sinyalleri hareket ve gözlem bölümlerine ayrıldı. Dokuz katılımcının tekrarlı hareket ve gözlemler sırasında kaydedilen her el hareketine karşılık gelen EEG sinyalleri 500 ms lik pencerelere ayrıldı. Bu pencereler üzerinde zaman-frekans analizi gerçekleştirildi. İki boyutlu zaman-frekans çıktısı ve zaman-frekans Gram matrisleri konvolüsyonel sinir ağlarına girdi olarak kullanılarak sınıflandırma gerçekleştirildi. Kaydedilen EEG sinyallerinin yapay sinir ağları ile değerlendirilmesi için özelleştirilmiş VGGNet yapay sinir ağı yapısı kullanıldı.

Bulgular: Farklı hareket bölümleri, ağ yapısı ve matematiksel işlemler ile oluşturulan görüntülerin değiştirilerek kullanıldığı yapay sinir ağlarında ikili grup eğitimi ve testlerinde en yüksek test skorlarına %80 üzerinde doğruluk yüzdesiyle dinlenim durumu ile hareket uygulaması ve gözlemleri arasında ulaşıldı. Zaman-frekans çıktısının Gram matrisleri kullanılması sonucu hareketin uygulanması bölümü kullanılarak oluşturulan setin, hareketin gözlemlenmesi ile test edilmesinde %75 doğruluk skoruna ulaşıldı.

Sonuç: EEG zaman-frekans ve zaman-frekans çıktısının Gram matrislerinden elde edilen geometrik görüntülerin yapay sinir ağları ile sınıflandırılması, hareketin ve ayna nöron aktivitesinin uzamsal ve zamansal değişimi hakkında bilgi vermektedir.

Anahtar kelimeler: ayna nöronlar, derin öğrenme, EEG, zaman-frekans görüntüleri, zaman-frekans Gram matrisi

Summary

Deep learning based classification of EEG signals recorded during execution and observation of hand movements to evaluate the mirror neuron activity

Student's Name: Hüseyin AKBULUT

Name of Supervisor: Assoc. Prof. Adil Deniz DURU

Objective: The neuronal activities in the motor and sensorimotor cortex at the EEG's alpha (8-13 Hz) and beta (14-25) frequency bands while the individuals observe the movement action of others, resemble the activity when execution the same movement pattern. The purpose of this study was to classify the situations in which the participants perform and observe the ball squeezing of hand movements from the recorded EEG signals.

Material and methods: Hand movements of the participants have been recorded at 1280x720 pixels with 60 Hz resolution, simultaneously with the EEG measurements to segment the EEG data. EEG signals corresponding to each hand movements recorded during repetitive movements and observations of nine participants were divided into 500 ms windows. Time-frequency analysis was calculated and the classification was applied using two-dimensional time-frequency output and time-frequencies' Gramian matrices as input to conventional neural networks.

Results: Convolutional neural networks have been run with different network structure, movement segments and calculated images sets. The highest test scores (83%) in binary group comparisons have been achieved between the resting state and movement execution. A 75% accuracy score have been achieved in testing using movement execution sets as training and movement observation sets as testing by time-frequency Gramian matrix.

Conclusion: Using artificial neural networks for classification of geometric images of EEG time-frequency distributions and their Gramian matrix provide information on the spatial and temporal dynamics of movement and the mirror neuron activity.

Key words: mirror neurons, EEG, deep learning, time-frequency analysis, time-frequency Gramian matrix

1. GİRİŞ ve AMAÇ

Bilişsel sinirbilim alanındaki temel konulardan biri beynin diğer canlıların eylemlerinden ve hareketlerinden nasıl etkilendiğini anlamak ve öğrenimin nasıl gerçekleştirdiğini araştırmaktır. Bu konudaki bilgilerde en önemli gelişmelerden biri ilk olarak primatların motor korteksinde keşfedilen ayna nöronlardır. Bu nöronlar herhangi bir hareketin uygulandığı esnada ateşlendiği gibi, aynı hareketin gözlemlendiği esnada da ateşlenir. Ayna nöronların bu aktiviteleri elektroensefalografi (EEG) aracılığıyla mu ritim frekans bantlarında gözlemlenebilir. Mu ritmin frekanslarındaki genlik baskılanması kortikal aktiviteyi ve ayna nöron mekanizmasını yansıtır (Fox ve ark., 2016). EEG kullanılarak yüksek zaman çözünürlüğünde kaydedilen sinyaller mu ritim aktivitelerinin gözlemlenmesine izin verir. Yetişkinlerde mu ritim, EEG'nin 8-13 Hz alfa, 14-25 Hz beta bantlarında, başlıca olarak frontal lobun motor korteks alanında ve parietal lobun sensorimotor korteks alanlarında görülür (Fox ve ark., 2016; Angelini ve ark., 2018). Bireyin hareketi uyguladığı gibi başka bir canlının hareketini gözlemlediği esnada motor korteks ve sensorimotor kortekste aktivite artışı olan nöronlarda görülen kortikal aktivite EEG sinyallerinde gözlemlenebilir. Gözlem sırasında gerçekleşen bu aktivite ayna nöron aktivitesi olarak adlandırılır (Rizolatti, 2004). Ayna nöron sistemi, gözlemsel olarak algılanan duyuşal informasyonları bireye özgün hareket örüntülerine dönüştürür. Bu düzenlemelerin gerçekleştirilmesi için farklı kortikal alanlarda bulunan duyuşal ve motor mekanizmalardan sorumlu bölgelerin birlikte çalışması gerektiği son 20 yıl boyunca birçok çalışma tarafından desteklenmiştir. Bunun için görsel alanlardan sorumlu oksipital lob, bedensel-duyuşal alanlardan sorumlu postsantral girus, işitsel alanlardan sorumlu superior temporal girus ve motor alanların bulunduğu agranular frontal kortekste bulunur. İletim alanları olarak adlandırılan kortikal bölgelerin bu duyuşal ve motor bölgelerin arasında bulunduğu ve temporo-parietal bölgelerde bulunan nöral düzenlemeler ile nesne ve mekânsal algı bilgilerinin düzenlenerek motor kortekse gönderildiği ve hareket düzenlenmesinin yapıldığı düşünülmektedir (Sinigaglia, 2006). Hareket ve davranışların amacının anlaşılması (Fogassi, 2005), empati (Singer, 2004) ve zihin teorisi (Gallese, 1998) ayna nöron mekanizmasının fonksiyonel karakteristik özelliklerindendir ve bu

sebeplere dayanarak yapılan arařtırmalar sonucunda ayna nron mekanizmasındaki iřlev bozukluęu otizmle iliřkilendirilir (Oberman, 2005). Birok alıřmada da farklı bir bireyin yaptıęı hareketin gzlemlenmesiyle kortikal nral aęda EEG aktivitesinde deęiřimler olduęu grlmekte ve ayna nron mekanizmasıyla iliřkilendirilmektedir (Angelini ve ark. 2018). Katılımcı gerek hareket yaptıęında EEG'nin frekans bantlarında grlen genlik ve zaman-frekans bilgilerinin kullanımıyla sinyaller sınıflandırılabilir (Shen ve ark., 2017).

EEG temelli insan-makine arayz uygulamaları makine ęrenimi yntemleri kullanılarak bařarılı řekilde kullanılmaktadır. Makine ęrenimi sınıflandırmaları sayesinde beyin aktiviteleri ileti ya da komutlara evrilebilir (Lotte, 2018), rehabilitasyon amacıyla kullanılabilir (Ang, 2013) veya bireylerin mental durumlarını belirlemek iin kullanılabilir (Zander, 2011). EEG sınıflandırmaları iin, farklı tr grevlerin etkileri, aę yapılarında girdi olarak kullanılan yntemler ve algoritmalar kullanılabilir (Craig, 2019). Literatrde birok makine ęrenimi ve rnt tanıma yntemi EEG verisi zerinde kullanılmaktadır. rneęin, Doęrusal Diskriminant Analizi, Destek Vektr Makineleri ve Karar Aęacı Algoritmaları uyaranların etkilerini sınıflandırmak iin kullanılabilir (Craig, 2019). Bu baęlamda ayna nron aktivitesinin elektrofizyolojik yanıtlar ercevesinde incelenmesi ile, bu aktiviteyi dinlenim durumu gibi dięer durumlardan ayrılmasını yksek bařarı yzdesi ile saęlayabilecek bir uzamsal rnt arařtırılacaktır. Ayrıca, bu rntnn zamansal olarak EEG ile elde edilen 1 saniyeden daha kısa pencerelerinden yola ıkılarak elde edilmesi insan-makine arayz uygulamalarında kullanıma da elveriřlidir.

Bu tez alıřmasının amacı, katılımcının bir stres topunu sıkmak iin uyguladıęı hareketler ile hareketi gzlemledięi esnada beyinde gerekleřen elektriksel aktivitelerin EEG aracılıęıyla kaydedilmesi ve hareketin farklı blmlerini hareketin uygulanması, hareketin gzlemlenmesi ve uygulama ile gzlemin birlikte eęitim ve test gruplarını oluřturarak yapay sinir aęlarında kullanılması ile sinir aęlarının deęerlendirilmesidir.

Çalışma kapsamında ele alınacak araştırma hipotezleri şu şekildedir;

- 1- Ayna nöron aktivitesi olarak kayıt altına alınan 500 milisaniyelik pencerelenmiş EEG sinyalleri, dinlenim durumu sinyallerinden ayırımsanabilir.
- 2- Kişinin hareket uygulaması sırasında EEG sinyallerinden öğrenilen öznitelikler, aynı kişinin hareketi gözlemesi sırasında elde edilen EEG sinyallerinin sınıflandırılmasında başarı sağlar.
- 3- Derin öğrenme tabanlı sınıflandırıcı kullanılarak EEG verilerinden planlanan hareketlere dair örüntüler çıkarılabilir.



2. GENEL BİLGİLER

2.1. Sinir Sistemi

Anatomik anlamda sinir sistemi iki başlık altında incelenir. Bunlar merkezi sinir sistemi ve periferik sinir sistemidir. Bunlardan periferik sinir sistemi duysal (afferent) ve motor (efferent) sinirler olarak ikiye ayrılırlar. Efferent sinir sistemi, somatik ve otonom sinir sistemi olarak iki bölümde incelenir. Periferik sinir sistemi, birey çevresel bir uyarana maruz kaldığı zaman bunu algılar ve efferent sinirler aracılığıyla bunu merkezi sinir sistemine iletir. Bu şekilde duysal sinirler acı, terleme, koku vb. olarak anlamlandırılabilir (Guyton ve Hall, 2008).

2.1.1. Nöronlar

Nöronlar, beyin yapısını oluşturan sinir hücreleridir. Bu hücreler beyinde bilgi transferi görevinde çalışırlar. Nöronlar beyin yapısında yaptıkları görevlere göre farklı şekillerde ve çeşitlerde bulunabilir. İçerisinde soma (hücre gövdesi), dendritler, akson ve terminal butonlar olarak adlandırılan dört farklı yapıya sahiptirler (Carlson, 2011).

İnsan beyinde bu hücrelerden yaklaşık olarak 100 milyar adet bulunur. Serebellumda (beyincik) bulunan küçük hücrelerden motor korteksteki pyramidal hücrelere kadar yapısal olarak değişkenlik gösteren özelliklere sahiptirler. Merkezi sinir sisteminde bulunan nöronlar beş temel yapıdan oluşur. Hücrenin diğer kısımlarını oluşturan ve besleyen yapı nöron gövdesidir. Nöron gövdelerinden dallanarak çıkan yapılara dendrit adı verilir. Bu dalların uzantıları diğer nöronlardan afferent sinyalleri almakla görevlidir. Efferent sinyaller nöronu aksonlar aracılığıyla geçer ve bu sinyaller kaslara, salgı bezlerine ya da diğer nöronlara iletilir. Bu aksonlar merkezi sinir sisteminde ise boyları oldukça kısadır. Periferik sinir sisteminde ise bu akson boyları 1 metreye kadar ulaşabilir. Nöronlar arasında 200'den 200.000'e kadar değişen temas noktaları (sinaps) bulunabilir. Sinapstaki iletimler genellikle aksondan dendrite doğru olur. Bu özellik bilgi aktarımının sağlanması ve sinyalin istenilen işlevi yerine getirmesi için tek yönlü iletim sağlar (Karakaş, 2008).

2.1.2. Gliyalar

Merkezi sinir sisteminde bulunan en önemli destek hücreleridir ve sayıları da nöronların yaklaşık olarak 10-15 katıdır. Temel işlevleri, nöronların bir arada kalmasını sağlayan ya da aksonları saran miyelin kılıflarını oluşturmaktır. Merkezi sinir sisteminde bulunan gliyal hücreler, astrositler, oligodendrositler ve ependimal hücreler olarak üç tipte karşımıza çıkar. Bunlar dışında mikrogliya olarak adlandırılan hücre topluluğu da bulunur ve bu topluluk nöral kökenli olmayıp kan hücrelerinden köken alır ve sinir sistemine kan damarları aracılığıyla ulaşır ve sinir hücrelerinde temizleyici olarak görev alırlar (Karakaş, 2008).

2.1.3. Hemisfer


Beyin kabuğu frontal, parietal, temporal ve oksipital olmak üzere dört bölümde incelenir. Sinir sisteminde kütleli olarak en büyük yer frontal alana aittir. Araştırmacılar bu alanı birincil motor alan, premotor alan ve prefrontal alan olarak üç bölümde inceler (Taner, 2015). Frontal alan saldırganlık, cinsellik, açlık, kin ve nefret dürtülerinde görevlidir. Bu alan ayrıca problem çözme, anlama, yargılama, olay örgüsü, zaman yönetimi, motor hareketler ve ruhsal durum ve analitik düşünme konularında etkilidir. Orta alanda bulunan parietal alan sağ ve sol kavramlarının ayrıştırılması, yön duygusu, dokunma hissi, bilgi işleme, okuma ve yazma fonksiyonlarının gerçekleştirildiği bölümdür. Temporal alan işitme, görsel öğrenme fonksiyonlarını gerçekleştirir. Temporal alan sağ ve sol olarak ikiye ayrılır. Sağ temporal lob ses kodlama, ritim farkındalığı, yüz tanımlamada, sol temporal alan ise okuma, anlama, anladıklarını değerlendirmede etkilidir. Oksipital alan, kafatasının arka bölümünde bulunur, Gözden gelen bilgi doğrultusunda renk ayrımı, okuma, hareketleri algılama ve değerlendirme fonksiyonlarından sorumludur (Sürmeli, 2010).

Birincil motor alan, frontal lobta, santral sulkusun hemen önünde konumlanır. Presantral girusta bulunan 2 cm genişlikte bir şerittir. Motor korteksin sağ tarafında bulunan nöronlar, vücudun sol tarafında bulunan istemli kasılmalardan sorumludur. Bu alanda parmak, dudak ve ağız gibi çizgili iskelet kasları için ayrılan kısmı, bacak ve ayaktaki çizgili kaslara göre daha fazladır. Birincil somatik duyu alanı, parietal lobta bulunur.

Santral sulkusun arkasında bulunan post-santral girusta yer alır. Bu bölümün sağ yanı, vücudun sol yanını kontrol eder. Reseptörlerden gelen sinyaller doğrudan somatik duysal alana ulaşır ve dokunma, basınç, ısı ve ağrı gibi duyların ayrıştırılmasını sağlar. Somatik duysal alan bölümlenmesi motor korteks gibi ters taraflı olarak bilgiyi saklar ve vücuttaki duyu bölümü ne kadar duyarlı ise bu alanda o bölgeye o kadar yer ayrılmış olur. Premotor alan, motor korteksin önündedir. Bu alan vücut hareketlerinin karmaşık kemik ve kas işbirliğinde rol oynar. Atletik hareketlerin gerektirdiği nöronal bilgiler ön motor alanda depolanır. Yardımcı motor alan, ön motor alanın önünde konumlanır. Büyük bir bölümü hemisferin içindedir. Bu alanın görevi ise birincil motor bölgedeki nöral aktiviteleri düzenlemektir (Karakaş, 2008).

2.1.4. Aksiyonların Elektriksel Potansiyellerinin Ölçülmesi

Nöronal aktiviteler sırasında iletilerin akson boyunca uzanması için üzerinde taşınabilecek büyüklükte bir aksone ihtiyaç duyarlar. Akson ile mesajın iletildiği sırada elektriksel aktivite meydana gelir. Aksonun içi, dışarıya göre negatif yüklüdür, fark -70mV olarak ölçülebilir ve bu elektriksel yüke membran potansiyeli adı verilir. Bu aktiviteyi ölçebilmek için elektrotlar kullanılabilir. Eksitator uyaranlar ile bir mesaj akson boyunca iletildiğinde membran potansiyelinde değişiklik oluşur. Bu iletinin hızlı olması sebebi ile gözlemlemek için osiloskop kullanılır. Osiloskop voltaj ölçer. Voltajın grafiksel gösterimi için, zaman ve volt boyutları kullanılır (Carlson, 2011). Kortekse dik piramidal hücrelerin oluturduğu post sinaptik potansiyellerin kafaderisindeki bileşkesi EEG kayıtlarında gözlenebilir. Bu sayede katılımcı hareket uyguladığında EEG kullanılarak toplanılan sinyallerin genlik ve zaman-frekans bilgileri değerlendirilerek sinyaller sınıflandırılabilir (Shen ve ark., 2017). Şekil 1’de nöron olarak tasvir edilen yapılar aksonlar aracılığıyla birbirleriyle etkileşimde bulunur. Bu etkileşimde elektro-kimyasal iletiler rol oynar. Eğer bir nöron ateşlenirse, bunu nöronun içine ve nörondan dışarı giden iyonlar aracılığıyla gerçekleştirir. Bu iyon değişimleri, bir nöron popülasyonunda senkronize bir şekilde gerçekleşirse yaratılan elektriksel alan EEG gibi elektrotlar aracılığıyla kaydedilebilir (Freeman, 2014; Cohen, 2015).



Şekil 1. Aksiyon potansiyellerinin yarattığı elektro-manyetik alanın elektrot aracılığıyla ölçülmesi (Freeman, 2014)

2.1.5. Görme Sisteminin Anatomisi

Gözün iç tabakası olan retinanın odaklanması ile, görme işlemi gerçekleşir. Bu görüntünün oluşması için milyonlarca nöronda elektriksel aktivitelerinde değişim oluşur ve ileti optik sinirler kullanılarak beynin gerekli bölgelerine iletilir. Retina ve optik sinirler merkezi sinir sisteminde bulunur. Gözler, kafatasının ön tarafında bulunan orbitanın içinde asılı olarak bulunur. Gözakı, en dış katmandır, sert yapıda ve beyaz renklidir. Gözler, ekstraoküler kaslar ile gözakına tutunur ve hareketini gerçekleştirir. Göz küremizin arka bölümünü ve orada bulunan kasları görmeyiz, bunun sebebi göz bağlantısının konjonktiva ile gizlenmesidir. Bir olayı incelediğinizde gözünüz, görüntüyü yavaş ve akış içinde değil, kesikli olarak gözlemler. Bu kesintili hareket, gözlerin görüntü üzerinde atlamalar yaparak ilerlemesine neden olur (Carlson, 2011).

Gözün en dış katmanı olan sklera, opaktır ve ışık geçişine kapalıdır. Dış katman olan kornea ise ön kısımda yer alır, saydamdır ve ışık geçişine izin verir. Geçen ışığın miktarı, iristeki göz bebeğinin büyümesi ya da küçülmesi ile belirlenir. İris, korneanın arkasında bulunarak kasılabilen halkalardan oluşur. İrisin arkasındaki lens ise şeffaf halkalardan meydana gelir. Dış ucunda bulunan kas liflerindeki değişiklikler sonucunda lens şekil değiştirir. Bu değişiklikler ile nesneye olan uzaklığa bağlı olarak retinanın odaklanmasına yardımcı olur ve bu işleme akomodasyon adı verilir.

Işık, lensi geçtiğinde iç kısımda bulunan retinaya düşer. Retinada rod ve kon olarak, şekillerine göre ayrılan fotoreseptörler bulunur. Retinada 120 milyona yakın rod ve 6 milyona yakın kon hücreleri bulunur. Çevremiz hakkında ve gün içindeki görüşümüzden sağlanan bilginin büyük bir kısmı konlar tarafından sağlanarak keskin görüşün kaynağıdır. Retinanın merkez kısmında bulunurlar ve farklı dalga boylarını ayırmamızda etkindirler. Rodlar ise renklerin ayırımında etkin olmasalar da ışık seviyesi düşük olan çevrede etkindirler (Carlson, 2011).

Retina yakından incelendiğinde, burada bulunan nöronal hücre yapıları akson ve dendritleri ile fotoreseptörlerin katmanlarından oluştuğu gözlenir. Primat retinası kesitinde bulunan tabakalar foto-kavrayıcı, bipolar ve gangliyon hücre tabakalarıdır. Bu düzende fotoreseptörlerin retinanın arkasındadır. Işık buraya ulaşırken şeffaf tabakalardan geçer. Fotoreseptörlerin sinaps oluşturduğu hücreler bipolar olanlardır. Bu hücreleri iki kolları vardır ve retinada bulunan en derin ve sığ tabakaları ile temasta bulunur. Sonrasında ise sinaps oluşturmak için gangliyon hücrelerle temasta bulunurlar. Burada bulunan gangliyon hücreleri optik sinirlerin aksonları boyunca yol alır ve görsel bilgiyi beyin diğer kısımlarına taşırlar. Ayrıca, retina horizontal ve amakrin hücrelere de sahiptir. Bu iki hücre de retina yüzeyine paralel bir doğrultu üzerinde bilgiyi iletir ve böylece fotoreseptörlerden gelen bilgileri bir araya getirirler.

