



TÜRKİYE CUMHURİYETİ
MARMARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**CİMNASTİK SPORCULARI VE SEDANTERLERDE EĞİK
MASA KULLANILARAK YARATILAN AY YERÇEKİMİ ANALOĞUNDA
ARTAN MENTAL İŞ YÜKÜ ETKİSİNİN
BEYİN GÖRÜNTÜLEME İLE İNCELENMESİ**

SELEN GÜNEY

YÜKSEK LİSANS TEZİ

BEDEN EĞİTİMİ VE SPOR ANABİLİM DALI SPORDA BİLİŞİM
TEKNOLOJİLERİ

DOÇ. DR. ADİL DENİZ DURU

2021-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 olmadığı beyan ederim.

Selen GÜNEY



Teşekkür

Lisans eğitimimden başlayarak şu an sunulan tez aşamasına kadar olan tüm süreçte öngörüsü ve üzerine tartışmak istediğim yalnızca akademik değil aynı zamanda etik konulardaki yaklaşımlarından etkilendiğim ve destek aldığım danışmanım Doç. Dr. Adil Deniz Duru'ya, soruları ile zihnimde yeni sorular oluşmasına sebebiyet veren, 'peki böyle yapsak' şeklindeki yaklaşımının bendeki etkisinden ötürü Prof. Dr. Hasan Birol Çotuk' a, Karar Verme Algoritmaları dersinin ilk gününde sorduğu bir soru ile hala hayatıma etki eden cevabından ötürü Prof. Dr. Haludun Akpınar'a, hiçbir zaman resmiyette dersini almadığım fakat bunun bilgisini ve tecrübesini paylaşması için bir kriter olmadığını büyük bir yakınlıkla hissettiğim Dr. Dilek Göksel Duru'ya, lise yıllarımda asla yüksek lisans yapmak istemediğimi söylerken bu düşüncemi değiştirmem konusundaki yaklaşımını ve desteğini unutmayacağım Beyhan Özgür'e, birçok çalışma üzerine birlikte düşündüğüm, karşılıklı tartışmalarımızın o anın ötesine geçtiğine inandığım Hüseyin Akbulut'a, bu süreçte ve süreçten bağımsız çok değer verdiğim dostluğu ve desteği için Kübra Tan'a ve karamsar anlarımda bir şekilde çıkış yolu bulacağımı bana çok içten hissettiren Savaş Akbaş'a, sayamadığım diğer laboratuvar arkadaşlarıma, ve hayatımın her sürecinde olduğu gibi bu noktada da varlıkları ile beni rahatlatan aileme çok ve çok teşekkürlerimi sunarım.

İÇİNDEKİLER

BEYAN	i
Teşekkür	ii
1. ÖZET	1
2. SUMMARY	2
1. GİRİŞ ve AMAÇ	3
2. GENEL BİLGİLER.....	6
2.1. Cimnastik.....	6
2.2. Sinir Sistemi Fizyolojisi.....	6
2.2.1. Serebral Korteks	7
2.2.2. Nöronlar	8
2.2.3 Aksiyon Potansiyeli ve Ölçülmesi.....	9
2.3. Zihinsel İş Yüğü	13
2.4. Sinir Sistemi Aktivitesinin Sınıflandırılması.....	14
2.4.1 Entropi	14
2.4.1.1 Yaklaşık Entropi (Approximate Entropy, ApEn)	14
2.4.2 Makine Öğrenimi.....	15
2.4.3 K-Katlamalı (Fold) Çapraz Doğrulama Yapısı.....	16
2.4.4. EEG Sinyal Sınıflandırması.....	17
2.4.5. Ön İşleme ve Öznitelik Çıkarımı	19
2.4.6. Sınıflandırıcı Algoritmaları.....	19
2.4.6.1. K-En Yakın Komşu (K-Nearest Neighbor) Algoritması	19

2.4.6.2. Karar Ağacı Algoritması (Decision Tree)	20
2.4.6.3. Doğrusal ve Quadratik Diskriminant Analiz (Linear and Quadratic Discriminant Analysis)	21
2.4.6.4. Destek Vektör Makinesi (Support Vector Machine)	22
2.4.6.5. Lojistik Regresyon Analizi (Logistic Regression).....	24
2.4.7. Sınıflandırıcı Performansının Değerlendirilmesi.....	25
2.4.7.1. Hata Matrisi (Confusion Matrix)	25
2.4.7.2. Sınıflandırıcı Performans Ölçütleri.....	25
3. GEREÇ ve YÖNTEM	27
3.1. Araştırma Grubu	27
3.2. Araştırma Yöntemi.....	27
3.3 Araştırmanın Çalışma Alanı.....	29
3.4. Araştırmada Uygulanan Testler ve Ölçümler.....	29
3.4.1. EEG.....	29
3.5. EEG Gürültülerinin Arındırılması ve Özniteliklerin Hesaplanması.....	30
4. BULGULAR.....	37
4.1. Tek Katılımcı Tabanlı Oluşan Veri Seti, Yaklaşık Entropi Sınıflandırması	37
4.1.1. Ay_Göz kapalı_Çıkarma-Zaman Penceresi (A_GK_Ç-Zaman Penceresi) Durumu	37
4.1.2. Dünya_Göz kapalı_Çıkarma-Zaman Penceresi (D_GK_Ç-Zaman Penceresi) Durumu	47
4.1.3. Göz Kapalı_Dünya_Ay-Zaman Penceresi (GK_D_A-Zaman Penceresi) Durumu	57
4.1.4. Çıkarma_Dünya_Ay-Zaman Penceresi (Ç_D_A-Zaman Penceresi) Durumu	66

4.2. Tüm Katılımcılardan Oluşan Veri Seti, Yaklaşık Entropi Sınıflandırması	75
4.2.1. Tüm Katılımcılar_Çıkarma_Dünya_Ay (TK_Ç_D_A) Durumu	75
4.2.2. Tüm Katılımcılar_Göz Kapalı_Dünya_Ay (TK_GK_D_A) Durumu.....	81
4.2.3. Tüm Katılımcılar_Dünya_Çıkarma_Göz kapalı (TK_D_Ç_GK) Durumu .	81
4.2.4. Tüm Katılımcılar_Ay_Çıkarma_Göz kapalı (TK_A_Ç_GK) Durumu.....	92
4.3. Cimnastik ve Sedanter Grubun Oluşturduğu Veri Seti, Yaklaşık Entropi Sınıflandırması.....	92
4.3.1. Dünya_Cimnastik_Sedanter_Göz Kapalı (D_C_S_GK) Durumu	98
4.3.2. Ay_Cimnastik_Sedanter_Göz Kapalı (A_C_S_GK) Durumu	98
4.3.3. Dünya_Cimnastik_Sedanter_Çıkarma (D_C_S_Ç) Durumu	98
4.3.4. Ay_Cimnastik_Sedanter_Çıkarma (A_C_S_Ç) Durumu.....	115
5. Tartışma ve Sonuç	121
KAYNAKÇA.....	130
EKLER	142

Kısaltmalar ve Simgeler Listesi

EEG: Elektroensefalografi

BOS: Beyin Omurilik Sıvısı

MSS: Merkezi Sinir Sistemi

PSS: Periferik Sinir Sistemi

LDA: Lineer Diskriminant Analizi

DVM: Destek Vektör Makinesi

K-En: K-En Yakın Komşu

TK: Tüm Katılımcılar

GK: Göz Kapalı

Ç: Çıkarma

D: Dünya

A: Ay

C: Cimnastik

S: Sedanter

mV: Milivolt

μ V: Mikrovolt

δ : delta

θ : teta

α : alfa

β : beta

γ : gama

Şekiller Listesi

Şekil 1. Membran potansiyelinin değişimi (Ka Xiong Charand, http://hyperphysics.phy-astr.gsu.edu/hbase/Biology/actpot.html).....	10
Şekil 2. Normal EEG sinyalinde görülen farklı frekanslara sahip dalgalar (Brainwave Entrainment, Itsu sync).....	12
Şekil 3. Normal, kısmi nöbet, jeneralize nöbet EEG paterni (Seizure, Drugs.com) .	12
Şekil 4. K-katmanlı çapraz doğrulama yapısı (Siuly ve ark., 2016).....	17
Şekil 5. EEG sinyali sınıflandırması için blok diyagram	18
Şekil 6. İki boyutlu ayrılabilir veri kümesi ve ayırıcı düzlem (Sanei ve Chambers, 2013)	23
Şekil 7. Optimal bir ayırıcı düzlem (Sanei ve Chambers, 2013).....	23
Şekil 8. Hata matrisi yapısı.....	25
Şekil 9. Sınıflandırıcı performans ölçütleri ve formülleri	26
Şekil 10. Ay yerçekimine denk eğik sehpa açısı (https://ispyphysiology.files.wordpress.com/2016/03/bed-rest.png).....	28
Şekil 11. Dünya yerçekimine denk eğik sehpa açısı (https://ispyphysiology.files.wordpress.com/2016/03/bed-rest.png).....	28
Şekil 12. 16 Kanallı bir EEG set örneği: 1. Elektriksel sinyal güçlendirici, 2. Kep, 3. Elektrotlar	30
Şekil 13. Kafa üzerindeki elektrot yerleşim modeli	30
Şekil 14. 5 katmanlı çapraz doğrulama yapısı.....	31
Şekil 15. Ay-göz kapalı koşulunda 6 numaralı katılımcıya (cimnastik) ait 250 milisaniyelik pencere örneği.....	31
Şekil 16. Ay-çıkarma görevi koşulunda 4 numaralı katılımcıya (cimnastik) ait 500 milisaniyelik pencere örneği.....	32
Şekil 17. Ay-çıkarma görevi koşulunda 2 numaralı katılımcıya (sedanter) ait 750 milisaniyelik pencere örneği.....	32
Şekil 18. Dünya-çıkarma görevi koşulunda 6 numaralı katılımcıya (cimnastik) ait 1000 milisaniyelik pencere örneği.....	33
Şekil 19. Dünya-göz kapalı görevi koşulunda 3 numaralı katılımcıya (sedanter) ait 1500 milisaniyelik pencere örneği.....	33
Şekil 20. Dünya-göz kapalı görevi koşulunda 4 numaralı katılımcıya (cimnastik) ait 2000 milisaniyelik pencere örneği.....	34

Şekil 21. Ay-göz kapalı görevi koşulunda 1 numaralı katılımcıya (sedanter) ait 3000 milisaniyelik pencere örneği.....	34
Şekil 22. Ay-çıkarma görevi koşulunda 5 numaralı katılımcıya (cimmastik) ait 4000 milisaniyelik pencere örneği.....	35
Şekil 23. Tüm kanallar için TK_Ç_D_A-250 durumuna ait ortalama ve standart sapma entropi değeri.....	77
Şekil 24. Tüm kanallar için TK_Ç_D_A-500 durumuna ait ortalama ve standart sapma entropi değeri.....	77
Şekil 25. Tüm kanallar için TK_Ç_D_A-750 durumuna ait ortalama ve standart sapma entropi değeri.....	78
Şekil 26. Tüm kanallar için TK_Ç_D_A-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	78
Şekil 27. Tüm kanallar için TK_Ç_D_A-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	79
Şekil 28. Tüm kanallar için TK_Ç_D_A-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	79
Şekil 29. Tüm kanallar için TK_Ç_D_A-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	80
Şekil 30. Tüm kanallar için TK_Ç_D_A-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	80
Şekil 31. Tüm kanallar için TK_GK_D_A-250 durumuna ait ortalama ve standart sapma entropi değeri.....	83
Şekil 32. Tüm kanallar için TK_GK_D_A-500 durumuna ait ortalama ve standart sapma entropi değeri.....	83
Şekil 33. Tüm kanallar için TK_GK_D_A-750 durumuna ait ortalama ve standart sapma entropi değeri.....	84
Şekil 34. Tüm kanallar için TK_GK_D_A-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	84
Şekil 35. Tüm kanallar için TK_GK_D_A-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	85
Şekil 36. Tüm kanallar için TK_GK_D_A-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	85
Şekil 37. Tüm kanallar için TK_GK_D_A-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	86
Şekil 38. Tüm kanallar için TK_GK_D_A-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	86

Şekil 39. Tüm kanallar için TK_D_Ç_GK-250 durumuna ait ortalama ve standart sapma entropi değeri.....	88
Şekil 40. Tüm kanallar için TK_D_Ç_GK-500 durumuna ait ortalama ve standart sapma entropi değeri.....	88
Şekil 41. Tüm kanallar için TK_D_Ç_GK-750 durumuna ait ortalama ve standart sapma entropi değeri.....	89
Şekil 42. Tüm kanallar için TK_D_Ç_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	89
Şekil 43. Tüm kanallar için TK_D_Ç_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	90
Şekil 44. Tüm kanallar için TK_D_Ç_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	90
Şekil 45. Tüm kanallar için TK_D_Ç_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	91
Şekil 46. Tüm kanallar için TK_D_Ç_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	91
Şekil 47. Tüm kanallar için TK_A_Ç_GK-250 durumuna ait ortalama ve standart sapma entropi değeri.....	94
Şekil 48. Tüm kanallar için TK_A_Ç_GK-500 durumuna ait ortalama ve standart sapma entropi değeri.....	94
Şekil 49. Tüm kanallar için TK_A_Ç_GK-750 durumuna ait ortalama ve standart sapma entropi değeri.....	95
Şekil 50. Tüm kanallar için TK_A_Ç_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	95
Şekil 51. Tüm kanallar için TK_A_Ç_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	96
Şekil 52. Tüm kanallar için TK_A_Ç_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	96
Şekil 53. Tüm kanallar için TK_A_Ç_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	97
Şekil 54. Tüm kanallar için TK_A_Ç_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	97
Şekil 55. Tüm kanallar için D_C_S_GK-250 durumuna ait ortalama ve standart sapma entropi değeri.....	101
Şekil 56. Tüm kanallar için D_C_S_GK-500 durumuna ait ortalama ve standart sapma entropi değeri.....	101

Şekil 57. Tüm kanallar için D_C_S_GK-750 durumuna ait ortalama ve standart sapma entropi değeri.....	102
Şekil 58. Tüm kanallar için D_C_S_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	102
Şekil 59. Tüm kanallar için D_C_S_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	103
Şekil 60. Tüm kanallar için D_C_S_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	103
Şekil 61. Tüm kanallar için D_C_S_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	104
Şekil 62. Tüm kanallar için D_C_S_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	104
Şekil 63. Tüm kanallar için A_C_S_GK-250 durumuna ait ortalama ve standart sapma entropi değeri.....	106
Şekil 64. Tüm kanallar için A_C_S_GK-500 durumuna ait ortalama ve standart sapma entropi değeri.....	106
Şekil 65. Tüm kanallar için A_C_S_GK-750 durumuna ait ortalama ve standart sapma entropi değeri.....	107
Şekil 66. Tüm kanallar için A_C_S_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	107
Şekil 67. Tüm kanallar için A_C_S_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	108
Şekil 68. Tüm kanallar için A_C_S_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	108
Şekil 69. Tüm kanallar için A_C_S_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	109
Şekil 70. Tüm kanallar için A_C_S_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	109
Şekil 71. Tüm kanallar için D_C_S_Ç-250 durumuna ait ortalama ve standart sapma entropi değeri.....	111
Şekil 72. Tüm kanallar için D_C_S_Ç-500 durumuna ait ortalama ve standart sapma entropi değeri.....	111
Şekil 73. Tüm kanallar için D_C_S_Ç-750 durumuna ait ortalama ve standart sapma entropi değeri.....	112
Şekil 74. Tüm kanallar için D_C_S_Ç-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	112

Şekil 75. Tüm kanallar için D_C_S_Ç-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	113
Şekil 76. Tüm kanallar için D_C_S_Ç-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	113
Şekil 77. Tüm kanallar için D_C_S_Ç-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	114
Şekil 78. Tüm kanallar için D_C_S_Ç-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	114
Şekil 79. Tüm kanallar için A_C_S_Ç-250 durumuna ait ortalama ve standart sapma entropi değeri.....	117
Şekil 80. Tüm kanallar için A_C_S_Ç-500 durumuna ait ortalama ve standart sapma entropi değeri.....	117
Şekil 81. Tüm kanallar için A_C_S_Ç-750 durumuna ait ortalama ve standart sapma entropi değeri.....	118
Şekil 82. Tüm kanallar için A_C_S_Ç-1000 durumuna ait ortalama ve standart sapma entropi değeri.....	118
Şekil 83. Tüm kanallar için A_C_S_Ç-1500 durumuna ait ortalama ve standart sapma entropi değeri.....	119
Şekil 84. Tüm kanallar için A_C_S_Ç-2000 durumuna ait ortalama ve standart sapma entropi değeri.....	119
Şekil 85. Tüm kanallar için A_C_S_Ç-3000 durumuna ait ortalama ve standart sapma entropi değeri.....	120
Şekil 86. Tüm kanallar için A_C_S_Ç-4000 durumuna ait ortalama ve standart sapma entropi değeri.....	120

Tablolar Listesi

Tablo 1. TK_GK_D_A, TK_Ç_D_A, TK_D_Ç_GK, TK_A_Ç_GK, C_S_GK_D, C_S_GK_A, C_S_Ç_D, C_S_Ç_A, A_GK_Ç ve D_GK_Ç durumları için sınıflandırıcıda kullanılan tüm zaman pencerelerindeki veri setine ait girdi sayısı...	36
Tablo 2. GK_D_A durumu için, her bir katılımcının sınıflandırıcıda kullanılan tüm zaman pencerelerindeki veri setine ait girdi sayısı	36
Tablo 3. Ç_D_A durumuna ait, her bir katılımcının sınıflandırıcı için kullanılan tüm zaman pencerelerindeki girdi sayıları	36
Tablo 4. Sedanter, cimnastik ve tüm katılımcılarda kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri	38
Tablo 5. Sedanter ve cimnastik katılımcıların, A_GK_Ç-250 durumuna ait sınıflandırma sonuçları (%)	39
Tablo 6. Sedanter ve cimnastik katılımcıların, A_GK_Ç-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	39
Tablo 7. Sedanter ve cimnastik katılımcıların, A_GK_Ç-500 durumuna ait sınıflandırma sonuçları (%)	40
Tablo 8. Sedanter ve cimnastik katılımcıların, A_GK_Ç-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	40
Tablo 9. Sedanter ve cimnastik katılımcıların, A_GK_Ç-750 durumuna ait sınıflandırma sonuçları (%)	41
Tablo 10. Sedanter ve cimnastik katılımcıların, A_GK_Ç-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	41
Tablo 11. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1000 durumuna ait sınıflandırma sonuçları (%)	42
Tablo 12. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	42
Tablo 13. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1500 durumuna ait sınıflandırma sonuçları (%)	43
Tablo 14. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	43

Tablo 15. Sedanler ve cimnastik katılımcıların, A_GK_Ç-2000 durumuna ait sınıflandırma sonuçları (%)	44
Tablo 16. Sedanler ve cimnastik katılımcıların, A_GK_Ç-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	44
Tablo 17. Sedanler ve cimnastik katılımcıların, A_GK_Ç-3000 durumuna ait sınıflandırma sonuçları (%)	45
Tablo 18. Sedanler ve cimnastik katılımcıların, A_GK_Ç-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	45
Tablo 19. Sedanler ve cimnastik katılımcıların, A_GK_Ç-4000 durumuna ait sınıflandırma sonuçları (%)	46
Tablo 20. Sedanler ve cimnastik katılımcıların, A_GK_Ç-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	46
Tablo 21. Sedanler, cimnastik ve tüm katılımcılar için kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri	47
Tablo 22. Sedanler ve cimnastik katılımcıların, D_GK_Ç-250 durumuna ait sınıflandırma sonuçları (%)	48
Tablo 23. Sedanler ve cimnastik katılımcıların, D_GK_Ç-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma sonuçları (%)	48
Tablo 24. Sedanler ve cimnastik katılımcıların, D_GK_Ç-500 durumuna ait sınıflandırma sonuçları (%)	49
Tablo 25. Sedanler ve cimnastik katılımcıların, D_GK_Ç-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma sonuçları (%)	49
Tablo 26. Sedanler ve cimnastik katılımcıların, D_GK_Ç-750 durumuna ait sınıflandırma sonuçları (%)	50
Tablo 27. Sedanler ve cimnastik katılımcıların, D_GK_Ç-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	50
Tablo 28. Sedanler ve cimnastik katılımcıların, D_GK_Ç-1000 durumuna ait sınıflandırma sonuçları (%)	51
Tablo 29. Sedanler ve cimnastik katılımcıların, D_GK_Ç-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	51
Tablo 30. Sedanler ve cimnastik katılımcıların, D_GK_Ç-1500 durumuna ait sınıflandırma sonuçları (%)	52

Tablo 31. Sedanter ve cimnastik katılımcıların, D_GK_Ç-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	52
Tablo 32. Sedanter ve cimnastik katılımcıların, D_GK_Ç-2000 durumuna ait sınıflandırma sonuçları (%)	53
Tablo 33. Sedanter ve cimnastik katılımcıların, D_GK_Ç-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	53
Tablo 34. Sedanter ve cimnastik katılımcıların, D_GK_Ç-3000 durumuna ait sınıflandırma sonuçları (%)	54
Tablo 35. Sedanter ve cimnastik katılımcıların, D_GK_Ç-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	54
Tablo 36. Sedanter ve cimnastik katılımcıların, D_GK_Ç-4000 durumuna ait sınıflandırma sonuçları (%)	55
Tablo 37. Sedanter ve cimnastik katılımcıların, D_GK_Ç-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	55
Tablo 38. Sedanter, cimnastik ve tüm katılımcılar için kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri	57
Tablo 39. Sedanter ve cimnastik katılımcıların, GK_D_A-250 durumuna ait sınıflandırma sonuçları (%)	58
Tablo 40. Sedanter ve cimnastik katılımcıların, GK_D_A-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	58
Tablo 41. Sedanter ve cimnastik katılımcıların, GK_D_A-500 durumuna ait sınıflandırma sonuçları (%)	59
Tablo 42. Sedanter ve cimnastik katılımcıların, GK_D_A-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	59
Tablo 43. Sedanter ve cimnastik katılımcıların, GK_D_A-750 durumuna ait sınıflandırma sonuçları (%)	60
Tablo 44. Sedanter ve cimnastik katılımcıların, GK_D_A-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	60
Tablo 45. Sedanter ve cimnastik katılımcıların, GK_D_A-1000 durumuna ait sınıflandırma sonuçları (%)	61
Tablo 46. Sedanter ve cimnastik katılımcıların, GK_D_A-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	61

Tablo 47. Sedanler ve cımnastik katılımcıların, GK_D_A-1500 durumuna ait sınıflandırma sonuçları (%)	62
Tablo 48. Sedanler ve cımnastik katılımcıların, GK_D_A-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	62
Tablo 49. Sedanler ve cımnastik katılımcıların, GK_D_A-2000 durumuna ait sınıflandırma sonuçları (%)	63
Tablo 50. Sedanler ve cımnastik katılımcıların, GK_D_A-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	63
Tablo 51. Sedanler ve cımnastik katılımcıların, GK_D_A-3000 durumuna ait sınıflandırma sonuçları (%)	64
Tablo 52. Sedanler ve cımnastik katılımcıların, GK_D_A-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	64
Tablo 53. Sedanler ve cımnastik katılımcıların, GK_D_A-4000 durumuna ait sınıflandırma sonuçları (%)	65
Tablo 54. Sedanler ve cımnastik katılımcıların, GK_D_A-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	65
Tablo 55. Sedanler, cımnastik ve tüm katılımcılar için kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri	66
Tablo 56. Sedanler ve cımnastik katılımcıların, Ç_D_A-250 durumuna ait sınıflandırma sonuçları (%)	67
Tablo 57. Sedanler ve cımnastik katılımcıların, Ç_D_A-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	67
Tablo 58. Sedanler ve cımnastik katılımcıların, Ç_D_A-500 durumuna ait sınıflandırma sonuçları (%)	68
Tablo 59. Sedanler ve cımnastik katılımcıların, Ç_D_A-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	68
Tablo 60. Sedanler ve cımnastik katılımcıların, Ç_D_A-750 durumuna ait sınıflandırma sonuçları (%)	69
Tablo 61. Sedanler ve cımnastik katılımcıların, Ç_D_A-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	69
Tablo 62. Sedanler ve cımnastik katılımcıların, Ç_D_A-1000 durumuna ait sınıflandırma sonuçları (%)	70

Tablo 63. Sedanter ve cimnastik katılımcıların, Ç_D_A-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	70
Tablo 64. Sedanter ve cimnastik katılımcıların, Ç_D_A-1500 durumuna ait sınıflandırma sonuçları (%)	71
Tablo 65. Sedanter ve cimnastik katılımcıların, Ç_D_A-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	71
Tablo 66. Sedanter ve cimnastik katılımcıların, Ç_D_A-2000 durumuna ait sınıflandırma sonuçları (%)	72
Tablo 67. Sedanter ve cimnastik katılımcıların, Ç_D_A-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	72
Tablo 68. Sedanter ve cimnastik katılımcıların, Ç_D_A-3000 durumuna ait sınıflandırma sonuçları (%)	73
Tablo 69. Sedanter ve cimnastik katılımcıların, Ç_D_A-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	73
Tablo 70. Sedanter ve cimnastik katılımcıların, Ç_D_A-4000 durumuna ait sınıflandırma sonuçları (%)	74
Tablo 71. Sedanter ve cimnastik katılımcıların, Ç_D_A-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	74
Tablo 72. Tüm zaman pencereleri için TK_Ç_D_A durumuna ait sınıflandırma sonuçları (%).....	76
Tablo 73. Tüm zaman pencereleri için TK_Ç_D_A durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	76
Tablo 74. Tüm zaman pencereleri için TK_GK_D_A durumuna ait sınıflandırma sonuçları (%).....	82
Tablo 75. Tüm zaman pencereleri için TK_GK_D_A durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%).....	82
Tablo 76. Tüm zaman pencereleri için TK_D_Ç_GK durumuna ait sınıflandırma sonuçları (%).....	87
Tablo 77. Tüm zaman pencereleri için TK_D_Ç_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%).....	87
Tablo 78. Tüm zaman pencereleri için TK_A_Ç_GK durumuna ait sınıflandırma sonuçları (%).....	93

Tablo 79. Tüm zaman pencereleri için TK_A_Ç_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%).....	93
Tablo 80. Tüm zaman pencereleri için D_C_S_GK durumuna ait sınıflandırma sonuçları (%).....	100
Tablo 81. Tüm zaman pencereleri için D_C_S_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	100
Tablo 82. Tüm zaman pencereleri için A_C_S_GK durumuna ait sınıflandırma sonuçları (%).....	105
Tablo 83. Tüm zaman pencereleri için A_C_S_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	105
Tablo 84. Tüm zaman pencereleri için D_C_S_Ç durumuna ait sınıflandırma sonuçları (%).....	110
Tablo 85. Tüm zaman pencereleri için D_C_S_Ç durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	110
Tablo 86. Tüm zaman pencereleri için A_C_S_Ç durumuna ait sınıflandırma sonuçları (%).....	116
Tablo 87. Tüm zaman pencereleri için A_C_S_Ç durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)	116

1. ÖZET

Cimnastik sporcuları ve sedanterlerde eğik masa kullanılarak yaratılan ay yerçekimi analogunda artan mental iş yükü etkisinin beyin görüntüleme ile incelenmesi

Öğrenci Adı: Selen GÜNEY

Danışman Adı: Doç. Dr. Adil Deniz DURU

Anabilim Dalı: Beden Eğitimi ve Spor

Amaç: Sunulan çalışmada; Ay yerçekimi analogu ve Dünya yerçekimi pozisyonunda, cimnastik sporcuları ve sedanter bireylerin, zihinden çıkarma ve göz kapalı görevlerini gerçekleştirdiği esnada ölçülen EEG sinyalleri ile; pozisyonun, katılımcıların ve görevlerin sınıflandırılması amaçlanmıştır.

Gereç ve yöntem: Çalışmada 3 cimnastik sporcusu ve 3 sedanter birey yer aldı. EEG kaydı, katılımcıların Ay yerçekimi analogu ve Dünya yerçekimi pozisyonunda 180 saniye göz kapalı, 60 saniye zihinden çıkarma görevi icrası sırasında alındı. EEG sinyalleri 250, 500, 750, 1000, 1500, 2000, 3000 ve 4000 ms lik zaman pencerelerine ayrıldı ve her pencereye Yaklaşık entropi uygulandı. Her zaman penceresinde 16 EEG kanalına uygulanan Yaklaşık entropi değeri makine öğrenimine girdi olarak verildi ve 23 farklı sınıflandırıcı algoritması ile test edildi.

Bulgular: Cimnastik sporcuları ve sedanter bireyler; Dünya ve Ay koşulunda göz kapalı ve çıkarma görev icrasını gerçekleştirdiği esnada %95' in üzerinde, Dünya ve Ay pozisyonu; göz kapalı ve çıkarma görev icrası sırasında %95' in üzerinde, göz kapalı ve çıkarma görev icrası sırası; Dünya ve Ay pozisyonunda %90'ın üzerinde doğruluk ile sınıflandırılmıştır. Zaman pecereleri genişledikçe sınıflandırma başarısı artış göstermiştir.

Sonuç: Tüm zaman pencerelerinde EEG sinyallerine uygulanan Yaklaşık entropi değeri ile; katılımcıların, pozisyonun ve görevlerin yüksek doğruluk yüzdesi ile sınıflandırılması beyin yapısının pozisyona bağlı şekilde konumlanmasının neden olabileceği bilişsel süreç yapısı hakkında bilgi vermektedir.

Anahtar kelimeler: Yaklaşık Entropi, Ay yerçekimi, Dünya yerçekimi, EEG, Makine öğrenimi

2. SUMMARY

Examination of increased mental workload by brain imaging on gymnasts and sedentary subjects using the head down tilt in the moon gravity analog

Student Name: Selen GÜNEY

Name of Supervisor: Doç. Dr. Adil Deniz DURU

Department: Faculty of Sport Science

Objective: The purpose of this study to classify the position, participants and tasks by the measured EEG signals while the gymnastic and sedentary participants performed the subtraction and eyes-close tasks in the Moon gravity analogue and Earth gravity position.

Material and methods: 3 gymnastic athletes and 3 sedentary participants were included in the study. The EEG was measured during the participants' Moon gravity analogue and the Earth gravity position while the participants performing 180-second eyes-closed, 60-second Subtraction task. The EEG signals were divided into 250, 500, 750, 1000, 1500, 2000, 3000 and 4000 ms time windows and the Approximate entropy (ApEn) algorithm was applied to each window. ApEn value applied to 16 EEG channels in each time window was used as input to machine learning and tested with 23 different classifier algorithms.

Results: Gymnastic athletes and sedentary participants; It was classified over 95% accuracy when performing the eyes-close and subtraction task in the Earth and Moon conditions. In the Earth and Moon positions; It was classified over 95% accuracy when performing eyes-close and subtraction task. Eyes-closed and subtraction task; classification scores were over 90% accuracy in the Earth and Moon position.

Conclusion: Classification of participants, positions and tasks, with a high percentage of accuracy through approximate entropy applied to EEG signals in different all-time windows; provides information about the cognitive process structure that may be caused by the positioning of the brain structure relative to the position.

Keywords: Approximate entropy, moon gravity, earth gravity, EEG, machine learning

1. GİRİŞ ve AMAÇ

Günlük yaşantımızın büyük bir çoğunluğunu, oturur veya ayakta-dik pozisyonda geçirdiğimiz ve bir tam gün içinde, saati-süresi fark etmeksizin dinlenmek için yatağa uzandığımız hipotezi çoğumuz için doğru kabul edilebilmektedir. Tecrübe edilen vücut pozisyonlarını, içinde yer alan Beyin Omurilik Sıvısını (BOS) da hesaba katarak incelemek pozisyonun etkilerini anlamak için önemlidir. BOS' un ve beyin yapısının pozisyona bağlı şekilde konumlanmasının neden olabileceği bilişsel süreçlerin yapısını incelemek en basit ifade ile karmaşık olarak tanımlayabileceğimiz beyin süreçlerinin anlaşılmasına katkı sağlar niteliktedir.

Gün içinde tecrübe edilen dik oturma pozisyonu esnasında hidrostatik gradyan vücut içindeki sıvıyı ayaklara doğru çekmektedir. Aksine sırtüstü yatar pozisyonda, genellikle gece uyurken vücut sıvısı baş kısma doğru hareket etmektedir. Vücut içinde ve bölgesel basınçta yaşanan günlük dalgalanmalara neden olan faktör yerçekimi etkisi olarak bilinmektedir (Iatridis, 1987; Lawley ve ark., 2017). Yerçekimi, tek hücreli formlardan insanlara kadar tüm organizmalar tarafından algılanmakta olup uzaydaki oryantasyonun belirlenmesinde ve duruşun kontrol edilmesinde önemli bir yere sahiptir. Yeryüzü koşullarında, intrakraniyal hipotansiyon (Ducros ve Biousse, 2015) gibi bazı patolojik durumlar dışında vücut içindeki sıvı ve bölgesel basınçta yaşanan dalgalanmalar göz ardı edilebilmektedir. Fakat uzun yatak istirahati, parabolik uçuş, Uzay ve Ay koşulu gibi şartlarda mikro çekime maruz kalmanın vücut ve özellikle beyin fonksiyonlarında önemli değişikliklere neden olduğu düşünülmektedir (Schneider ve ark., 2013; Borghini ve ark., 2014; Wollseiffen ve ark., 2016). Literatürde mikro yerçekiminin insan; kas, iskelet, kalp damar sistemi üzerine etkisi ile ilgili yapılmış çalışmaların yanı sıra merkezi sinir sistemi (MSS) aktivitesinin de nasıl etkilediğini araştıran çalışmalar mevcuttur (Marušič ve ark., 2014). Mikro çekimin sensorimotor sistemler üzerine etkisi ve mikro çekime maruz kalan astronotların duruş kontrolü, lokomasyon ve manuel kontrol ile ilgili yaşadıkları zorluklar açık bir şekilde rapor edilmekte (Lackner ve DiZio, 1996) olmasına rağmen bilişsel sürece olan etkisi konusunda ortak bir fikre ulaşılmamıştır (Strangman ve Bevan, 2013). Son on yılda nörogörüntüleme ve bilişsel sinirbilim alanında teknolojik ilerlemenin istikrarlı bir şekilde geliştiği gözlemlenmektedir. Nörogörüntüleme alanındaki gelişim; algı, biliş ve karmaşık diğer insan görevlerinin nöral devreleri

arkasındaki ilişkiyi ve fizyolojik fenomenleri daha ayrıntılı şekilde incelenebilir kılınmaktadır. Aynı zamanda nörofizyolojik sinyallerin, insan zihninde olup bitenlere erişim için bir nevi arayüz oluşturduğu da bilinmektedir. Nörogörüntüleme cihazlarından biri olan elektroensafolografi (EEG), beyin sinyallerinin yüksek zamansal çözünürlükle elde edilmesine olanak tanımaktadır. EEG'den ölçülen beyin sinyalleri temelde; delta (1-3 Hz), teta (4-7 Hz), alfa (8-13 Hz), beta (14-30 Hz) ve gamma (31-80 Hz) olarak frekans bantlarına ayrılmaktadır (Siuly ve ark., 2016). Literatürde farklı mikro çekimlerde yapılan EEG çalışmaları incelendiğinde, Chéron ve arkadaşları (2006), sensorimotor, parieto-okspital alanın yerçekiminden etkilenen ortak bir örüntüye sahip olduğunu ileri sürmüş ve alfa, mu ritimlerinin, yerçekimine bağlı duysal girdilerin azalmasıyla bağlantılı olabileceği sonucuna varmıştır. Pletser ve Quadens (2003) ise parabolik uçuş sırasında değişen yerçekimi koşullarında görülen beyin elektrokortikal aktivite değişikliklerinin bireyler arasında oldukça değişken olduğunu bildirmiş: bazı katılımcılar mikro çekim durumuna artan EEG aktivitesiyle cevap verirken, bazı katılımcıların beyin elektrokortikal aktivitesinde azalma olduğu rapor edilmiştir.

EEG' den alınan sinyaller, karmaşıklığı ve öngörülebilirliği zorlu sinyallerdir (Elbert ve ark., 1994; Pritchard ve ark., 1995; Natarajan ve ark., 2004) ve bunun yanı sıra farklı zihinsel durumlar farklı motiflere sahiptir. EEG sinyallerinden, zihinsel içerik bilgisinin nasıl ve ne şekilde anlaşılacağı ise önemli bir sorudur (Zhiwei ve Minfen, 2007). Beyin sinyallerinin karakteristiğinden ötürü EEG zaman serisi sinyal analizinde entropi hesaplanmak araştırmacılar için alternatif bir çözüm olmuş durumdadır (Wang ve ark., 2018). 1949'da Claude E. Shannon tarafından öne sürülen entropi kavramı sinyal bileşenlerinin dağılımını tanımlamak için bilgi teorisine dahil edilmiştir. Temelde entropi, rastgelelik ve öngörülebilirliği ele alan bir kavramdır ve daha yüksek entropi genellikle daha yüksek rastgelelik ve daha az sistem düzeni ile ilişkilendirilmektedir (Abásolo, 2006). Araştırmacılar birçok entropi algoritması kullanmaktadır. Bunlardan bazıları; yaklaşık entropi (Approximate entropi, ApEn) ve Sample entropi (SampEn) şeklindedir.

Sinyal entropi deęerinin hesaplanması ise makine öğrenimi yöntemi için öznelilik deęeri taşımaktadır (Thul, 2016). Literatürde yer alan Doğrusal Diskriminant Analiz, Karar Ağacı Algoritmaları ve Destek Vektör Makineleri gibi makine öğrenimi yöntemleri (Craik ve ark., 2019) kullanılarak beyin sinyalleri iletiye ya da komuta çevrilebilir veya farklı zihinsel süreçlerin sınıflandırılması gerçekleştirilmektedir.

Bu doğrultuda mevcut çalışma, Ay yerçekimi analogu ve Dünya yerçekimi pozisyonunda, cimmastik ve sedanter katılımcıların zihinden çıkarma ve göz kapalı görevlerini gerçekleştirdiğı esnada ölçülen EEG sinyallerine Yaklaşık entropi uygulayarak; pozisyonun (Dünya-Ay), katılımcıların (cimmastik-sedanter) ve görevlerin (göz kapalı- çıkarma) sınıflandırılması amaçlanmıştır.

Çalışma kapsamında ele alınan hipotezler aşağıda sunulmaktadır.

1. Cimmastik sporcuları ve sedanter bireyler, çıkarma görevi sırasında 250, 500, 750, 1000, 1500, 2000, 3000 ve 4000 ms lik pencerelenmiş EEG sinyalleri ile ayırmsanabilir.
2. Cimmastik sporcuları ve sedanter bireyler, göz kapalı görevi sırasında 250, 500, 750, 1000, 1500, 2000, 3000 ve 4000 ms lik pencerelenmiş EEG sinyalleri ile ayırmsanabilir.
3. Çıkarma görevi sırasında katılımcılardan ölçülen 250, 500, 750, 1000, 1500, 2000, 3000 ve 4000 ms lik pencerelenmiş EEG sinyalleri ile katılımcıların dünya koşulunda mı yoksa ay koşulunda mı olduğunu ayırmsayabilir.
4. Göz kapalı görevi sırasında katılımcılardan ölçülen 250, 500, 750, 1000, 1500, 2000, 3000 ve 4000 ms lik pencerelenmiş EEG sinyalleri ile katılımcıların dünya koşulunda mı yoksa ay koşulunda mı olduğunu ayırmsayabilir.

2. GENEL BİLGİLER

2.1. Cimnastik

Uzun bir tarihe sahip olan cimnastik eski İndus, Yunan ve Mısır Uygarlıklarına kadar uzanmaktadır. Branşın ilk örnekleri; yeryüzünde insanların topluluk halinde yaşamaya başladığı ilk çağlarda tanrılar ile daha yakın olma amacı ve onlara adaklar sundukları törenlerde görülmektedir (Morpa Spor Ansk., 1997).

Dünyadaki popüler spor branşlarından biri olan cimnastik sporunda sporculardan, mücadele etmesi zor hareketlerin hatasız, mükemmele yakın, akıcı olacak şekilde müzik eşliğinde tamamlanması istenmektedir. Noble'a göre, cimnastik faaliyetlerine erken yaşta katılımdan kaynaklanan pek çok fayda mevcuttur, bunlar: görsel algıyı geliştirmek, lokomotor beceriler yoluyla el-göz koordinasyonu geliştirmek; vücudun her iki tarafını uyum içinde kullanarak vücut pozisyonlarını ve hareketlerini öğrenmek; dengeyi korumak ve nihayetinde normal nöromüsküler işlevi üretmek için kişinin kendi ağırlığını yönetmeyi öğrenmesi şeklindedir (Noble, 1983; Fotiadou ve ark., 2002).

2.2. Sinir Sistemi Fizyolojisi

Sinir sistemi, merkezi sinir sistemi (MSS) ve periferik sinir sistemi (PSS) olmak üzere iki bölümden oluşmaktadır. MSS, beyin ve omurilikten meydana gelmekte olup hem fiziksel olarak sinir sisteminin çekirdeği olduğu hem de davranışa aracılık eden çekirdek bir yapıya sahip olduğu için "merkezi" olarak tanımlanmaktadır.

Beyin ve omuriliğin dışına yayılan tüm sinir yolları ve tüm nöronlar ise PSS'i meydana getirmektedir. PSS, otonom ve somatik sinir sistemi olacak şekilde iki başlık altında incelenmektedir

PSS' deki kapsamlı duyu nöronları ağı, MSS için duyuşsal bilgi toplamak üzere vücudun yüzeyindeki reseptörlere, iç organlara ve kaslara bağlanmaktadır. PSS, çevreden gelen uyarıların algılayan ve ardından afferent sinirler topluluğu aracılığı ile MSS'ne ileten bir yapıya sahiptir (Squire ve ark., 2012). PSS' deki efferent sinirler ise somatik sinir sistemi aracılığı ile MSS' den yüz, vücut ve uzuvların kaslarını hareket ettirmek için bilgi taşımak ile görevlidir. PSS' nin diğer bir parçası olan otonom sinir

sistemi vücut iç organlarının işleyişi, kalbin çarpması, mide kasılması gibi otonomik fonksiyonları yönetmektedir (Kolb ve ark., 2001; Guyton ve Hall, 2008).