Primat retinaları bilinen 55 farklı tipte nörona sahiptir. Bu nöronlar;

- 1 tip rod,
- 3 tip kon,
- 2 tip horizontal,

- 10 tip bipolar,
- 24-29 tip amakrin ve
- 10-15 tip gangliyon hücreleridir (Carlson, 2011).

2.1.6. Göz-Beyin Bağlantısı

Bilgiyi beynin kalan kısmına getiren retinal gangliyon hücrelerinin aksonlarıdır. Bu aksonlar, optik sinirler yolunda iletilir ve talamusun dorsal lateral genikulat çekirdeğine (LGN) ulaşırlar. LGN'ler altı tabakalı nöronlardan oluşur. İçteki ilk iki tabakada bulunan nöronlar dıştakilere göre daha geniş hücre yapıları içerir.

Optik sinirler beynin tabanında bir araya gelerek X-şekilli optik kavşaklar oluştururlar. Lens ise retinaya ulaşan görüntüyü ters şekilde işler. Retinada ayrılan aksonlar beynin ters tarafında olduğu için, hemisferler görüntü bilgisini ters taraftan alır. İleriye doğru bakıldığında sağ hemisferin işlediği bilginin büyük bir kısmı görme alanının sol yarısından gelir. Sol hemisfer için ise bu durumun tersi geçerlidir. Ancak hemisferlerin, görüntüdeki bilgiyi sadece ters tarafta bulunan gözden aldığını söylemek doğru değildir. Retinada bulunan fiberler aracılığıyla çeşitli yollar da işleme devam eder. Örnek olarak hipotalamusa giden bir yolak, 24 saatlik ritimleri düzenlemede etkin rol oynar. Özellikle optik tektum ile orta-beyin çekirdeğine ulaşan yollar göz hareketlerini koordine eder. Pupil ölçüsünü kontrol eden iris kaslarını ve lensleri kontrol eden silial kaslar kontrol edilerek görme alanımızın periferinde meydana gelen ani hareketlere doğrudan ilgi duymamızda yardımcı olurlar (Carlson, 2011).

2.1.7. Hareketin Algısı


Birey hareketi gözlemlediğinde yalnızca ne olduğunu değil, nerede olduğunu ve eğer hareket halinde ise nereye yöneldiğini bilmek ister. Bunun sebebi bireyin hareketi öngörmek için hareketin yönünü ve hızını hesaplama isteğinden dolayıdır. Hayvan çalışmalarında ulaşılan bilgiler sonucunda ekstrastriat korteks bölgelerinden V5 alanında (MT olarak da bilinir) bulunan nöronlar harekete tepki gösterir. Bu bölgenin hasarı sonucunda hareketi algılama yeteneğinde kayıplar görülür (Siegal ve Andersen, 1986). V5 alanı bilgiyi striat ve ekstrastriat korteksten alır. Buna ek olarak superior kolikulustan bilgi alır ve görsel refleksle ilişkilendirir. Ayrıca gözün refleksif hareketleri de V5

alanının kontrolündedir. V5a (medial superior temporal (MST) olarak bilinir) olarak adlandırılan ve V5 alanına da yakın olan bir bölge hareket hakkında bilgi alır ve hareketin işlemlerini gerçekleştirir. Bu nöronlar hareketin detaylarına, döngüsel hareketlere, merkezden çevreye yayılan yarı dairesel, kıvrımlı ve boyutsal hareketler ile ilgilidir ve optik akışın analizinde gözlemlenir. Birey hareket halinde olduğu zaman ve etrafındaki objeleri gözlemlediğinde retina aktiftir ve retinadaki bu değişimler çevresel özelliklerin boyutları ve biçimlerine göre şekillenir.

İnsan üzerinde yapılan çalışmalar sonucunda ise fonksiyonel görüntüleme çalışmalarında harekete duyarlı olan beyin bölgesinin alt temporal sulkusunda bulunduğu gözlemlenmiştir (Dukelow ve ark., 2001). Bu bölgenin lateral oksipital kortekse yerleştiği, lateral ve alt oksipital sulkuları arasında bulunduğu gözlemlenmiştir. İnsan beyninde bilateral hasar oluştuğunda bu durum harekete duyarlı alanı da etkiler. Hareket algısının kaybolması hastalığı akinetopsiadır. Zihl ve arkadaşlarının 1991 yılında yaptıkları çalışmada V5a alanı zarar görmüş lezyonlu bir hasta vakasını rapor etmişlerdir. 1998 yılında yapılan bir çalışmada ise Walsh ve Delvin'in üzerinde çalıştığı insan vakasında transkraniyal manyetik uyarım yöntemi kullanılarak bilgisayarda gösterilen objelerin hareketlerini algılama güçlerini düşürdüğünü bulmuşlardır. Uyarım kesildiğinde ise objelerin hareketliliğinin algılandığı gözlemlenmiştir. Aynı şekilde farklı bölgeler uyarıldığında ise hareket algılama yeteneklerinde bozulma gözlemlenmemiştir (Carlson, 2011).

Hareketin algılanmasını incelemek amacıyla 1973 yılında Johansson ve arkadaşları farklı örnekte çalışmalarla açıklamaya çalışmışlardır. Yapılan çalışma hazırlığında aktörlere siyah kıyafet giydirilmiş, vücudun birçok eklem bölgesine ışıklar takmış ve karanlık bir odada farklı hareketler sergilemelerini istemişlerdir. Bu hareketler günlük hayatta birçok kez gözlemlediğimiz yürüme, koşma, zıplama, şınav çekme gibi hareketlerdir ve bunların uygulanması sırasında aktörler videoya çekilmiştir. Bu video serilerini seyreden katılımcı grup, karanlıkta sadece ışık hareketlerinden bireyin hareketlerini algılayabilmişlerdir, üstüne aktörlerin cinsiyetini de kesin olarak söyleyebilmişlerdir. Bireylerin hareketleri,

omuz ve kalça hareketlerinden elde edilen ipuçları ile algıladıkları gözlemlenmiştir (Kozlowski ve Cutting, 1977; Barclay, Cutting ve Kozlowski 1978).



Şekil 2. Sensorimotor korteks ve motor korteks. Hareket yapıldığında ve gözlemlendiği esnada aktivite artışı başlıca bu iki bölgede gözlemlenir (Fox ve ark., 2016).

2.1.8. İnsanlarda Ayna Nöronlar


Bir fincanı tutmak ne kadar basit bir hareket gibi görünse de ardışık nöral aktiviteler sonucunda hareket tamamlanır. İlk olarak fincana yönelmek için fincanın diğer nesnelerden ayrılması gerekir. Bunun için fincanın görüntüsü göz çukuruna düşmeli, sonrasında da fincanın rengi, şekli ve uzaysal konum bilgileri sensorimotor korteks tarafından hesaplanmalıdır. Bu hesaplamalar sonucunda fincanın tutulması en doğru şekilde hesaplanır ve tutuş gerçekleştirilir. Bir fincanı tutmak gibi bir hareket için harekete başlamadan önce ve hareket sırasında kontrol amaçlı olarak hareketin sonunun tahmin edilmesi gerekir. Bu sırada vücudun dinamik dengesini korumak için gerekli postural düzenlemeler ile nesneleri tanıma, uzaysal konumlarını belirleme, duyular, propriyoseptif bilgiler ve motor aktivitenin ortak çalışması söz konusudur (Sinigaglia, 2006).

Bu düzenlemelerin gerçekleştirilmesi için farklı kortikal alanlarda bulunan duysal ve motor mekanizmalardan sorumlu bölgelerin birlikte çalışması gerektiği son 20 yıl boyunca birçok çalışma tarafından desteklenmiştir. Bunun için görsel alanlardan sorumlu

oksipital lob, bedensel-duyusal alanlardan sorumlu postsantral girus, işitsel alanlardan sorumlu superior temporal girus ve motor alanların bulunduğu agranular frontal kortekste bulunur. İletim alanları olarak adlandırılan kortikal bölgelerin bu duyusal ve motor bölgelerin arasında bulunduğu ve temporo-parietal bölgelerde bulunan nöral düzenlemeler ile nesne ve mekânsal algı bilgilerinin düzenlenerek motor kortekse gönderildiği ve hareket düzenlenmesinin yapıldığı düşünülmektedir (Sinigaglia, 2006).


Motor korteksin organizasyonunu incelemek amacıyla yapılan bir araştırma sonucunda makalenin yazarı Elwood Henneman'ın açıklamasında ayna nöron mekanizması, düşünce ve hislerin harekete aktarılması olarak tanımlanmıştır. Ancak aktarımın hangi koşullarda, nasıl oluştuğunu anlamak için daha birçok çalışma ve analizin yapılması gerektiğini de eklemiştir. Kısa süre içinde motor sistemin kortikal alanlarda çok daha fazla ve karmaşık bağlantıyı da içerdiğini gözlemleyen çalışmalar da yayımlamıştır (Henneman, 1984).

Anlık kortikal etkinlikleri kaydeden EEG'den alınan verinin frekans değerlendirmeleri sonucunda sağlıklı ve yetişkin bireyler gözlerin kapalı olduğu dinlenme durumunda alfa frekansları (8-12 Hz) posterior alanlarda gözlemlenirken, senkronizasyonu bozulan ritimler frontal lobta gözlemlenir. Daha önce yapılan birçok beyin görüntüleme çalışmasında başka birinin hareketinin gözlemlenmesi ile kaydedilen nöral aktivitelerin ilişkili olduğu görülmüştür (Gallese, 1996). Motor ilişkili kortikal alanların hareket algısı sonucunda aktif olması sonucunda ayna nöron mekanizması devreye girer. Hareketin gözlemlenmesi ile beyin kendi içinde hareketi simüle eder. Bu hareket simülasyonu ile nöronal aktivitelerin organizasyonu yeniden düzenlenir ve ayna nöronların yardımı ile motor gözlemin anlaşılmasına katkıda bulunur (Nakano, 2017).



Şekil 3. İnsanlarda ayna nöron mekanizması. Mor alanlar (SPL ve PMD) uzanma hareketinden sorumludur. Sarı alanlar (IFG, PMV, IPL, IPS) vücuttan uzaklaşan geçişli hareketlerden sorumludur. Mavi alanlar (STS) üst dudak hareketlerinin gözleminde, yeşil alanlar (A) intransitif hareketlerde, turuncu alanlar (B) nesne kullanımında aktifleşir. (Kısaltmalarda PMD dorsal premotor korteksi, SPL superior parietal lobçuğu, IFG inferior frontal girusu, PMV ventral premotor korteksi, IPL inferior parietal lobçuğu, IPS intraparietal sulkusu, STS superior temporal sulkusu temsil eder.) (Nakano, 2017).

İnvazif olmayan elektrofizyolojik (örneğin elektroensefalografi, manyetoensefalografi (MEG), transkraniyal manyetik uyarım (TMS)) ve beyin görüntüleme (örneğin pozitron emisyon tomografisi (PET), fonksiyonel manyetik rezonans görüntüleme (fMRG)) yöntemler kullanılarak yapılan çalışmalar sonucunda insanlarda da ayna nöron mekanizmasının varlığı keşfedilmiştir (Fadiga, 1995; Rizzolatti, 1996b; Grafton, 1996; Grezes, 1996). Beyin görüntüleme çalışmaları sayesinde (Caspers ve ark., 2010; Molemberghs ve ark., 2012) ayna nöron alanlarını tanımlamak ve konumlandırmak daha kolay hale geldi. Bu çalışmalar sonucunda geçişli bir hareketin gözlemlenmesi sonucunda hareketi izleyen katılımcının kanın oksijene bağlı ölçülen (BOLD) sinyal seviyesindeki artışın yalnızca gözlemsel işlevle ilişkili bölgelerinde değil, inferior parietal lobta, ventral premotor kortekste ve inferior frontal girusun kaudal kısmında da aktif olduğu gözlemlenmiştir.



Şekil 4. Meta-analiz sonucunda hareket gözlemi için ulaşılan anlamlı BOLD (fMRG) değişimi sonuçları (Caspers, 2010).

Vücut hareketlerinin gözlemlenmesi -geçişli ya da geçişsiz (transitive and intransitive actions) olması farketmeksizin- sonucunda premotor kortekste aktivite görülür (Buccino et al. 2001). Yapılan çalışmalar sonucunda ayna nöronların hedefe yönelik motor hareketlerde etkinleştiği birçok çalışma tarafından kabul görür (Rizzolatti ve ark., 2001). Umilta ve arkadaşları 2001 yılında bu hipotezi test etmek amacıyla iki deney tasarladı. İlk deneyde ayna nöronların özellikle gözlemlenen obje tutuşunun ileri safhalarında aktifleştiği gözlemlendi ve iki koşulda gözlemlenmek üzere nesne tutuşu iki ayrı yolla gösterildi. İlk denemede, maymun kavramanın ve tutuşun tamamını izledi. Diğer denemede ise maymun yalnızca el hareketini gözlemledi. Bu iki durumun karşılaştırılmasıyla maymunlarda F5 ayna nöronlarının yarısından çoğunun ateşlendiği görüldü (Umilta ve ark., 2001). Araştırmacılar bu canlandırmanın sonucunda hareketin gözlemlenmesi sonucunda değil, anlaşılması sonucunda ayna nöron aktivitesinin görüldüğünü rapor etmişlerdir. İkinci çalışmada motor hareketin sunumu sesli uyarım yöntemi kullanılarak uygulandı. Bu çalışmanın sonucunda çok sayıda ayna nöronun yalnızca hareketin (ör. Fıstığın kırılması) gözlemlenmesine değil aynı zamanda hareketin sesine de tepki verdiği görüldü (Kohler ve ark., 2002). Araştırmacılar aynı zamanda beyaz gürültü gibi spesifik olmayan sesli uyarımlar da verdiğinde bu bölgelerde aktivite


görülmediği sonucunu da paylaştı. Bu bulgular sonucunda ayna nöron tepkilerinin görsel uyaranların yokluğunda dahi tepki verdiği gözlemlenmiştir.

Ayna nöron mekanizması, gözlemsel olarak elde edilen duyuşsal informasyonları bireye özgün hareket örüntülerine dönüştürür. Bu süreç canlıların hareket ve davranışlarını anlamamıza olanak sağlar. Ek olarak hareketin amacını ve sonuçlarını hesaplamak için kognitif süreçlerden yararlanır. Hareket ve davranışların amacının anlaşılması (Fogassi, 2005), empati (Singer, 2004) ve zihin teorisi (Gallese, 1998) ayna nöron mekanizmasının fonksiyonel karakteristik özelliklerindendir ve bu sebeplere dayanarak yapılan araştırmalar sonucunda ayna nöron mekanizmasındaki işlev bozukluğu otizmle ilişkilendirilir (Oberman, 2005).

Watabane ve arkadaşları 2013 yılında, Angelini ve arkadaşları ise 2018 yılında nesne yönelimli hareketin katılımcı tarafından gözlemlendiği yönün ayna nöron aktivitesi üzerindeki etkisini araştırmak için yaptıkları çalışmada hareketi gerçekleştiren katılımcının perspektifinden yapılan gözlemi birinci tekil gözlem perspektifi olarak, harekete 180 derece karşı açıdan bakılarak yapılan gözlemi ise üçüncü tekil gözlem perspektifi olarak adlandırmışlardır. Watabane ve arkadaşlarının yaptığı çalışmada araştırma konusu reaksiyon zamanı ve beyin aktivitesinin birinci tekil perspektif ve üçüncü tekil perspektif arasındaki farkları, hareket ve hareket gözlemi amacıyla fonksiyonel manyetik rezonans görüntüleme cihazı kullanarak araştırdılar ve birinci tekil gözlem perspektifinin ayna nöron aktivitesi için daha etkili olduğu sonucunu yayımladılar. Dahası sunulan çalışmada birinci tekil gözlem perspektifinin motor ilişkin alanlarda anlamlı farklılıkla gözlemlenen bu etkinliğin aynı zamanda motor öğrenimi geliştirdiği sonucuna varmışlardır (Watabane ve ark., 2013). Benzer şekilde Angelini ve arkadaşları da dört farklı gözlem açısı kullanarak yaptıkları çalışmada birinci tekil gözlem perspektifinin ayna nöron aktivitesi için en etkin yöntem olduğunu ve üçüncü tekil gözlem perspektifinin ise birinci tekil gözlem perspektifinden sonraki en etkin gözlem perspektifi olduğu sonucunu paylaştılar (Angelini ve ark., 2018).

EEG, yöntem olarak ayna nöron çalışmalarında oldukça yaygın olarak kullanılmaktadır. Spesifik olarak gözlemlenen EEG ritimlerinden Mu ritim (8-13 Hz) insan beyninde

sensorimotor korteks olarak adlandırılan bölgede gözlemlenir. Mu ritmin baskılanması için bireyin hareketi gerçekleştirilmesi, gözlemlemesi ya da imgelemesi gerekir (Pfurtscheller, 1997). Daha önce yayımlanan birçok EEG çalışmasında Mu ritim ayna nöron aktivitesine dair fizyolojik işaret olarak kullanıldı ve bu çalışmalarda Mu ritmin ayna nöron mekanizmasındaki aktiviteleri temsil ettiği sonucu ile yayımlandı. Benzer aktivitelerin fonksiyonel manyetik rezonans görüntüleme yöntemi kullanılarak araştırılması ile Mu ritim desenkronizasyonu ile hareket ve hareket gözlemi arasında anlamlı korelasyon gözlemlenmiş ve yayımlanmıştır (Fox ve ark., 2016).



Şekil 5. Mu ritim desenkronizasyonu. Şekil, 8-13 Hz frekans bantlarındaki Mu ritim desenkronizasyonunun simülasyonudur. Referans noktasına göre hareket ve hareket gözleminin EEG genliklerinde gözlemlenen düşüş paylaşılmıştır (Fox ve ark., 2016).

2.2. Makine Öğrenimi

2.2.1. Makine Öğrenimi Uygulamaları

Derin öğrenme yöntemi, bir tür makine öğrenimi uygulamasıdır. Bu sebeple derin öğrenme yöntemlerini iyi anlamak için öncelikle makine öğrenimi uygulamalarının temellerini bilmek gerekir. Makine öğrenimi uygulamalarında, başlangıçta hiperparametre ayarları yapılır. Bu ayarlar, ağı kendi içinde yaptığı değişikliklerin dışında, ağı düzenleyen kişi tarafından verilen ayarlardır. Makine öğrenimi, zor fonksiyonları istatistiksel olarak tahmin etmek için bilgisayarların hesaplama gücünün kullanıldığı, buna bağlı olarakta güven aralıklarını düşürerek yapılan bir uygulamalı istatistik alanıdır. Birçok makine öğrenimi uygulamaları, gözetimli ve gözetimsiz olarak iki gruba bölünebilir. Birçok derin öğrenme uygulaması ise eniyileme algoritmasına dayanır. Makine öğrenimi uygulamasının başarılı olması için eniyileme algoritması (optimization algorithm), değer fonksiyonu (cost function), model ve veri setinin farklı algoritma bileşenlerine göre nasıl düzenlenmesi gerektiğini bilmek gerekir (Goodfellow ve ark., 2016).

EEG temelli insan-makine arayüzü uygulamaları makine öğrenimi yöntemleri kullanılarak başarılı şekilde kullanılmaktadır. Makine öğrenimi sınıflandırmaları sayesinde beyin aktiviteleri ileti ya da komutlara çevrilebilir (Lotte, 2018), rehabilitasyon amacıyla (Ang, 2013) veya bireylerin mental durumlarını belirlemek için kullanılabilirler (Zander, 2011). EEG sınıflandırmaları için, farklı tür görevlerin etkileri, EEG ön işleme yöntemlerinin denemeleri, ağ yapılarında girdi olarak kullanılan yöntem ve algoritma yapıları kullanılabilir (Craik, 2019). Literatürde birçok makine öğrenimi ve örüntü tanıma yöntemi EEG verisi üzerinde kullanılır. Örneğin, Bağımsız Bileşen Analizi sinyalin artefaktlardan arındırılması için, Temel Bileşen Analizi veya Fisher's Diskriminant Analizi özellik boyutunu azaltmak için (Velu, 2013), gözetimli öğrenim yöntemlerinden Doğrusal Diskriminant Analizi ve Destek Vektör Makineleri ve Karar Ağacı Algoritmaları uyaranların etkilerini sınıflandırmak için kullanılabilir (Craik, 2019).

Makine öğrenimi uygulamaları üç temel prensip altında incelenebilir. Bu prensipler alt başlıklar halinde açıklanmıştır.

2.2.1.1. Görev

Makine öğrenimi, yalnızca formül kullanılarak çözülmesi zor problemlerin aşılmasında yardımcı olur. Makine öğrenimi sistemlerinin bir örneği nasıl tanımladığı, görev olarak tanımlanabilir. Buradaki örnek kelimesi, bir nesne ya da olaydan elde edilen ve makine öğrenimi uygulamasının çözümlemesini istediğimiz özellikleri temsil eder. Bir örneği vektör olarak temsil etmek için, χ_i girdilerinin her bir vektörünün ayrı bir özellik olduğu varsayıldığında $\chi \in \mathbb{R}^n$ şeklinde temsil edilir. Örnek olarak, bir görüntünün özellikleri, her bir pikseldeki değerlerdir. Makine öğrenimi uygulamalarında görev, sınıflandırma, regresyon, tanımlama, dil çevirisi, anomali saptama, sentez, gürültü temizleme ve olasılık belirleme gibi farklı alanlardan ve değerlendirme gruplarından olabilir (Goodfellow ve ark., 2016).