2.2.1. Serebral Korteks

Beyin dıştan içe doğru incelenmek istenildiğinde ilk karşımıza çıkan beyin zarıdır. Zarın altında beyin yüzeyini saran kan damarları mevcuttur. Beynin yüzey kısmı nöronların gri renkli çekirdeklerinden meydana gelmektedir ve bu nedenle gri madde adını almaktadır. Bu sinir hücreleri 2mm derinde bulunmakta olup kıvrımlardan meydana gelir ve serebral korteksi oluşturmaktadır. Kıvrımlı yapının üste kalan kısmı girus, kıvrımlar arasında kalan kısım ise sulkus olarak bilinmektedir. Beyin parçalara ayrılıp incelendiğinde iç kısmının beyaz liflerden oluştuğu görülmektedir. Bu kısma ak madde (beyaz madde) denilmektedir. Daha derinlerde ise korteks altı yapılar mevcuttur. Beynin merkez kısmında omuriliği de dolaşan ve içerisinde beyin omurilik sıvısı bulunduran ventriküller yer almaktadır (Greesnstein ve Greenstein, 2000).

Beyin bir başka açıdan incelendiğinde, sağ ve sol yarımküre olmak üzere iki bölümden oluştuğu bilinmektedir. İki yarım küre birbirinin neredeyse yapısal olarak kopyası olmasına rağmen büyüklük ve fonksiyon bakımından farklılaştığını görülmektedir. İki yarımküre birbirine büyük sinir lif demeti ile bağlıdır ve bu sinir lif demeti korpus kallosum olarak isimlendirilmektedir. Nöroanatomik olarak beyni incelemek istediğimizde ise her bir yarımküreyi dört temel parça altında incelemek mümkündür; frontal lob (kafatasının ön kemiği altında), parietal lob (kafatasının üst kısmındaki parietal kemiğin altında, frontal lobun arkasında ve temporal lobun üzerinde), temporal lob (kafatasının yan tarafındaki temporal kemiğin altında) ve oksipital lob (oksipital kemiğin altında ve yarım kürenin arkasında).

En büyük lob olarak bilinen frontal alan, düşüncelerin ve davranışların sıralamasında, akıl yürütmede, istemli hareketlerin planlanması ve problem çözme gibi davranışların yürütülmesinde rol oynamaktadır. Temporal alan, kulaktan gelen bilginin duyulması ve anlaşılmasında etkilidir. Ek olarak görsel belleğin zihinde oturtulmasında ve alınan görsel bilginin daha önceden bilinip bilinmediğinin kararının verilmesine olanak tanımaktadır. Parietal alan, uzaydaki konum ile ilgili bilginin sağlandığı kısım olarak bilinmektedir. Parietal alanın ön kısmında bulunan girus duyuusal bölge, bedenin farklı bölgelerinin (örneğin başparmak) duyu bilgisinin alındığı ve her farklı bölge için

değişik büyüklüklerde temsiline yer aldığı beyin bölgesidir. Oksipital alan ise gözden gelen ya da hayal etme sırasında zihinden gelen görsel imgeyi işlemektedir (Kolb ve Whishaw, 2009).

2.2.2. Nöronlar

Vücudun diğer tüm organları gibi beyin de çeşitli şekil ve boyutta milyarlarca hücreden meydana gelmektedir. Beyin hücreleri nöron (sinir hücresi) olarak isimlendirilmektedir. Bir beyin yapısının yaklaşık 100 milyar kadar nöron ve nöronların yaklaşık 10-15 katı kadar glial hücreye sahip olduğu düşünülmektedir. Nöronlar arasındaki iletişim elektrik sinyali ile sağlanmakta olup nöronların en büyük görevi aksiyon potansiyeli oluşturarak bunu iletmektir (Kolb ve ark., 2001; Noback ve ark., 2005; Mai ve Paxinos, 2011). Glial hücreler ise sistemin sabit tutulmasına ve nöronların beslenmesine yardımcı olmaktadır. Fakat glial hücrelerin aksiyon potansiyelinde herhangi bir etkinliğinin olmadığı düşünülmektedir.

Nöron yapıları farklı türlerde görülebilmektedir. Bunlar şu şekilde sıralanabilir; Unipolar Nöron: Hücre gövdesinden uzanan tek aksona sahip, Bipolar Nöron: Hücre gövdesinden çıkan iki uzantısı karşıt kutuplara giden nöronlar, Multipolar Nöron: Hücre gövdesinden çıkan tek bir aksona ve çok sayıda dendrite sahip, Piramidal Nöron: Hücre gövdesi üçgensel bir yapıya sahip, adını şeklinden almış ve bir aksonu ve büyük bir dendrit yapısı vardır. (Carter, 2019).

Bunun yanı sıra temel nöron yapısını incelediğimizde dört ana bölgeden söz etmek mümkündür. Çekirdeği içeren hücre gövdesi (soma olarak da bilinir), hücre gövdesine bağlı diğer nöronlardan gelen sinyalin alındığı dallı yapıya sahip dendrit, nöronun kuyruğu olarak düşünülebilen elektrik sinyalinin yol aldığı akson ve başka dendritlere veya başka bir dokuya, kasa bağlanan, mesajların iletildiği akson uçlarından oluşmaktadır. Aksonlar kendi arasında miyelin kılıflı ve miyelin kılıfsız olarak ikiye ayrılmaktadır. Miyelin kılıf, yağlı ve yalıtkan bir yapıya sahiptir. Fakat miyelin kılıf aksonu boydan boya değil arada ufak boşluklar kalacak şekilde sarmaktadır. Arada yer alan bu boşluklara ranvier boğumu adı verilmektedir. Ranvier boğumları ile kesintili oluşumlar şeklinde çevrelenmiş olan miyelin kılıfın iki önemli görevi bulunmaktadır; Aksiyon potansiyelinin akson boyunca hızlı bir şekilde (atlayarak) iletilmesini

sağlamak ve aksonun çevre nöronların elektriğinden etkilenmesini önlemektir (yapıyı izole etmek).


Yunanca "birlikte kenetlenmek" anlamına gelen sinapslar ise, bir nöronun diğeriyle iletişim kurduğu temas noktalarıdır. Fakat bu fiziksel bir temas noktası değildir. Çünkü nöronlar fiziksel temas halinde değildir, aralarında sinaptik boşluk olarak isimlendirilen ince bir boşlukla birbirlerinden ayrılmaktadır ve nöronlar arasında 200'den 200.000'e kadar değişebilen sinaps alanı bulunduğu tahmin edilmektedir. Nöronlar arasındaki iletimler çoğunlukla aksondan dendrite doğru gerçekleşmekte olup bu özellik bilgi aktarımının sağlanması ve sinyalin istenilen işlevi yerine getirmesi için tek yönlü iletim sağlamaktadır (Karakaş, 2008)

2.2.3 Aksiyon Potansiyeli ve Ölçülmesi

Sodyum ve potasyum hareketlerine duyarlı kanalların açılıp kapanması sırasında yaşanan ani değişimler, aksiyon potansiyelinin temelini oluşturmaktadır. Hücre içi ve dışının voltaj bakımından farklı potansiyellere sahip olduğu bilinmektedir. Bu voltaj farklılığının temel sebebi ise sodyum ve potasyum iyonlarıdır. Hücre içi dinlenme durumunda hem sodyum hem de potasyum iyonu içermesine rağmen potasyum iyonu hücre içinde daha fazla bulunmaktadır. Hücre içi ve hücre dışı arasındaki elektriksel fark yaklaşık -70mV olup, elektriksel yük membran potansiyeli olarak isimlendirilmektedir. Hücre içinin dışına göre negatif olduğu dinlenme durumu polarizasyon olarak bilinmektedir. Bir aksonun membranı üzerinde çok sayıda voltaj kapılı iyon kanalları bulunmaktadır. Bu kapılar polarize durumda kapalıdır. Membran potansiyeli eşik değerinin (yaklaşık -50mV) üzerine çıktığında yani buna sebebiyet verecek bir uyarı ile karşılaştığında ise iyon kanallarının birçoğu açılmaktadır. Kanalların açılması ile sodyum iyonu hücre içine akmaktadır (difüzyon kuralı gereği). Hücre içi ve dışı arasındaki elektrik potansiyel farkının azaldığı ve yaklaşık $+30\text{mV}$ 'a ulaştığı durum ise depolarizasyon olarak isimlendirilmektedir. Sodyum kapılarının kapanıp potasyum kapılarının açılması ile pozitif yüklü iyonlar yavaşça hücre dışına akmaya başlamaktadır. Hücre içinin yeniden negatif yüklü olması durumuna repolarizasyon denilmektedir. Bu süreçte hücre içi ve dışı elektriksel fark başlangıç noktasından daha fazla olmaktadır. Bunun nedeni potasyum kapılarının geç

kapanmasından kaynaklanmaktadır. Bu süreçten sonra hücre yeniden dinlenme durumuna geçmekte yani polarize olmaktadır (Barker ve ark., 2017).

Sodyum ve potasyum kanallarının kapılarındaki dinamik değişiklikler, aksiyon potansiyelinin önemli bir özelliği olan refrakter döneminin temelini oluşturmaktadır. Refrakter dönem, akson membranı, aksiyon potansiyelinin depolarize veya repolarize etme fazı sırasında uyarılırsa, sodyum kapıları duyarsız olduğu ve yeni bir aksiyon potansiyeline cevap veremediği durum olarak tanımlanmaktadır. Öte yandan, akson zarı hiperpolarizasyon fazı sırasında uyarılırsa, yeni bir aksiyon potansiyeli indüklenebilir, ancak sadece uyarının yoğunluğu, ilk aksiyon potansiyelini başlatandan daha yüksek olması şartı ile bu durum meydana gelebilmektedir. Bu aşamada, zar 'nispeten refrakter' olarak tanımlanmaktadır. Refrakter dönemler, aksiyon potansiyellerinin oluşma sıklığını sınırlayan bir özelliktir. Bu nedenle, nöronda başka bir aksiyon potansiyeli ortaya çıkmadan önce dinlenme potansiyeline geri dönmeli ve aksiyon potansiyellerini ayrı olaylar haline getirmelidir (Kolb ve ark., 2001).




Şekil 1. Membran potansiyelinin değişimi (Ka Xiong Charand, 2016
<http://hyperphysics.phy-astr.gsu.edu/hbase/Biology/actpot.html>)


Kortekse dik gelen piramidal hücrelerin meydana getirdiği post sinaptik potansiyellerin kafa derisinde oluşturduğu bileşke EEG ile gözlemlenebilmektedir. Bir nöronun ateşlenmesiyle iyon bazında başlayarak meydana gelen değişiklikler bir nöron grubunu etkileyen senkronize yanıtı neden olduğunda oluşan elektriksel etkiler EEG aracılığıyla kaydedilebilmektedir (Sieu ve ark., 2015). Kaynak olarak milyarlarca nöronun hareketi ile oluşan insan EEG potansiyeli; aralıklı salınım patlamaları, periyodik olmayan ve öngörülemeyen salınımlar olarak da ifade edilebilir.

İnsan beynindeki elektriksel potansiyelin ölçümü ilk kez nöropsikiyatr Hans Berger'in 1924' te başlattığı çalışmalar sonucunda gerçekleşmiştir. Fakat beyindeki elektriksel sinyalin ilk ölçümü, 1895'te Richard Caton'un hayvan denekler üzerinde yaptığı çalışmalara dayanmaktadır (Collura 1993).

EEG zamansal olarak farklı (ör. 1000) örnekleme frekansına sahip olabilmektedir. Frekans, ritmik olarak tekrarlayan aktiviteyi ifade etmekte ve saniyedeki döngü sayısı frekans olarak bilinmektedir. Sağlıklı yetişkinlerde, bu tür sinyallerin genlikleri ve frekansları bir durumdan diğerine, örneğin uyanıklık ve uyku gibi durumlarda değişebilmektedir. EEG sinyalinin genliği, normal bir yetişkinde tipik olarak yaklaşık 1-100 μ V arasında değişir ve iğne elektrotlar gibi subdural elektrotlarla ölçüldüğünde yaklaşık 10-20 mV'dir. Beyinden ölçülen frekans farklı aralıklarla ayırt edilen beş ana banda sahiptir. Bu frekans bantları, sırası ile: 0.5-4 Hz (delta, δ), 4-8 Hz (teta, θ), 8-13 Hz (alfa, α), 14-30 Hz (beta, β) ve 30 Hz üstü (gama, γ) şeklindedir. EEG sinyallerinde gözlemlenen farklı frekanslar, genetik etkenler, yaş, cinsiyet, uykusuzluk, matematiksel işlem çözme, okuma veya uyanıklık gibi birçok değişkenden etkilenmektedir (Kaiser, 2007).



Şekil 2. Normal EEG sinyalinde görülen farklı frekanslara sahip dalgalar (Siuly ve ark., 2016)



Şekil 3. Normal, kısmi nöbet, jenaralize nöbet EEG paterni (Siuly, 2016)

2.3. Zihinsel İş Yüğü

Zihinsel iş yüğü kavramı için kesin bir tanımdan söz etmek zordur ancak son on yıl içinde kavram ile ilgili çeşitli tanımlar yapılmıştır: (Gopher ve Donchin, 1986; Hart ve ark., 1988; Eggemeier ve ark., 1991; Cain, 2007; Babiloni, 2019) Araştırmacılar kavramı; bir veya daha fazla görevi yerine getirirken, bir bireyin zihinsel katılım ve çaba düzeyini yansıtan karmaşık bir yapı olarak ele almaktadır. Çevrenin acil taleplerinin ve bir bireyin maksimum zihinsel kapasitesinin ürünü olarak da düşünülebilmektedir. Bu nedenle zihinsel iş yüğü, yalnızca talep edilen görev kaynaklarına değil, aynı zamanda mevcut olanlara da bağlı olan çok faktörlü bir yapıdır (Muñoz-de-Escalona ve Cañas, 2019).

Çevrenin veya görevin talepleri bir kişinin zihinsel kapasitesini zorladığında, zihinsel aşırı yük meydana gelir ve sınırlı kapasitemizin bir sonucu olarak performans kötüleşir (Durantin ve ark., 2014). Bunun nedeni, insan zihinsel kaynaklarının tam sınırına geldiğinde, bu kaynakları uyarlanabilir bir şekilde yeniden tahsis edememekten kaynaklanmaktadır. Aksine, otomatikleştirilmiş çalışma durumlarında yani görevin çok az talep gerektirdiği durumlarda, zihinsel yük yetersizliği oluşur ve aşırı zihinsel yük durumundaki performansa benzer şekilde bozulmalar yaşanır. Düşük çevresel taleplerin neden bu şekilde sonuç verdiği tam olarak anlaşılamamıştır, ancak araştırmacılar bunun çevresel talebin azaltılmasına yanıt olarak maksimum zihinsel kapasitemizdeki daralmalardan kaynaklanabileceğini öne sürmüştür (Young ve Stanton, 2002); bu da tetikte olma, iş yüğü, dikkat ve durum farkındalığı gibi çeşitli faktörleri etkileyebilmektedir (Endsley, 2017; Muñoz-de-Escalona ve Cañas, 2019). Aşağıda geçmişten günümüze zihinsel iş yüküne ait bazı tanımlar mevcuttur:

- "Zihinsel iş yüğü, bir görevi gerçekleştirmek için gereken bilişsel kaynakların operatör tarafından ne ölçüde aktif olarak devreye sokulduğunu açıklayan varsayımsal bir yapıdır" (Gopher ve Donchin, 1986)
- "İş yüğü, içsel bir özellik değildir, daha ziyade bir görevin gereksinimleri, gerçekleştirildiği koşullar ve operatörün becerileri, davranışları ve algıları arasındaki etkileşimden ortaya çıkar" (Hart ve Staveland, 1988)

- "Zihinsel iş yükü, operatör bilgi işleme kapasitesinin veya kaynaklarının sistem taleplerini karşılamak için gerçekten gerekli olan kısmını ifade eder" (Eggemeier ve ark., 1991)
- "Zihinsel iş yükünü belirlemenin ve değerlendirmenin nedenleri, operatör ve sistem performansını tahmin etmek için görev performansı sırasında ortaya çıkan zihinsel maliyeti ölçmektir" (Cain, 2007).

2.4. Sinir Sistemi Aktivitesinin Sınıflandırılması

2.4.1 Entropi

İlk kez 1867’de Rudolf Clausius tarafından termodinamik alanında önerilen entropi kavramı, gazlı veya akışkan sistem moleküllerinin dağılım olasılığını tanımlamaktadır. Ardından 1949’da Claude E. Shannon tarafından, sinyal bileşenlerinin dağılımını tanımlamak için entropi bilgi teorisine dahil edilmiştir (Shannon, 1949). Yüksek entropi, çok sayıda süreçten kaynaklanırken, düşük entropinin, zaman serilerini oluşturan az sayıda hâkim süreçten kaynaklandığı bilinmektedir. Örneğin rastgele dağıtılan gürültü, yüksek entropi değerlerine sahiptir. Aksine, sinüzoidler gibi düzenli hareketler düşük entropi değerleri içerdiği bilinmektedir (Rezek ve Roberts, 1998).

EEG aktivitesini hesaplamak için birçok entropi algoritması öne sürülmektedir. Bunlardan bazıları şu şekildedir: Spektral Entropi [Response Entropi (RE) ve State Entropiyi (SE)], Approximate entropi (ApEn), Sample entropi (SampEn), Fuzzy entropy (FuzzyEn), Shannon Permutation entropi (SPE), Shannon Wavelet entropi (SWE) ve Hilbert-Huang spectral entropi (HHSE) (Zhang ve ark., 2013; Richman ve Moorman, 2000).

2.4.1.1 Yaklaşık Entropi (Approximate Entropy, ApEn)

Yaklaşık Entropi, Pincus tarafından "sistem karmaşıklığının" bir ölçüsü olarak geliştirilmiştir. Yüksek bir ApEn değeri rastgele ve öngörülemeyen değişimi gösterirken, düşük ApEn değeri, bir zaman serisindeki düzenliliği ve öngörülebilirliği temsil etmektedir (Pincus, 1991; Burioka, 2005). Özellikle ApEn, doğrusal olmayan deterministik, stokastik ve gürültülü sistemler dahil olmak üzere çok çeşitli sistemleri

ayırt edebilir ve orta ölçekli zaman serilerine uygulanabilmektedir. Yaklaşık entropi hesaplamak için, $\{p(n)\} = p(1), p(2), \dots, p(N)$, şeklindeki zaman serilerindeki N veri noktası, iki girdi parametresi m ve r , ApEn'i hesaplamak için gerekli olan sabitlerdir. ApEn (m, r, N) olarak gösterilmektedir (Abásolo ve ark., 2006). ApEn değerini tahmin etmek için,

$$X(i) = [x(i), x(i + 1), \dots, x(i + m - 1)], i = 1 \sim N - m + 1$$

Bu vektörler, i noktasından başlayarak m ardışık x değerini temsil eder. $X(i)$ ve $X(j)$, $d[X(i), X(j)]$, arasındaki mesafe maksimum mutlak fark olarak tanımlanır. Belirli bir $X(i)$ için $j = 1 \sim N - m + 1, j \neq i$ sayısını sayılır, böylece $d[X(i), X(j)] \leq r$, $N^m(i)$ olarak gösterilir. Ardından $i = 1 \sim N - m + 1$ için $C_r^m(i) = \frac{N^m(i)}{N - m + 1}$ hesaplanır.

2.4.2 Makine Öğrenimi

Verilerdeki örüntüleri tanıma problemi temel bir sorun olmakla birlikte, uzun ve başarılı bir geçmişe sahiptir. Örüntü tanıma alanı, bilgisayar algoritmalarının kullanılması yoluyla verilerdeki düzenin veya sürekliliğin otomatik olarak keşfedilmesi ve bu düzenliliğin, verileri farklı kategorilere sınıflandırma sürecinde kullanılması ile ilişkilidir. Eğer el yazısı rakamlarını tanıma örneğini düşünülürse, her rakam 28×28 piksellik bir görüntüye karşılık gelir ve 784 gerçek sayı içeren bir x vektörü ile temsil edilir. Amaç, böyle bir x vektörünü girdi olarak alacak ve çıktı olarak $0, \dots, 9$ rakamlarının kimliğini sunacak bir makine inşa etmektir.

Uyarlanabilir bir modelin parametrelerini ayarlamak için eğitim seti olarak adlandırılan büyük bir N rakam kümesinin $\{x_1, \dots, x_N\}$ kullanıldığı bir makine öğrenimi yaklaşımı benimseyerek daha iyi sonuçlar elde edilebilmektedir. Eğitim setindeki rakamların kategorileri, önceden tipik olarak ayrı ayrı incelenerek ve elle etiketlenerek bilinmektedir. Karşılık gelen rakamın kimliğini temsil eden hedef vektör t 'yi kullanarak bir rakam kategorisi ifade edilir ve her rakam görüntüsü x için böyle bir hedef vektör t ye sahip olduğunun bilinmesi önemlidir. Makine öğrenimi algoritmasının çalıştırılmasının sonucu, girdi olarak yeni bir rakam görüntüsü x olan ve hedef vektörlerle aynı şekilde kodlanmış çıktı vektörü y üreten bir fonksiyon $y(x)$ olarak ifade edilebilir. $Y(x)$ işlevi, öğrenme aşaması olarak da bilinen eğitim

aşamasında belirlenir. Model eğitildikten sonra; sistem, bir test seti içeriği olan yeni rakam görüntülerinin kimliğini belirleyebilmek için göreve başlamaktadır.

Sınıflandırma iki ana bölümden meydana gelmektedir bunlar: denetimli sınıflandırma ve denetimsiz sınıflandırmadır (Siuly ve ark., 2016). Denetimli sınıflandırmada, bir dizi verinin gözlemleri sınıf etiketleriyle ilişkilendirilmektedir. Denetimsiz sınıflandırmada gözlemler etiketlenmemekte veya bilinen bir sınıfa atanmamaktadır (Jain ve ark., 2000). Sınıflandırma algoritmalarının çoğu, veri kümesi hakkında bazı bilgiler içeren bir grup veri ile ilgilenir. Başka bir deyişle, sınıf etiketi bilgisi, sınıflandırıcıyı eğitmek için veri seti içinde verilir. Bu sınıflandırma türü, bir denetçinin sınıflandırma modelinin inşası sırasında sınıflandırıcıya talimat verdiği denetimli öğrenmeye aittir.


Denetlenen prosedür, doğru çıktıyla elle uygun şekilde etiketlenmiş bir dizi örnekten oluşan bir dizi eğitim verisinin (eğitim seti) sağlandığını varsayar (Duda ve ark., 2001; Brunelli 2009). Denetimsiz sınıflandırma prosedürü, bazı doğal yetenek ölçülerine (örneğin, çok boyutlu bir vektör uzayında vektörler olarak kabul edilen örnekler arasındaki mesafe) dayalı olarak verilerin sınıflar halinde gruplandırılmasını içerir. Bu prosedür, eğitim verilerinin elle etiketlenmediğini varsayar ve verilerde daha sonra yeni veri örnekleri için doğru çıktı değerini belirlemek için kullanılabilecek içsel kalıplar bulmaya çalışır (Duda ve ark., 2001). Denetimsiz öğrenmede, küçük bir veri kümesi için bile ölçümlerin sınıf etiketleri hakkında herhangi bir bilgi mevcut değildir.

2.4.3 K-Katlamalı (Fold) Çapraz Doğrulama Yapısı

Çapraz doğrulama, analizin sonuçlarını değerlendirmek için bir model doğrulama tekniğidir. Genellikle bir tahmin modelinin pratikte ne kadar doğru performans göstereceğini tahmin etmek şeklinde bir yapıya sahiptir. Çapraz doğrulama süreci, verilerin alt kümelerine bölünmesini, analizin bir alt kümede (eğitim kümesi olarak adlandırılır) gerçekleştirilmesini ve diğer alt kümede (doğrulama kümesi veya test kümesi olarak adlandırılır) analizin doğrulanmasını içermektedir. Değişkenliği azaltmak için, farklı bölümler kullanılarak çoklu çapraz doğrulama turları gerçekleştirilmektedir ve doğrulama sonuçlarının ortalamaları turlarda alınmaktadır. K-katlamalı (fold) çapraz doğrulamada, bir veri seti, yaklaşık olarak eşit büyüklükte k

tane alt kümeye bölünmektedir ve yöntem k kez (katlar) tekrarlanmaktadır (Ryali ve ark., 2010; Siuly ve Li 2012). Her seferinde, alt kümelerden biri bir test seti olarak kullanılır ve diğer k alt grupları bir eğitim seti oluşturmak için bir araya getirilir.

Daha sonra tüm k denemelerindeki ortalama doğruluk hesaplanır. Şekil 4' de, bu öznitelik vektörlerinin k -katlamalı (fold) çapraz doğrulama sistemine göre k alt kümeye nasıl bölündüğü gösterilmektedir. Şekil 4 'de gösterildiği gibi, özellik vektör seti k alt gruba bölünür ve prosedür k kez (katlar) tekrarlanır. Her seferinde, bir alt küme bir test seti olarak kullanılır ve kalan dokuz alt küme, şekilde gösterildiği gibi bir eğitim seti olarak kullanılır. Test setindeki her k zamanın sonuçlarının ortalaması, "k-katlamalı çapraz doğrulama performansı" adı verilen yinelemeler üzerinden alınır. Geleneksel doğrulamayı (örneğin, veri setini eğitim için %70 ve test için %30 olmak üzere iki sete bölmek), kullanmak yerine çapraz doğrulama kullanmanın ana nedenlerinden biri modelleme veya test kabiliyetini kaybetmeden ayrı eğitim ve test kümelerine ayırmak için yeterli veri bulunmamasıdır.



Şekil 4. K-katmanlı çapraz doğrulama yapısı (Siuly ve ark., 2016)

2.4.4. EEG Sinyal Sınıflandırması


EEG sinyallerinin sınıflandırılması, beyin hastalıklarının teşhisinde ve bilişsel süreçlerin daha iyi anlaşılmasına katkıda bulunmak açısından önemlidir. Etkili bir sınıflandırma tekniği, bir kişinin sağlığına ilişkin karar vermede EEG segmentlerinin ayırt edilmesine yardımcı olur. EEG kayıtları büyük miktarda veri içerdiğinden; önemli bir problem, kaydedilen EEG sinyallerinin, sınıflandırma gibi daha ileri

analizler için nasıl temsil edileceğidir. Öncelikle, işlenmemiş EEG sinyallerinden gerekli özelliklerin çıkarılması ve ardından çıkarılan özelliklerin sınıflandırma için kullanılması önemlidir.

Makine öğreniminde ve örüntü tanımada, sınıflandırma, belirli bir girdi verisi parçasını verilen kategorilerden birine atamak için bir algoritma prosedürünü ifade eder (Brunelli, 2009). EEG yoluyla beyin aktivitesinin ölçülmesi, büyük miktarda verinin alınmasına yol açar.

Mümkün olan en iyi performansı elde etmek için, sinyallerin bazı ilgili özelliklerini tanımlayan daha az sayıda değerle çalışmak önemlidir. Bu değerler "öznitelik veya özellik" olarak bilinir. Öznitelikler, genellikle "öznitelik vektörü" olarak bilinen bir vektörde toplanır (Lotte, 2014). Bu nedenle, öznitelik çıkarma, bir veya birkaç sinyali bir öznitelik vektörüne dönüştüren bir işlem olarak tanımlanabilir. Bir modeli tanımlamak için kullanılan tüm özniteliklerin kümesini içeren öznitelik vektörü, bu modelin küçültülmüş boyutlu bir temsilidir.

Sinyal sınıflandırması, bir sinyalin farklı karakteristik özelliklerini analiz etmek anlamına gelir ve bu karakteristik özelliklere dayanarak, sinyalin hangi gruba veya sınıfa ait olduğuna karar vermektedir. Ortaya çıkan sınıflandırma kararı, sinyali oluşturan fiziksel süreç hakkındaki bilgileri ortaya çıkarmak için fiziksel dünyaya geri döndürülebilir.



Şekil 5. EEG sinyali sınıflandırması için blok diyagram

2.4.5. Ön İşleme ve Öznitelik Çıkarımı

Çoğu pratik uygulama, orijinal girdi değişkenlerini, örüntü tanıma probleminin çözülmesinin daha kolay olacağı ön işleme (pre-processing) aşamasına tabii tutmaktadır. Rakam tanıma problemi için rakamların görüntüleri tipik olarak çevrilir ve ölçeklenir, böylece her rakam sabit bir boyutta bir kutu içinde yer alır. Bu, her basamak sınıfındaki değişkenliğin büyük ölçüde azalmasına katkı sağlamaktadır. Çünkü tüm basamakların konumu ve ölçeği aynı olmakta ve bu da sonraki bir örüntü tanıma algoritmasının farklı sınıflar arasında ayırım yapılmasını çok daha kolay hale getirmektedir. Bu ön işleme aşamasına bazen özellik veya öznitelik çıkartma (feature extraction) da denilmektedir. Önemli bir nokta da yeni test verilerinin eğitim verileriyle aynı adımlar kullanılarak önceden işlenmesi gerektiğidir.

Ön işlemenin bir diğer avantajı da hesaplamayı hızlandırmaktır. Örneğin, hedef, yüksek çözünürlüklü bir video akışından gerçek zamanlı yüz algılama sürecini gerçekleştirmek için bilgisayar saniyede çok büyük sayıda piksel bilgisini işlemelidir. Fakat bunları doğrudan karmaşık bir model tanıma algoritmasına sunmak, hesaplama açısından olanaksızla yakın zor olabilmektedir. Bunun yerine amaç, hesaplaması hızlı olan ve yine de yüzlerin yüz olmayanlardan ayırt edilmesini sağlayan kullanışlı, ayırmacı bilgileri koruyan özellikler bulmaktır ve bu özellikler daha sonra model tanıma algoritmasının girdileri olarak kullanılmaktadır. Fakat ön işlemenin hangi titizlikle yapıldığı büyük bir önem arz etmektedir. Çünkü ön işleme sırasında kullanılacak veriler için ayırmacı niteliği sahip bilgiler de önceden budanabilir ve budanan kısım sorunun çözümü için önemliyse, sistemin genel doğruluğu zarar görebilmektedir.

2.4.6. Sınıflandırıcı Algoritmaları

2.4.6.1. K-En Yakın Komşu (K-Nearest Neighbor) Algoritması

K-En Yakın Komşu (K-En) algoritması makine öğrenimi algoritmalarının en basitlerinden biri olarak kabul görmektedir (Qin ve ark., 1967). K-En algoritmasının temel fikri ilk önce her test örneği için k en yakın komşuyu seçmek, ardından bu test örneğini tahmin etmek için öğrenilen K en yakın komşuyu kullanmaktır (Cheng ve

ark., 2014). Eğer $K = 1$ ise, nesne basitçe en yakın komşunun sınıfına atanmakta olup (Han ve ark., 2005) modeldeki tek ayarlanabilir parametre, en yakın komşuların sayısı olan K 'dir. Bu tez çalışması kapsamında K-En için yedi farklı modelde değerlendirildi: (i) Fine K-En: Komşuların sayısı bir olarak ayarlanmıştır, sınıflar arasında ince ayrımlar yapabilen en yakın komşu sınıflandırıcıdır. (ii) Medium K-En: Komşu sayısının 10'a ayarlandığı, Fine K-En'den daha az ayırım yapabilen en yakın komşu sınıflandırıcısıdır. (iii) Coarse K-En: Komşu sayısının 100 olarak ayarlandığı, sınıflar arasında kaba ayırım yapan en yakın komşu sınıflandırıcıdır. (iv) Cosine K-En: Kosinüs mesafe metriğini kullanan en yakın komşu sınıflandırıcıdır. (v) Cubic K-En: Kübik mesafe metriğini kullanan en yakın komşu sınıflandırıcıdır. (vi) Weighted K-En: Mesafe ağırlıklandırmasını kullanan en yakın komşu sınıflandırıcıdır. (vii) Subspace K-En: Her temel K-En sınıflandırıcısı için girdi, özellik vektörünün rastgele seçilen bir alt uzayı olacak şekilde çalışmaktadır (Johnson ve Yadav, 2018; Xing ve ark., 2018; Ferizi ve ark., 2019).

2.4.6.2. Karar Ağacı Algoritması (Decision Tree)

Karar ağaçları, veri madenciliğinde kullanılan en popüler tahmine dayalı öğrenme yöntemlerinden biridir. Kökten yaprağa, her düğümde bir testin (önceki adıma/düğümüne bağlı) gerçekleştirildiği ve dalın sonucu (yaprağa) taşıdığı ağaç benzeri bir tablodur. Bu, örnek uzayın özyinelemeli bir bölümü olarak düşünülebilir. Sunulan çalışmadaki verileri sınıflandırmak için altı farklı karar ağacı sınıflandırıcısı kullanılmıştır: Basit, orta ve kompleks ağaçlar, sırasıyla 4, 20 ve 100 derinliğe ulaşabilmektedir. Bu ağaç modellerine ek olarak “Boosted” yükseltilmiş ağaçlar, çalışma kapsamında uygulanmıştır. Tahmin için tek bir ağaç kullanmak yerine birçok ağacın doğrusal bir kombinasyonu olarak oluşan “Boosted” ağaçlar, tek ağaç modellemenin neredeyse tüm avantajlarını korurken, doğruluklarını da önemli ölçüde artırır. Hataya yol açan tek ağaç modellerinin özelliklerinden biri, sonuçta ortaya çıkan yaklaşımın kaba parçalı sabit doğasıdır. “Boosted” ağaç makinaları, tek tek ağaçların doğrusal kombinasyonları olduğundan, parçalı sabit yaklaşımların bir süper pozisyonunu üretirler. Bunlar elbette parça parça sabittir, ancak daha birçok parçayla birlikte çalışırlar. Karşılık gelen sürekli olmayan sıçramalar çok daha küçüktür ve düzgün hedef işlevlerine daha doğru şekilde yaklaşabilirler (Schapire, 2003; Friedman, 2006).

(v) “Random under-sampling” (RUS)-Boosted, (Rastgele aşağı örneklenmiş güçlendirilmiş) ağaçlar, eğitim veri setinin sınıf dağılımını ayarlayarak sınıf dengesizliği problemini hafifletmeye çalışan bir toplu algoritma ve veri örnekleme tekniğidir. Bu, çoğunluk kategorisinden (örnekleme altında) örneklerin çıkarılmasıyla veya azınlık kategorisine örnekler eklenerek (aşırı tahmin) sağlanmaktadır. En yaygın veri örnekleme tekniklerinden biridir (büyük ölçüde basitliklerinden dolayı) ve daha karmaşık veri örnekleme algoritmalarının aksine, RUS-Boosted, eğitim verisi örneklerini akıllıca kaldırmaya çalışmaz bunun yerine, istenen sınıf dağılımına ulaşılan kadar örnekleri çoğunluk sınıfından rasgele olacak şekilde kaldırarak çalışır (Seiffert ve ark., 2010). (vii) Bagged (torbalanmış) Ağaç, önceden oluşturulmuş bir dizi sınıflandırıcıyı kullanan toplu bir yaklaşımdır. Eğitim verilerinin farklı alt kümelerini seçmek için, birkaç kez görünen birçok örnekle orijinal veri kümesiyle aynı boyutta Bagged ler oluşturulur. Bootstrap olarak bilinen bu süreç, eğitim verilerinin çoğalması ile sonuçlanmaktadır. Bagged genellikle derin ağaçlar inşa eder. Bu yapı çok fazla zaman ve hafıza tüketir. Aynı zamanda nispeten yavaş tahminlere yol açmaktadır (Seiffert ve ark., 2010; Hafez ve arkl., 2018). Karar ağaçlarının, anlaması ve takip etmesi nispeten kolay olmasının yanı sıra, bir başka avantajı da aykırı değerlere ve ilişki düzeyi düşük değerlere karşı bağımsızlıklarının olmasıdır. Bu avantajlar nedeniyle, karar ağacı veri madenciliğinde en popüler araç haline gelmiş durumdadır (Ferizi ve ark., 2019).

2.4.6.3. Doğrusal ve Quadratik Diskriminant Analiz (Linear and Quadratic Discriminant Analysis)

Doğrusal Diskriminant Analizi (DDA) (Fisher’s LDA olarak da bilinmektedir) grup nesneleri için tahmine dayalı bir model oluşturmakta olup farklı sınıfları temsil eden verileri ayırmak için hiper düzlemler kullanmaktadır (Duda ve ark., 2001). Model, tahmin değişkenlerin doğrusal kombinasyonlarına dayanan bir ayırt edici işlevden sunmaktadır. DDA tekniğinin amacı, orijinal veri matrisini daha düşük boyutlu bir alana yansıtmaktır. Bu hedefe ulaşmak için üç adımın gerçekleştirilmesi gerekmektedir: İlk adım, sınıflar arası varyans veya sınıflar arası matris olarak adlandırılan farklı sınıflar arasındaki ayrılabilirliği (yani farklı sınıfların araçları arasındaki mesafeyi) hesaplamaktır. İkinci adım, sınıf içi varyans veya sınıf içi matris

olarak adlandırılan her bir sınıfın ortalaması ve örnekleri arasındaki mesafeyi hesaplamaktır. Üçüncü adım, sınıflar arası varyansı en üst düzeye çıkaran ve sınıf içi varyansı en aza indiren alt boyut uzayı inşa etmektir.

Quadratic diskriminant analizi (QDA), sınıf içi kovaryans matrislerinin sınıflar arasında farklılık göstermesine izin vererek DDA'yı genişletir, böylece ayırım X'in doğrusal fonksiyonlarından ziyade ikinci dereceden temel alınmaktadır (Pardoe ve ark., 2007).


2.4.6.4. Destek Vektör Makinesi (Support Vector Machine)

Destek Vektör Makinesi (DVM), Vapnik tarafından sunulan veri sınıflandırma ve regresyon için güçlü bir istatistiksel makine öğrenme yöntemidir. Metin sınıflandırma, el yazısı, karakter tanıma ve biyolojik veri madenciliği gibi çok çeşitli uygulamalarda diğer öğrenme yöntemlerinin çoğundan daha iyi performans göstermektedir. DVM sınıflandırmasının amacı, iki sınıflandırmayı maksimum olarak ayırabilen yüksek boyutlu bir özellik uzayında en uygun ayırma alt düzlemi bulmaktır (Vapnik, 1995; Mu ve ark., 2017; Zhang ve ark., 2017).

Destek Vektör Makinesi (DVM) kavramını daha iyi anlamak için doğrusal olarak ayrılabilir eğitim örneklerinin iki boyutlu özellik uzayının basit durumu için ikili bir sınıflandırma olarak düşünebiliriz. $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ burada $x \in \mathbb{R}^d$ giriş vektörü ve $y \in \{-1, 1\}$ sınıf etiketidir. Ayırt edici bir işlev şu şekilde tanımlanabilir:


$$f(\mathbf{x}) = \text{sgn}(\langle \mathbf{w}, \mathbf{s} \rangle + b) = +1 \text{ eğer } x \text{ birinci sınıfa ait ise} \bullet \\ -1 \text{ eğer } x \text{ ikinci sınıfa ait ise} \circ$$

Bu formülasyonda w , bir ayırt edici düzlemin (veya hiper düzlemin) yönünü belirler. Açıktır ki, eğitim verilerini doğru şekilde sınıflandırabilecek sonsuz sayıda olası düzlem vardır.



Şekil 6. İki boyutlu ayrılabilir veri kümesi ve ayırıcı düzlem (Sanei ve Chambers, 2013)

Optimal bir sınıflandırıcı, kendisi için en iyi genelleme hiper düzlemin eşit uzaklıkta veya her nokta kümesinden en uzak olduğu hiper düzlemi bulur. Girdi vektörleri kümesinin, hatasız olarak ayrılırlarsa ve en yakın vektör ile hiper düzlem arasındaki mesafe maksimumsa, hiper düzlem ile en uygun şekilde ayrıldığı söylenir. Bu durumda, optimum ayırmayı elde etmek için yalnızca bir hiper düzlem olacaktır (Sanei ve Chambers, 2013)



Şekil 7. Optimal bir ayırıcı düzlem (Sanei ve Chambers, 2013)

DVM yukarıda bahsedildiği gibi iki sınıfı ayıran maksimum aralıklı hiperdüzlemi arayarak doğrusal model oluşturmaya ve iyileştirmeye çalışmaktadır. Fakat sınıfların çakıştığı ve dolayısıyla doğrusal olmayan sınırlar gerektiren durumlarda, DVM' ler orijinal örnek uzayını doğrusal olmayan sınırın çizilebileceği daha yüksek boyutlu bir

alana dönüştürür (burada, ikinci dereceden veya kübik) çekirdeklerin kullanımına izin verilir (Ferizi ve ark., 2019).

Çok sayıda öznelik olduğunda (i) Doğrusal DVM, tercih edilmektedir. Doğrusal çekirdek (kernel), doğrusal olarak ayrılabilir veriler için uygundur ve sınıflandırıcıyı diğer çekirdeklere göre eğitmek daha hızlıdır çünkü doğrusal çekirdek herhangi bir eşleme yapmamaktadır. Doğrusal DVM, büyük miktarda veri kümesiyle verimli bir şekilde ilgilenmektedir. (ii) Quadratik DVM' de; eğitim aşamasında ikili sınıflandırma için bellek kullanımı orta düzeydedir, çok sınıflı sınıflandırma için ise büyüktür. İkili sınıflandırma için tahmin hızlıdır ve çoklu sınıf için düşüktür. Quadratik DVM'de yorumlanabilirlik zordur ve model esnekliği orta düzeydedir (Zhang ve Leatham, 2017; Bhati ve Rai, 2020). (iii) Fine Gauss DVM' sinde, eğitim aşamasında, ikili sınıflandırma için bellek kullanımı orta, çoklu sınıf için bellek kullanımı büyüktür. Bu durumda yorumlana bilirlik zordur ve model esnekliği yüksektir ve çekirdek ölçeği $\sqrt{P} / 4$ olarak kullanılmaktadır. Sınıflar arasında ayrıntılı ayrımlar yapılmaktadır. İkili sınıflandırma için tahmin hızlı ve çoklu sınıf için düşüktür. (iv) Medium Gauss DVM'sinde, ikili sınıflandırma için eğitim aşamasındaki tahmin hızlı ve çoklu sınıf için yavaştır. Çoklu sınıf için bellek kullanımı büyüktür ve ikili sınıflandırma için orta düzeydedir. Yorumlana bilirlik zordur ve Medium Gauss DVM'sinde modelin esnekliği orta düzeydedir (Bhati ve Rai, 2020). (v) Coarse Gauss algoritması hızlı ikili ve orta zor, yavaş ve büyük çok sınıflı ve çekirdek ölçek kümesiyle çalışmaktadır. (Farayola ve ark., 2018) (vi) Cubic SVM düşük bellek alanı ikilemiyle karşılaşıldığında kullanılabilir, sınıfları mümkün olan en iyi şekilde bölen çok boyutlu uzayda bir hiper düzlem bulabilen bir yapıya sahiptir (Jain ve ark., 2018).