2.2.1.2. Performans

Makine öğreniminde, öğrenim yeteneğini test edebilmek için sayısal bir değer belirlenmelidir. Bu değer verilen göreve göre çeşitlilik gösterebilir. Sınıflandırma görevlendirmelerinde, genellikle doğruluk yüzdesini performans çıktısı olarak seçilir. Doğruluk yüzdesi, verilen örneklerde kullanılan modelin başarısını gösterir. Ayrıca hata oranı ölçülerek makine öğrenimi için değerli bilgilere ulaşılabilir. Doğruluk ve hata oranları için 0 ile 1 arasındaki gösterim değerleri kullanılır. Bu değerler eğitim ve test skorlarının değerlendirilmesinde ayrı ayrı kullanılabilir (Goodfellow ve ark., 2016).

2.2.1.3. Deneyim

Gözetimli ve gözetimsiz olarak gruplandırılan makine öğrenimi algoritmalarında hangi tür deneyimle öğrenimin gerçekleştiği durumu ifade etmek için kullanılır. Makine öğrenimi için kullanılan en yaygın örnek iris çiçeği örneklerinden toplanılan özelliklerin kullanılmasıdır (Fisher, 1963). Çiçeklerin dört özelliği toplanarak 3 türün hangisine ait olduğu hesaplanır ve sınıflandırılır (Goodfellow ve ark., 2016).

2.2.1.3.1. Gözetimsiz öğrenim algoritmaları

Bu tür deneyimin kullanıldığı veri seti birçok özelliği içerir. Öğrenimin gerçekleşmesi için veri setindeki en belirgin özelliğin belirlenmesi algoritma özelindedir. Derin öğrenme

kapsamında, veri setindeki tüm dağılımın özelliklerini öğrenmek amacıyla hareket ederiz. Diğer gözetimsiz öğrenim algoritmaları ise kümeleme gibi benzer özelliklerdeki verileri içeren bir seti iki ya da daha fazla gruba bölmek gibi hedefler ile uygulanır (Goodfellow ve ark., 2016).


2.2.1.3.2. Gözetimli öğrenim algoritmaları

Bu tür algoritmaların kullanımı için oluşturulan veri setinde her bir özellik, gözetimli olarak bir etiket ile belirlenir. Örnek olarak iris çiçeği veri setinde, özellik sütunlarının yanına bir ek olarak, özelliklerin hangi tür çiçeğe ait olduğu da girdi olarak verilir.

2.2.2. Derin Öğrenme

Yapay sinir ağları, verilerin sınıflandırılmasında yüksek doğruluk yüzdelere ulaşmak için, basit ve çok sayıda bağlantı kurulması ile oluşturulur. Bu modeller hesaplama hızının yüksek olması gereken çevrimiçi sistemlerde, aynı zamanda paralel işleme gerektiren görüntü işleme ve ses tanımadaki kullanılır. Öğrenme algoritmasında, derin ağ mimarisinin bilinen ilk çalışması ve ağ etimi, 1966 yılında Aleksei Ivakhnenko ve Lapa tarafından gerçekleştirilmiş ve yayımlanmıştır. Bu ağın temel özelliği, her ağdan elde edilen en ayırt edici özelliklerin istatistiksel yöntemler kullanılarak belirlenmesi ve diğer katmanda kullanılmasıdır. Geri besleme yöntemi bu mimaride kullanılmamış, en küçük kareler yöntemi ağ katmanları için girdileri oluşturmuştur (Lippmann, 1987).

Şekil 6'da gösterilen Ivakhnenko'dan sonra yapılan ilk ağ mimarisi Fukushima tarafından 1979 yılında Neokognitron adıyla uygulanmıştır. Bu yapının önemli bir özelliği omurgalı canlıların görsel sistemleri örnek alınarak oluşturulması ve denetimsiz öğrenme yöntemini benimsemesidir. Bu ağ yapısının aynı zamanda modern ağ yapılarına benzer katmaları içermesi de önemli bir noktadır (Fukushima, 1980). Derin ağlarda, geri besleme yönteminin negatif geribildirim olarak kullanılması ve ağın ulaştığı sonuçlardan hatalı olanların düzeltilmesi için ilk geri beslemeli derin ağ Yann ve arkadaşları tarafından 1989 yılında kullanılmıştır (Lecun, 1989).



Şekil 6. İlk derin ağ mimarisi, (Ivankhnenko, 1966).


Derin öğrenme kavramı ilk olarak “Multiple-Valued Threshold Logic and Multi-Valued Neurons” adıyla, 2000 yılında Igor Aizenberg, Naum Aizenberg ve Joos Vandewalle tarafından yayımlanan kitapta kullanılmıştır. Ardından 2006 yılında Geoffrey Hinton, Yee-Whye Teh ve Simon Osindero’nun yayımladığı ve günümüzde derin öğrenme için temel olarak kabul edilen “A Fast Learning Algorithm for Deep Belief Nets” adlı makalede bu kavram kullanılmış, gizli katmanların en ayırt edici özelliklerin seçiminde, daha hızlı nasıl kullanılabilecekleri açıklanmıştır. Derin öğrenme, temelde bir makine öğrenimi olmakla beraber son yıllarda kullanımı oldukça artmıştır. Makine öğreniminde en önemli nokta özellik seçimidir. Bu sebeple birçok ön işleme yöntemi ve boyut indirgeme kullanılmaktadır. Özellik çıkarımı için derin öğrenmede doğrusal olmayan katmanlar kullanılır. Katmanların her birinde ulaşılan çıktı, diğer katmanda girdi olarak kullanılır (Deng ve ark., 2014). Bu katmanların kullanımı ile yapılan özellik çıkarımında hesaplanan değerler, verinin farklı düzeylerde temsillerini oluşturur. Derin öğrenmede bu temsiller hiyerarşik bir düzende kullanılır (Bengio, 2009). Bu veri temsili görüntüde kullanıldığında, görüntünün piksel yoğunluğundan elde edilen değer vektörü ya da örüntü kümeleri olabilir. Derin öğrenme yönteminin iyi olmasının sebeplerinden biri, verinin hiyerarşik olarak temsillerinden en ayırt edici olanın, kullanılan algoritmalar tarafından seçilmesidir (Song, 2013).

2.2.2.1. Konvolüsyonel Sinir Ağları

Konvolüsyonel sinir ağları, girdilerden çıktıların tek yönlü enformasyon akışını sağladığı, ileri beslemeli ağlardır. Yapay sinir ağlarında olduğu gibi konvolüsyonel sinir ağlarının da esin kaynağı biyolojik ağlardır. Basit ve kompleks hücrelerin alternatif katmanları ile oluşan beyindeki görsel korteks (Hubel ve Wiesel, 1959, 1962), bu katmanları kullanarak yapısını düzenler. Konvolüsyonel sinir ağları, birçok varyasyondan meydana gelse de, genellikle konvolüsyon ve havuzlama ya da indirgeme katmanlarını modül olarak kullanır. Bir ya da daha fazla sayıda bağlantılı katmanlar da modüller içinde gruplanır. Şekil 6'da örnek bir konvolüsyonel sinir ağları yapısı gösterilmektedir. Sinir ağına girdi olarak verilen örnek bir görüntü, birçok farklı konvolüsyon ve havuzlama katmanı kullanılarak oluşturulabilir (Rawat ve Wang, 2017).

Dijital alanda piksellerin bir araya gelmesiyle oluşturulan ve kalitesi çözünürlük ve kullanılan renk sayısı ile belirlenen görüntülerin sınıflandırılmasında konvolüsyonel sinir ağları, görüntü işleme amacıyla başarılı bir şekilde kullanılmaktadır.

Eğer görüntünün sadece siyah ve beyaz olarak temsil edilen piksellerden oluştuğu düşünülürse, her piksel 0 yada 1 olarak adlandırılır ve bu piksellerin her biri hafıza olarak 1 bit yer işgal eder. Renk sayısı ile kullanılması gereken hafıza alanı da artacaktır. Renkli görüntü günümüzün dijital dünyasında üç renk kullanımı ile oluşturulur. RGB düzeni kullanılarak -bu harfler sırasıyla kırmızı, yeşil ve mavi bileşenleri temsil eder- her bir renk 0 ile 256 arasında, farklı bir renk tonunu temsil edecek şekilde numaralanır ve görüntüdeki her bir piksel bu renk tonlarının karışımı ile oluşturulur. Bu renk tonlarının her biri görüntü işleme alanında kanal olarak isimlendirilir ve her bir renk tonu ile görüntü üç farklı kanal kullanılarak değerlendirilir.



Şekil 7. Örnek bir konvolüsyonel sinir ağı yapısı (Rawat ve Wang, 2017)

Konvolüsyonel sinir ağı, temel olarak 4 aşamadan geçen bir süreç sonucunda tamamlanır. Bu süreçler;

- Konvolüsyon + ReLU
- Havuzlama, Örnekleme, İndirgeme
- Sınıflandırma
- Hata Azaltma

alt başlıkları ile açıklanmıştır.

1) Konvolüsyon + ReLU

Konvolüsyon katmanları özellik çıkarımında kullanılır ve bu özelliklerin örneklerini öğrenirler. Konvolüsyon katmanlarında kullanılan nöronlar, çıkarılan özellik haritası (feature map) tarafından düzenlenir. Özellik haritasındaki her nöron, önceki katmanda bulunan komşu nöronların ağırlık katsayılarını kullanılması ile filtre görevi gören algılayıcılar gibi çalışır. Girdi olarak kullanılan verinin tekrar özellik haritası çıkarılır ve öğrenim katsayılarına dönüştürülür. Bu sonuçlar doğrusal olmayan aktivasyon fonksiyonunda dönüştürülür (LeCun, 2015). Konvolüsyon katmanlarında bulunan özellik haritaları ağ içinde farklı ağırlıklara sahiptir. Bu sebeple her noktadan farklı bir özellik çıkarımı yapılabilir (LeCun, 2015). Matematiksel olarak, k sırasındaki bir özellik haritası için Y_k şu şekilde hesaplanabilir

$$Y_k = f(W_k * x)$$

ve girdi olarak kullanılan görüntünün x olarak temsil edildiği kabul edilir; konvolüsyonel filtrenin k sırasındaki özellik haritası W_k olarak temsil edilir; bu formülde yıldız işareti 2D konvolüsyonel operatörü temsil ederek, girdi görüntüsünün her noktasındaki filtreler olarak iç çarpımların hesaplanmasında kullanılır; ve $f(.)$ doğrusal olmayan aktivasyon fonksiyonunu temsil eder (Yu ve ark., 2014). Bu fonksiyon doğrusal olmayan özelliklerin çıkarılmasını sağlar. Geleneksel olarak, sigmoid ve hiperbolik tanjant fonksiyonları kullanılır ve son zamanlarda, düzleştirilmiş doğrusal birim katmanı (rectified linear units, ReLUs; Nair ve Hinton, 2010) yaygın olarak kullanılmaktadır (LeCun, 2015).


2) Havuzlama (Pooling)

Havuzlama katmanlarının amacı, özellik haritalarındaki uzaysal çözünürlüğü azaltmaktır. Bu işlem veride bilgi kaybına yol açsa da ağır görüntüyü ezberlemesinin önüne geçer ve diğer katmanda hesaplama yükünü azaltır. Konvolüsyon katmanında olduğu gibi bu katmanda da filtreler kullanılır. Bu katmanda kullanılan filtreler görüntü üzerinde seçilen yönteme göre azami değerleri ya da ortalama değerleri alır. Genel olarak her algılayıcı parçadaki en geniş bölüm seçilir ve azami havuzlama katmanı şu formülle;

$$Y_{kij} = \max_{(p,q) \in \mathcal{R}_{ij}} x_{kpq}$$

havuzlama katmanının çıktısı olarak, k sıradaki özellik haritası Y_{kij} ile temsil edilir. x_{kpq} görüntüde havuzlama alanını kapsayan $\mathcal{R}_{ij}$ ile temsil edilir ve $\mathcal{R}_{ij}$, algılayıcı alan konumunu (i, j) temsil ederek, (p, q) noktasındaki her unsuru kapsar (Yu ve ark., 2014). Şekil 5'te azami ve ortalama havuzlama katmanlarının işlem farklılığı gösterilmektedir. Örnekte görüldüğü gibi 4x4 matrisle verilen bir görüntüde 2x2'lik bir filtre alanı kullanılırsa, azami havuzlama seçildiğinde her 2x2'lik matrisin azami değeri, ortalama havuzlama

seçildiğinde ortalama değeri kullanılarak diğer katmana girdi hazırlanır. Ortalama havuzlama katmanında yapılan her hesaplamada, matrislerin ortalaması tam sayıya yuvarlanır (Rawat ve Wang, 2017).



Şekil 8. Azami ve ortalama havuzlama örnekleri (Rawat ve Wang, 2017)

3) Tam Bağlantılı Katmanlar (Fully Connected Layers)

Birçok konvolüsyonel ve havuzlama katmanı özellik çıkarımı ve veri indirgeme için ağ boyunca tekrarlı olarak kullanılır. Bu katmanları takip eden tam bağlantılı katmanlar, çıktıları aracılığı ile sınıflandırma işlevi görür (Hinton ve ark., 2012; Simonyan, 2014). Bu işlevin gerçekleştirilebilmesi için gerekli olan tam bağlantılı katmanın önceki noktada tüm çıktılara bağlanmasıdır.

3. GEREÇ ve YÖNTEM

3.1. Araştırma Grubu

Çalışmada, İstanbul'da ikamet eden, Marmara Üniversitesi'nde veya İstanbul Arel Üniversitesi'nde öğrenim gören, yaşları 19 ile 28 arasında değişen 10 sağlıklı erkek gönüllü (ortalama yaş 23.60 ± 2.79), katılımcı grubunu oluşturmuştur. Katılımcıların herhangi bir sinir sistemi rahatsızlığına sahip olmaması ya da geçmiş dönemde bu tür bir rahatsızlık yaşamamış olması çalışmaya dahil olma kriterleri arasındadır. Katılımcı grubunu, günlük aktivitelerde genellikle sağ ellerini kullanan katılımcılar, katılımcı beyanına göre doğrulanarak çalışmaya dahil edilmiştir. Bu tez çalışmasının yapılması için Marmara Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu'ndan 09.2018.842 protokol kodu, 07.12.2018 tarihi ile etik kurul izni alınmıştır.

3.2. Araştırmanın Yöntemi

Çalışmada katılımcılara el hareketinin uygulanması ve aynı hareketin gözlemlenmesi görevleri olmak üzere iki farklı EEG deneyi, sıralamaları kişiler arasında rastgele olacak şekilde uygulanmıştır. Hareket görevinde katılımcının stres topunu sıkma hareketini, ölçüm süresi boyunca kendi karar vererek tekrarlı şekilde uygulaması istenmiş ve 64 kanallı EEG cihazı kullanılarak veriler toplanmıştır. Gözlem görevinde katılımcıdan ölçüm boyunca hareketsiz bir şekilde kalması ve başka bir bireyin hareket görevini gözlemlemesi istenmiştir. İki görev süresinde uygulanacak el hareketi şekilde gösterildiği gibi, katılımcının kendi kararı doğrultusunda uygulaması ile gerçekleştirilmiştir. 6.50 cm çapta, yaklaşık 20 gr ağırlıkta stres topu, katılımcıların hareketi uygulaması ve gözlemlemesi için kullanılmıştır. Her katılımcıdan 4 farklı EEG kaydı, iki hareket ve iki gözlem deneyi olmak üzere ölçülmüştür. Ölçüm süreleri 5 dakika olarak belirlenmiş ancak katılımcıya herhangi bir süre ya da top sıkma sayısı görev olarak belirtilmemiştir. EEG ölçümleri hareket görevi ile başlarsa, her katılımcının ölçümler arasında 2-4 dakika ara verilerek yapılan 4 ölçüm hareket-gözlem-hareket-gözlem sırası ile, ölçüm gözlem görevi ile başlarsa ise gözlem-hareket-gözlem-hareket sırası takip edilerek uygulanmıştır. Ölçüm başlangıcında katılımcılardan göz kapalı olmak üzere 3 dakikalık referans kayıtları alınmıştır.



Hareket



Gözlem

Şekil 9. Katılımcıların uyguladığı ve gözlemlediği hareketlerden örnek görüntüler

3.3. Araştırmanın Çalışma Alanı

Deney kurulumu ve ölçümleri Arel Üniversitesi Mühendislik-Mimarlık Fakültesi Biyomedikal Mühendisliği Bölümü'nde, analizleri Marmara Üniversitesi Spor Bilimleri Fakültesi Sinirbilim Laboratuvarı'nda gerçekleştirilmiştir.


3.4. Araştırmada Uygulanan Testler ve Ölçümler

Katılımcılara, deney başlamadan önce araştırma ve elde edilecek sonuçların literatüre sağlayacağı katkılar hakkında bilgi verilerek test protokolüne sadık kalmaları istenmiştir. Katılımcılar test gününde ilaç, nikotin ve alkol kullanmamaları hususunda uyarılmıştır.

Elektroensafalografi (EEG)

Beyin aktiviteleri esnasında oluşan elektriksel aktivitelerinin yüksek çözünürlüklü kayıtları için 64 kanallı EEG ölçüm cihazı kullanılacaktır. Bu elektrotlardan santral bölgede bulunan bir elektrot referans olarak kullanılacaktır. Kayıtlarda kullanılan EEG cihazı, 512 Hz zamansal örnekleme frekansında kullanılacaktır. Elektrot yerleşiminde 63 elektrot sinyal kaydı, 1 elektrot referans ve ek olarak 1 elektrot toprak kanalı olarak kullanılmıştır. Aktivitelerin yüksek zaman çözünürlüğünde kaydedebilmesi sayesinde farklı frekans bantlarının incelenebilmesine olanak sağlar. EEG'de gözlemlenen farklı frekansların ortaya çıkmasında yaş, cinsiyet, genetik etkenler gibi değişkenlerin yanında uyku, uyanıklık, gözlemsel veya duyuşsal olarak maruz kalınan birçok değişkenin etkisi de vardır (Kolev, 2002). Yüksek zamansal örnekleme frekansında kayıt altına alınan EEG

sinyallerinden geleneksel frekans bantlarındaki güç değerlerine ulaşmak mümkündür. Katılımcıların gerçekleştirdikleri hareketlerin öncesinde ve sonrasında kaydedilen EEG sinyalleri, 500 milisaniyelik pencerelerde bölümlenerek, literatürde genel olarak frekans aralıkları olarak kullanılan zaman-frekans çıktıları hesaplanıp -teta bandı (4-8 Hz), alfa bandı (8-13 Hz) ve beta bandı (13-30 Hz)- ileri analizlere tabii tutuldu.



Şekil 10. 64 kanallı EEG seti. 1. Elektriksel sinyal güçlendirici, 2. Başlık, 3. Elektrotlar numaralandırılmış olarak gösterilmektedir.

3.5. Analiz

Analiz için ilk olarak Matlab® programında EEGLAB eklentisi kullanılarak, EEG verileri elektrik ve göz hareketlerinin oluşturduğu etkilerden arındırıldı ve sinyal 3-44 Hz arasında sınırlandırıldı. Sinyaller, katılımcının ve gözlemlediği el hareketleri sırasında kaydedilen video görüntüleri kullanılarak EEG verisi üzerinde zaman noktaları belirlendi. Bölümleme işlemi için EEG ölçümleri sırasında 1280x720 piksel çözünürlükte, 60 saniye/kare ile kaydedilen videolardan ayrıştırılan görüntüler incelenerek görüntü numaraları bulundu, bu değerler kullanılarak EEG sinyallerinde Matlab® programı aracılığıyla sinyallerde elin hareket başlangıcı, nesneyle temas anı ve hareketsiz olduğu zaman noktaları belirlendi ve sinyal zaman noktaları işaretlendi.



Şekil 11. Katılımcının gerçekleştirdiği hareket esnasında kaydedilen video kayıtlarından örnek görüntü dizisi. (A: Sabit duruş, B: Hareket, C: Nesne Teması ve topu sıkma, D: Topu terkediş)



Şekil 12. Katılımcının gözlemlediği hareket esnasında kaydedilen video kayıtlarından örnek görüntü dizisi. (E: Sabit duruş, F: Hareket, G: Nesne Teması ve topu sıkma, H: Topu terkediş)


Ölçümlerde toplanan veri seti, hareket ve gözlem olarak ilk grup ile yapay sinir ağları sınıflandırmalarında girdi olarak kullanıldı. Literatürdeki bu konuda yapılan araştırmalardan yola çıkılarak 10 gönüllü katılımcı çalışmada ölçüm grubunu oluşturmuştur (Babiloni, 2002; Angelini, 2018; Coll, 2015).

3.5.1. Zaman-Frekans Analizi

Zaman-frekans analizi, frekans bilgisinin zamana bağlı olarak değişimini gösteren bir dönüşümdür. Bu metotta sinyalin durağan olduğu kabul edilir ve pencerelere bölünür. Her penceredeki Fourier dönüşümü hesaplanmasıyla kısa zamanlı Fourier dönüşümü bilgisi elde edilir. Durağanlık geçerliyse sinyal pencere fonksiyonu ile çarpılan sinyalden sonuca ulaşılabilir. Sinyalde durağanlık geçerli değil ise sinyal küçük parçalara ayrılıp, ardından Fourier dönüşümü yapılır ve her pencerenin frekans bilgisi ayrı ayrı elde edilir. Durağan olmayan verilerde bu yöntemin uygulanma sebebi zaman kaybını önlemektir (Keeton ve ark., 1998).

Fourier dönüşümleri yerine dalgacık dönüşümü yönteminin kullanılma sebebi, Fourier dönüşümlerinin zaman boyutundaki frekans değişimlerini göstermemesidir. Morlet dalgacık dönüşümü, sinyalde bu değişimleri görmek için oldukça kullanışlı bir yöntemdir.

Morlet dalgacığı yaratmak için, aynı zaman noktası boyunca aynı örnekleme frekansında üretilen sinüs dalgası ve Gaussian eğrisi çarpımı kullanılır. Dalgacık dönüşümü ile hesaplanacak frekanslar, sahip olunan zaman noktası sayısı yerine işlem yapan kişi tarafından belirlenebilir. (Cohen, 2014).



Şekil 13. Bir Morlet dalgacığı (solda) ve farklı frekans temsilleri için Morlet dalgacıkları (sağda) (Cohen, 2014)

Görselde paylaşılan Morlet dalgacıkları, belirlenen zaman serisi sinyalinde nokta çarpım yoluyla kaydırılır ve sinyaldeki frekans bilgilerine ulaşılır (Cohen, 2014). Çalışmada görüntü setini oluşturan zaman-frekans hesaplamaları için EEG sinyallerinde belirlenen hareket noktaları başlangıç olarak belirlendi. Dalgacık dönüşümü hesaplamaları kısa zamanlı dalgacık dönüşümü kullanılarak, mutlak değerler ile 500 milisaniye ve 3-44 Hz aralığında uygulandı ve örnek hesaplama görüntüleri bulgulara paylaşıldı.

3.5.2. Zaman-Frekans Çıktısı Gram Matrisi

Tek ya da çok kanallı sayısal sinyaller genellikle matris olarak temsil edilir. Örnek olarak sütunların ölçüm kanalları, satırların ölçüm değerleri olarak kabul edildiği bir sinyal düşünelim. A 'nın $t \times n$ sinyal matrisi olduğunu kabul edersek, t zaman noktalarının sayısı ve n zaman boyutunda alınan dijital sinyalin sayısıdır. $t \times t$ kare matrisini M olarak düşündüğümüzde;

$$\mathbf{M} = \mathbf{A}^T \mathbf{A},$$

formülünde $\mathbf{A}^T$, $\mathbf{A}$ 'nın devriğidir (transpose). İşlem sonucunda $\mathbf{M}$ tek ya da çok sayıda kanalın yeni matris temsilidir. Bu formül sonucunda $\mathbf{M}$ 'nin boyutu, n 'ye bağlı değildir. Burada $\mathbf{M}$ 'nin ne ifade ettiği şöyle bir örnekle açıklanabilir;


$\mathbf{A}$ 'nın örnekte görüldüğü gibi 3 x 2'lik bir matris olarak kabul edersek,

$$\mathbf{A} = \begin{bmatrix} s_1(t_1) & s_2(t_1) \\ s_1(t_2) & s_2(t_2) \\ s_1(t_3) & s_2(t_3) \end{bmatrix},$$

$s_1()$ ve $s_2()$ iki ayrık sinyal ve t_1 , t_2 ve t_3 üç ardışık zaman noktası olarak temsil edilir. Sonucunda $\mathbf{M}$;


$$\begin{array}{lll} \{s_1(t_1)\}^2 + \{s_2(t_1)\}^2 & s_1(t_1)s_1(t_2) + s_2(t_1)s_2(t_2) & s_1(t_1)s_1(t_3) + s_2(t_1)s_2(t_3) \\ s_1(t_1)s_1(t_2) + s_2(t_1)s_2(t_2) & \{s_1(t_2)\}^2 + \{s_2(t_2)\}^2 & s_1(t_2)s_1(t_3) + s_2(t_2)s_2(t_3) \\ s_1(t_1)s_1(t_3) + s_2(t_1)s_2(t_3) & s_1(t_2)s_1(t_3) + s_2(t_2)s_2(t_3) & \{s_1(t_3)\}^2 + \{s_2(t_3)\}^2 \end{array}$$

ve $\mathbf{M}$ 'deki her eleman, farklı tek boyutlu sinyallerden gelen örnek değerlerin toplamıdır. $\mathbf{M}$ 'nin çarpımları dışında, tüm diğer elemanlarda aynı sinyalde farklı zaman noktalarındaki ölçüm değerlerinin çıktısıdır. Diyagonelde gözlemlenen, aynı zaman noktasında farklı sinyal değerlerinin karelerinin toplamıdır. Örnek görsellerde Ramesh ve arkadaşlarının 2016 yılında yaptıkları çalışmadan bu kavramın nasıl görselleştirilebileceği, şekil 6'da $\mathbf{M}$ görüntüsünde, $\mathbf{A}$ 'nın 1000 x 3'lük bir matris olduğu işlemin sonucudur. 3 farklı EEG kanalından epileptik nöbet sırasında alınan ardışık 1000 ölçüm noktasını kullanmışlardır. Nöbet sırasında EEG genliklerinin arttığı ve nöbet boyunca aynı kaldığı görülmüştür ve soldaki görselde gözlemlenebilir (bkz. şekil 12). Sağ görselde ise iki epileptik nöbet arasındaki bölümde alınan aynı sürede EEG sinyalleri kullanılarak görselleştirilmiştir (Ramesh, 2016).



Şekil 14. 256 Hz ile kaydedilen EEG sinyallerinden epileptik nöbet sırasında (solda) ve iki epileptik nöbet arasında kaydedilen 1000 zaman noktasında hesaplanan matris temsili (Ramesh, 2016)

Bu çalışmada 64 kanallı EEG cihazı kullanılarak 500 Hz çözünürlüğünde elde edilen sinyallerden 1. katılımcının ilk serisinde hareketsiz duruş esnasında ve hareket başlangıcında kaydedilen 250 örneklem kullanılarak hesaplanan zaman frekans çıktılarının kanal bazında devrik değerleri ile çarpılarak hesaplanan örnek matris görselleri şekil 13'te gösterilmiştir.



Şekil 15. 500 Hz ile kaydedilen EEG sinyallerinden Cz elektrotunun 1 katılımcının ilk seride bireyin sabit duruş bölümünde (solda) ve hareket başlangıcında kaydedilen 250 zaman noktasında hesaplanan matris temsili

3.6. Veri seti

Araştırmada derin öğrenme ağının girdi seti olarak EEG sinyallerinden hesaplanan zaman-frekans görüntüleri ve zaman-frekans Gram matrisleri ile oluşturulan hareket ve gözlem seti kullanıldı. Veri setinde toplamda 872 930 imgeye ulaşıldı. Hareket setleri için A, B1, B2, C1, C2, D1 ve D2, gözlem setleri için E, F1, F2, G1, G2, H1 ve H2 olarak yedişer grup zaman görüntüleri için, yedişer grup ise zaman-frekans Gram matrisi görüntüleri için oluşturuldu. Derin öğrenme ağında farklı ölçümler (göz kapalı, hareket ve gözlem) ve farklı hareket bölümlerinden elde edilen gruplar tekrarlı denemelerde kullanıldı. Zaman-frekans ve zaman-frekans Gram matrisleri kullanılarak elde edilen gruplardaki imge sayıları tabloda paylaşıldı.

Tablo 1. Göz kapalı dinlenim, hareket ve gözlem setlerindeki görüntü sayıları

Ölçüm	İşlem	Hareket Bölümü	İmge Sayısı
Hareket	Zaman-Frekans Görüntüleri	A	2x28098
		B1	2x26964
	Zaman Frekans Kovaryans Görüntüleri	B2	2x26964
		C1	2x27027
		C2	2x27027
		D1	2x27027
		D2	2x27027
Gözlem	Zaman-Frekans Görüntüleri	E	2x33894
		F1	2x32760
	Zaman Frekans Kovaryans Görüntüleri	F2	2x32760
		G1	2x32760
		G2	2x32760
		H1	2x32760
		H2	2x32760
Göz Kapalı	Zaman-Frekans Görüntüleri	GK	2x15877
	Zaman Frekans Kovaryans Görüntüleri		

3.7. Derin Ağ Yapıları

Çalışmada kullanılan derin ağ yapılarında Python programa dilinde Keras ve TensorFlow kütüphaneleri kullanıldı. Yapılan konvolüsyonel sinir ağlarının eğitim ve testlerinde 32 GB RAM gücüne sahip dizüstü bilgisayar kullanıldı. Çalışmada kullanılan konvolüsyonel sinir ağı yapıları, zaman-frekans çıktıları ve zaman-frekans Gram matrisleri için oluşturuldu. Zaman-frekans çıktıları için oluşturulan ağ tablo 2’de paylaşıldı. 44x250x32 olarak 32’lik konvolüsyon katmanı ile başlayıp ağırlık-2 katmanında görüldüğü üzere 2 gruplu sınıflandırmalar için kullanıldı. 6 konvolüsyon katmanı ikili bloklar olarak kullanıldı. Her blok sonrasında azami havuzlama ve seyreltme katmanları kullanıldı.

Tablo 2. Zaman-frekans çıktılarında kullanılan derin ağ katmanları

Katman	Form	Parametre
Konv-2D-1	44x250x32	896
Konv-2D-2	42x238x32	9248
Azami Havuzlama-2D-1	14x82x32	0
Seyreltme-1	14x82x32	0
Konv-2D-3	14x82x64	18496
Konv-2D-4	12x80x64	36928
Azami Havuzlama-2D-2	6x40x64	0
Seyreltme-2	6x40x64	0
Konv-2D-5	6x40x64	36928
Konv-2D-6	4x38x64	36928
Azami Havuzlama-2D-3	2x19x64	0
Seyreltme-3	2x19x64	0
Düzleştirme	2432	0
Ağırlık-1	64	155712
Seyreltme-4	64	0
Ağırlık-2	2	130

Toplam Parametre: 295266

Eğitilen Parametre: 295266

Zaman-frekans çıktılarının Gram matrisleri için oluşturulan ağ tablo 3’te paylaşıldı. 250x250x32 olarak 32’lik konvolüsyon katmanı ile başlayıp ağırlık-2 katmanında görüldüğü üzere 2 gruplu sınıflandırmalar için kullanıldı. 6 konvolüsyon katmanı ikili

bloklar olarak kullanıldı. Her blok sonrasında azami havuzlama ve seyreltme katmanları kullanıldı. Her katmanda hesaplanan görüntünün çıktıları tablo 3’te paylaşıldı.

Tablo 3. Zaman-frekans çıktılarının Gram matrisleri için kullanılan derin ağ katmanları

Katman	Form	Parametre
Konv-2D-1	250x250x32	2432
Konv-2D-2	246x246x32	25632
Azami Havuzlama-2D-1	49x49x32	0
Seyreltme-1	49x49x32	0
Konv-2D-3	49x49x64	51264
Konv-2D-4	45x45x64	102464
Azami Havuzlama-2D-2	22x22x64	0
Seyreltme-2	22x22x64	0
Konv-2D-5	22x22x64	36928
Konv-2D-6	20x20x64	36928
Azami Havuzlama-2D-3	10x10x64	0
Seyreltme-3	10x10x64	0
Düzleştirme	6400	0
Yoğunluk-1	64	409664
Seyreltme-4	64	0
Yoğunluk-2	2	130

Toplam Parametre: 665442

Eğitilen Parametre: 665442

4. BULGULAR


Çalışma sonucunda elde edilen bulgular, hareketin uygulanması ve gözlemlenmesi için iki başlık altında açıklandı. Üçüncü başlık altında hareket ve gözlem ölçümlerinden kullanılan iki veri seti birlikte kullanılarak yapılan değerlendirmeler paylaşıldı.

4.1. Hareketin Uygulanması


Katılımcıların hareketi uyguladığı esnada kaydedilen EEG sinyalleri, video görüntüleri kullanılarak hareket zamanlarını belirlemek için kullanıldı ve hareketin uygulandığı bölümler 6 sınıfa ayrıldı. Bu sınıflarda katılımcıların hareketsiz durumda olduğu bölümler sabit duruşu temsil eden A bölümü ile, katılımcıların nesneye yönelimli olarak elini hareket ettirdiği ancak nesne teması bulunmadığı hareketler B bölümü ile, katılımcıların elinin nesne ile temasından itibaren topu bırakmasına kadar olan hareketler C bölümü ile, katılımcıların nesneyi bırakarak elin sabit duruş bölümüne geldiği hareketler ise D bölümü ile temsil edildi. Katılımcıların B bölümünde elin ilk hareket anı görülen video görüntüsünden öncesi ve sonrası, B1 ve B2 olarak iki bölüme, katılımcıların nesneye teması ise öncesi ve sonrası olarak, sırası ile C1 ve C2 bölümlerine ayrıldı. Bu sınıflama ile el hareketi bölümlendi ve yapılan zaman-frekans ve zaman-frekans Gram matrisleri temsil eden görüntüler gruplandırıldı.

4.1.1. Zaman-Frekans Görüntüleri


Katılımcıların 6 sınıf olarak ayrı ayrı hesaplanan ve sınıflandırılan zaman-frekans görüntüleri, örnek gösterimler için 1 numaralı katılımcının Cz elektrotu ve ölçüm serisinde uyguladığı ilk hareket kullanılarak paylaşıldı. Zaman-frekans analizleri yatay eksen 0-500 ms aralığını, dikey eksen ise 3-44 Hz aralığını temsil edecek düzende hesaplandı.




Şekil 16. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, A bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 17. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, B1 bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 18. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, B2 bölümünde hesaplanan zaman-frekans görüntüsü



Şekil 19. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, C1 bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 20. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, C2 bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 21. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, D bölümünde hesaplanan zaman-frekans görüntüsü

4.1.2. Zaman-Frekans Gram Matrisleri


Katılımcıların 6 sınıf olarak ayrı ayrı hesaplanan ve sınıflandırılan zaman-frekans Gram matrisleri, örnek gösterimler için 1 numaralı katılımcının Cz elektrotu ve ölçüm serisinde uyguladığı ilk hareket kullanılarak paylaşıldı. Zaman-frekans Gram matris görüntüleri yatay ve dikey eksen 0-500 ms aralığını, görüntü boyutları 250x250 olarak her bir zaman-frekans görüntüsünün devrik dönüşümü ile çarpımı temsilleri olarak kullanıldı.




Şekil 22. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, A bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü



Şekil 23. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, B1 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü (solda) ve B2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü (sağda)



Şekil 24. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, C1 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü (solda) ve C2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü (sağda)



Şekil 25. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, D bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

4.1.3. Konvolüsyonel Sinir Ağları Çıktıları

Katılımcıların hareketi uyguladıkları esnada kaydedilen EEG sinyallerinin değerlendirilmesinde kullanılan VGGNet yapay sinir ağı yapısının eğitimi için 7 katılımcıdan elde edilen veriler, ağın test edilmesi için ise diğer 2 katılımcıdan elde edilen

veriler set halinde kullanıldı. Diğer bir geçerlilik seti için veri setlerinde 9 katılımcının verileri aynı kümede kullanılarak rastgele şekim yöntemiyle test seti oluşturuldu ve denemeler yapıldı. Hareket uygulamasının farklı bölümleri (A, B1, B2, C1, C2, D) ve göz kapalı dinlenme durumu (GK) kayıtları ikili karşılaştırmalar amacıyla yapay sinir ağına girdi olarak verildi ve genel değerlendirme tablosu ve ağ çıktılarının grafikleri paylaşıldı.

Tablo 4'te GK ile B2 ve C2 bölümlerinin zaman-frekans veri setleri kullanılarak eğitilen yapay sinir ağının farklı elektrot grupları ile ulaşılan eğitim ve test skorları paylaşıldı. Tabloda verilen gruplarda eğitim setinde 7 katılımcının verileri, test setinde 2 katılımcının veri seti kullanıldı. Tabloda ağın eğitiminde kullanılan adım sayısı (epoch) 100 olarak, küme büyüklüğü ise 128 olarak kullanıldı. GK ile B2 ve C2 grupları için kullanılan elektrot grupları, girdi sayıları, eğitim ve skorları tabloda paylaşıldı.

Tablo 4. Hareket uygulaması deneylerinde GK durumu ile C2 ve B2 durumlarının karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

<u>Girdi Grupları</u>	<u>Girdi Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim Seti (%)</u>	<u>Test Seti (%)</u>
		<u>Eğitim Seti</u>	<u>Test Seti</u>		
GK, C2	S.E.	31627 (GK-12349; C2-19278)	11277 (GK-3528; C2-7749)	89	77*
GK, C2	O.E.	4016	1432	96	83*
GK, B2	T.E.	11141 (GK-3921; B2-7220)	2560 (GK-1120; B2-1340)	90	66
GK, B2	C3	557 (GK-196; B2-361)	123 (GK-56; B2-67)	99	53
GK, B2	C3, C1	1114 (GK-392; B2-722)	246 (GK-112; B2-134)	99	58
GK, B2	C3	1671 (GK-588; B2-1083)	369 (GK-168; B2-201)	99	63
GK, B2	T.E.	33958 (GK-12349; B2-21609)	8883 (GK-3528; B2-5355)	86	64
GK, B2	S.E.	10781 (GK-3921; B2-6860)	2820 (GK-1120; B2-1700)	95	63
GK, B2	O.E.	4312 (GK-1568; B2-2744)	1128 (GK-448; B2-680)	98	72*
GK, B2	S.E.-O.E.	3773 (GK-1372; B2-2401)	987 (GK-392; B2-595)	98	67
GK, B2	O.S.E.	2156 (GK-784; B2-1372)	564 (GK-224; B2-340)	99	60
GK, B2	O1, O2, Oz	1617 (GK-588; B2-1029)	423 (GK-168; B2-255)	95	73*

*Tabloda test skorları yüzde %70'in üzerinde olan sonuçlara * simgesi eklenmiştir.

*(T.E.-Tüm elektrotlar; S.E.-Santral Elektrotlar; S.S.E.-Sol Santral Elektrotlar (C1, C3, Cz); O.E.-Oksipital Elektrotlar, C3-Tek elektrot; C3, C1-İki elektrot; O.S.E.-Orta Santral Elektrotlar; S.E.-O.E.- Santral ve Oksipital Elektrotlar)

Tablo 5'te hareket ölçümünde kaydedilen EEG sinyallerinde, ikili grup sınıflandırmaları amacıyla zaman-frekans veri setleri kullanılarak eğitilen yapay sinir ağlarında farklı

elektrot grupları ile ulaşılan eğitim ve test skorları paylaşıldı. Tabloda verilen gruplarda eğitim setinde 7 katılımcının verileri, test setinde 2 katılımcının veri seti kullanıldı. Tabloda ağın eğitiminde kullanılan adım sayısı (epoch) 100 olarak, küme büyüklüğü ise 128 olarak kullanıldı. GK ile B2 ve C2 grupları için kullanılan elektrot grupları, girdi sayıları, eğitim ve skorları tabloda paylaşıldı.

Tablo 5. Hareket uygulaması deneylerinde farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

<u>Girdi Grupları</u>	<u>Girdi Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim Seti (%)</u>	<u>Test Seti (%)</u>
		Eğitim Seti	Test Seti		
A, C2	T.E.	40185 (A-20907; C2-19278)	15750 (A-8001; C2-7749)	61	52
B2, C2	T.E.	14460 (B2-7220; C2-7240)	2680 (B2-1340; C2-1340)	85	52
A, B2	T.E.	44100 (A-22491; B2-21609)	10962 (A-5607; B2-5355)	92	53

*(T.E.-Tüm elektrotlar)

Tablo 6’da hareket ölçümünde kaydedilen EEG sinyallerinde, ikili grup sınıflandırmaları amacıyla zaman-frekans veri setleri kullanılarak eğitilen yapay sinir ağlarında farklı elektrot grupları ile ulaşılan eğitim ve test skorları paylaşıldı. Tabloda verilen gruplarda test seti, tüm katılımcıların verileri ile oluşturulan eğitim setinin %20’sinin rastgele seçimi ile oluşturuldu.

Tablo 6. Hareket uygulaması deneylerinde farklı bölümlerin karşılaştırmaları için rastgele test yöntemi ile yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar


<u>Girdi Grupları</u>	<u>Girdi Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim Seti (%)</u>	<u>Test Seti (%)</u>
		Eğitim Seti	Test Seti		
A, C2	T.E.	48288 (A-24687; C2-23601)	6837 (A-3411; C2-3426)	83	73*
A, C2	S.E.	15638 (A-7980; C2-7658)	1835 (A-913; C2-922)	93	71*
A, B1	T.E.	45310 (A-22864; B1-22446)	9741 (A-5228; B1-4513)	75	71*
A, B1	T.E.	27206 (A-13673; B1-13533)**	5922 (A-2954; B1-2968)	80	74*
A, B2	T.E.	45271 (A-22864; B2-22407)	9780 (A-5228; B2-4552)	74	70*
GK, C2	T.E.	36000 (GK-13548; C2-22452)	6892 (GK-2323; C2-4569)	90	81*

*Tabloda test skorları yüzde %70’in üzerinde olan sonuçlara * simgesi eklenmiştir.

*(T.E.-Tüm elektrotlar; S.E.-Santral Elektrotlar)


*Tabloda iki yıldız (**) eklenen eğitim ve test setlerinde katılımcıların ilk 15 hareketi kullanılarak ulaşılan sonuçlar verilmiştir.

Şekil 26’da hareketin A ve B1 bölümleri kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Eğitim setinde tüm katılımcılardan elde edilen setin, %20sinin test seti olarak kullanılarak tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağı 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 26. A ve B1 karşılaştırmaları için tüm elektrotlar kullanılarak 9 katılımcı ile eğitilen ve rastgele seçimle verinin %20’si ile test edilen ağı eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 27’de hareketin A ve C2 bölümleri kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Eğitim setinde tüm katılımcılardan elde edilen setin, %20sinin test seti olarak kullanılarak tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağı 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 27. A ve C2 karşılaştırmaları için tüm elektrotlar kullanılarak 9 katılımcı ile eğitilen ve rastgele seçimle verinin %20’si ile test edilen ağı eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 28’de hareketin GK ve B2 bölümleri kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Eğitim setini 7 katılımcının verileri, test setini ise kalan 2 katılımcının verileri oluşturdu. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağı 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 28. GK ve B2 karşılaştırmaları için santral bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 29’da GK ve B2 bölümlerinde oksipital bölge elektrotları kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Eğitim setini 7 katılımcının verileri, test setini ise kalan 2 katılımcının verileri oluşturdu. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağı 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 29. GK ve B2 karşılaştırmaları için parieto-okspital bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 30’da GK ve B2 bölümlerinde orta-santral bölge elektrotları kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Eğitim setini 7 katılımcının verileri, test setini ise kalan 2 katılımcının verileri oluşturdu. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağı 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 30. GK ve B2 karşılaştırmaları için orta santral bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 31’de GK ve B2 bölümlerinde O1, O2, Oz elektrotları kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Eğitim setini 7 katılımcının verileri, test setini ise kalan 2 katılımcının verileri oluşturdu. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağı 50 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.