2.4.6.5. Lojistik Regresyon Analizi (Logistic Regression)

Lojistik regresyon (LR) genellikle ikili sınıflandırma problemlerinde kullanılmaktadır. Girdi değerlerini doğrusal regresyonda tahmin edilen değerlere dönüştürür ve ardından bunları sigmoid işleviyle eşler. Değerler, x eksenini değişken, y eksenini bir olasılık olarak kullanılır. Tahmin edilen değere karşılık gelen y değeri, 1'e daha yakındır ve bu, tahmin edilen sonuçla tamamen uyumlu olduğunu göstermektedir. Diğer sınıflandırma algoritmalarıyla karşılaştırıldığında, lojistik regresyonun matematiksel modeli ve

çözümü nispeten basit ve uygulanması kolaydır (Michalaki, 2015; Zhang ve ark., 2020).

2.4.7. Sınıflandırıcı Performansının Değerlendirilmesi

2.4.7.1. Hata Matrisi (Confusion Matrix)

Bir sınıflandırmanın doğruluğu; doğru tanınan sınıf örneklerinin sayısı [gerçek pozitifler, (TP)], sınıfa ait olmayan doğru tanınan örneklerin sayısı [gerçek negatifler, (TN)], ve sınıfa yanlış olarak atanan [sahte pozitifler, (FP)] veya sınıf örnekleri olarak tanınmayan [sahte negatifler, (FN)] örneklerin hesaplanması ile değerlendirilebilmektedir. Bu dört hesaplama, ikili sınıflandırma durumu için Tablo 1'de gösterilen hata matrisini oluşturmaktadır (Sokolova ve Lapalme, 2009).

	Tahmin edilen Negatif	Tahmin edilen Pozitif
Gerçek Negatif	Gerçek Negatif (True Negatif-TN)	Sahte Pozitif (False Positive-FP)
Gerçek Pozitif	Sahte Negatif (False Negative-FN)	Gerçek Pozitif (True Positive-TP)

Şekil 8. Hata matrisi yapısı

2.4.7.2. Sınıflandırıcı Performans Ölçütleri

Doğruluk, modelin test işleminde, var olan sınıfları tahmin etme başarısını ifade eder; kesinlik, test kümesinde yer alan örüntülerin doğru tahmin etme başarısını (Eşitlik (3.10)). Duyarlık/Özgünlük, pozitif / negatif etiketin doğru olma olasılığını yaklaşık olarak tahmin eder (algoritmanın tek bir sınıf üzerindeki etkinliğini değerlendirir); Hata oranı elde edilen çıktıların ne düzeyde bir hata ile elde edildiğini hesaplamaya yaramaktadır. Son olarak, f-skor ise test edilen verilerin doğruluğunun ölçümünü ifade eder, daha yüksek duyarlılığa sahip algoritmaları tercih eden ve daha yüksek özgüllüğü olanlara meydan okuyan bileşik bir ölçüdür (Sokolova ve ark 2006; Sokolova ve Lapalme, 2009).

Ölçütler	Formüller
Doğruluk (Accuracy)	$\frac{TP + TN}{TP + FP + FN + TN}$
Duyarlılık (Sensitivity)	$\frac{TP}{TP + FN}$
Özgünlük (Specificity)	$\frac{TN}{TN + FP}$
Kesinlik (Precision)	$\frac{TP}{TP + FP}$
Yanlış Pozitif Oranı (False Positive Rate)	$\frac{FP}{TN + FP}$
Hata Oranı (Error Rate)	$\frac{FP + FN}{TP + FP + FN + TN}$
F1 Skor (F1 Score)	$\frac{2 * Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık}$

Şekil 9. Sınıflandırıcı performans ölçütleri ve formülleri

3. GEREÇ ve YÖNTEM

3.1. Araştırma Grubu

Çalışma grubuna; İstanbul'da ikamet eden, yaş ortalaması 22.66 ± 0.57 , sağlıklı, haftada en az 5 saat antrenman yapan, dominant eli sağ olan 3 erkek cimnastik sporcusu ve yaş ortalaması 25.33 ± 0.57 , sağlıklı, dominant eli sağ olan 3 erkek sedanter gönüllülük esasına dayalı olarak katılmıştır. Deney esnasında üçüncü ve karıştırıcı değişken etkilerini en aza indirmek için, katılımcıda herhangi bir nörolojik, psikolojik veya kronik hastalık tanısı olmaması deneye katılım ön şartı olarak belirlenmiştir. Bu tez çalışmasının yapılması için Marmara Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu'ndan 01.11.2019'de 09.2019.974 protokol kodu ile etik kurul izni alınmıştır.


3.2. Araştırma Yöntemi

Katılımcılara, deneyden önce araştırmanın amacı ve deneyin işleyişi hakkında bilgi verilmiştir. Katılımlardan, deney protokolüne devam etmelerine engel olan herhangi bir problem ile karşılaşmadıkları taktirde deney protokolüne sadık kalmaları istenmiş olup ölçümün yapılacağı gün; ilaç, nikotin, kafein, alkol kullanmamaları ve uykusuz olmamaları konusunda uyarılmışlardır.

Çalışma ay yerçekimi analoğu deneyimi ve dünya yerçekimi deneyimi olarak iki kısımdan meydana gelmektedir. EEG kaydı, yapılan her iki aşama süresince alınmıştır.

1. Aşama

Ay yerçekimi analoğu pozisyonunda; katılımcı ay yerçekimi etkisine denk olan ($9,5^\circ$) eğik masaya uzanmaktadır. Katılımcıdan ilk olarak 3 dakika olacak şekilde göz açık ve göz kapalı dinlenim durumu kayıtları alınmıştır. Ardından katılımcıdan, 1 dakika boyunca gözler kapalı olacak şekilde zihinden çıkartma görevi (örneğin: 900-9) yapmaları istenmiştir. Katılımcıya 1 dakika boyunca sayacağı bilgisi verilmemiş olup sadece kendisine durma talimatının deney sırasında verileceği söylenmiştir.



Şekil 10. Ay yerçekimine denk eğik sehpa açısı
(<https://ispyphysiology.files.wordpress.com/2016/03/bed-rest.png>)

2. Aşama

Dünya yerçekimi pozisyonunda; katılımcı rahat bir sandalyede dik pozisyonunda olacak şekilde oturtulmuştur. Katılımcıdan 3 dakika olacak şekilde göz açık ve göz kapalı dinlenme durumu kayıtları alınmıştır. Ardından katılımcıdan, 1 dakika boyunca gözler kapalı olacak şekilde zihinden çıkartma görevi (örneğin: 900-9) yapmaları istenmiştir. Katılımcıya 1 dakika boyunca sayacağı bilgisi verilmemiş olup sadece kendisine durma talimatının deney sırasında verileceği söylenmiştir.



Şekil 11. Dünya yerçekimi

Her iki aşama arasında 15 dakikalık ara verilmiştir. Bu ara katılımcının rahatlaması ve diğer aşamaya hazırlık için kullanılmıştır. Uygulanacak aşamalarının sırası, katılımcıların deneye aşına oluşundan ya da yorgunluk gibi karıştırıcı faktörlerden etkilenmemesi için aşamaların yerleri gruplar arası fark gözetmeden toplam katılımcı sayısının yarısının 1. Aşamadan diğer yarısının 2. Aşamadan başlaması şeklinde kurgulanmıştır.

3.3 Araştırmanın Çalışma Alanı

Mevcut deney kurulumu, ölçümü ve analizleri Marmara Üniversitesi Spor Bilimleri Fakültesi Sinirbilim Laboratuvarı'nda gerçekleştirilmiştir.

3.4. Araştırmada Uygulanan Testler ve Ölçümler


Ölçümler, olabildiğince parlak ışıktan ve sestten arındırılmış bir oda içinde yapılmıştır.

3.4.1. EEG

Beyin aktiviteleri sırasında meydana gelen farklı frekanslara sahip elektriksel sinyallerin yüksek çözünürlüklü kaydı için Brain Products actiCAP marka 16 kanallı kep ve 2 adet kulak elektrodu (referans ve toprak elektrot) kullanılmıştır. Kullanılan EEG cihazı zamansal olarak 1000 Hz örnekleme frekansına sahiptir. Frekans, ritmik tekrarlayan aktiviteyi ifade eder (Hz cinsinden) ve saniyedeki döngü sayısı frekans olarak sayılır. Kaynak olarak milyarlarca nöronun hareketi ile oluşan insan EEG potansiyeli; aralıklı salınım patlamaları, periyodik olmayan ve öngörülemeyen salınımlar olarak ifade edilir. Sağlıklı yetişkinlerde, bu tür sinyallerin genlikleri ve frekansları bir durumdan diğerine, örneğin uyanıklık ve uyku gibi durumlarda değişmektedir. Bir EEG sinyalinin genliği, normal bir yetişkinde tipik olarak yaklaşık 1 ila 100 μ V arasında değişir ve iğne elektrotlar gibi subdural elektrotlarla ölçüldüğünde yaklaşık 10-20 mV'dir. Genellikle frekans ise farklı aralıklarla ayırt edilen beş ana banda sahiptir. Düşük frekanslardan yüksek frekanslara bu frekans bantları, sırasıyla, tipik olarak aşağıdaki gibi belirli bantlarda kategorize edilir: 0,5–4 Hz (delta), 4–8 Hz (teta), 8-13 Hz (alfa), 13–30 Hz (beta) ve >30 Hz (gama). EEG sinyallerinde gözlemlenen farklı frekanslar, genetik etkenler, yaş, cinsiyet, uykusuzluk, matematiksel işlem çözme, okuma veya uyanıklık gibi birçok değişkenden etkilenmektedir (Kaiser, 2007).



Şekil 12. 16 Kanallı bir EEG set örneği: 1. Elektriksel sinyal güçlendirici, 2. Kep, 3. Elektrotlar



Şekil 13. Kafa üzerindeki elektrot yerleşim modeli

3.5. EEG Gürültülerinin Arındırılması ve Özniteliklerin Hesaplanması

EEG verileri, BrainVision Analyzer 2.0 kullanılarak elektrik ve kas hareketlerinin oluşturduğu ve 50 Hz şehir şebekesi gürültüsünden arındırıldı. Katılımcıların, ay-dünya pozisyonunda, göz kapalı ve sayı sayma görevine ait EEG sinyalleri Matlab®


programı kullanılarak 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms’lik zaman penceresinin yarısına denk örtüşmeli zaman pencerelerine ayrıldı ve Yaklaşık Entropi uygulandı. Yaklaşık Entropi için sabitlenen parametre değerleri: N, veri uzunluğu; m, verinin alt uzunluğu; ve r değeri, EEG zaman serisinin standart sapmasının 0.2 şeklindedir.

16 EEG kanalı için tüm zaman pencerelerinde hesaplanan Yaklaşık Entropi değeri 23 sınıflandırıcı algoritmasının bulunduğu makine öğrenimine oluşturulan farklı veri setleri girdi olarak verildi. Oluşturulan veri setleri **Tablo 1**, **Tablo 2** ve **Tablo 3** de sunulmaktadır.


Çalışmada kullanılan veri setleri 5 katlamalı çapraz doğrulama yapısı ile test edildi.

1. Tekrar	1-Katlamalı	2-Katlamalı	3-Katlamalı	4-Katlamalı	5-Katlamalı
2. Tekrar	1-Katlamalı	2-Katlamalı	3-Katlamalı	4-Katlamalı	5-Katlamalı
3. Tekrar	1-Katlamalı	2-Katlamalı	3-Katlamalı	4-Katlamalı	5-Katlamalı
4. Tekrar	1-Katlamalı	2-Katlamalı	3-Katlamalı	4-Katlamalı	5-Katlamalı
5. Tekrar	1-Katlamalı	2-Katlamalı	3-Katlamalı	4-Katlamalı	5-Katlamalı


Şekil 14. 5 katlamalı çapraz doğrulama yapısı




Şekil 15. Ay-göz kapalı koşulunda 6 numaralı katılımcıya (cimnastik) ait 250 milisaniyelik pencere örneği




Şekil 16. Ay-çıkarma görevi koşulunda 4 numaralı katılımcıya (cimnastik) ait 500 milisaniyelik pencere örneği




Şekil 17. Ay-çıkarma görevi koşulunda 2 numaralı katılımcıya (sedanter) ait 750 milisaniyelik pencere örneği




Şekil 18. Dünya-çıkarma görevi koşulunda 6 numaralı katılımcıya (cimnastik) ait 1000 milisaniyelik pencere örneği




Şekil 19. Dünya-göz kapalı görevi koşulunda 3 numaralı katılımcıya (sedanter) ait 1500 milisaniyelik pencere örneği



Şekil 20. Dünya-göz kapalı görevi koşulunda 4 numaralı katılımcıya (cimnastik) ait 2000 milisaniyelik pencere örneği



Şekil 21. Ay-göz kapalı görevi koşulunda 1 numaralı katılımcıya (sedanter) ait 3000 milisaniyelik pencere örneği



Şekil 22. Ay-çıkarma görevi koşulunda 5 numaralı katılımcıya (cimnastik) ait 4000 milisaniyelik pencere örneği

Tablo 1. TK_GK_D_A, TK_Ç_D_A, TK_D_Ç_GK, TK_A_Ç_GK, C_S_GK_D, C_S_GK_A, C_S_Ç_D, C_S_Ç_A, A_GK_Ç ve D_GK_Ç durumları için sınıflandırıcıda kullanılan tüm zaman pencerelerindeki veri setine ait girdi sayısı

Veri Seti	250	500	750	1000	1500	2000	3000	4000
TK_GK_D_A	17268	8628	5736	4038	2868	2148	1428	1056
TK_Ç_D_A	5748	2868	1896	1428	948	708	468	336
TK_D_Ç_GK	5748	2868	1896	1428	948	708	468	336
TK_A_Ç_GK	5748	2868	1896	1428	948	708	468	336
D_C_S_GK	8634	4314	2868	2154	1434	1074	714	528
A_C_S_GK	8634	4314	2868	2154	1434	1074	714	528
D_C_S_Ç	2874	1434	948	714	474	354	234	168
A_C_S_Ç	2874	1434	948	714	474	354	234	168
A_GK_Ç	535	267	177	131	88	66	43	31
D_GK_Ç	535	267	177	131	88	66	43	31

*Veri Seti (TK- Tüm Katılımcılar, GK- Göz Kapalı, Ç- Çıkarma, D- Dünya, A- Ay, C- Cimnastik, S- Sedanter)

Tablo 2. GK_D_A durumu için, her bir katılımcının sınıflandırıcıda kullanılan tüm zaman pencerelerindeki veri setine ait girdi sayısı

GK_D_A	250		500		750		1000		1500		2000		3000		4000	
YK	D	A	D	A	D	A	D	A	D	A	D	A	D	A	D	A
S_Katılımcı-1	1439	1455	719	727	478	484	359	363	239	241	179	181	119	120	88	89
S_Katılımcı-2	1439	1455	719	727	478	484	359	363	239	241	179	181	119	120	88	89
S_Katılımcı-3	1439	1447	719	723	478	481	359	361	239	240	179	180	119	119	88	89
C_Katılımcı-4	1439	1463	719	731	478	486	359	365	239	243	179	182	119	121	88	90
C_Katılımcı-5	1439	1439	719	719	478	478	359	359	239	239	179	179	119	119	88	88
C_Katılımcı-6	1439	1463	719	731	478	486	359	365	239	243	179	182	119	121	88	90

Tablo 3. Ç_D_A durumuna ait, her bir katılımcının sınıflandırıcı için kullanılan tüm zaman pencerelerindeki veri setine ait girdi sayısı

Ç_D_A	250		500		750		1000		1500		2000		3000		4000	
YK	D	A	D	A	D	A	D	A	D	A	D	A	D	A	D	A
S_Katılımcı-1	535	559	267	279	177	185	133	139	88	92	66	69	43	45	32	33
S_Katılımcı-2	535	535	267	267	177	177	129	123	85	88	64	66	42	43	32	32
S_Katılımcı-3	519	511	259	255	172	169	129	127	85	84	64	63	42	41	31	31
C_Katılımcı-4	527	527	263	263	174	174	131	131	87	87	65	65	43	43	31	31
C_Katılımcı-5	519	535	259	267	172	177	129	133	85	88	64	66	42	43	31	32
C_Katılımcı-6	519	535	259	267	172	177	129	133	85	88	64	66	42	43	31	32

4. BULGULAR

Çalışmada elde edilen bulgular; her katılımcının ayrı ayrı yaklaşık entropi değerinin hesaplanıp veri setinin oluşturulduğu birinci kısımdan ‘Tek Katılımcı Tabanlı Oluşan Veri Seti, Yaklaşık Entropi Sınıflandırması’, grup farkı gözetmeksizin her katılımcının entropi değerinin hesaplanıp tek veri setini oluşturduğu ikinci kısımdan ‘Tüm Katılımcılardan Oluşan Veri Seti, Yaklaşık Entropi Sınıflandırması’, ve cimmastik-sadanter olarak oluşturulan grupların entropi değerinin hesaplanıp veri setinin oluşturulduğu üçüncü kısımdan ‘Cimmastik ve Sedanter Grubun Oluşturduğu Veri Seti, Yaklaşık Entropi Sınıflandırması’ oluşmaktadır.

4.1. Tek Katılımcı Tabanlı Oluşan Veri Seti, Yaklaşık Entropi Sınıflandırması

Tüm katılımcılar için ayrılan tüm zaman pencerelerine -250, 500, 750, 1000, 1500, 2000, 3000, 4000- yaklaşık entropi değeri hesaplanmış ve veri setinin oluşturulduğu dört alt kısma ayrılmıştır: İlk kısım ay pozisyonunda, göz kapalı ve çıkarma görevinin yaklaşık entropi değeri hesaplanarak sınıflandırıldığı ‘Ay_Göz kapalı_Çıkarma-Zaman Penceresi (A_GK_Ç-Zaman Penceresi) Durumu’, ikinci kısım dünya pozisyonunda, göz kapalı ve çıkarma görevinin yaklaşık entropi değeri hesaplanarak sınıflandırıldığı ‘Dünya_Göz kapalı_Çıkarma- Zaman Penceresi (A_GK_Ç-Zaman Penceresi) Durumu’, üçüncü kısım göz kapalı görevinin, dünya ve ay pozisyonunda yaklaşık entropi değeri hesaplanarak sınıflandırıldığı ‘Gözkapalı_Dünya_Ay - Zaman Penceresi (GK_D_A-Zaman Penceresi) Durumu’ son olarak çıkarma görevinin, dünya ve ay pozisyonu için yaklaşık entropi değeri hesaplanarak sınıflandırıldığı ‘Çıkarma_Dünya_Ay - Zaman Penceresi (Ç_D_A-Zaman Penceresi) Durumu’ şeklindedir.

4.1.1. Ay_Göz kapalı_Çıkarma-Zaman Penceresi (A_GK_Ç-Zaman Penceresi) Durumu

Ay yerçekimi pozisyonunda, göz kapalı ve çıkarma görevinin gerçekleştirildiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır.

Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların göz kapalı ve çıkarma görevini ayırma başarısında artış olduğu **Tablo 4.** de görülmektedir. 6 katılımcıya ait tüm zaman pencerelerinin, sınıflandırıcı algoritmalarının doğruluk değerlerinin ve performans sonuçların yer aldığı tablolar konu ile ilişkili bölüm altında gösterilmektedir.

Tablo 4. Sedanter, cimnastik ve tüm katılımcılarda kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri

Zaman Penceresi	250	500	750	1000	1500	2000	3000	4000
S_Ortalama	73,13	79,9	84,76	84,96	90,9	90,9	94,53	96,16
S_Standart Sapma	7,4	6,34	4,79	3,23	2,94	2,64	3,1	5,39
C_Ortalama	71,86	80,13	87,2	89,53	90,66	93,7	95,8	98,06
C_Standart Sapma	4,72	4,27	3,89	2,92	2,45	1,9	1,21	1,04
Genel_Ortalama	72,5	80,01	85,98	87,25	90,78	92,3	95,16	97,11
Genel_Standart Sapma	5,59	4,8	4,13	3,72	2,43	2,57	2,21	3,62

Tablo 5. Sedanter ve cimnastik katılımcıların, A_GK_Ç-250 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-250	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	61.4	63.1	60.4	64.3	69.1	67	66.6	69.6	64.7	59.9	69.9*	69.6
S_Katılımcı-2	70.7	73.4	70.4	68.7	69.6	76.9	77.8	81.6*	76.8	63.7	80.9	76.2
S_Katılımcı-3	58	61.5	61.5	62.9	64.9	66.3	66.8	64.7	62.8	56.1	67.9*	67.2
C_Katılımcı-4	61.9	64.5	62.3	66.2	66.2	67	66.8	67.7	66	56.4	68.7*	68.1
C_Katılımcı-5	67.8	71.9	72.1	73.6	74.9	76.3	76.3	76	71.1	63.4	77	77.3*
C_Katılımcı-6	61.6	64.7	64.7	62.6	63.2	66.7	66.6	69.6*	67.7	59.3	69.3	67.7
A_GK_Ç-250	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	60.6	62.9	61.4	64.7	64.2	64.7	66.5	68	65.5	66	63	
S_Katılımcı-2	70.8	75.4	73	76.8	76.4	75.3	76.7	78.3	75.9	76.9	73.3	
S_Katılımcı-3	61.6	60.5	62.3	64.2	62	62.6	64.8	64.4	66.1	62.7	61.7	
C_Katılımcı-4	60.4	62.5	63.7	64.3	62.5	62.8	67.8	67.2	67	65.4	64.5	
C_Katılımcı-5	67	73.9	74.6	74.8	73.9	74.1	76	75.8	76.4	73.6	72.3	
C_Katılımcı-6	60.7	63.6	66.2	64.6	63.9	64.9	68.1	69.4	65.9	66.5	65	

Tablo 6. Sedanter ve cimnastik katılımcıların, A_GK_Ç-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-250	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	69.9	67	72	70	27	30	68
S_Katılımcı-2	Quadratic SVM	81.6	82	80	81	19	18	81
S_Katılımcı-3	M. Gaussian SVM	67.9	66	69	68	30	32	66
C_Katılımcı-4	M. Gaussian SVM	68.7	69	67	68	32	31	68
C_Katılımcı-5	C. Gaussian SVM	77.3	73	80	78	19	22	75
C_Katılımcı-6	Quadratic SVM	69.6	62	76	72	23	30	66

Tablo 7. Sedanter ve cimnastik katılımcıların, A_GK_Ç-500 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	67.6	67.6	69	72	69.7	71.7	72.6	74	67.6	60.6	75.1*	73.5
S_Katılımcı-2	77.2	77.5	76.2	76.8	77	81.3	82	87.1*	85	68	86.7	82.8
S_Katılımcı-3	60.8	63.9	67.1	71.6	71.4	75.5	74.9	76.3	76.3	62.5	77.5*	75.9
C_Katılımcı-4	66.9	68.7	68.6	74.8	76.5	77.4	78	78.3	73.8	62.9	79.2*	79.1
C_Katılımcı-5	75.1	76	72.8	78.8	80.3	82.8	83.1	82.4	82.4	65	84.8*	82.4
C_Katılımcı-6	67.4	70.6	74	69.7	70	76.4*	74	74.9	69.1	66.7	76.2	74.3
A_GK_Ç-500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	68.1	66.5	64.5	70.3	67.2	69.9	72	73.7	71.7	72.4	67.7	
S_Katılımcı-2	78.5	85	77.3	83	84.1	84.6	83.9	83.9	82.2	85.6	77.3	
S_Katılımcı-3	74.5	71.4	66.3	71.6	71.4	73.5	67.8	71	74.7	72.9	63.1	
C_Katılımcı-4	71.4	73.3	71.1	74	74.4	73.3	77	77.4	79.2*	76.1	68.9	
C_Katılımcı-5	77.7	81.3	78.7	82.6	80.3	83	80.1	82.2	82.8	83.7	75.8	
C_Katılımcı-6	66.5	71.2	72.3	69.3	71.5	71.3	74.2	74.3	75.7	74.2	71.5	

Tablo 8. Sedanter ve cimnastik katılımcıların, A_GK_Ç-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	75.1	75	74	74	25	24	74
S_Katılımcı-2	Quadratic SVM	87.1	88	86	86	13	12	86
S_Katılımcı-3	M. Gaussian SVM	77.5	79	74	75	25	22	76
C_Katılımcı-4	M. Gaussian SVM	79.2	80	78	78	21	20	78
C_Katılımcı-5	M. Gaussian SVM	84.8	85	84	84	15	15	84
C_Katılımcı-6	Logis Reg	76.4	76	76	76	23	23	76

Tablo 9. Sedanter ve cimnastik katılımcıların, A_GK_Ç-750 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-750	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	65.7	67.3	66.2	76.5	75.4	77.8	78.6	78.1	76.2	64.1	80.8*	80.8*
S_Katılımcı-2	75.1	74.6	81.9	78.8	78.5	84.7	86.2	90.1*	90.1*	72.6	88.1	85
S_Katılımcı-3	68.9	68.9	71.3	77.5	76.6	80.5	80.5	82.2	81.7	62.7	83.4*	79.6
C_Katılımcı-4	74.9	76.5	76.3	82.9	82.7	86.2*	84.2	85.4	82.9	69.1	85.4	84.4
C_Katılımcı-5	81.6	81.4	79.4	86.7	85.3	89	88.4	91.5*	89.5	65.5	90.7	88.1
C_Katılımcı-6	74.3	74	77.1	76.8	75.7	83.9*	82.8	82.5	78.8	71.2	83.1	81.1
A_GK_Ç-750	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	71.6	73.2	67	76.2	71.6	77.8	70.5	75.7	79.5	76.2	68.1	
S_Katılımcı-2	86.2	85.9	75.1	85.9	84.7	84.7	85.3	85	84.7	86.2	76	
S_Katılımcı-3	74.9	74.9	65.1	77.8	74.9	76.9	73.7	76.3	79.3	79.9	69.8	
C_Katılımcı-4	80.5	80.4	77.8	82.1	80.9	80	81.7	83.7	84.6	81.1	77.2	
C_Katılımcı-5	87	85.9	84.5	87.9	85	88.1	83.1	86.7	88.1	89.5	80.2	
C_Katılımcı-6	78	79.7	80.8	81.4	80.2	81.6	79.7	81.4	81.6	81.9	75.4	

Tablo 10. Sedanter ve cimnastik katılımcıların, A_GK_Ç-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-750	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	80.8	77	83	82	16	19	79
S_Katılımcı-2	Cubic SVM	90.1	89	9	9	.09	.09	89
S_Katılımcı-3	M. Gaussian SVM	83.4	82	84	83	15	16	82
C_Katılımcı-4	Logis Reg	86.2	86	85	85	14	13	85
C_Katılımcı-5	Quadratic SVM	91.5	9	92	92	.07	.08	90
C_Katılımcı-6	Logis Reg	83.9	84	83	83	16	16	83

Tablo 11. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1000 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-1000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	67.6	68	69.4	78.1	78.1	82.4	83.1*	81.3	80.2	61.9	82	80.9
S_Katılımcı-2	83.1	83.1	79.7	82.3	83.1	85.3	87.2	88.7*	85	73.3	88.7*	86.5
S_Katılımcı-3	69.7	69.7	69.3	74.8	74.4	79.9	79.5	83.1*	82.7	66.5	83.1*	78.7
C_Katılımcı-4	78	77.5	74.9	83.4	84.7	86	88.1*	85	85	71.5	85.8	85.8
C_Katılımcı-5	82.7	82.7	81.2	88	90.2	89.1	89.1	92.9*	91.7	63.5	92.1	88.3
C_Katılımcı-6	73.3	73.3	78.2	80.5	77.8	87.6*	85.7	84.2	80.1	68	86.1	84.2
A_GK_Ç-1000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	74.8	74.8	69.4	77.7	73.7	78.1	74.1	78.1	81.3	81.3	66.9	
S_Katılımcı-2	85	87.6	80.5	88.3	87.6	88	68.8	87.2	87.6	86.1	70.7	
S_Katılımcı-3	75.6	75.2	65.4	76	75.6	76.4	76.4	77.2	79.9	80.7	69.7	
C_Katılımcı-4	82.1	82.6	74.6	84.2	83.9	84.5	82.1	85.8	87.3	85.8	78	
C_Katılımcı-5	90.6	88.3	83.8	89.5	87.2	89.8	56.8	90.2	89.1	88.3	63.9	
C_Katılımcı-6	75.9	83.1	83.8	83.5	82.7	83.8	78.6	85.3	84.6	84.2	75.6	

Tablo 12. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-1000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Linear SVM	83.1	85	80	81	19	16	82
S_Katılımcı-2	M. Gaussian SVM	88.7	91	85	86	14	11	88
S_Katılımcı-3	M. Gaussian SVM	83.1	79	86	85	13	16	81
C_Katılımcı-4	Linear SVM	88.1	89	87	87	12	11	87
C_Katılımcı-5	Quadratic SVM	92.9	90	94	94	.05	.07	91
C_Katılımcı-6	Logis Reg	87.6	88	86	86	13	12	86

Tablo 13. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1500 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-1500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	77.2	77.2	74.5	83.2	83.7	81.5	85.9	87	89.1*	60.3	88	84.2
S_Katılımcı-2	84.1	84.1	85.8	85.2	87.5	88.6	89.8	92.6	92.6	73.9	92	89.2
S_Katılımcı-3	70.8	70.8	69	81	75.6	85.7	81.5	89.3*	85.7	66.7	86.9	82.1
C_Katılımcı-4	84	84	83.2	85.9	90.6	89.5	91	89.5	90.2	71.9	93*	87.1
C_Katılımcı-5	86.4	86.4	86.4	90.3	88.1	88.6	89.2	90.9*	90.9*	56.8	90.9*	86.4
C_Katılımcı-6	80.7	80.7	75.6	85.2	84.1	88.1*	86.9	85.2	84.7	65.3	86.4	85.8
A_GK_Ç-1500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	82.6	82.1	65.2	86.4	83.7	84.2	53.3	82.1	85.9	87.5	60.9	
S_Katılımcı-2	90.9	90.9	83	91.5	90.3	92.6	48.9	90.9	90.9	94.3*	48.9	
S_Katılımcı-3	79.8	76.8	56	78.6	77.4	83.9	49.4	81.5	82.7	76.8	49.4	
C_Katılımcı-4	87.5	88.7	77.7	89.1	89.5	89.5	49.2	90.6	90.6	91.8	49.2	
C_Katılımcı-5	86.9	85.2	76.1	88.6	84.7	90.3	48.9	89.2	88.1	90.9*	63.6	
C_Katılımcı-6	81.2	85.2	86.9	84.7	83	84.7	48.9	85.2	87.5	86.9	48.9	

Tablo 14. Sedanter ve cimnastik katılımcıların, A_GK_Ç-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-1500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Cubic SVM	89.1	93	84	86	15	10	89
S_Katılımcı-2	Subspace KNN	94.3	94	94	94	.05	.05	94
S_Katılımcı-3	Quadratic SVM	89.3	85	92	92	.07	10	88
C_Katılımcı-4	M. Gaussian SVM	93	92	93	93	.06	.07	92
C_Katılımcı-5	M. Gaussian SVM	90.9	90	90	90	.09	.09	9
C_Katılımcı-6	Logis Reg	88.1	88	87	87	12	11	87

Tablo 15. Sedanter ve cimnastik katılımcıların, A_GK_Ç-2000 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-2000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	72.5	72.5	74.6	81.2	85.5	85.5	86.2	87	88.4	63.8	89.9*	85.5
S_Katılımcı-2	85.6	85.6	85.6	86.4	89.4	84.8	87.9	92.4	92.4	73.5	93.9*	91.7
S_Katılımcı-3	77	77	74.6	81	74.6	83.3	86.5	86.5	86.5	69	88.9*	81.7
C_Katılımcı-4	80.7	80.7	84.4	86.5	87.5	87.5	90.6	91.1	91.7*	70.8	90.6	88
C_Katılımcı-5	84.8	84.8	83.3	92.4	90.2	90.9	93.2	94.7	92.4	59.1	94.7	89.4
C_Katılımcı-6	84.1	84.1	85.6	87.1	86.4	87.1	89.4	90.9	93.9*	66.7	90.2	88.6
A_GK_Ç-2000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	84.8	77.5	50.7	83.3	79	87	49.3	79.7	85.5	87.7	60.9	
S_Katılımcı-2	90.2	90.9	81.1	90.2	90.2	90.2	49.2	87.1	89.4	92.4	57.6	
S_Katılımcı-3	82.5	73.8	51.6	81	73	81	48.4	81.7	84.9	84.9	56.3	
C_Katılımcı-4	84.9	88	76.6	88	87.5	89.1	49.5	86.5	90.1	89.1	49.5	
C_Katılımcı-5	92.4	90.2	75	92.4	87.1	90.2	49.2	93.9	89.4	95.5*	49.2	
C_Katılımcı-6	90.9	88.6	61.4	84.8	88.6	89.4	49.2	92.4	89.4	92.4	56.8	

Tablo 16. Sedanter ve cimnastik katılımcıların, A_GK_Ç-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-2000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	89.9	91	88	88	11	.08	89
S_Katılımcı-2	M. Gaussian SVM	93.9	92	95	95	.04	.06	93
S_Katılımcı-3	M. Gaussian SVM	88.9	93	84	85	15	11	88
C_Katılımcı-4	Cubic SVM	91.7	92	90	90	.09	.08	90
C_Katılımcı-5	Subspace KNN	95.5	93	96	96	.03	.04	94
C_Katılımcı-6	Cubic SVM	93.9	93	93	93	.06	.06	93

Tablo 17. Sedanter ve cimnastik katılımcıların, A_GK_Ç-3000 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-3000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	73.3	73.3	74.4	87.8	85.6	88.9	91.1	91.1	94.4*	75.6	90	84.4
S_Katılımcı-2	89.5	89.5	89.5	89.5	91.9	97.7*	94.2	95.3	96.5	66.3	94.2	89.5
S_Katılımcı-3	82.9	82.9	82.9	84.1	79.3	91.5*	90.2	89	82.9	56.1	89	82.9
C_Katılımcı-4	80.2	80.2	81	88.9	88.9	92.9	92.1	92.1	90.5	57.1	94.4*	92.1
C_Katılımcı-5	88.4	88.4	88.4	94.2	95.3	88.4	95.3	91.9	90.7	51.2	96.5*	90.7
C_Katılımcı-6	93	93	93	95.3	95.3	93	94.2	94.2	91.9	64	96.5*	96.5*
A_GK_Ç-3000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	87.8	87.8	50	88.9	86.7	93.3	50	86.7	88.9	93.3	50	
S_Katılımcı-2	89.5	89.5	47.7	89.5	90.7	89.5	47.4	91.9	94.2	94.2	47.4	
S_Katılımcı-3	81.7	80.5	48.8	82.9	76.8	82.9	48.8	84.1	89	87.8	48.8	
C_Katılımcı-4	89.7	88.9	46	92.1	88.1	88.9	48.4	90.5	92.1	92.9	69.8	
C_Katılımcı-5	90.7	89.5	47.7	89.5	87.2	93	47.7	96.5	91.9	90.7	47.7	
C_Katılımcı-6	94.2	95.3	47.7	93	94.2	95.3	47.7	94.2	95.3	95.3	57	

Tablo 18. Sedanter ve cimnastik katılımcıların, A_GK_Ç-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-3000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Cubic SVM	94.4	97	91	91	.08	.05	93
S_Katılımcı-2	Logis Reg	97.7	100	95	95	.04	.02	97
S_Katılımcı-3	Logis Reg	91.5	92	90	90	.09	.08	90
C_Katılımcı-4	M. Gaussian SVM	94.4	90	98	98	.01	.05	93
C_Katılımcı-5	M. Gaussian SVM	96.5	100	93	93	.06	.03	96
C_Katılımcı-6	M. Gaussian SVM	96.5	97	95	95	.04	.03	95

Tablo 19. Sedanter ve cimnastik katılımcıların, A_GK_Ç-4000 durumuna ait sınıflandırma sonuçları (%)

A_GK_Ç-4000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	75.8	75.8	77.3	89.4	92.4	93.9	92.4	98.5*	98.5*	56.1	98.5*	92.4
S_Katılımcı-2	92.2	92.2	92.2	95.3	98.4	95.3	98.4	98.4	98.4	62.5	100*	93.8
S_Katılımcı-3	58.3	58.3	58.3	80	80	90*	88.3	88.3	88.3	68.3	88.3	78.3
C_Katılımcı-4	81.9	81.9	81.9	91.5	92.6	97.9	97.9	96.8	95.7	53.2	98.9*	92.6
C_Katılımcı-5	89.1	89.1	89.1	96.9*	95.3	90.6	95.3	95.3	95.3	64.1	95.3	96.9*
C_Katılımcı-6	93.8	93.8	93.8	93.8	93.8	93.8	92.2	95.3	95.3	67.2	96.9	96.9
A_GK_Ç-4000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	98.5*	87.9	47	89.4	86.4	97	47	87.9	90.9	97	53	
S_Katılımcı-2	93.8	96.9	46.9	96.9	90.6	98.4	46.9	98.4	100*	95.3	46.9	
S_Katılımcı-3	83.3	71.7	50	76.7	70	85	50	76.7	86.7	76.6	59	
C_Katılımcı-4	96.8	96.8	92.6	47.9	92.6	92.6	95.7	47.9	96.8	98.9*	47.9	
C_Katılımcı-5	93.8	93.8	46.9	96.9*	89.1	93.8	46.9	95.3	93.8	93.8	46.9	
C_Katılımcı-6	98.4*	96.9	46.9	93.8	95.3	98.4*	46.9	92.2	95.3	95.3	46.9	

Tablo 20. Sedanter ve cimnastik katılımcıların, A_GK_Ç-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

A_GK_Ç-4000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	98.5	96	100	100	0	.01	97
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Logis Reg	90	86	93	92	.06	.1	88
C_Katılımcı-4	M. Gaussian SVM	98.9	97	100	100	0	.01	98
C_Katılımcı-5	C. Gaussian SVM	96.9	93	100	100	0	.03	96
C_Katılımcı-6	Weighted KNN	98.4	100	96	96	.03	.01	97

4.1.2. Dünya_Göz kapalı_Çıkarma-Zaman Penceresi (D_GK_Ç-Zaman Penceresi) Durumu

Dünya yerçekimi pozisyonunda, göz kapalı ve çıkarma görevinin gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması kullanılarak sınıflandırılmıştır.

Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların göz kapalı ve çıkarma görevini ayırma başarısında artış olduğu **Tablo 21.** de görülmektedir. 6 katılımcıya ait tüm zaman pencerelerinin, sınıflandırıcı algoritmalarının doğruluk değerlerinin ve performans sonuçların yer aldığı tablolar konu ile ilişkili bölüm altında gösterilmektedir.

Tablo 21. Sedanter, cimnastik ve tüm katılımcılar için kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri

Zaman Penceresi	250	500	750	1000	1500	2000	3000	4000
S_Ortalama	72,26	79,53	84,06	86,1	85,13	87,9	92,53	89,93
S_Standart Sapma	12,1	12,54	11,58	11,09	11,44	10,11	7,17	8,77
C_Ortalama	72,06	78,46	83,86	85,93	86,8	89	91,83	93,63
C_Standart Sapma	10,84	10,36	11,58	9,3	9,165	6,51	7,06	6,45
Genel_Ortalama	72,16	79	83,96	86,01	85,96	88,45	92,18	91,78
Genel_Standart Sapma	10,27	10,3	10,36	9,15	9,31	7,63	6,38	7,18

Tablo 22. Sedanter ve cimnastik katılımcıların, D_GK_Ç-250 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-250	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	62.2	64.8	61.8	65.5	67.4	67.1	67.1	65.5	64.3	60.9	67.4	68.1
S_Katılımcı-2	79.3	82	77.8	80.5	82	82.9	82.8	85.1	83.2	66.2	85.7	82.6
S_Katılımcı-3	56.8	56.3	53.9	57.6	57.4	60.3	60.6	61	58.4	54.7	62.8*	60.7
C_Katılımcı-4	53.9	57.7	57.4	56.5	58.4	58.2	59.4	59.8*	57.1	53.2	59.7	57.9
C_Katılımcı-5	62.9	68.5	63.9	70	69.8	74.1	73.6	74	69.3	56	76*	74.5
C_Katılımcı-6	71.3	75	69.3	76.3	78.6	77.5	78.1	78.7	75.8	66.9	80.4*	79
D_GK_Ç-250	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	61.1	63.7	64	66.1	62.7	64.9	68.1*	66.4	67.1	66.9	64	
S_Katılımcı-2	78.9	83.6	81.5	83.1	82.6	83.1	83.6	85.9*	82	84.9	81.6	
S_Katılımcı-3	56.6	59.8	60.6	61.1	60.5	59.2	60.7	61	60.8	57.5	57	
C_Katılımcı-4	54.1	53	57.5	56.2	53.9	54.6	59	57.2	57.8	57.5	56.4	
C_Katılımcı-5	65.7	69.9	72.9	71.6	70.5	70.7	72.1	73.8	72.8	71.7	68.5	
C_Katılımcı-6	71.8	77.9	78.7	77.8	77.9	77.2	79.1	79.7	77.5	78.3	74	

Tablo 23. Sedanter ve cimnastik katılımcıların, D_GK_Ç-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma sonuçları (%)

D_GK_Ç-250	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Boosted Trees	68.1	67	69	68	30	31	67
S_Katılımcı-2	Bagged Trees	85.9	82	88	88	11	14	84
S_Katılımcı-3	M. Gaussian SVM	62.8	59	65	63	34	37	60
C_Katılımcı-4	Quadratic SVM	59.8	61	58	59	41	40	59
C_Katılımcı-5	M. Gaussian SVM	76	73	78	77	21	24	74
C_Katılımcı-6	M. Gaussian SVM	80.4	79	80	80	19	19	79

Tablo 24. Sedanter ve cimnastik katılımcıların, D_GK_Ç-500 durumuna ait sınıflandırma sonuçları (%)

D GK Ç-500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	66.5	66.5	66.9	71	71.3	73.4	73.2	73.2	72.1	61.4	75.5*	72.5
S_Katılımcı-2	89.5	90.3	89.5	90.1	91	91	91.4	92.7	90.8	71.7	93.4	91.4
S_Katılımcı-3	56.2	60.4	59.1	63.3	64.1	65.3	66.6	65.4	65.8	55.6	69.5*	68.1
C_Katılımcı-4	58.9	59.9	61	63.1	62.9	60.8	60.3	66.7	63.3	54	66.9*	62.5
C_Katılımcı-5	71.3	74.2	72.1	74.2	77.2	78.8	78.7	79	80.1	57.3	81.6*	78.1
C_Katılımcı-6	77.6	77.8	73.8	82.5	82.3	85.2	84.4	86.5	84.4	86.5	84.4	72.6
D GK Ç-500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	68.4	73.6	71.2	73.2	70.6	73.4	72.3	74.7	72.8	74.9	65.2	
S_Katılımcı-2	90.8	92.9	91.2	92.7	92.1	92.3	92.1	93.3	91.6	93.6*	90.6	
S_Katılımcı-3	62.7	65.1	67	66	66.2	65.8	66.2	66.4	66.2	62.9	61.4	
C_Katılımcı-4	61	59.3	60.5	62.2	63.7	60.8	63.7	65.6	62.4	62.2	61.6	
C_Katılımcı-5	72.5	75.3	77.2	76.4	74	77	77.7	78.3	76.6	79.6	73	
C_Katılımcı-6	86.9*	86.3	80.8	85.4	85.4	83.7	84.8	84.2	82.5	85.2	85	