Şekil 31. GK ve B2 karşılaştırmaları için oksipital bölge elektrotları kullanılarak 7 katılımcı ile eğitilen ve 2 katılımcıyla test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 32’de GK ve C2 bölümlerinde tüm elektrotlar kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Test seti rastgele seçin yöntemiyle 9 katılımcının verileri arasından seçildi. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağıın 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.



Şekil 32. GK ve C2 karşılaştırmaları için tüm bölge elektrotları kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Tablo 7’de hareket ölçümünde kaydedilen EEG sinyallerinde, ikili grup sınıflandırmaları amacıyla zaman-frekans çıktısının Gram matrisleri veri setleri kullanılarak eğitilen yapay sinir ağlarında farklı elektrot grupları ile ulaşılan eğitim ve test skorları paylaşıldı. Tabloda verilen gruplarda test seti, tüm katılımcıların verileri ile oluşturulan eğitim setinin %20’sinin rastgele seçimi ile oluşturuldu.

Tablo 7: Hareket uygulaması deneylerinde farklı bölümlerin karşılaştırmaları için zaman-frekans Gram matris görüntülerinin rastgele test yöntemi ile yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

<u>Girdi Grupları</u>	<u>Girdi Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim Seti (%)</u>	<u>Test Seti (%)</u>
		Eğitim Seti	Test Seti		
GK, C2	T.E.	38486 (GK-14198; C2-24288)	2384 (GK-2739; C2-1680)	82	72*
A, B2	T.E.	46881 (A-23995; B2-22886)	8182 (A-4104; B2-4078)	77	64
GK, C2	S.E.	11237 (GK-4036; C2-7201)	2384 (GK-1379; C2-1005)	90	65
A, B2	S.E.	15280 (A-7815; B2-7465)	2201 (A-1106; B2-1095)	79	61
A, B2	S.S.E.	3831 (A-1961; B2-1870)	2201 (A-269; B2-270)	92	58
A, C2	T.E.	35160 (GK-12519; C2-22641)	7729 (GK-3357; C2-4372)	81	68

*Tabloda test skorları yüzde %70'in üzerinde olan sonuçlara * simgesi eklenmiştir.

*(T.E.-Tüm elektrotlar; S.E.-Santral Elektrotlar; S.S.E.-Sol Santral Elektrotlar (C1, C3, Cz))


4.2. Hareketin Gözlemlenmesi

Katılımcıların hareketi gözlemlendiği esnada kaydedilen EEG sinyalleri, video görüntüleri kullanılarak gözlem zamanlarını belirlemek için kullanıldı ve katılımcıların hareketin uygulanışını gözlemlendiği ölçümlerden elde edilen sinyaller hareket bölümlenmesinde olduğu gibi 6 sınıfa ayrıldı. Bu sınıflarda katılımcıların hareketsiz durumu gözlemlendiği bölümler sabit duruşu temsil eden E bölümü ile, katılımcıların nesne yönelimli olarak elini hareket ettiren ancak nesneye temasta bulunmayan bireyin hareketlerini gözlemlemesi F bölümü ile, katılımcıların elin nesne ile temasından itibaren topu bırakmasına kadar olan hareketleri gözlemlemesi G bölümü ile, katılımcıların nesneyi bırakarak elin sabit duruş bölümüne geldiği hareketleri gözlemlemesi ise H bölümü ile temsil edildi. Katılımcıların gözlemlendiği bireyin F bölümünde elin ilk hareket anı görülen video görüntüsünden öncesi ve sonrası F1 ve F2 olarak iki bölüme, katılımcıların gözlemlendiği bireyin nesneye temas anının öncesi ve sonrası da sırası ile G1 ve G2 bölümlerine ayrıldı. Bu sınıflama ile gözlemlenen el hareketleri bölümlendi ve yapılan zaman-frekans ve devrik dönüşümleri temsil eden görüntüler sınıflandırmada kullanılmak üzere gruplandırıldı.


4.2.1. Zaman-Frekans Görüntüleri

Katılımcıların 6 sınıf olarak ayrı ayrı hesaplanan ve sınıflandırılan zaman-frekans görüntüleri, örnek gösterimler için 1 numaralı katılımcının Cz elektrotu ve ölçüm serisinde


gözlemlediği ikinci hareket kullanılarak paylaşıldı. Görüntüler, yatay eksen 0-500 ms aralığını, dikey eksen ise 3-44 Hz aralığını gösterecek şekilde hesaplandı.




Şekil 33. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, E bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 34. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, F1 bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 35. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, F2 bölümünde hesaplanan zaman-frekans görüntüsü



Şekil 36. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, G1 bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 37. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, G2 bölümünde hesaplanan zaman-frekans görüntüsü




Şekil 38. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, H bölümünde hesaplanan zaman-frekans görüntüsü

4.2.2. Zaman-Frekans Gram Matrisleri


Katılımcıların 6 sınıf olarak ayrı ayrı hesaplanan ve sınıflandırılan zaman-frekans matris çarpımları, örnek gösterimler için 1 numaralı katılımcının Cz elektrotu ve ölçüm serisinde gözlemlendiği ikinci hareket kullanılarak örnek görseller paylaşıldı. Yatay ve dikey eksen 250x250 zaman noktasını temsil ediyor.




Şekil 39. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, E bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü



Şekil 40. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, F1 bölümünde (solda) ve F2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüleri (sağda)



Şekil 41. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, G1 bölümünde (solda) ve G2 bölümünde hesaplanan zaman-frekans Gram matrisi görüntüleri (sağda)



Şekil 42. 1 numaralı katılımcıdan elde edilen EEG sinyallerinde Cz elektrotu kullanılarak, H bölümünde hesaplanan zaman-frekans Gram matrisi görüntüsü

4.2.3. Konvolüsyonel Sinir Ağları Çıktıları

Katılımcıların hareketi gözlemledikleri esnada kaydedilen EEG sinyallerinin değerlendirilmesinde kullanılan yapay sinir ağlarının eğitimi için 7 katılımcıdan elde edilen veriler, ağın test edilmesi için ise diğer 2 katılımcıdan elde edilen veriler set halinde kullanıldı. Diğer bir geçerlilik seti için veri setlerinde 9 katılımcının verileri aynı kümede

kullanılarak rastgele şekim yöntemiyle test seti oluşturuldu ve denemeler yapıldı. Hareket gözleminin farklı bölümleri (E, F1, F2, G1, G2, H) ve göz kapalı dinlenme durumu (GK) kayıtları ikili karşılaştırmalar amacıyla yapay sinir ağına girdi olarak verildi ve genel değerlendirme tablosu ve ağ çıktılarının grafikleri paylaşıldı.

Tablo 8’de hareket gözlemi ölçümünde kaydedilen EEG sinyallerinde, ikili grup sınıflandırmaları amacıyla zaman-frekans veri setleri kullanılarak eğitilen yapay sinir ağlarında farklı elektrot grupları ile ulaşılan eğitim ve test skorları paylaşıldı. Tabloda verilen gruplarda eğitim setinde 7 katılımcının verileri, test setinde 2 katılımcının veri seti kullanıldı. Farklı gözlem bölümleri, elektrot grupları, girdi sayıları, eğitim ve skorları tabloda paylaşıldı.

Tablo 8: Hareket gözlemi deneylerinde farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

<u>Girdi</u> <u>Grupları</u>	<u>Girdi</u> <u>Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim</u> <u>Seti</u> (%)	<u>Test</u> <u>Seti</u> (%)
		Eğitim Seti	Test Seti		
E, F2	T.E.	51661 (E-26272; F2-25389)	15750 (E-7625; F2-7371)	75	51
E, F2	S.E.	16401 (E-8341; F2-8060)	4761 (E-2421; F2-2340)	88	51

*(T.E.-Tüm elektrotlar; S.E.-Santral Elektrotlar)

Tablo 9’da hareket gözlemi ölçümlerinde kaydedilen EEG sinyallerinde, ikili grup sınıflandırmaları amacıyla zaman-frekans veri setleri kullanılarak eğitilen yapay sinir ağlarında farklı elektrot grupları ile ulaşılan eğitim ve test skorları paylaşıldı. Tabloda verilen gruplarda test seti, tüm katılımcıların verileri ile oluşturulan eğitim setinin %20’sinin rastgele seçimi ile oluşturuldu. Tabloda son satırlarda belirtildiği üzere zaman-frekans Gram matrisi gruplarını temsil eden sonuçlarda yer almaktadır.

Tablo 9. Hareket gözlemi deneylerinde farklı bölümlerin karşılaştırmaları için rastgele test yöntemi ile yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar

<u>Girdi Grupları</u>	<u>Girdi Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim Seti (%)</u>	<u>Test Seti (%)</u>
		Eğitim Seti	Test Seti		
GK, G2	T.E.	39992 (GK-12847; G2-27145)	8630 (3024-12847; G2-5606)	95	80*
GK, G2	S.E.	12702 (GK-3876; G2-8826)	12702 (GK-1163; G2-1570)	98	78*
E, G2	T.E.	55221 (E-27675; G2-27546)	11425 (E-6220; G2-5205)	89	71*
E, G2	T.E.	48016 (E-24716; G2-23300)**	(E-2455; G2-4150)	79	75*
E, G2	S.E.	17981 (E-9161; G2-8820)	3177 (E-1601; G2-1576)	95	75*
E, G2	O.E.	5571 (E-2759; G2-2812)**	1368 (E-692; G2-676)**	95	81*
E, F2	T.E.	53686 (E-27048; F2-26638)	12960 (E-6847; F2-6113)	72	69
E, F2	S.E.	17532 (E-8939; F2-8593)	3628 (E-1823; F2-1805)	77	68
E, G2	T.E.	37762 (E-18852; B2-18910)***	7595 (E-3829; B2-3766)	71	65
E, G2	S.E.	12116 (E-6040; B2-6076)***	1909 (E-1105; B2-804)	87	67
E, F2	T.E.	54649 (E-27794; F2-26855)***	11994 (E-6100; F2-5894)	57	57
E, F2	S.E.	16692 (E-8576; F2-8116)***	4463 (E-2185; F2-2278)	72	61
GK, G2	T.E.	40818 (GK-13356; G2-27462)***	7810 (GK-2520; G2-5290)	72	69
GK, G2	S.E.	12832 (GK-4038; G2-8794)***	2607 (GK-1002; G2-1605)	71	68


*Tabloda test skorları yüzde %70'in üzerinde olan sonuçlara * simgesi eklenmiştir.

*(T.E.-Tüm elektrotlar; S.E.-Santral Elektrotlar; O.E.-Oksipital Elektrotlar)

*Tabloda iki yıldız (**) eklenen eğitim ve test setlerinde katılımcıların ilk 20 gözlemi kullanılarak ulaşılan sonuçlar verilmiştir.


*Tabloda üç yıldız (***) eklenen eğitim ve test setleri, zaman-frekans çıktısının Gram matrisi görüntüleri kullanılarak oluşturulmuştur.

Şekil 43'te GK ve G2 bölümleri için tüm elektrotlar kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Test seti rastgele seçim yöntemiyle 9 katılımcının verileri arasından seçildi. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağıın 250 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 43. GK ve G2 karşılaştırmaları için tüm bölge elektrotları kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 44'te E ve G2 bölümleri için santral bölge elektrotları kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Test seti rastgele seçim yöntemiyle 9 katılımcının verileri arasından seçildi. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağın 250 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.



Şekil 44. E ve G2 karşılaştırmaları için santral bölge elektrotları kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

Şekil 45'te E ve G2 bölümleri için tüm elektrotlar kullanıldığında ulaşılan yapay sinir ağı sonuçları paylaşıldı. Test seti rastgele seçim yöntemiyle 9 katılımcının verileri arasından seçildi. Tüm elektrotlardan hesaplanan zaman-frekans görüntüleri ile ağın 250 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları gösterildi.




Şekil 45. E ve G2 karşılaştırmaları için tüm elektrotlar kullanılarak rastgele seçim yöntemiyle test edilen yapay sinir ağlarının eğitim ve test skorları ile eğitim ve test kayıpları

4.3. Hareket Uygulanması ve Gözlemlenmesi Setleri Yapay Sinir Ağları Çıktıları

Katılımcıların hareketi uyguladıkları ve gözlemledikleri esnada kaydedilen EEG sinyallerinin birlikte değerlendirilmesi ile ulaşılan sonuçlar tablo ve grafikler olarak bu başlık altında açıklandı. Hareket uygulamasının bölümleri (A, B1, B2, C1, C2, D) ile hareketin gözleminin bölümleri (E, F1, F2, G1, G2, H) kullanılarak hesaplanan zaman-frekans ve zaman-frekans Gram matris görüntüleri, konvolüsyonel sinir ağlarına girdi olarak verildi. Ağın yapısı (konvolüsyon sayıları, adım sayıları, küme büyüklüğü), girdi bölümleri (GK, A, B1, B2, C1, C2, D, E, F1, F2, G1, G2, H) ve girdi görüntüleri (zaman-frekans, zaman-frekans Gram matrisleri) değiştirilerek yapılan denemeler paylaşıldı.

Tablo 10’da zaman-frekans Gram matrisi görüntüleri girdi olarak kullanılarak, farklı grupların değerlendirmeleri ve sonuçları, tablo 11’de ise zaman-frekans görüntüleri girdi olarak kullanılarak, farklı grupların değerlendirmeleri ve sonuçları verildi. Tablolarda katılımcı grupları, girdi bölümleri, girdi elektrotları, girdi sayıları ve test skorları paylaşıldı.

Şekil 46’da katılımcılardan elde edilen verilerin eğitim ve testte kullanılmasının orta santral bölgeden seçilen 4 elektrottan hesaplanan zaman-frekans görüntüleri ile eğitilen yapay sinir ağının 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları paylaşıldı.



Şekil 46. 9 katılımcının B2 ve C2 grupları zaman-frekans görüntüleri kullanılarak eğitilen hareket setinin, katılımcıların F2 ve G2 gruplarının orta santral bölge elektrotları ile test edilmesinde ulaşılan eğitim ve test skorları ile eğitim ve test kayıpları

Tablo 10: Hareket uygulaması ve gözlemlenmesi değerlendirmelerinde zaman-frekans Gram matris görüntülerinin farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı deneyleri ve ulaşılan sonuçlar

<u>Katılımcı Grubu</u>		<u>Girdi Grupları</u>		<u>Girdi Elektrotları</u>		<u>Girdi Savısı</u>		<u>Eğitim Seti</u>	<u>Test Seti</u>
<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>
9 Katılımcı	9 Katılımcı	A, B2	E, F2	CP2	CP2	1946 (A-1338; B2-428)	2134 (E-1614; F2-520)	75	71*
9 Katılımcı	9 Katılımcı	A, B2	E, F2	Cz	Cz	1946 (A-1338; B2-428)	2134 (E-1614; F2-520)	78	75*
9 Katılımcı	9 Katılımcı	A, B2	E, F2	C3	C3	1946 (A-1338; B2-428)	2134 (E-1614; F2-520)	74	75*
9 Katılımcı	9 Katılımcı	A, B2	E, F2	S.S.E	S.S.E	15894 (A-12042; B2-3852)	19206 (E-14526; F2-4680)	76	75*
9 Katılımcı	9 Katılımcı	E, F2	A, B2	S.E.	S.E.	42680 (E-32280; F2-10400)	35320 (A-26760; B2-8560)	75	75*
Katılımcı No: 1	Katılımcı No: 1	E, F2	A, B2	S.E.	S.E.	4041 (E-3021; F2; 1020)	3720 (A-2820; B2-900)	76	75*
Katılımcı No: 6	Katılımcı No: 6	E, F2	A, B2	S.E.	S.E.	4734 (E-3534; F2-1200)	3400 (A-2580; B2-820)	76	75*
Katılımcı No: 1	Katılımcı No: 1	E, F2	A, B2	S.E.	S.E.	4041 (E-3021; F2; 1020)	3720 (A-2820; B2-900)	76	75*
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	S.E.	S.E.	17160 (B2-8580; C2-8580)	20800 (F2-10400; G2; 10400)	55	50
Katılımcı No: 3	Katılımcı No: 3	B2, C2	F2, G2	S.E.	S.E.	2360 (B2-1180; C2-1180)	(F2-1120; G2-1120)	52	50
9 Katılımcı	9 Katılımcı	A, C2	E, G2	S.E.	S.E.	35320 (A-26760; C2-8580)	41066 (E-32280; G2-10400)	78	74*

Tablo 11: Hareket uygulaması ve gözlemlenmesi değerlendirmelerinde zaman-frekans görüntülerinin farklı bölümlerin karşılaştırmaları için yapılan yapay sinir ağı deneyleri ve ulaşılan sonuçlar

<u>Katılımcı Grubu</u>		<u>Girdi Grupları</u>		<u>Girdi Elektrotları</u>		<u>Girdi Savısı</u>		<u>Eğitim Seti</u>	<u>Test Seti</u>
<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>	<u>Eğitim Seti</u>	<u>Test Seti</u>
9 Katılımcı	9 Katılımcı	A, B2	E, F2	T.E.	T.E.	55062 (A; B2)	66657 (F2; G2)	72	51
9 Katılımcı	9 Katılımcı	E, F2	A, C2	T.E.	T.E.	66646 (E-33895; F2-32751)	55113 (A-28092; C2-27021)	82	52
9 Katılımcı	9 Katılımcı	A, B2	E, F2	C3	C3	1946 (A-1338; B2-428)	2134 (E-1614; F2-520)	74	70*
9 Katılımcı	9 Katılımcı	A, B2	E, F2	S.S.E.	S.S.E.	15894 (A-12042; B2-3852)	19206 (E-14526; F2-4680)	74	65
Katılımcı No: 1	Katılımcı No: 1	E, F2	A, B2	S.E.	S.E.	4041 (E-3021; F2; 1020)	3720 (A-2820; B2-900)	76	75*
Katılımcı No: 1	Katılımcı No: 1	E, F2	A, B2	S.E.	S.E.	4041 (E-3021; F2; 1020)	3720 (A-2820; B2-900)	78	75*
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	T.E.	T.E.	53991 (B2-26964; C2-27027)	65520 (F2-32760; G2-32760)	71	51
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	T.E.	T.E.	53991 (B2-26964; C2-27027)	65520 (F2-32760; G2-32760)	71	51
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	S.E.	S.E.	17140 (B2; C2)	20800 (F2; G2)	94	51
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	O.E.	O.E.	6856 (B2; C2)	8320 (F2; G2)	98	51
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	O.S.E.	O.S.E.	5999 (B2; C2)	7280 (F2; G2)	98	52
9 Katılımcı	9 Katılımcı	B2, C2	F2, G2	P.S.E.	P.S.E.	5999 (B2; C2)	7280 (F2; G2)	98	52
Katılımcı No:5	Katılımcı No:5	B2, C2	F2, G2	T.E.	T.E.	3276 (B2; C2)	7686 (F2; G2)	98	51
Katılımcı No:5	Katılımcı No:5	B2, C2	F2, G2	S.E.	S.E.	1040 (B2; C2)	2440 (F2; G2)	99	52

Tablo 12’de katılımcının nesne ile temas ettiği hareket bölümü olan C2 ve katılımcının nesne ile teması gözlemlendiği G2 bölümlerini sınıflandırmak amacıyla çalıştırılan yapay sinir ağı sonuçları verildi. Tablo sonuçları, zaman-frekans analizleri girdi seti olarak kullanıldığında ulaşılan sonuçları temsil etmektedir. Son iki satırda sunulan sonuçlar açıklamada belirtildiği üzere zaman-frekans Gram matrisleri ile yapılan değerlendirmelerdir. Tabloda verilen gruplarda test seti, tüm katılımcıların verileri ile oluşturulan eğitim setinin %20’sinin rastgele seçimi ile oluşturuldu.

Tablo 12. Hareketin uygulandığı C2 ve gözlemlendiği G2 bölümlerinin ayrıştırılması için yapılan yapay sinir ağı denemeleri ve ulaşılan sonuçlar


<u>Girdi Grupları</u>	<u>Girdi Elektrotları</u>	<u>Girdi Sayısı</u>		<u>Eğitim Seti (%)</u>	<u>Test Seti (%)</u>
		Eğitim Seti	Test Seti		
C2, G2	T.E.	51526 (C2-23039; G2-28487)	8162 (C2-3982; G2-4264)	88	72
C2, G2	S.E.	16248 (C2-7426; G2-8822)	2726 (C2-1152; G2-1574)	96	75
C2, G2	S.S.E.	2394 (C2-1059; G2-1335)	451 (C2-227; G2-224)	89	62
C2, G2	O.E.	2388 (C2-1057; G2-1331)	458 (C2-230; G2-228)	94	62
C2, G2	T.E.***	49552 (C2-22081; G2-27471)	10213 (C2-4932; G2-5281)	64	61
C2, G2	S.E.***	16262 (C2-7192; G2-9070)	2713 (C2-1384; G2-1329)	75	62

*Tabloda test skorları yüzde %70’in üzerinde olan sonuçlara * simgesi eklenmiştir.