Tablo 25. Sedanter ve cimnastik katılımcıların, D_GK_Ç-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma sonuçları (%)

D GK Ç-500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	75.5	82	68	72	31	24	76
S_Katılımcı-2	Subspace KNN	93.6	93	93	93	.06	.06	93
S_Katılımcı-3	M. Gaussian SVM	69.5	66	72	70	27	30	67
C_Katılımcı-4	M. Gaussian SVM	66.9	69	63	65	36	33	66
C_Katılımcı-5	M. Gaussian SVM	81.6	82	80	80	19	18	80
C_Katılımcı-6	Fine KNN	86.9	87	86	86	13	13	86

Tablo 26. Sedanter ve cimnastik katılımcıların, D_GK_Ç-750 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-750	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	69.8	70.6	77.1	74.3	77.1	75.1	74.6	78.5	78.2	63	79.7*	76.6
S_Katılımcı-2	89.8	89.8	88.1	91.5	92.9	93.5	95.5	95.5	94.4	77.4	95.2	95.8
S_Katılımcı-3	60.5	57.3	58.4	64.5	66.9	69.8	69.2	69.2	70.3	62.5	74.1	68.6
C_Katılımcı-4	62.1	61.5	58.9	62.6	67.8	65.2	62.4	67	67.5	54.6	68.4	61.5
C_Katılımcı-5	76.8	76.6	73.4	79.4	79.1	84.7	85	87.6	84.2	62.4	88.4*	85
C_Katılımcı-6	81.9	81.9	81.6	88.8	84.5	90.2	90.5	90.2	88.5	73.9	92.5*	90.5
D_GK_Ç-750	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	75.7	73.7	73.4	76.8	74.3	75.1	74.9	77.4	75.1	78	72.9	
S_Katılımcı-2	94.4	94.1	91.2	94.1	93.8	94.1	49.4	94.6	94.6	97.2*	49.4	
S_Katılımcı-3	71.2	70.6	63.4	67.2	70.9	74.1	65.1	68.9	69.5	75.3*	59.9	
C_Katılımcı-4	70.4	61.5	57.8	64.7	64.9	66.1	70.7*	69.8	62.6	68.7	60.1	
C_Katılımcı-5	81.4	82.8	79.4	84.2	81.4	85.6	79.9	85	85	85.3	76.8	
C_Katılımcı-6	83.9	89.7	88.5	87.9	89.1	89.4	84.8	89.4	89.9	90.5	81.9	

Tablo 27. Sedanter ve cimnastik katılımcıların, D_GK_Ç-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

D_GK_Ç-750	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	79.7	81	77	78	22	20	79
S_Katılımcı-2	Subspace KNN	97.2	95	98	98	.01	.02	96
S_Katılımcı-3	Subspace KNN	75.3	73	76	76	23	24	74
C_Katılımcı-4	Boosted Trees	70.7	68	51	58	48	39	62
C_Katılımcı-5	M. Gaussian SVM	88.4	88	88	88	11	11	88
C_Katılımcı-6	M. Gaussian SVM	92.5	91	93	93	.06	.07	91

Tablo 28. Sedanter ve cimnastik katılımcıların, D_GK_Ç-1000 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-1000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	70.7	70.3	70.7	75.9	80.1	75.2	77.8	79.3	76.3	59.4	82.7*	77.8
S_Katılımcı-2	91.4	91.4	91.7	94	95.5	92.1	96.2	97.4	98.5*	77.4	95.9	97.4
S_Katılımcı-3	65.1	64.7	62	64.3	64.7	75.2	73.6	71.3	71.7	59.3	72.1	70.2
C_Katılımcı-4	66	64.9	64.5	61.5	67.2	63.4	63.4	74.8	72.9	53.4	71.8	63
C_Katılımcı-5	85	85	77.8	79.3	81.6	88.7	88.3	90.2	86.8	60.2	91*	86.1
C_Katılımcı-6	81.3	81.3	85.9	90.5	88.9	89.3	90.8	91.2	89.3	71.8	91.6*	90.1
D_GK_Ç-1000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	78.6	78.9	69.9	82.3	75.9	81.2	75.9	77.8	77.1	82	68.4	
S_Katılımcı-2	96.2	96.2	93.2	95.5	96.2	95.9	49.2	94.7	96.6	97.7	49.2	
S_Katılımcı-3	69.4	68.6	64.3	65.1	66.3	73.6	65.1	72.1	72.9	77.1*	61.6	
C_Katılımcı-4	70.6	63.4	64.1	73.3	65.6	71.8	64.5	70.2	64.9	75.2*	66	
C_Katılımcı-5	86.1	87.2	80.1	85	87.6	88.7	63.9	85	86.8	86.8	64.7	
C_Katılımcı-6	85.9	90.5	88.5	90.5	90.5	89.3	70.6	90.5	90.5	88.5	70.2	

Tablo 29. Sedanter ve cimnastik katılımcıların, D_GK_Ç-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

D_GK_Ç-1000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	82.7	84	80	81	19	17	82
S_Katılımcı-2	Cubic SVM	98.5	98	98	98	.01	.01	98
S_Katılımcı-3	Subspace KNN	77.1	75	79	78	20	22	76
C_Katılımcı-4	Subspace KNN	75.2	80	69	72	30	24	75
C_Katılımcı-5	M. Gaussian SVM	91	93	88	89	11	.09	90
C_Katılımcı-6	M. Gaussian SVM	91.6	92	90	90	.09	.08	90

Tablo 30. Sedanter ve cimnastik katılımcıların, D_GK_Ç-1500 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-1500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	77.3	77.3	76.7	80.1	82.4*	76.1	77.8	78.4	75.6	65.3	80.1	79
S_Katılımcı-2	93.2	93.2	92.6	95.5	95.5	96	94.9	95.5	96.6	75.6	97.7*	96.6
S_Katılımcı-3	67.6	67.6	65.9	69.4	71.8	65.9	65.9	72.9	69.4	58.8	75.3*	68.2
C_Katılımcı-4	66.7	66.7	68.4	66.7	67.2	67.8	64.9	71.3	67.2	53.4	76.4*	66.1
C_Katılımcı-5	79.5	79.5	76.7	78.4	80.7	87.5	87.5	90.3*	89.8	58.5	87.5	83
C_Katılımcı-6	79.9	79.9	82.8	90.8	91.4	88.5	92.5	93.7*	91.4	70.7	93.7*	87.9
D-GK-Ç-1500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	77.3	75.6	63.1	77.3	77.3	80.7	48.9	82.4*	77.3	82.4*	48.9	
S_Katılımcı-2	95.5	94.9	90.9	96	95.5	94.9	48.9	96	96.6	96.6	48.9	
S_Katılımcı-3	65.9	67.1	65.9	62.9	65.9	70	67.1	64.7	68.8	71.2	68.2	
C_Katılımcı-4	66.1	66.7	62.1	70.7	67.8	70.7	62.6	69.5	67.2	73	67.2	
C_Katılımcı-5	81.8	83.5	76.1	85.2	84.1	85.8	48.9	85.8	87.5	86.9	48.9	
C_Katılımcı-6	91.4	91.4	86.8	91.4	93.1	90.8	48.9	92	87.9	92	54	

Tablo 31. Sedanter ve cimnastik katılımcıların, D_GK_Ç-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

D_GK_Ç-1500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Quadratic Dis	82.4	86	78	80	21	17	82
S_Katılımcı-2	M. Gaussian SVM	97.7	98	96	96	.03	.02	96
S_Katılımcı-3	M. Gaussian SVM	75.3	81	69	72	30	24	76
C_Katılımcı-4	M. Gaussian SVM	76.4	77	75	76	24	23	76
C_Katılımcı-5	Quadratic SVM	90.3	90	89	89	10	.09	89
C_Katılımcı-6	M. Gaussian SVM	93.7	94	93	93	.06	.06	93

Tablo 32. Sedanter ve cimnastik katılımcıların, D_GK_Ç-2000 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-2000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	72	72	80.3	76.5	80.3	75.8	78	81.8	74.2	56.8	82.6	78.8
S_Katılımcı-2	84.8	84.8	84.8	95.5	96.2	94.7	97	96.2	95.5	76.5	97.7	97
S_Katılımcı-3	63.3	63.3	66.4	71.9	67.2	73.4	72.7	75.8	71.9	53.9	78.9	75
C_Katılımcı-4	67.7	67.7	63.1	73.1	69.2	78.5	74.6	81.5*	77.7	63.1	81.5*	70
C_Katılımcı-5	83.3	83.3	84.8	87.9	93.2*	90.2	90.9	90.9	91.7	59.1	91.7	89.4
C_Katılımcı-6	86.2	86.2	84.6	92.3*	90.8	88.5	91.5	90.8	91.5	74.6	92.3*	91.5
D_GK_Ç-2000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	75	72.7	55.3	78	70.5	81.1	49.2	84.8*	80.3	78	49.2	
S_Katılımcı-2	99.2*	95.5	86.4	95.5	95.5	95.5	49.2	95.5	97	99.2*	49.2	
S_Katılımcı-3	68	65.6	47.7	63.3	57.8	68	49.2	74.2	74.2	79.7*	57	
C_Katılımcı-4	78.5	73.1	50.8	73.8	67.7	76.9	50	76.9	73.1	76.9	50	
C_Katılımcı-5	87.1	90.9	72.7	90.9	90.9	93.2*	49.2	89.4	90.9	91.7	56.8	
C_Katılımcı-6	88.5	91.5	56.9	92.3*	90.8	91.5	50	92.3*	90.8	91.5	50	

Tablo 33. Sedanter ve cimnastik katılımcıların, D_GK_Ç-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

D_GK_Ç-2000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Bagged Trees	84.8	84	84	84	15	15	84
S_Katılımcı-2	Subspace KNN	99.2	100	98	98	.01	0	98
S_Katılımcı-3	Subspace KNN	79.7	79	79	79	20	20	79
C_Katılımcı-4	Quadratic SVM	81.5	84	78	79	21	18	81
C_Katılımcı-5	Quadratic Dis	93.2	96	89	90	10	.06	92
C_Katılımcı-6	M. Gaussian SVM	92.3	92	92	92	.07	.07	92

Tablo 34. Sedanter ve cimnastik katılımcıların, D_GK_Ç-3000 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-3000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	73.3	73.3	73.3	84.9	89.5	84.9	87.2	89.5	86	50	89.5	84.9
S_Katılımcı-2	93	93	93	96.5	98.8	97.7	98.8	98.8	98.8	80.2	100*	98.8
S_Katılımcı-3	81	81	81	70.2	83.3	73.8	73.8	79.8	82.1	54.8	85.7*	73.8
C_Katılımcı-4	70.9	70.9	70.9	77.9	81.4	81.4	82.6	81.4	77.9	50	79.1	64
C_Katılımcı-5	79.1	79.1	79.1	82.6	86	90.7	91.9	95.3*	94.2	54.7	93	86
C_Katılımcı-6	94.2	94.2	94.2	94.2	96.5*	87.2	90.7	93	93	70.9	95.3	90.7
D_GK_Ç-3000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	88.4	86	47.7	81.4	80.2	91.9*	47.7	89.5	87.2	91.9*	47.7	
S_Katılımcı-2	98.8	98.8	47.7	97.7	98.8	98.8	47.7	96.5	98.8	98.8	47.7	
S_Katılımcı-3	82.1	81	47.6	75	75	85.7*	47.6	84.5	76.2	84.5	54.8	
C_Katılımcı-4	75.6	81.4	47.7	76.7	73.3	77.9	47.7	77.9	82.6	83.7*	57	
C_Katılımcı-5	91.9	93	47.7	84.9	89.5	91.9	47.7	87.2	90.7	94.2	47.7	
C_Katılımcı-6	93	91.9	47.7	90.7	90.7	94.2	47.7	95.3	93	95.3	55.8	

Tablo 35. Sedanter ve cimnastik katılımcıların, D_GK_Ç-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

D_GK_Ç-3000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Subspace KNN	91.9	95	88	89	11	.08	91
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	M. Gaussian SVM	85.7	90	80	82	19	14	85
C_Katılımcı-4	Subspace KNN	83.7	88	79	80	20	16	83
C_Katılımcı-5	Quadratic SVM	95.3	95	95	95	.04	.04	95
C_Katılımcı-6	Quadratic Dis	96.5	95	97	97	.02	.03	95

Tablo 36. Sedanter ve cimnastik katılımcıların, D_GK_Ç-4000 durumuna ait sınıflandırma sonuçları (%)

D_GK_Ç-4000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	71.9	71.9	71.9	78.1	85.9	76.6	82.8	82.8	81.2	48.4	82.8	81.2
S_Katılımcı-2	93.8	93.8	93.8	98.4	98.4	98.4	98.4	98.4	98.4	79.7	100*	100*
S_Katılımcı-3	75.8	75.8	77.4	77.4	79	72.6	71	80.6	72.6	58.1	82.3	72.6
C_Katılımcı-4	64.5	64.5	64.5	71	71	77.4	75.8	85.5	83.9	54.8	87.1*	62.9
C_Katılımcı-5	79.7	79.7	79.7	87.5	90.6	82.8	93.8*	93.8*	90.6	54.7	92.2	89.1
C_Katılımcı-6	88.7	88.7	88.7	96.8	100*	91.9	93.5	96.8	96.8	82.3	95.2	95.2
D_GK_Ç-4000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	85.9*	71.9	46.9	73.4	70.3	78.1	46.9	82.8	82.8	84.4	46.9	
S_Katılımcı-2	100*	98.4	46.9	100*	98.4	100*	46.9	100*	100*	100*	57.8	
S_Katılımcı-3	79	79	48.4	72.6	71	82.3	48.4	80.6	77.4	83.9*	56.5	
C_Katılımcı-4	72.6	74.2	48.4	69.4	71	72.6	48.4	69.4	74.2	74.2	56.5	
C_Katılımcı-5	92.2	84.4	46.9	85.9	85.9	89.1	46.9	87.5	92.2	93.8*	46.9	
C_Katılımcı-6	96.8	96.8	48.4	95.2	96.8	95.2	48.4	96.8	95.2	100*	48.4	

Tablo 37. Sedanter ve cimnastik katılımcıların, D_GK_Ç-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

D_GK_Ç-4000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Fine KNN	85.9	87	84	84	15	14	85
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Subspace KNN	83.9	90	77	.08	22	16	84
C_Katılımcı-4	M. Gaussian SVM	87.1	93	80	82	19	12	87
C_Katılımcı-5	Subspace KNN	93.8	100	87	88	12	.06	93
C_Katılımcı-6	Subspace KNN	100	100	100	100	0	0	100

4.1.3. Göz Kapalı_Dünya_Ay-Zaman Penceresi (GK_D_A-Zaman Penceresi) Durumu

Göz kapalı görevinin, Dünya ve Ay yerçekimi pozisyonunda gerçekleştirildiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların göz kapalı ve çıkarma görevini ayırma başarısında artış olduğu **Tablo 38.** de görülmektedir. 6 katılımcıya ait tüm zaman pencerelerinin, sınıflandırıcı algoritmalarının doğruluk değerlerinin ve performans sonuçların yer aldığı tablolar konu ile ilişkili bölüm altında gösterilmektedir.

Tablo 38. Sedanter, cimnastik ve tüm katılımcılar için kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri

Zaman Penceresi	250	500	750	1000	1500	2000	3000	4000
S_Ortalama	85	92,7	94,8	95,76	97,3	98,13	97,16	99,23
S_Standart Sapma	8,7	6,45	4,86	3,87	2,52	1,61	2,8	0,86
C_Ortalama	76,33	86,86	92,36	94,93	96,4	97,66	99,03	99,8
C_Standart Sapma	3,72	4,66	4,1	2,768	2,81	2,41	0,98	0,34
Genel_Ortalama	80,66	89,78	93,58	95,35	96,85	97,9	98,1	99,51
Genel_Standart Sapma	7,64	5,96	4,24	3,04	2,44	1,85	2,13	0,66

Tablo 39. Sedanter ve cimnastik katılımcıların, GK_D_A-250 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-250	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	67.8	69	67.8	71.1	72.9	73.9	73.9	74.9	73	63.1	75.8*	74.1
S_Katılımcı-2	87	87.5	85.4	90.4	90.4	92.4	92	93.1*	91.6	73.6	92.9	92.1
S_Katılımcı-3	79.5	79.9	77.3	77.3	77.4	84	83.7	86.1*	84.5	77.4	85.8	84
C_Katılımcı-4	73.3	75.1	72.9	76.9	77.6	78.3	78.7	79.9	77.4	60.4	80.6*	79
C_Katılımcı-5	67	66.4	65.2	70.9	71	71.4	71.3	73.6	69.5	58.5	74.7*	72
C_Katılımcı-6	65.4	65.6	66.1	66	68.6	69.6	69.3	73.7*	70.1	61.8	73.1	71.1
GK_D_A-250	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	67.1	72.6	71.3	73.8	72.4	72	73.9	74.3	74.1	72.9	69.5	
S_Katılımcı-2	89.3	92	90.9	93	91.7	92	91.5	92.3	91.7	92.6	87.5	
S_Katılımcı-3	77.9	82.8	83	82.5	82	83.4	83.9	84.3	83.1	83.4	80.2	
C_Katılımcı-4	72.1	74.1	75.5	78.1	73.8	76.2	79.6	79.9	78.3	78.8	75.3	
C_Katılımcı-5	64.6	69	73.1	71.2	68.5	69.3	72.4	71.8	71.7	70.7	66.5	
C_Katılımcı-6	62.9	67.5	65.5	68.7	66.9	67.4	70.8	71	70.1	69.7	67.2	

Tablo 40. Sedanter ve cimnastik katılımcıların, GK_D_A-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-250	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	75.8	78	73	74	26	24	75
S_Katılımcı-2	Quadratic SVM	93.1	93	93	93	.06	.06	93
S_Katılımcı-3	Quadratic SVM	86.1	87	84	85	15	13	85
C_Katılımcı-4	M. Gaussian SVM	80.6	79	81	81	18	19	79
C_Katılımcı-5	M. Gaussian SVM	74.7	76	72	73	27	25	74
C_Katılımcı-6	Quadratic SVM	73.7	80	66	71	33	26	75

Tablo 41. Sedanter ve cimnastik katılımcıların, GK_D_A-500 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	77	79.9	78.8	83.7	84.2	85.3	85.2	85.5	84.1	72.5	86.3*	85.3
S_Katılımcı-2	96.3	96.3	96.3	98.8	98.6	98.8	99	99.2*	99	81.7	99.2	99
S_Katılımcı-3	84.7	87.2	86.3	84.4	85.6	90.4	90.4	92.6*	91.2	82.9	92.3	90.3
C_Katılımcı-4	85.2	86.1	83.4	86.6	87.7	89.2	89.7	90.7	90.6	62.2	92*	89.3
C_Katılımcı-5	73.5	77.2	74.6	82.8	82.8	84	84.3	84.2	83.8	71.4	85.7*	84.4
C_Katılımcı-6	73.9	77.7	72.8	73.6	74.1	80.3	80.5	82.9*	79.9	68.6	82.8	81.1
GK_D_A-500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	77.9	82.6	83.7	83.5	84.3	83.9	84.7	85.1	84.7	84.3	80.2	
S_Katılımcı-2	98.9	99	98.5	98.9	98.9	99.2	97.2	98.5	99	99.2	96.5	
S_Katılımcı-3	85.2	88.3	87.7	88.7	88.7	89.2	91.3	91.3	89.7	89.9	87.2	
C_Katılımcı-4	86.6	88.3	86.3	89.7	87.9	89.4	89.4	89.6	88.1	89.7	86.5	
C_Katılımcı-5	78.3	84.6	84.8	83.6	83.2	84.4	82.8	83.7	83.9	83.9	77.1	
C_Katılımcı-6	76.2	81.4	77.4	81.2	81.2	81.4	79.9	80.1	80.7	80.5	78.1	

Tablo 42. Sedanter ve cimnastik katılımcıların, GK_D_A-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	86.3	87	85	85	14	13	85
S_Katılımcı-2	Quadratic SVM	99.2	99	99	99	0	0	99
S_Katılımcı-3	Quadratic SVM	92.6	93	92	92	.07	.07	92
C_Katılımcı-4	M. Gaussian SVM	92	91	92	92	.07	.08	91
C_Katılımcı-5	M. Gaussian SVM	85.7	87	84	84	15	14	85
C_Katılımcı-6	Quadratic SVM	82.9	84	81	82	18	17	82

Tablo 43. Sedanter ve cimnastik katılımcıların, GK_D_A-750 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-750	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	84.1	83.6	81.9	87.3	87.1	89.3	89.2	88.6	87.5	78.5	90.2*	89.3
S_Katılımcı-2	97.4	97.4	96.9	99.4	99.7	99.6	99.7	99.7	99.8	84.5	99.6	99.4
S_Katılımcı-3	88.4	90.3	87.6	87.9	87.8	92.2	91.7	93.7	92.4	78.4	94.3*	91.9
C_Katılımcı-4	90.4	91.3	92.1	92.7	94.3	94.1	94.4	96.2	96	64.9	96.5*	94.5
C_Katılımcı-5	82.8	83.8	82.1	90.5	90	90.8	91	90.9	91.3	74.8	92.3*	90.5
C_Katılımcı-6	77	78.7	77.1	78.8	78.2	87.7	87.4	88.3*	86.6	73.5	88.3*	86.9
GK_D_A-750	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	86.1	88.4	88.3	86.3	87.9	88.6	88.5	88.5	89	89.5	83.9	
S_Katılımcı-2	99.6	99.1	98.5	99.1	99.1	99.5	50.3	99.6	99.4	99.9*	50.3	
S_Katılımcı-3	90	91.4	90.5	91.7	92.1	92.3	92.5	92.9	91.2	92.8	90.6	
C_Katılımcı-4	93.5	92.8	92	94.5	92.3	94.1	93.5	94.3	93.8	95.2	92.1	
C_Katılımcı-5	87.3	90.9	91	91.6	90.1	91.7	89.7	90	90.9	90.5	83.4	
C_Katılımcı-6	81.7	85.6	83.2	87	85.4	85.3	84.2	86.9	85.8	87	79.7	