*(T.E.-Tüm elektrotlar; S.E.-Santral Elektrotlar; O.E.-Oksipital Elektrotlar (O1, O2, Oz); S.S.E.-Sol Santral Elektrotlar (C1, C3, Cz))

*Tabloda üç yıldız (***) eklenen eğitim ve test setleri, zaman-frekans çıktısının Gram matrisi görüntüleri kullanılarak oluşturulmuştur.

Şekil 47’de katılımcıdan hareketin uygulandığı C2 ve hareketin gözlemlendiği G2 bölümlerinde elde edilen verilerin, C1, C3 ve Cz elektrotları kullanılarak hesaplanan zaman-frekans görüntüleri ile eğitilen yapay sinir ağının 100 adım boyunca ulaştığı eğitim ve test skorları ile eğitim ve test kayıpları paylaşıldı.



Şekil 47. 9 katılımcının B2 ve C2 grupları zaman-frekans görüntüleri kullanılarak eğitilen hareket setinin, katılımcıların F2 ve G2 gruplarının orta santral bölge elektrotları ile test edilmesinde ulaşılan eğitim ve test skorları ile eğitim ve test kayıpları

5. TARTIŞMA ve SONUÇ

Sunulan çalışmada hareket ve gözlem esnasında 500 Hz örnekleme frekansında kaydedilen sinyaller aracılığıyla EEG elektrotlarına yansıyan elektriksel aktivitelerin zaman-frekans ve zaman-frekans kovaryans görüntüleri konvolüsyonel derin öğrenme ağının eğitilmesinde ve test edilmesinde kullanıldı. Oluşturulan görüntü setlerinde ağın eğitimi için 64 kanallı EEG cihazının tüm elektrotları, elektrot yerleşim yerlerine göre - santral, sol santral, oksipital gibi- girdi setleri oluşturularak yapay sinir ağlarında girdi olarak kullanıldı ve eğitim-test değerleri kaydedildi. Derin öğrenme ağının eğitilmesi için hareketin farklı bölümleri, eğitim ve test için aynı katılımcıların rastgele seçilen hareketleri kullanılarak, bir grup katılımcı ile ağ eğitildikten sonra diğer katılımcılar test için kullanılarak ve hareket sırasında kaydedilen ölçüm bölümü eğitim için ve gözlem sırasında kaydedilen ölçüm bölümleri test için kullanılarak farklı grup ve bölüm değerlendirmeleri yapıldı.

Pfurtscheller ve arkadaşlarının 2003 yılında 99 katılımcı üzerinde iki elektrotlu (Cz ve C3) EEG kullanarak yaptıkları çalışmada beyin-bilgisayar arayüzü kullanımı başarısı değerlendirildi. İki ölçüm yaptıkları deneylerin ilk ölçümünde toplanılan eğitim verisi, 40 tekrarlı ve geribildirim verilmeden katılımcıdan ekranda çıkan ok işareti sağ yönde ise sağ el hareketini imgelemeleri, ok işareti sol yönde ise çift ayak hareketini imgelemeleri istendi. Elde edilen eğitim verisinde uygulanan oto-regresif model kullanılarak yapılan denemeler sonucunda katılımcılardan %93'ünün %60'ın üstünde beyin-bilgisayar arayüzü kullanabilme başarısını gösterdiği sonucuna ulaşmışlardır. Ancak paylaşılan sonuçlarda katılımcıların yalnızca %18'inin beyin-bilgisayar arayüzü kullanımında %80'in üstünde sonuç aldığı görülmüştür (Pfurtscheller, 2003). Sunulan çalışmada ayna nöron mekanizması, gözlem potansiyellerini EEG sinyallerinden ayırtmak için kullanılmış ve 9 katılımcının verilerinin kullanılması ile eğitilen ağın, rastgele test yöntemi ile test edilmesi ile %76 doğruluk ile sınıflandırıldığı görülmüştür ve sonuçlar tablo 9'da paylaşılmıştır. Bu sinir ağı yapısının, çalışmadaki 9 katılımcının verilerine özel bir insan-makine arayüzü uygulamasında başarılı şekilde kullanılabilir. İnsan-makine arayüzlerinin bireylere özel olarak eğitilmesi yaygın bir kullanım olmakla beraber, makine

öğrenimi algoritmalarının gelişimi ile ortak insan-makine arayüzü uygulamalarının oluşturulabileceği görülmüştür.

Ramesh ve arkadaşlarının 2016 yılında matematiksel formülünü yayınladıkları, eşit uzunluktaki tek ya da daha fazla sayıda dijital sinyal üzerinde uygulanabilen iki boyutlu covaryans temsil imgelerinin sinyalleri ayırtmak ve sınıflandırmak için yararlı bilgiler içerdiği görüşünü paylaşılmışlar ve örnek olarak katılımcılardan epileptik nöbet esnasında ve nöbetler arasında topladıkları veri üzerinde uygulamalı olarak gösterilmiştir (Ramesh, 2016). Bu tez çalışmasında zaman-frekans görüntülerine ek olarak, zaman-frekans Gram matrisleri kullanılmıştır. Zaman-frekans Gram matrisleri, hareket ve gözlem görevlerinde verileri zaman-frekans analizleri ile karşılaştırıldığında daha düşük doğruluk yüzdesi ile sınıflandırdığı sonucuna ulaşılmıştır. Ancak bu yöntem kullanılarak hareket seti ile eğitilen bir ağı, ayna nöron yansımalarını da yansıttığı düşünülen gözlem görevinde daha başarılı sonuçlar verdiği görülmüştür. Çalışmanın ikinci hipotezi olan “Kişinin hareket uygulaması sırasında EEG sinyallerinden öğrenilen öznitelikler, aynı kişinin hareketi gözlemesi sırasında elde edilen EEG sinyallerinin sınıflandırılmasında başarı sağlar.” varsayımını zaman-frekans Gram matrisleri yöntemi ile ortalama %75 eğitim ve test skorları ikili grup sınıflandırmalarında şans seviyesinin üzerinde sınıflandırıldığı görülmüştür.

Çalışma sonuçlarında katılımcının uyguladığı hareket bölümlerinden elde edilen sinyallerin zaman-frekans görüntülerinin yapay sinir ağları tarafından %75’in üzerinde bir değerle tanındığı görülmüş, aynı şekilde katılımcının hareket gözlemi yaptığı bölümlerin de %80 doğruluk yüzdesi üzerinde skora ulaşılmıştır. Bu bağlamda çalışmanın birinci hipotezi olan “Ayna nöron aktivitesi olarak kayıt altına alınan 500 milisaniyelik pencerelemiş EEG sinyallerinin, dinlenim durumu sinyallerinden ayırtılabilir.” kapsamında sonuçların ikili grup sınıflandırmalarında şans düzeyinin üzerinde olduğu görülmüştür. İnsan-makine arayüzü uygulamalarında EEG elektrotlarına yansıyan bu bilgilerin kullanılarak sınıflandırma ve görev başarıları artırılabilir. Lim ve arkadaşlarının 2017 yılında gözlemsel uyaran potansiyelleri ile ayna nöron aktivitesini birlikte kullanarak hem beyin-bilgisayar arayüzü kullanım başarısını yükseltmek hem de

rehabilitasyon için kullanımını göstermek amacıyla yayınladıkları çalışmada, santral ve oksipital alandaki etkileri zaman-frekans analizi kullanarak incelemişlerdir. Çalışmada görsel uyaran olarak sağ ve sol dirseğin fleksiyon ve ekstansiyonu ve beyaz gürültü kullanmışlardır. Çalışmada 17 katılımcı (yaşları $22,45 \pm 2,31$) üzerinde, 19 elektrotlu EEG ile 10 dakika süresince 40 tekrarlı seriler kullanılarak ölçüm alınmıştır. Video uyaranları 20 Hz kare hızı ile gösterilmiştir. Paylaşılan sonuçlarda katılımcıların dirsek hareketi gözlemlerinde santral elektrotlarda alfa (8-13 Hz) baskılanması gözlemlendiği ancak beyaz gürültü gözleminde bu baskılanmanın gerçekleşmediği, ayrıca gözlemsel uyaran potansiyelinin üç video gözleminde de oksipital elektrotlarda gözlemlendiği görülmüştür. Sonuç olarak üst ekstremité hareketleri ve 20 Hz video uyaranlarının birlikte beyin-bilgisayar arayüzü kullanımlarında gözlemsel uyaran potansiyelleri ile kullanılabileceği paylaşılmıştır (Lim, 2017).

Hyeon ve Young'un 2018 yılında yayımlanan çalışmasında, konvolüsyonel sinir ağları kullanılarak sağ ve sol el imgeleme görevleri sırasında kaydedilen EEG sinyalleri sınıflandırıldı. Girdi olarak 250 Hz örneklem frekansında kaydedilen EEG sinyallerinin dalgacık dönüşümü hesaplamaları kullanıldı. C3, C4 ve Cz elektrotları, 6-13 Hz alfa ve 17-30 Hz beta frekans bantları kullanıldı. Üç elektrodu, imge birleştirme yöntemi ile tek bir girdi görüntüsü olarak yapay sinir ağı yapısında kullandı. 9 katılımcıda $\%78.93 \pm 6.83$ ortalama doğruluk yüzdesine ulaşıldı. Sunulan çalışmada ulaşılan sonuçlarda gözlem görevleri için ortalama $\%76$ doğruluk yüzdesine ulaşıldı (Lee, 2018).

Ayna nöron mekanizması sensorimotor korteks ve oksipital korteksin yanında, inferior parietal lobta, premotor kortekste ve inferior frontal girusta da aktivite artışı yarattığı birçok çalışmada paylaşılmıştır (Fadiga, 1995; Rizzolatti, 1996b; Grafton, 1996; Grezes, 1996; Caspers ve ark., 2010; Moleberghs ve ark., 2012). Çalışmada gözlem görevinde elde edilen EEG verilerinin tüm elektrotlar kullanılarak yapay sinir ağlarına girdi olarak verilmesi ile, nesneyle temasın gözlemini temsil eden G2 bölümünün ağlar tarafından en yüksek doğruluk yüzdesi ile sınıflandırıldığı görülmüştür. Zhang ve arkadaşlarının 2019 yılında yayımlanan hareket gözlemini beyin-bilgisayar arayüzü yönlendirmek için kullandıkları çalışmada ekranda hareket gözlemi potansiyellerini kullanmak farklı video

hızlarında yürüyüş görüntüleri kullandılar. Çalışmada 20-30 yaşları arasında 5 katılımcıya (4 erkek, 1 kadın), uyaran ekranında öncelikle R (sağ), L (sol), D (alt) ve U (üst) olmak üzere dört farklı noktayı temsil eden harflerin iki saniye boyunca gösterilmesi ve sonunda harflerin yerini alan yürüyüş hareketinin gösterimlerinin 8.5, 12, 10 ve 15 Hz görüntü hızında, ekranda 6 saniye boyunca gösterimini gözlemlene görevi verildi. Katılımcıya gözlemlenemesi gereken yürüyüş hareketi, ekranda aynı ayna farklı kare hızlarında gösterilen 4 görüntüden ilk iki saniye sonunda gösterilen harflerden rastgele şekilde görev olarak belirlenen harfin farklı renkte gösterilmesi ile verildi. Katılımcıların altı saniye boyunca gözlemledikleri yürüyüş hareketinin konvolüsyonel sinir ağlarına girdi olarak verilmesi, alfa bandında hesaplanan güçlerin 1, 2, 3 ve 4 saniyeler süresince hesaplanması ile oluşturuldu. Pencere genişliğinin alfa gücü için yüksek tutulmasının ağın başarısını yükselttiği, ayrıca kullanılan 8 elektrottan -6'sı oksipital, 2'si frontal alanda bulunan- birlikte kullanılmasının, yalnızca oksipital alanda bulunan elektrotlar kullanıldığında ulaşılan sınıflandırma başarısından daha yüksek başarıya ulaştığını gözlemledikler. Ulaşılan sonuçlarda gözlemsel uyaran potansiyellerinin ayna nöron mekanizmasında görev alan sensoriyel bilgilerde kullanılarak beyin-bilgisayar arayüzlerinin başarısının artırılabilceği sonucuna ulaşmışlardır (Zhang, 2019).

Birçok çalışmada katılımcının hareketi uygulaması ile hareketi gözlemlenmesinin aynı bölgede gözlemlendiği sonucuna ulaşılmıştır (Molenberghs, 2012). Bu bulgulara benzer şekilde EEG ve MEG çalışmalarında da hareketin uygulandığı esnada santral kortikal alandaki desenkronizasyonun (Chatrian, 1959; Pfurtscheller, 1979) hareketin gözleminde de aynı şekilde ortaya çıktığı görülmüştür (Muthukumaraswamy, 2004; Streltsova, 2014). Sunulan çalışmada hareket ölçümlerinde elde edilen sinyallerin zaman-frekans veya zaman-frekans kovaryans bilgileri ile eğitilen ağın, gözlem görevleri sırasında elde edilen sinyallerin zaman-frekans veya zaman-frekans kovaryans bilgileri ile test edilmesiyle ortaya çıkan sonuçlar 3-44 Hz frekans bantlarında benzer bilgiler sunduğu görülmüştür. Rizolatti ve arkadaşlarının 2012'de yayımlanan, hareketin uygulanması ve gözlemlenmesinde sensorimotor kortikal osilasyonları incelemek için EEG elektrotlarında gözlemlenebilen desenkronizasyon aktivitesini sağ elin farklı tipte hareketleri gözlemleri

ile test ettikleri çalışmada 13 katılımcıya (8 erkek, 5 kadın, yaşları $25,8 \pm 5,5$) uyaran olarak 2000 ms sürelerde 4 farklı video görüntüsü izleme görevi vermişlerdir. Görev olarak verilen 4 farklı el hareketi hedefli-hedefsiz hareketler (hedefli hareketler: kavrama ve parmakla işaretleme; hedefsiz hareketler: el supinasyonu ve kenetleme) olarak ve döngüsel-döngüsel olmayan olarak iki farklı grupta incelemişlerdir. Ayrıca hedefli-hedefsiz ikişer hareket videoları da kendi içinde döngüsel ve döngüsel olmayan olarak gruplandırarak analiz edilmiştir. Video uyaranlarında ilk 400 milisaniye el hareketsiz durumda, sonraki 1600 ms boyunca ise hareketlerin uygulanması olarak tasarlanmıştır. Ölçümün toplamda 20 dakika boyunca sürdüğü ve her uyaran videosunun 30 kez ekranda gösterildiği, ölçümde 250 Hz çözünürlükte 128 kanallı EEG cihazı kullanıldığı belirtilmiştir. Çalışma sonucunda alfa (8-13 Hz), düşük beta (13-18 Hz) ve yüksek beta (18-25 Hz) bantlarında hareket başladıktan sonra en az 700 ms içinde desenkronizasyonun görüldüğü sonucu paylaşılmıştır. İncelenen alfa, düşük beta ve yüksek beta sonuçlarına göre, neredeyse hareketin başlangıcı ile başlayan desenkronizasyonun ayrıca hareket bitişinden sonra 400-600 ms kadar sürdüğü sonucu paylaşılmıştır. İncelenen üç frekans bandında da aynı basit mekanizma görülmesine rağmen, düşük beta bandındaki desenkronizasyon hareketinin alfa bandından yaklaşık 200 ms daha hızlı tepki verdiği görülmüştür (Avanzini, 2012). İstemli ve hareket hızının katılımcı tarafından belirlendiği hareketlerde, olaya ilişkin desenkronizasyonun hareketin davranışsal olarak başlangıcından önce karşı taraftaki korteks bölgesinde, ardından yine hareketin öncesinde ve uygulandığı esnada kortekste çift taraflı olarak yansıdığı daha önceki çalışmalarda görülmüştür. Avanzini ve arkadaşlarının yaptığı çalışmada sonuç olarak tekrar paylaşıldığı gibi hareket gözleminde hareket öncesi olaya ilişkin desenkronizasyon görülmemiş, hareket gözlemi sırasında sinyallerde görülen baskılanmanın çift taraflı olduğu, hemisferler arasında baskılanmada farklılık gözlemlenmediği sonucuna ulaşılmıştır. Hedefli ve hedefsiz hareketlerin analizlerinde desenkronizasyon aktivitesinin hareket gözlem başlangıcında birbirine yakın olduğu ancak gözlemin sonuna doğru hedefli harekette baskılanmanın arttığı gözlemlenmiştir (Avanzini, 2012). Babiloni ve arkadaşlarının 10 katılımcı ile gerçekleştirdiği çalışmada ise hareket gözlemi sırasında alfa bandı desenkronizasyonunun yalnızca sensorimotor alana ek olarak, parieto-okspital

alanlarda gözlemlendiği görülmüş, yazarlar bu sonucu gözlemsel, duyuşal ve motor bölgedeki işbirliği ile açıklamışlardır (Babiloni, 2002). Çalışmamızda gözlem deneylerinde elde edilen EEG verilerinin zaman-frekans temsillerinin 500 ms uzunlukta olması sebebiyle, gözlemlenen elin nesneye temas ettiği G2 bölümünün, nesneye uzanma bölümünden daha yüksek doğruluk yüzdesi ile sınıflandırılmasının sebebinin katılımcının hareketi algılayıp, 400-600 ms sonra tepki vermesi olabileceği düşünülmektedir. Çünkü gözlemlenen elin nesneye uzanma süresi 600-800 ms aralığında olduğu, elin ilk hareketinden itibaren 500 ms ile hesaplanan zaman-frekans temsillerinin sinyal değişimini görmek için erken olması olabilir. Elin nesne ile teması sırasında işbirliğine katılan gözlemsel, duyuşal ve motor nöronların da bu sınıflandırma başarısını olumlu yönde etkilediği sonucuna varılmıştır. Wang ve arkadaşlarının 2019 yılında yayımladığı çalışmada hareketin planlanmasına dair kaydedilen ve analiz edilen EEG sinyalleri, olaya ilişkin de-senkronizasyon bilgisini sınıflandırmak amacıyla diskriminant analizi kullanarak 12 katılımcıda ortalama $80,96 \pm 6,62$ başarıya ulaştıkları sonucu paylaşıldı. Tez çalışmamızda katılımcının hareket deneylerinde, el hareketinin kamera görüntüleri kullanılarak belirlenmesi ile, hareket başlangıcından önceki 500 milisaniyelik bölüm ile (B1 bölümü), katılımcının deney süresince el hareketinde bulunmadığı sabit duruş bölümlerinin yapılan farklı yapay ağ denemelerinde %70'in üzerinde bir doğruluk ile sınıflandırıldığı görülmüş ve tablo 6'da sonuçları paylaşılmıştır.

Zhang ve arkadaşları 2019 yılında konvolüsyonel sinir ağları ile geliştirdikleri dalgacık dönüşümü sinir ağlarının yapısını ve gözlemsel uyaran potansiyelleri ile motor imgeleme setlerinde kullanarak başarı düzeylerini karşılaştırdılar. Çalışmada gözlemsel uyaran potansiyelleri için oluşturulan verisetinde (240 gözlem, %50'si eğitim, %50'si test için kullanıldı) 6-8 Hz aralığında gözlemlenen uyaran, 256 Hz çözünürlük ile kaydedilmiş ve analiz için tek elektrot olarak Oz elektrotu seçilmiştir. Kullanılan dalgacık dönüşümü sinir ağının başarı skorunun %98 olduğu ve bu yöntemin gözlemsel uyaran potansiyellerinde kullanılabileceği sonucuna ulaşmışlardır. Motor ve sensorimotor aktiviteler için elektrotlar santral bölgeye yerleştirilmiştir. EEG sinyalleri, 128 Hz çözünürlükte, 8-30 Hz frekans bantlarında, C3, C4 ve Cz bölgelerinde incelenmiştir. Çalışmada kullanılan ilk

verisetinde (BCI Competition II, veriseti III) katılımcıların toplamda 280 sağ ve sol el imgelemesi görevi yaptığı set seçilmiş, oluşturdukları yeni ağ yapısı ile karşılaştırılan çift katmanlı konvolüsyonel sinir ağlarında girdi olarak N (imgeleme sayısı) * 23 frekans * 49 zaman noktası * 14 elektrot kanalı kullanılmıştır. Kullanılan en yakın komşu algoritması, doğrusal diskriminant analizi, destek vektör makinesi, konvolüsyonel sinir ağları ve dalgacık dönüşümü sinir ağlarından 5 katılımcıda ortalama %90 başarı ile konvolüsyonel sinir ağlarının ilk sırada olduğu, konvolüsyonel sinir ağından sonraki en başarılı sinir ağının dalgacık dönüşümü sinir ağları olduğunu ve başarı ortalamasının %85 olduğu görülmüştür. Üçüncü sırada en yakın komşu algoritması %81, doğrusal diskriminant analizi %75 ve destek vektör makinesi ise %72 doğruluk yüzdesi ile veriyi sınıflandırdığı sonucu paylaşılmıştır. Bu veri setinde ulaşılan sonuçlardan sonra dalgacık dönüşümü sinir ağlarının etkisini daha büyük veri setinde denemek için 62 kanallı EEG aracılığıyla, 500 Hz çözünürlükte alınan kayıtlar kullanılmış, kayıtlarda imgeleme görevlerinin her katılımcı için 200 kez tekrarlı olarak ölçüldüğü yeni veri setinde dalgacık dönüşümü sinir ağlarının konvolüsyonel sinir ağlarında daha yüksek doğruluk yüzdesine ulaşıldığı ancak oluşturulan dalgacık dönüşümü sinir ağlarında hesaplama süresinin 5 katına çıktığını görmüşlerdir (Zhang, 2019). Sunulan çalışmada dalgacık dönüşümü hesaplamaları konvolüsyonel sinir ağlarında girdi olarak hareket ve gözlem potansiyellerini ayrıştırmak için kullanılmış, gözlemlenen elin nesne ile temasının oluşturduğu kortikal aktivitelerin EEG cihazı ile kaydedilen verilerden %70 üzerinde doğruluk ile sınıflandırıldığı görülmüştür.

Sunulan çalışmada göz kapalı dinlenim durumu ile nesne yönelimli el hareketinin ve hareketin gözlemi esnasında kaydedilen sinyallerin zaman-frekans görüntüleri girdi olarak kullanıldığında yapay sinir ağlarının %80'in üzerinde başarıya ulaştığı görüldü. Dharmendra ve arkadaşlarının 2018 yılında yayımladıkları çalışmada gözün açıklık ve kapalılık durumunu kaydedilen EEG sinyallerinden ayrıştırmak için konvolüsyonel sinir ağları kullanıldı. Yapay sinir ağlarına girdi olarak zaman-frekans temsilleri verildi ve gözün açık-kapalılık durumunu %91 doğruluk ile sınıflandırıldığı sonucu paylaşıldı (Dharmendra, 2018). Tang ve arkadaşlarının 2017 yılında yayımlanan çalışmalarında,

insan-makine arayüzlerinde kullanılması amacıyla sağ ve sol el imgelemelerini sınıflandırmak için konvolüsyonel sinir ağları kullanıldı. Çalışmada 5 katmanlı bir konvolüsyonel sinir ağı yapısı kullanılarak %86 doğruluk yüzdesi ile el imgeleme görevlerinin EEG sinyallerinden ayrıştırıldığı gözlemlendi (Tang ve ark., 2017). Baoguo ve arkadaşlarının 2018 yılında yayınladıkları çalışmada ise dalgacık dönüşümü analizleri konvolüsyonel sinir ağlarında girdi olarak kullanıldı. Çalışmada, sağ ve sol el motor imgeleme görevleri kullanıldı. EEG sinyalleri 8-30 Hz arasında filtrelendi ve C3, C4 ve Cz elektrotlarını kullanarak 9 katılımcı için ortak bir insan-makine arayüzü uygulamasında kullanılabilecek yapay sinir ağının %89 doğruluk yüzdesi ile Morlet dalgacık dönüşümü görüntülerini sınıflandırdığı sonucu paylaşıldı (Xu ve ark., 2018). Sunulan çalışmada benzer frekans aralıkları kullanılarak hareket ve gözlem potansiyelleri incelendi. Konvolüsyonel sinir ağı yapısı 64 kanallı EEG elektrotları girdi olarak verilerek kullanıldı ve hareket ile gözlemin farklı bölümlerinin değerlendirilmesi sağlandı.

Çalışmada incelenen üçüncü araştırma hipotezi olan “Derin öğrenme tabanlı sınıflandırıcı kullanılarak EEG verilerinden planlanan hareketlere dair örüntüler çıkarılabilir.” kapsamında, hareket deneylerinde video kayıtları kullanılarak belirlenen hareket başlangıç noktalarından geriye doğru olarak ele alınan 500 milisaniyelik sinyallerde zaman-frekans ve zaman-frekans Gram matrisleri görüntülerinin konvolüsyonel sinir ağlarında girdi olarak kullanılmasında %71 doğruluk yüzdesiyle hareket öncesi B1 durumu ve sabit duruş bölümlerinin sınıflandırıldığı sonucuna ulaşılmıştır. 2019 yılında yayımlanan, Wang ve arkadaşlarının insan-makine arayüzleri uygulamalarında kullanılmak amacıyla hareket potansiyellerini doğrusal diskriminant analizi yöntemini sınıflandırma amaçlı, DSPM adını verdikleri yöntemi CSP yöntemi ile birlikte özellik çıkarımı amacıyla kullanmışlar ve 12 katılımcıda bireysel olarak yapılan sınıflandırmaların ortalama %80.96 sonucu ile sınıflandırıldığı sonucunu paylaşmışlardır (Wang, 2019).

Lapenta ve arkadaşlarının 2018 yılında yayımlanan EEG desenkronizasyonunun incelendiği çalışmada, video uyarınları kullanılarak katılımcıya gösterilen el hareketleri EEG ve TMS kullanarak ölçüldü. Çalışmada nesneye uzanma ve nesneyi yakalama

hareketleri değerlendirildi. Mu (8-12 Hz) ve Beta (15-23 Hz) bandı bağımlı değişken, zaman (t1, t2), durum (nesne boyutu küçük ve büyük olarak) ve elektrotlar (C3, C4) ise faktör olarak değerlendirilerek varyans analizi uygulamışlar ve sonuçlarda Coll ve arkadaşlarının 2017 yılında yaptıkları çalışmada da belirtildiği gibi, hareket gözleminde Mu ritmin nesnenin tutuluş şeklinden etkilenmediği sonucuna ulaşmışlardır. Hareket gözleminde Mu ritimdeki baskılanma farklılığının hareketin fazlarında gözlemlenebileceği ve yapılan çalışmada da ERD'nin uzanma hareketinde daha iyi gözlemlendiği sonucuna varmışlardır (Lapenta, 2018; Coll, 2017). Hareket gözleminde ortaya çıkan nöral işlemlerin, birbirine bağlı birçok işlevsel katmanların işbirliği ile ortaya çıkması çalışmada değerlendirilen sinyalleri etkilediği de çalışmada paylaşılmıştır. Bunlar; hareketin gerçekleştirilmesi için kas düzeyinde, uzay ve zaman noktasını belirlenmesi için kinematik düzeyde, nesneye yönelik hareketin hazırlığı ve planlanmasını içeren kısa süreli hedef ile ve hareketin uzun vadede sağlayacağı yarar ile ilgili olabileceği görüşünü paylaşmışlardır (Lapenta, 2018). Çalışmada ayrıca Mu ritmin bireysel olarak değil grup olarak 8-12 Hz arasında değerlendirilmesinin çalışmada bir sınırlılık yarattığı paylaşılmıştır. Sunulan çalışmada da bireysel Mu ritim aralığının seçilmemesi ve oluşturulan zaman-frekans görüntü setlerinde kullanılan aralık 3-44 Hz bantlarını kapsaması ve bu aralıkta teta, alfa ve beta bandı tek bir zaman-frekans penceresinde değerlendirilmesinin yapay sinir ağlarının hareket ve gözlemi tanımak için bir kısıtlılık olabileceğinin göz önünde bulundurulması gerekmektedir. Ancak tartışmaya açık bir şekilde hareketin uygulanması ve gözlemlenmesini ayırtırmak için yapay sinir ağları kullanıldığında %70'in üzerinde doğruluk yüzdesi ile sınıflandırıldığı görüşmüştür. Bu doğruluk yüzdesi yalnızca tüm elektrotlar girdi olarak kullanıldığında değil, santral bölge elektrotları kullanıldığında da gözlemlenmiştir. Bunun sonucunda hareketin uygulanması ve gözlemlenmesinin EEG'nin teta, alfa ve beta frekanslarına 500 hareketin başlangıcından sonraki 500 milisaniyelik bölümde farklı yansıdığı düşünülebilir. Daha geniş pencere aralıkları ve diğer hareket ve gözlem bölümleri değerlendirilerek bu farklılaşmanın kaynaklandığı elektrotların gelecek çalışmalarda ayırtırılabilmesi ve yapay sinir ağlarının örüntülere ulaşabileceği düşünülmektedir.

Çalışmada EEG cihazı ile katılımcının hareket ve gözlem esnasında kaydedilen aktiviteleri, yapay sinir ağları aracılığıyla değerlendirilmiş, zaman-frekans ve zaman-frekans çıktısı Gram matrisi görüntüleri ile ağın yapısı ve hareket bölümleri değiştirilerek yapılan denemeler paylaşılmıştır. Sinir ağlarını değerlendirmek için yapay sinir ağlarının daha sistematik ve tekrarlı olarak kullanılması ile hem yapay sinir ağlarının hem de sinir ağlarının çalışma prensiplerinin daha iyi anlaşılabilceğı düşünölmektedir. Derin öğrenme temelli sınıflandırma yaklaşımı ile çok kanallı EEG ölçümlerinden elde edilen kısa zaman pencerelerinden yola çıkılarak, ayna nöron aktivitesinin dinamiklerinin incelenmesi gerçekleştirilmiştir. Davranışla gözlenen hareketlerin EEG sinyalindeki yansımalarının, konvolüsyonel sinir ağlarında farklı örüntölere karşılık gelerek sınıflandırabildiğı sonucuna ulaşölmıştır.

KAYNAKÇA

- A. G. Ivakhnenko and V. G. Lapa, “Cybernetic Predicting Devices,” 1966.
- Aizenberg, I. N., Aizenberg, N. N., & Vandewalle, J. (2000). Multiple-Valued Threshold Logic and Multi-Valued Neurons. In *Multi-Valued and Universal Binary Neurons* (pp. 25-80). Springer, Boston, MA.
- Aleksandrov, A. A., & Tugin, S. M. (2012). Changes in the mu rhythm in different types of motor activity and on observation of movements. *Neuroscience and Behavioral Physiology*, 42(3), 302-307.
- Ang, K. K., & Guan, C. (2013). Brain-computer interface in stroke rehabilitation.
- Angelini, M., Fabbri-Destro, M., Lopomo, N. F., Gobbo, M., Rizzolatti, G., & Avanzini, P. (2018). Perspective-dependent reactivity of sensorimotor mu rhythm in alpha and beta ranges during action observation: an EEG study. *Scientific reports*, 8(1), 12429.
- Avanzini, P., Fabbri-Destro, M., Dalla Volta, R., Daprati, E., Rizzolatti, G., & Cantalupo, G. (2012). The dynamics of sensorimotor cortical oscillations during the observation of hand movements: an EEG study. *PLoS One*, 7(5), e37534.
- Babiloni, C., Babiloni, F., Carducci, F., Cincotti, F., Coccozza, G., Del Percio, C., ... & Rossini, P. M. (2002). Human cortical electroencephalography (EEG) rhythms during the observation of simple aimless movements: a high-resolution EEG study. *Neuroimage*, 17(2), 559-572.
- Beisteiner, R., Höllinger, P., Lindinger, G., Lang, W., & Berthoz, A. (1995). Mental representations of movements. Brain potentials associated with imagination of hand movements. *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, 96(2), 183-193.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Carlson, N. R. (2011). Fizyolojik psikoloji davranışın nörolojik temelleri. M., Şahin (çev. ed.). Ankara: Nobel Akademik Yayıncılık.

- Caspers S, Zilles K, Laird AR, Eickhoff SB. 2010. ALE meta-analysis of action observation and imitation in the human brain. *Neuroimage*. 50: 1148–67.
- Cassim, F., Szurhaj, W., Sediri, H., Devos, D., Bourriez, J. L., Poirot, I., ... & Guieu, J. D. (2000). Brief and sustained movements: differences in event-related (de) synchronization (ERD/ERS) patterns. *Clinical neurophysiology*, 111(11), 2032-2039.
- Chatrian, G. E., Petersen, M. C., & Lazarte, J. A. (1959). The blocking of the rolandic wicket rhythm and some central changes related to movement. *Electroencephalography and clinical neurophysiology*, 11(3), 497-510.
- Cheng, D., Liu, Y., & Zhang, L. (2018, April). Exploring Motor Imagery Eeg Patterns for Stroke Patients with Deep Neural Networks. In 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 2561-2565). IEEE.
- Cohen, M. X. (2014). Analyzing neural time series data: theory and practice. MIT press.
- Coll, M. P., Bird, G., Catmur, C., & Press, C. (2015). Cross-modal repetition effects in the mu rhythm indicate tactile mirroring during action observation. *Cortex*, 63, 121-131.
- Coll, M. P., Press, C., Hobson, H., Catmur, C., & Bird, G. (2017). Crossmodal classification of mu rhythm activity during action observation and execution suggests specificity to somatosensory features of actions. *Journal of Neuroscience*, 37(24), 5936-5947.
- Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*, 16(3), 031001.
- Erbil, N., & Urgan, P. (2007). Changes in the alpha and beta amplitudes of the central EEG during the onset, continuation, and offset of long-duration repetitive hand movements. *Brain research*, 1169, 44-56.

- Fadiga, L., Fogassi, L., Pavesi, G., & Rizzolatti, G. 1995. Motor facilitation during action observation: a magnetic stimulation study. *Journal of neurophysiology*, 73(6), 2608-2611.
- Fogassi, L., Ferrari, P. F., Gesierich, B., Rozzi, S., Chersi, F., & Rizzolatti, G. (2005). Parietal lobe: from action organization to intention understanding. *Science*, 308(5722), 662-667.
- Fox, N. A., Bakermans-Kranenburg, M. J., Yoo, K. H., Bowman, L. C., Cannon, E. N., Vanderwert, R. E., ... & Van IJzendoorn, M. H. (2016). Assessing human mirror activity with EEG mu rhythm: A meta-analysis. *Psychological Bulletin*, 142(3), 291.
- Freeman WJ. (2004a) Origin, structure, and role of background EEG activity. Part 1, Part 2. Analytic amplitude. *Clinical Neurophysiology*. 115(9):2077–88
- 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.
- Gabor, D., 1946. Theory of communication, *Journal of IEEE*, 93, 429-457.
- Gallese V, Fadiga L, Fogassi L, Rizzolatti G. Action recognition in the premotor cortex. *Brain*. 1996 Apr;119(Pt 2):593-609
- Gallese, V., & Goldman, A. (1998). Mirror neurons and the simulation theory of mind-reading. *Trends in cognitive sciences*, 2(12), 493-501.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Grafton ST, Arbib MA, Fadiga L, Rizzolatti G. 1996. Localization of grasp representations in humans by positron emission tomography. *Exp Brain Res*. 112(1): 103-111.
- Grèzes J, Costes N, Decety J. 1999. The effects of learning and intention on the neural network involved in the perception of meaningless actions. *Brain*. 122(10): 1875-1887.
- Grèzes, J. (1998). Top down effect of strategy on the perception of human biological motion: A PET investigation. *Cognitive Neuropsychology*, 15(6-8), 553-582.

- Guger, C., Edlinger, G., Harkam, W., Niedermayer, I., & Pfurtscheller, G. (2003). How many people are able to operate an EEG-based brain-computer interface (BCI)?. *IEEE transactions on neural systems and rehabilitation engineering*, 11(2), 145-147.
- Gurve, D., & Krishnan, S. (2018). Deep Learning of EEG Time–Frequency Representations for Identifying Eye States. *Advances in Data Science and Adaptive Analysis*, 10(02), 1840006.
- Guyton A ve Hall J. Tıbbi Fizyoloji. Nobel Tıp Kitabevleri Ltd. Şti. İstanbul; 2008, 1111-1112.
- H. A. Song and S.-Y. Lee, “Hierarchical Representation Using NMF,” in *International Conference on Neural Information Processing*, 2013, pp. 466–473.
- Han, J., Pei, J., & Kamber, M. (2011). *Data mining: concepts and techniques*. Elsevier.
- Henneman, E. (1984). Organization of the motor systems—a preview. *Medical Physiology, XIV Edition. B. Saint Louis The CV Mosby Company*, 669-673.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- Hobson, H. M., & Bishop, D. V. (2016). Mu suppression—a good measure of the human mirror neuron system?. *Cortex*, 82, 290-310.
- Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). *A practical guide to support vector classification*.
- Hubel, D. H., & Wiesel, T. N. (1959). Receptive fields of single neurons in the cat's striate cortex. *The Journal of physiology*, 148(3), 574-591.
- Hubel, D. H., & Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of physiology*, 160(1), 106-154.
- Karakaş, S., & İrkeç, C. (Eds.). (2008). *Kognitif nörobilimler*. MN Medikal & Nobel.

- Keeton, P. I. J., & Schlindwein, F. S. (1998). Spectral broadening of clinical Doppler signals using FFT and autoregressive modelling. *European Journal of Ultrasound*, 7(3), 209-218.
- Kohler E, Keysers C, Umiltà MA, Fogassi L, Gallese V, Rizzolatti G. 2002. Hearing sounds, understanding actions: action representation in mirror neurons. *Science* 297: 846–848.
- Kolev, V., Yordanova, J., Basar-Eroglu, C., & Basar, E. (2002). Age effects on visual EEG responses reveal distinct frontal alpha networks. *Clinical Neurophysiology*, 113(6), 901-910.
- Kong, W., Huang, W., & Lei, Y. (2017, September). Image Fusion Using Pulse Coupled Neural Network and CNN. In *International Conference on Intelligent Science and Big Data Engineering* (pp. 147-160). Springer, Cham.
- L. Deng and D. Yu, “Deep Learning: Methods and Applications,” *Found. Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2014.
- Lapenta, O. M., Ferrari, E., Boggio, P. S., Fadiga, L., & D’Ausilio, A. (2018). Motor system recruitment during action observation: No correlation between mu-rhythm desynchronization and corticospinal excitability. *PloS one*, 13(11), e0207476.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- 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.
- Lee, H. K., & Choi, Y. S. (2018, January). A convolution neural networks scheme for classification of motor imagery EEG based on wavelet time-frequency image. In *2018 International Conference on Information Networking (ICOIN)* (pp. 906-909). IEEE.
- Leocani, L., Toro, C., Manganotti, P., Zhuang, P., & Hallett, M. (1997). Event-related coherence and event-related desynchronization/synchronization in the 10 Hz and 20 Hz EEG during self-paced movements. *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, 104(3), 199-206.

- Lim, H., & Ku, J. (2017). Flickering exercise video produces mirror neuron system (MNS) activation and steady state visually evoked potentials (SSVEPs). *Biomedical engineering letters*, 7(4), 281-286.
- Lippmann, R. (1987). An introduction to computing with neural nets. *IEEE Assp magazine*, 4(2), 4-22.
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of neural engineering*, 15(3), 031005.
- Molenberghs, P., Cunnington, R., & Mattingley, J. B. (2012). Brain regions with mirror properties: a meta-analysis of 125 human fMRI studies. *Neuroscience & Biobehavioral Reviews*, 36(1), 341-349.
- Muthukumaraswamy, S. D., & Johnson, B. W. (2004). Primary motor cortex activation during action observation revealed by wavelet analysis of the EEG. *Clinical Neurophysiology*, 115(8), 1760-1766.
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- Nakano, H., & Kodama, T. (2017). Understanding Neural Mechanisms of Action Observation for Improving Human Motor Skill Acquisition. *Electroencephalography*, 1.
- Oberman, L. M., Hubbard, E. M., McCleery, J. P., Altschuler, E. L., Ramachandran, V. S., & Pineda, J. A. (2005). EEG evidence for mirror neuron dysfunction in autism spectrum disorders. *Cognitive brain research*, 24(2), 190-198.
- Oberman, L. M., Pineda, J. A., & Ramachandran, V. S. (2007). The human mirror neuron system: a link between action observation and social skills. *Social cognitive and affective neuroscience*, 2(1), 62-66.
- Pereira, F., Mitchell, T., & Botvinick, M. (2009). Machine learning classifiers and fMRI: a tutorial overview. *Neuroimage*, 45(1), S199-S209.

- Pfurtscheller, G., & Aranibar, A. (1979). Evaluation of event-related desynchronization (ERD) preceding and following voluntary self-paced movement. *Electroencephalography and clinical neurophysiology*, 46(2), 138-146.
- Pfurtscheller, G., & Neuper, C. (1997). Motor imagery activates primary sensorimotor area in humans. *Neuroscience letters*, 239(2-3), 65-68.
- Pfurtscheller, G., Neuper, C., Andrew, C., & Edlinger, G. (1997). Foot and hand area mu rhythms. *International Journal of Psychophysiology*, 26(1-3), 121-135.
- Ramesh, A., Pathak, A., & Majumdar, K. (2016). A Novel Matrix Representation of Discrete Biomedical Signals. *arXiv preprint arXiv:1601.03255*.
- Rawat, W., & Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9), 2352-2449.
- Rizzolatti G, Fadiga L, Matelli M, Bettinardi V, Paulesu E, Perani D, Fazio F. 1996b Localization of grasp representations in humans by PET: 1. Observation versus execution. *Exp Brain Res* 111: 246– 252.
- Rizzolatti, G., & Craighero, L. (2004). The mirror-neuron system. *Annu. Rev. Neurosci.*, 27, 169-192.
- Rizzolatti, G., & Sinigaglia, C. (2006). *So quel che fai: il cervello che agisce ei neuroni specchio*. R. Cortina ed.
- Rizzolatti, G., Fogassi, L., & Gallese, V. 2001. Neurophysiological mechanisms underlying the understanding and imitation of action. *Nature reviews neuroscience*, 2(9), 661-670.
- Shen, Y., Lu, H., & Jia, J. (2017, September). Classification of Motor Imagery EEG Signals with Deep Learning Models. In *International Conference on Intelligent Science and Big Data Engineering* (pp. 181-190). Springer, Cham.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Singer, T., Seymour, B., O'doherty, J., Kaube, H., Dolan, R. J., & Frith, C. D. (2004). Empathy for pain involves the affective but not sensory components of pain. *Science*, 303(5661), 1157-1162.

- Streltsova, A., Berchio, C., Gallese, V., & Umiltà, M. A. (2010). Time course and specificity of sensory-motor alpha modulation during the observation of hand motor acts and gestures: a high density EEG study. *Experimental brain research*, 205(3), 363-373.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Taner PDD. Fonksiyonel Nöroanatomi. ODTÜ Geliştirme Vakfı Yayıncılık ve İletişim A.Ş. Yayınları. Ankara; 2015, 1-282.
- Tang, Z., Li, C., & Sun, S. (2017). Single-trial EEG classification of motor imagery using deep convolutional neural networks. *Optik*, 130, 11-18.
- Toro, C., Deuschl, G., Thatcher, R., Sato, S., Kufta, C., & Hallett, M. (1994). Event-related desynchronization and movement-related cortical potentials on the ECoG and EEG. *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, 93(5), 380-389.
- Umiltà MA, Escola L, Intskirveli I, Grammont F, Rochat M, Caruana F, Jezzini A, Gallese V, Rizzolatti G. 2008. When pliers become fingers in the monkey motor system. *Proc Natl Acad Sci USA* 105: 2209–2213.
- V. Gallese, L. Fadiga, L. Fogassi, and G. Rizzolatti, “Action recognition in the premotor cortex,” *Brain*, 119, 593–609 (1996).
- Velu, P., & de Sa, V. R. (2013). Single-trial classification of gait and point movement preparation from human EEG. *Frontiers in neuroscience*, 7, 84.
- Wang, K., Xu, M., Wang, Y., Zhang, S., Chen, L., & Ming, D. (2019). Enhance decoding of pre-movement EEG patterns for Brain-Computer Interfaces. *Journal of neural engineering*.
- Xu, B., Zhang, L., Song, A., Wu, C., Li, W., Zhang, D., ... & Zeng, H. (2018). Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification. *IEEE Access*, 7, 6084-6093.

- Y. Bengio, “Learning Deep Architectures for AI,” *Found. trends® Mach. Learn.*, vol. 2, no. 1, pp. 1–127, 2009.
- Yu, D., Wang, H., Chen, P., & Wei, Z. (2014, October). Mixed pooling for convolutional neural networks. In *International Conference on Rough Sets and Knowledge Technology* (pp. 364-375). Springer, Cham.
- Zander, T. O., & Kothe, C. (2011). Towards passive brain–computer interfaces: applying brain–computer interface technology to human–machine systems in general. *Journal of neural engineering*, 8(2), 025005.
- Zhang, X., Xu, G., Ravi, A., Pearce, S., & Jiang, N. (2019, October). A Hybrid BCI Approach to Detect Brain Switch in Action Observation by Utilizing Convolution Neural Network. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)* (pp. 1327-1330). IEEE.
- Zhang, Z., Duan, F., Solé-Casals, J., Dinarès-Ferran, J., Cichocki, A., Yang, Z., & Sun, Z. (2019). A novel deep learning approach with data augmentation to classify motor imagery signals. *IEEE Access*, 7, 15945-15954.

EK 1 – Etik Kurul Raporu



Marmara Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu

BAŞVURU BİLGİLERİ	PROTOKOL KODU	09.2018.842
	PROJE ADI	El hareketlerinin gerçekleştirilmesi ve gözlenmesi esnasında kaydedilen EEG sinyallerinden derin öğrenme temelli sınıflandırma ile ayna nöron aktivitesinin değerlendirilmesi
	SORUMLU ARAŞTIRICI ÜNVANI/ADI	Dr. Öğr. Üyesi Adil Deniz DURU

KARAR BİLGİLERİ	Tarih : 07.12.2018
Yukarıda başvuru bilgileri verilen araştırma başvuru dosyası ve ilgili belgeler araştırmanın gereke, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve gerçekleştirilmesinde sakınca bulunmadığı için Kurulumuzca onaylanmasına oy birliği ile karar verilmiştir. Onay sonrasında yapılacak her türlü proje değişiklikleri (katılımcılar, başlık vb.) veya protokol değişikliklerinin Etik Kurula bildirilerek proje onayının yenilenmesi gerekmektedir.	

ÜYELER					
Ünvanı / Adı / Soyadı	Uzmanlık Dalı	Kurumu / EK Üyeliliği	Onaylanan Proje ile İlişkisi	Toplantıya katılım	İmza
Prof.Dr. Haner DİRESKENELİ	Romatoloji	M.Ü Tıp Fakültesi/ Başkan	Var Yok	☐ Evet ☒ Hayır	
Prof.Dr. Tülin ERGUN	Dermatoloji	M.Ü Tıp Fakültesi/Başkan Yrd.	Var Yok	☐ Evet ☒ Hayır	
Prof.Dr. Atilla KARAALP	Farmakoloji	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Prof. Dr. Şefik GÖRKEY	Tıp Tarihi ve Etik	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Prof.Dr. Handan KAYA	Patoloji	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Prof.Dr. M.Bahadır GÜLLÜOĞLU	Genel Cerrahi	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Prof.Dr. Semra SARDAŞ	Eczacı	M.Ü Eczacılık Fak./Üye	Var Yok	☐ Evet ☒ Hayır	
Prof.Dr. Başak DOĞAN	Diş Hekimi	M.Ü Diş Hekimliği Fak./Üye	Var Yok	☐ Evet ☒ Hayır	
Prof. Dr. Beste Melek ATASOY	Radyasyon Onkolojisi	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Doç. Dr. Ebf KARAKOÇ AYDINER	Çocuk Sağlığı ve Hastalıkları	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Doç.Dr. Meltem KORAY	Diş Hekimi	İstanbul Üniv. Diş Hekimliği Fak./Üye	Var Yok	☐ Evet ☒ Hayır	
Doç. Dr. Gürkan SERT	Hukukçu	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Doç.Dr. Figen DEMİR	Halk Sağlığı	Acıbadem Üniv. Tıp Fak.	Var Yok	☐ Evet ☒ Hayır	
Doç.Dr. Pınar Mega TİBER	Biyofizik	M.Ü Tıp Fakültesi/Üye	Var Yok	☐ Evet ☒ Hayır	
Gözde Aynur MİRZA	Sağlık Mensubu olmayan kişi	Serbest	Var Yok	☐ Evet ☒ Hayır	

EK 2 – Katılımcı Onam Formu

KATILIMCI ONAM FORMU

Bir araştırma projesine davet edilmektesiniz. Bu araştırmanın yürütülmesi, Marmara Üniversitesi Tıp Fakültesi Bilimsel Araştırmalar Değerlendirme Komisyonu'nun 07.12.2018 tarih ve 09.2018.842 sayılı kararı ile onaylanmıştır.

Araştırmaya katılmaya karar vermeden önce araştırmanın neden ve nasıl yapılacağını anlamanız çok önemlidir.

Araştırmaya katılım tamamen gönüllülük ilkesine bağlı olup katılmayı reddetmeniz herhangi bir cezaya ya da elde edilecek herhangi bir yararın kaybedilmesine kesinlikle yol açmayacaktır.

Aynı şekilde araştırmaya katılmayı kabul ettikten sonra da araştırmanın herhangi bir yerinde hiçbir neden göstermeksizin herhangi bir zarar ya da elde edilmesi beklenen bir yarar kaybına yol açmadan araştırmadan ayrılabilirsiniz.

Lütfen biraz zaman ayırın ve aşağıdaki bilgileri dikkatlice okuyun, isterseniz başkalarıyla tartışın. Açık olmayan bir bölüm varsa ya da daha ayrıntılı bilgiye ihtiyaç duyuyorsanız lütfen bizi arayın. Ancak araştırmaya katılmak isteyip istemediğinize karar vermek için lütfen iyi düşünün.

Araştırmayla İlgili Bilgiler

Araştırmanın Bilimsel Adı: EL HAREKETLERİNİN GERÇEKLEŞTİRİLMESİ VE GÖZLEMLENMESİ ESNASINDA KAYDEDİLEN EEG SİNYALLERİNDEN DERİN ÖĞRENME TEMELLİ SINIFLANDIRMA İLE AYNA NÖRON AKTİVİTESİNİN DEĞERLENDİRİLMESİ

Araştırmanın Anlaşılabilir Basit Adı: Gerçek hareketin uygulanması ve aynı hareketin başka bir birey tarafından uygulanırken gözlemlenmesine beynin verdiği yanıtları incelemek ve bu yanıtların derin öğrenme algoritmalarıyla sınıflandırılarak bilgisayar öğrenimi sağlanması

Araştırmanın Niteliği (Klinik, Laboratuvar, Epidemiyolojik – Tez çalışması vb.): Deneysel bir yüksek lisans tez çalışmasıdır.

Araştırmanın Amacı: Çalışmanın amacı, katılımcı gerçek bir el hareketi uyguladığı esnada beyinde ortaya çıkan elektriksel aktivitelerin elektroensefalografi (EEG) aracılığıyla kaydedilmesi ve bu aktivitenin aynı hareket gözlemlendiği esnada görülmesinin derin öğrenme algoritmaları kullanılarak sınıflandırılmasını temel alır. Bu aktivitenin kaynağı olan

ayna nöronlar, hareketin yapılması ve gözlemlenmesi sırasında benzer beyin bölgelerinde aktivitelerin meydana çıkması durumuna denir.

Araştırmanın Yöntemi

Çalışmamızda katılımcı olarak el hareketini uygulama ve hareketin gözlemlenmesi görevlerine özel iki farklı EEG deneyi uygulanacaktır. İlk deneyde bilgisayar aracılığıyla Matlab® programı kullanılarak uyaran ekranından gösterilen yap ya da yapma görevleri aracılığıyla sizden hareketi uygulamanız ya da uygulamamanız istenecektir ve elektroensefalografi (EEG) aracılığıyla veri toplanacaktır. Katılımcı olarak, uyaran ekranından (bilgisayar monitörü) gelen görevi takip ederek stres topunu sıkacak ve EEG aracılığıyla beynin verdiği yanıt olarak ele alınan elektriksel aktiviteler kaydedilecektir.

İkinci deney sırasında katılımcı olarak başka bir birey tarafından gerçekleştirilen hareketi gözlemlemeniz istenecek ve beyin aktiviteleriniz kaydedilecektir. İki ölçümde de kullanılacak ve izlenecek el hareketi şekilde gösterildiği gibi avuç içinde, katılımcı olan sizden uyaran doğrultusunda parmak hareketleri uygulamasıyla gerçekleştirilecektir. 6.35-6.67 cm arası çapta, yaklaşık 20 gram ağırlıkta stres topu, katılımcıların hareketi uygulaması ve gözlemlemesi için kullanılacaktır.



Şekil 1: Katılımcı olarak uygulayacağınız ve gözlemleyeceği hareket şekildeki gibi uygulanacaktır. Hareket ortalama 4 saniye boyunca uygulanacak ve uyaran ekranında çıkacak görev doğrultusunda topu bırakmanız istenecektir. Bu şekilde ardışık hareket serileri devamlı olarak uygulanacaktır.

Beyin aktivitelerinde görülen elde aktivitelerin kaydedilmesi için materyal kısmında özellikleri açıklanan EEG ölçüm cihazı kullanılacaktır. Bu elektrotlara ek olarak 2 elektrot ise referans olarak kulaklara takılacaktır. Kayıtlarda, 512 Hz çözünürlüğe sahip, 107 Hz alçak

geçiren filtreye (low pass filter) sınırlandırılmış EEG cihazı kullanılacaktır.

Ölçüme başlamadan önce göz açık ve göz kapalı olmak üzere 3'er dakikalık referans kayıtları alınacaktır. Hareketleri sağ elinizle yapmanız istenecek ve ikinci ölçümde gözlemediğiniz birey tarafından hareket sağ eliyle uygulanacaktır. Katılımcı, ilk ölçümlerde uyarı ekranında gösterilecek görevleri siyah ekran üzerinde beyaz harflerle yazılan "HAREKET" ve "RAHATLAYINIZ" uyarıları doğrultusunda uygulayacaktır. İkinci ölçümde ise, ilk ölçüm için geçerli olan uyarı hedeflerinin başkası tarafından uygulanışını izleyecek ve elde edilen EEG kayıtları ile ilk ölçümdeki kayıtlarda elde edilen aktivitenin kaydedilmesi tarafımızdan sağlanacaktır.

İki ölçümde de sizden 120'si hareketi yap ve 120'si hareketi yapma görevleri olmak üzere toplamda 240 görev uygulamanız istenecektir. "Hareket" ve "Rahatlayınız" komutları ekranda 4'er saniye kalacaktır ve her 80 görev tamamladıktan sonra 30 saniyelik dinlenme bölümü verilecektir. Bu dinlenme bölümlerinde zaman kısıtından dolayı EEG kepini çıkarmamanız gerekmektedir. Ölçümlerin 18'er dakika sürmesi planlanmaktadır. Referans kayıtları ile toplamda iki ölçümde 30'ar dakika sürecektir.

Araştırmada Kullanılacak Materyaller

Elektroensefalografi

Beynin en önemli bölgelerinden biri olan serebral korteks (beyin kabuğu) sağ ve sol hemisfer olmak üzere 2 bölgeden oluşur. Her iki hemisferde yer alan frontal (alın lobu), pariyetal (yan lob), temporal (şakak lobu) ve oksipital (arka lob) alanlar bireyin içinde bulunduğu duruma göre minimal güçlerde elektrik üretir ve farklı frekans aralıklarında bu elektriksel aktivite gözlemlenebilir. Elektroensefalografi, bu elektriksel aktiviteleri yüksek zaman çözünürlüğünde kaydederek farklı frekans bantlarının daha detaylı incelenmesine olanak sağlar.



Şekil 2: Örnek bir EEG seti. 1. Elektriksel sinyal güçlendirici, 2. Başlık, 3. Elektrotlar numaralandırılmış olarak gösterilmektedir.

Bu çalışmada kullanılmasının sebebi, katılımcıların el hareketi gerçekleştirdiğinde beynin bazı bölümlerinde (motor korteks ve sensorimotor korteks) görülen aktivitenin izlenmesi ve katılımcının aynı hareketi gözlemlemesi esnasında kaydedilen elektriksel aktivitenin incelenmesidir. Elektroensafalografi, bu elektriksel aktiviteyi kafa derisini saran elektrotlar aracılığıyla cerrahi olmayan bir şekilde ölçer ve katılımcıya herhangi bir zararı yoktur.

Uygulama Sırasında Karşılaşılabileceğiniz Riskler ve Rahatsızlıklar: Katılımcı hastalık veya isteksizlik vb. durumlarda kendi rızasıyla araştırmadan ayrılabilir. Deney düzeneğinin uygulanamaması veya eksik uygulanması da katılımcının araştırmadan ayrılması için yeterlidir.

Araştırmanın Katkıları: Araştırmada kullanılan yöntemin öncelikle hareket ve gözlem sırasında beyinde görülen aktivitenin anlaşılması ve gelişen teknolojiye yararlanarak bu hareketin makinelerle yüzde kaç başarıyla öğretilebileceği amaçlanmaktadır. Ayrıca uygulanacak yöntemin olumlu etkileri gözlemlendiğinde tüm spor dallarında, sporcuların hareketin inşası ve gözlemi üzerinde gelişim sağlayacağını düşünüyoruz. Bu araştırmanın temel amacı uzun yıllardır araştırmaları devam eden ayna nöron aktivitelerinin yeni bir yaklaşım ile değerlendirilmesi ve literatüre yeni yöntem ve bilgiler sunması beklenmektedir.

Araştırmaya Katılması Beklenen Katılımcı Sayısı: Çalışmaya 15 katılımcının katılması hedeflenmektedir.

Katılımcı için Araştırmadan Beklenen Yarar: Katılımcılardan hareketin uygulandığı ve gözlemlendiği esnada beynin yanıtlarını ve hareketin temelinde yatan zihinsel süreçlerin anlaşılmasına yardım etmektir.

GÖNÜLLÜ ÇALIŞMAYA KATILMA ONAYI

Yukarıda açıkça tanımlanan çalışmanın ne amaçla, kimler tarafından ve nasıl gerçekleştirileceği anlayabileceğim bir ifade ile bana anlatıldı.

Bu araştırmadan elde edilen bilgilerin bana ve başka insanlara sağlayacağı yararlar bana anlatıldı.

Araştırma sırasında meydana gelebilecek riskler ve rahatsızlıklar bana anlayabileceğim bir dille anlatıldı.

Araştırma sırasında oluşabilecek zarar durumunda gerçekleştirilecek işlemler bana anlatıldı.

Araştırmanın yürütülmesi sırasında olası yan etkiler, riskler ve zararlar ve haklarım konusunda 24 saat bilgi alabileceğim bir yetkilinin adı ve telefonu bana verildi.

Araştırma kapsamındaki bütün muayene, tetkik ve testler ile tıbbi bakım hizmetleri için benden ya da bağlı bulunduğum sosyal güvenlik kuruluşundan hiçbir ücret istenmeyeceği bana anlatıldı.

Araştırmaya hiçbir baskı ve zorlama altında olmaksızın gönüllü olarak katılıyorum.

Araştırmaya katılmayı reddetme hakkına sahip olduğum bana bildirildi.

Sorumlu araştırmacıya haber vermek kaydıyla, hiçbir gerekçe göstermeksizin istediğim anda bu çalışmadan çekilebileceğimin bilincindeyim.

Bu çalışmaya katılmayı reddetmem ya da sonradan çekilmem halinde hiçbir sorumluluk altına girmediğimi ve bu durumun şimdi ya da gelecekte gereksinim duyduğum tıbbi bakımı hiçbir biçimde etkilemeyeceğini biliyorum.

Çalışmanın yürütücüsü olan araştırmacı veya destekleyen kuruluş, çalışma programının gereklerini yerine getirmedeki ihmalim nedeniyle, benim onayımı almadan beni çalışma kapsamından çıkarabilir.

Çalışmanın sonuçları bilimsel toplantılar ya da yayınlarda sunulabilir. Ancak, bu tür durumlarda kimliğim kesin olarak gizli tutulacaktır.

Yukarıda yer alan ve araştırmadan önce gönüllüye verilmesi gereken bilgileri gösteren Gönüllü Bilgilendirme Formu adlı metni kendi anadilimde okudum.

Bu bilgilerin içeriği ve anlamı yazılı ve sözlü olarak açıklandı.

Aklıma gelen bütün soruları sorma olanağı tanındı ve sorularıma doyurucu cevaplar aldım. Bu koşullarla, söz konusu araştırmaya hiçbir baskı ve zorlama olmaksızın gönüllü olarak katılmayı kabul ediyorum.

Sayın Dr. Adil Deniz Duru tarafından Marmara Üniversitesi Spor Bilimleri Fakültesi Beden Eğitimi ve Spor Anabilim Dalı'nın bulunduğu Anadolu Hisarı kampüsünde tıbbi bir araştırma yapılacağı belirtilerek bu araştırma ile ilgili yukarıdaki bilgiler bana aktarıldı. Bu bilgilerden sonra böyle bir araştırmaya “katılımcı” (denek) olarak davet edildim.

Eğer bu araştırmaya katılırsam hekim ile aramda kalması gereken bana ait bilgilerin gizliliğine bu araştırma sırasında da büyük özen ve saygı ile yaklaşılacağına inanıyorum. Araştırma sonuçlarının eğitim ve bilimsel amaçlarla kullanımı sırasında kişisel bilgilerimin ihtimamla korunacağı konusunda bana yeterli güven verildi.

Projenin yürütülmesi sırasında herhangi bir sebep göstermeden araştırmadan çekilebilirim. Ancak araştırmacıları zor durumda bırakmamak için araştırmadan çekileceğimi önceden bildirmemim uygun olacağının bilincindeyim. Ayrıca tıbbi durumuma herhangi bir zarar verilmemesi amacıyla araştırmacı tarafından araştırmadan çıkartılabileceğimi de biliyorum. Araştırma için yapılacak harcamalarla ilgili herhangi bir parasal sorumluluk altına girmiyorum. Aynı zamanda tarafıma ödeme yapılmayacaktır. İster doğrudan, ister dolaylı olsun araştırma uygulamasından kaynaklanan nedenlerle meydana gelebilecek herhangi bir sağlık sorununun ortaya çıkması halinde, her türlü tıbbi müdahalenin sağlanacağı konusunda gerekli güvence verildi. Bu tıbbi müdahalelerle ilgili olarak da parasal bir yük altına girmeyeceğimi biliyorum.

Araştırma sırasında bir sağlık sorunu ile karşılaştığımda; herhangi bir saatte, Dr. Hasan Birol Çotuk'ı 05334326414 adlı telefon numarasından arayabileceğimi ve Marmara Üniversitesi Anadolu Hisarı Kampüsü Sinirbilim Laboratuvarı'nda ulaşabileceğimi biliyorum. Bu araştırmaya katılmak zorunda değilim ve katılmayabilirim. Araştırmaya katılmam konusunda zorlayıcı bir davranışla karşılaşmış değilim. Eğer katılmayı reddedersem, bu durumun tıbbi bakımına ve hekim ile olan ilişkiye herhangi bir zarar getirmeyeceğini de biliyorum.

Bana yapılan tüm açıklamaları ayrıntılarıyla anlamış bulunmaktayım. Kendi başıma belli bir düşünme süresi sonunda adı geçen bu araştırma projesinde “katılımcı” (denek) olarak yer alma kararını aldım. Bu konuda yapılan daveti büyük bir memnuniyet ve gönüllülük içerisinde kabul ediyorum. İmzalamış bulunduğum bu form kâğıdının bir kopyası bana verilecektir.

GÖNÜLLÜ ONAY FORMU

Yukarıda gönüllüye araştırmadan önce verilmesi gereken bilgileri gösteren metni okudum. Bunlar hakkında bana yazılı ve sözlü açıklamalar yapıldı. Bu koşullarla söz konusu klinik araştırmaya kendi rızamla hiçbir baskı ve zorlama olmaksızın katılmayı kabul ediyorum.

Gönüllünün Adı-soyadı, İmzası, Adresi (varsa telefon no., faks no,...)

Velayet veya vesayet altında bulunanlar için veli veya vasinin adı-soyadı, imzası, adresi (varsa telefon no., faks no,...)

Açıklamaları yapan araştırmacının adı-soyadı, imzası

Rıza alma işlemine başından sonuna kadar tanıklık eden kuruluş görevlisinin adı-soyadı, imzası, görevi