Tablo 44. Sedanter ve cimnastik katılımcıların, GK_D_A-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-750	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	90.2	90	89	90	10	.09	90
S_Katılımcı-2	Subspace KNN	99.9	100	99	99	0	0	99
S_Katılımcı-3	M. Gaussian SVM	94.3	95	93	93	.06	.05	93
C_Katılımcı-4	M. Gaussian SVM	96.5	95	97	97	.02	.03	95
C_Katılımcı-5	M. Gaussian SVM	92.3	92	92	92	.07	.07	92
C_Katılımcı-6	M. Gaussian SVM	88.3	89	86	87	13	11	87

Tablo 45. Sedanter ve cimnastik katılımcıların, GK_D_A-1000 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-1000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	85.5	86.1	83.9	89.3	89.3	91.6	91.4	91.7	91.3	81.9	92.4*	90.7
S_Katılımcı-2	98.5	98.5	97.4	99.6	99.7	100*	100*	100*	100*	85.3	99.7	99.4
S_Katılımcı-3	90.4	90.6	89.2	88.9	89.2	91.7	92.8	94	93.9	84.4	94	93.2
C_Katılımcı-4	93.5	93.5	92.8	95.5	96	96.4	96.4	97.1	97.5*	70.2	97.5*	96.8
C_Katılımcı-5	87.9	88.4	87.5	93	92.6	93.5	92.9	94.3	94.6	75.1	95.3*	93.5
C_Katılımcı-6	84.1	85.4	81.9	81.1	81.2	89.6	89.6	92*	91.2	75.8	91.6	89.1
GK_D_A-1000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	88.5	89.6	89.3	90.4	90	90.4	89.3	91	90.6	92.4*	86.3	
S_Katılımcı-2	99.3	99.3	98.6	99	99.3	99.3	50.3	100*	99.6	99.7	50.3	
S_Katılımcı-3	94.3	93.2	90.3	91.4	92.4	93.5	93.6	93.8	92.4	94.9*	91	
C_Katılımcı-4	96	95.4	93.5	97.1	94.3	96.2	95.5	96.7	96.2	97.4	93.5	
C_Katılımcı-5	92.3	94.6	94.2	93.3	93.9	95.1	92.1	95	92.9	95.1	88.7	
C_Katılımcı-6	88.8	89.2	86.3	88.8	87.3	89.4	88.4	90.3	89.1	90.5	86.6	

Tablo 46. Sedanter ve cimnastik katılımcıların, GK_D_A-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-1000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	92.4	91	93	93	.06	.07	91
S_Katılımcı-2	Quadratic SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Subspace KNN	94.9	94	95	95	.04	.05	89
C_Katılımcı-4	M. Gaussian SVM	97.5	97	97	97	.02	.02	97
C_Katılımcı-5	M. Gaussian SVM	95.3	95	94	94	.05	.04	94
C_Katılımcı-6	Quadratic SVM	92	93	90	90	.09	.08	91

Tablo 47. Sedanter ve cimnastik katılımcıların, GK_D_A-1500 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-1500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	88.1	88.1	90	93.3	92.7	94	93.8	95*	91.9	77.5	94.4	94.4
S_Katılımcı-2	98.5	98.5	98.8	99.2	99.8	100*	99.8	100*	100*	85.8	100*	99.2
S_Katılımcı-3	92.5	92.5	92.7	91.2	90.8	92.3	94.4	95	95.2	84.8	96.9*	95
C_Katılımcı-4	96.3	96.3	96.9	97.1	96.9	96.5	96.9	98.1	97.5	65.8	98.5*	97.5
C_Katılımcı-5	92.5	92.5	93.5	95.2	95.2	95	95.8	96	96.9	74.9	96.4	96.4
C_Katılımcı-6	85.9	85.9	82.8	84.6	82.2	91.9	93.2*	92.7	92.3	79	92.5	91.7
GK_D_A-1500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	90	91	91.7	89	91.2	92.7	91.2	93.1	93.5	94.2	90.4	
S_Katılımcı-2	99.6	99.4	97.9	99	99	99.6	49.8	99.8	99.6	100*	49.8	
S_Katılımcı-3	94.6	94.4	91.4	93.7	94.2	96.7	49.9	95.8	94.8	96	49.9	
C_Katılımcı-4	97.5	95.4	94.8	96.5	94	96.9	50.4	97.5	97.5	98.5*	58.7	
C_Katılımcı-5	96	96.4	94.4	96	94.6	97.1	76.6	95.4	95.6	97.5*	76.6	
C_Katılımcı-6	92.1	92.3	89	90.5	91.5	92.3	89.6	92.5	92.7	92.9	85.5	

Tablo 48. Sedanter ve cimnastik katılımcıların, GK_D_A-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-1500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Quadratic SVM	95	95	94	94	.05	.05	94
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	M. Gaussian SVM	96.9	97	96	96	.03	.03	96
C_Katılımcı-4	M. Gaussian SVM	98.5	98	98	98	.01	.01	98
C_Katılımcı-5	Subspace KNN	97.5	96	98	98	.01	.02	96
C_Katılımcı-6	Linear SVM	93.2	93	93	93	.06	.06	93

Tablo 49. Sedanter ve cimnastik katılımcıların, GK_D_A-2000 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-2000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	86.9	86.9	86.4	94.4	95.3	94.2	95	97.2*	96.9	77.8	96.1	94.4
S_Katılımcı-2	99.4	99.4	99.4	99.4	99.4	99.7	99.2	100*	100*	82.2	100*	99.4
S_Katılımcı-3	93.6	93.6	93.9	93	94.2	93.6	95.5	95.8	95.8	87.5	97.2*	95.5
C_Katılımcı-4	97.2	97.2	97.2	97.2	97.5	97.8	98.1	98.9	98.9	69.8	99.7*	98.1
C_Katılımcı-5	94.7	94.7	92.5	96.1	97.2	95	96.1	97.2	96.9	79.3	98	96.6
C_Katılımcı-6	90	90	85.9	86.1	83.7	92.8	92.8	94.7	93.4	80.9	95*	93.9
GK_D_A-2000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	94.4	93.3	92.5	94.2	92.8	93.9	49.7	94.2	94.7	97.2*	66.1	
S_Katılımcı-2	99.4	99.2	99.2	98.6	99.2	99.4	49.7	100*	99.4	99.7	49.7	
S_Katılımcı-3	96.1	95.3	92.5	95.3	93.3	96.4	49.9	95.8	95.3	97.2*	49.9	
C_Katılımcı-4	97	97.5	93.9	97.8	96.4	98.3	50.4	98.6	98.1	98.9	50.4	
C_Katılımcı-5	97.5	98.3*	95.8	96.4	97.2	98.3*	49.7	97.2	96.9	98.3*	58.4	
C_Katılımcı-6	92	93.4	89.5	93.6	92.2	94.2	66.2	93.1	93.6	93.9	80.9	

Tablo 50. Sedanter ve cimnastik katılımcıların, GK_D_A-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-2000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Quadratic SVM	97.2	97	97	97	.02	.02	97
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	M. Gaussian SVM	97.2	97	97	97	.02	.02	97
C_Katılımcı-4	M. Gaussian SVM	99.7	99	100	100	0	0	99
C_Katılımcı-5	Subspace KNN	98.3	97	98	98	.01	.01	97
C_Katılımcı-6	M. Gaussian SVM	95	95	94	95	.05	.04	95

Tablo 51. Sedanter ve cimnastik katılımcıların, GK_D_A-3000 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-3000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	73.3	73.3	74.4	87.8	85.6	88.9	91.1	91.1	94.4*	75.6	90	84.4
S_Katılımcı-2	97.9	97.9	97.9	98.7	100*	100*	99.6	100*	100*	85.8	100*	99.6
S_Katılımcı-3	92.9	92.9	92.9	95.8	95	94.5	95.8	96.6	96.2	86.6	96.2	95.8
C_Katılımcı-4	98.3	98.3	98.3	97.9	98.3	98.3	97.9	99.6*	99.6*	69.6	99.6*	98.8
C_Katılımcı-5	93.7	93.7	93.3	96.6	98.3	99.2	98.7	99.6*	99.2	77.7	98.7	97.5
C_Katılımcı-6	90.8	90.8	89.2	89.2	85	93.3	97.9*	97.9*	97.1	79.6	97.9*	95.8
GK_D_A-3000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	87.8	87.8	50	88.9	86.7	93.3	50	86.7	88.9	93.3	50	
S_Katılımcı-2	100*	99.6	99.2	99.6	99.2	100*	49.8	99.2	99.2	100*	49.8	
S_Katılımcı-3	94.5	95.8	92	94.5	95	95.8	49.6	95.8	96.2	97.1*	49.6	
C_Katılımcı-4	98.3	97.5	95.4	98.3	97.1	97.9	49.6	97.9	98.8	99.6*	49.6	
C_Katılımcı-5	99.6*	98.3	95.8	97.5	98.7	98.3	49.6	98.3	98.7	99.6*	49.6	
C_Katılımcı-6	95.4	97.1	89.2	95	96.2	97.9	49.6	95	97.1	96.7	49.6	

Tablo 52. Sedanter ve cimnastik katılımcıların, GK_D_A-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-3000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Cubic SVM	94.4	97	99	99	0	.01	97
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Subspace KNN	97.1	95	98	98	.01	.02	96
C_Katılımcı-4	M. Gaussian SVM	99.6	99	100	100	0	0	99
C_Katılımcı-5	Subspace KNN	99.6	99	100	100	0	0	99
C_Katılımcı-6	M. Gaussian SVM	97.9	99	96	96	.03	.02	97

Tablo 53. Sedanter ve cimnastik katılımcıların, GK_D_A-4000 durumuna ait sınıflandırma sonuçları (%)

GK_D_A-4000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	91.5	91.5	92	97.2	95.5	98.3	98.3	98.3	98.3	75	98.9	97.2
S_Katılımcı-2	98.9	98.9	98.9	99.4	100*	100*	100*	100*	100*	87.6	100*	99.4
S_Katılımcı-3	97.2	97.2	97.2	97.2	96	95.5	96	96	97.2	84.2	98.3*	96
C_Katılımcı-4	96.6	96.6	96.6	100*	99.4	98.3	99.4	99.4	99.4	64	99.4	98.9
C_Katılımcı-5	98.3	98.3	98.3	97.7	98.3	99.4	99.4	100*	99.4	73.9	99.4	98.3
C_Katılımcı-6	89.3	89.3	91	93.8	89.3	96.6	98.9	98.9	96.6	84.8	99.4*	95.5
GK_D_A-4000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	97.2	96.6	91.5	96	95.5	98.3	48.9	96.6	97.2	99.4*	48.9	
S_Katılımcı-2	100*	99.4	98.3	100*	99.4	100*	49.2	99.4	99.4	100*	49.2	
S_Katılımcı-3	98.3	96	91	95.5	96	97.7	49.2	96	97.2	97.7	49.2	
C_Katılımcı-4	99.4	97.8	94.9	98.3	96.6	99.4	50.6	99.4	99.4	100*	50.6	
C_Katılımcı-5	99.4	99.4	93.2	97.7	98.3	99.4	48.9	97.7	99.4	100*	48.9	
C_Katılımcı-6	96.1	97.8	85.4	95.5	97.2	98.3	50.6	96.6	98.9	97.8	75.3	

Tablo 54. Sedanter ve cimnastik katılımcıların, GK_D_A-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

GK_D_A-4000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Subspace KNN	99.4	98	100	100	0	0	98
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	M. Gaussian SVM	98.3	97	98	98	.01	.01	97
C_Katılımcı-4	Subspace KNN	100	100	100	100	0	0	100
C_Katılımcı-5	Subspace KNN	100	100	100	100	0	0	100
C_Katılımcı-6	M. Gaussian SVM	99.4	100	98	98	.01	0	98

4.1.4. Çıkarma_Dünya_Ay-Zaman Penceresi (Ç_D_A-Zaman Penceresi) Durumu

Zihinden çıkarma görevinin, Dünya ve Ay yerçekimi pozisyonunda gerçekleştirildiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların göz kapalı ve çıkarma görevini ayırma başarısında artış olduğu **Tablo 55.** de görülmektedir. 6 katılımcıya ait tüm zaman pencerelerinin, sınıflandırıcı algoritmalarının doğruluk değerlerinin ve performans sonuçların yer aldığı tablolar konu ile ilişkili bölüm altında gösterilmektedir.

Tablo 55. Sedanter, cimmastik ve tüm katılımcılar için kullanılan her zaman pencerelerindeki en yüksek sınıflandırma başarısının ortalama ve standart sapma değeri

Zaman Penceresi	250	500	750	1000	1500	2000	3000	4000
S_Ortalama	85,8	94,83	96,27	97,43	98,47	99	99	100
S_Standart Sapma	8,8	4,07	3,92	3,02	1,42	1,11	0,69	0
C_Ortalama	78,77	87,43	93,7	98,07	98,07	99,23	100	100
C_Standart Sapma	2,61	3,19	3,29	1,19	1,19	0,75	0	0
Genel_Ortalama	82,28	91,13	94,98	97,75	98,27	99,12	99,8	100
Genel_Standart Sapma	6,97	5,21	3,53	2,08	1,19	0,86	0,49	0

Tablo 56. Sedanter ve cimnastik katılımcıların, Ç_D_A-250 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-250	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	66.4	71.2	70.2	75	75.4	75.6	76.5*	75.5	71.7	54.3	76	75.9
S_Katılımcı-2	86.6	88.2	85.3	85.5	86.6	92.2	93.4	93.3	91.9	74	94*	92.2
S_Katılımcı-3	79.2	80.2	78.3	82	83.6	85.1	85.2	85.2	83.5	71.3	86.9*	85
C_Katılımcı-4	63.4	66.9	68.1	73.5	73.6	74.3	74.3	79.8*	74	57.5	78.3	73.6
C_Katılımcı-5	71.4	74.1	73.5	72.4	74	74.5	75.2	79.2	76.9	52.8	80.7*	76.1
C_Katılımcı-6	65.7	68	65.9	67.6	67.6	73.9	74.1	73.8	70.1	61.3	75.8*	73.5
Ç_D_A-250	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	66.7	70.7	73.6	70.9	69.1	71.2	76.2	75.4	75.9	72.7	71.7	
S_Katılımcı-2	88.8	91.3	88.1	90.8	91.6	91.5	90.8	91.5	92.1	92.8	88	
S_Katılımcı-3	78.5	82.3	82.5	84.2	81.8	83.6	83.5	84.8	84.2	83.6	80.6	
C_Katılımcı-4	67.1	71.1	71.8	74.5	70.3	72.1	73.2	73.9	73.4	74	66.4	
C_Katılımcı-5	70.1	74.8	74.5	76.5	74.9	75.5	78.6	78.9	75.5	78.1	75	
C_Katılımcı-6	64.9	69	69.8	70.4	68.1	69.2	72.2	72.8	73.5	70.7	69	

Tablo 57. Sedanter ve cimnastik katılımcıların, Ç_D_A-250 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-250	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Linear SVM	76.5	80	72	75	27	23	77
S_Katılımcı-2	M. Gaussian SVM	94	94	94	.05	.05	94	1
S_Katılımcı-3	M. Gaussian SVM	86.9	88	85	85	14	13	86
C_Katılımcı-4	Quadratic SVM	79.8	76	82	81	17	20	78
C_Katılımcı-5	M. Gaussian SVM	80.7	81	80	80	19	19	80
C_Katılımcı-6	M. Gaussian SVM	75.8	78	72	74	27	24	75

Tablo 58. Sedanter ve cimnastik katılımcıların, Ç_D_A-500 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	84.4	85.9	87.2	87.2	86.8	89.2	89.6	89.6	87.7	56.8	91*	88.1
S_Katılımcı-2	96.8	96.8	96.4	96.8	96.3	97.9	99.1*	98.3	98.5	83.1	98.5	98.5
S_Katılımcı-3	85.6	86.2	85	90.1	91.1	91.8	91.4	92.8	92.6	75.1	94.4*	93
C_Katılımcı-4	81.2	83.5	85.4	83.1	85.4	83.8	84.8	87.8	85.7	63.1	88*	84.2
C_Katılımcı-5	82.1	82.7	82.7	83.1	83.1	87.3	87.6	89.4	89.5	52.9	90.3*	86.7
C_Katılımcı-6	71.5	73.4	71.7	74.5	72.4	84*	82.7	82.3	82.9	68.1	83.7	82.5
Ç_D_A-500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	82.6	86.6	83.9	85.2	87.2	87.4	89	89.6	87.7	87.4	87.2	
S_Katılımcı-2	98.5	97.4	96.3	97	97.2	97.4	96.6	96.6	98.7	98.7	96.6	
S_Katılımcı-3	88.3	92	88.3	89.3	91.2	91.8	89.7	92	92.2	90.5	86.6	
C_Katılımcı-4	78.5	80.6	79.8	84.6	79.3	82.7	83.3	85.9	84.6	83.1	83.7	
C_Katılımcı-5	82.9	87.3	83.3	88	86.5	88	88.8	87.5	87.8	88.8	84	
C_Katılımcı-6	75.5	76.8	76.4	80.2	77.8	77.4	79.3	79.1	83.8	79.3	73.8	

Tablo 59. Sedanter ve cimnastik katılımcıların, Ç_D_A-500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	91	91	91	91	.08	.08	91
S_Katılımcı-2	Linear SVM	99.1	98	99	99	0	0	98
S_Katılımcı-3	M. Gaussian SVM	94.4	94	93	94	.05	.05	94
C_Katılımcı-4	M. Gaussian SVM	88	87	88	88	11	11	87
C_Katılımcı-5	M. Gaussian SVM	90.3	91	92	92	.07	.08	93
C_Katılımcı-6	Logis Reg	84	85	82	83	17	15	83

Tablo 60. Sedanter ve cimnastik katılımcıların, Ç_D_A-750 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-750	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	89	89	88.7	89	88.7	90.6	91.7	91.2	88.7	55	92*	89.8
S_Katılımcı-2	98.3	98.3	98.3	98.6	98.6	99.7*	99.4	99.4	99.7	86.2	99.4	99.4
S_Katılımcı-3	89.7	89.7	88.3	93	94.4	93.8	95.3	95.9	96.5	85.6	97.1*	95
C_Katılımcı-4	92.5	92.5	92	92.5	92.2	92	93.1	93.4	92.5	64.9	94.8*	92.8
C_Katılımcı-5	90.5	90.5	89.7	88.5	90.3	92.3	92	95.1	95.7	56.4	95.4	90.8
C_Katılımcı-6	79.7	79.1	80.5	80.2	78.8	88.5	89.4	89.7	88.3	69.1	90*	89.7
Ç_D_A-750	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	84.5	88.1	84.8	85.6	87.8	89.5	59.4	91.7	90.9	89.2	81.8	
S_Katılımcı-2	98.3	97.7	96.6	97.7	97.7	98	49.4	99.2	99.7*	99.2	49.4	
S_Katılımcı-3	93.8	92.7	83.3	93.3	92.7	94.7	65.7	95.3	95	95.6	82.4	
C_Katılımcı-4	88.5	90.5	87.6	90.2	88.5	91.4	49.7	94	93.1	94	49.7	
C_Katılımcı-5	92.3	89.7	84	90.8	88	92.3	60.2	92.8	90.8	96.3*	50.7	
C_Katılımcı-6	83.1	86.2	84.2	87.7	86.5	86.5	86.2	85.4	89.4	88	81.1	

Tablo 61. Sedanter ve cimnastik katılımcıların, Ç_D_A-750 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-750	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	92	90	93	93	.06	.08	91
S_Katılımcı-2	Subspace Dis	99.7	99	100	100	0	0	99
S_Katılımcı-3	M. Gaussian SVM	97.1	96	97	97	.02	.02	96
C_Katılımcı-4	M. Gaussian SVM	94.8	94	94	94	.05	.05	94
C_Katılımcı-5	Subspace KNN	96.3	96	96	96	.03	.03	96
C_Katılımcı-6	M. Gaussian SVM	90	91	93	89	11	10	89

Tablo 62. Sedanter ve cimnastik katılımcıların, Ç_D_A-1000 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-1000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	91.5	91.5	92.3	90.4	91.9	91.9	94.1*	93.8	91.5	56.6	93.4	90.1
S_Katılımcı-2	98.5	98.5	98.5	98.9	98.5	99.6	99.2	99.6	100*	80.9	99.6	98.9
S_Katılımcı-3	94.7	94.7	94.7	95.9	94.7	97.6	96.4	98.2*	98.2*	71	97.6	96.4
C_Katılımcı-4	98.9	98.9	98.9	97.7	97.7	98.9	98.9	99.4*	98.9	60.3	97.7	97.7
C_Katılımcı-5	87.9	87.9	87.3	91.3	92.5	96.5	94.8	96.5	96	56.1	95.4	90.8
C_Katılımcı-6	84.4	84.4	85	85.5	86.7	94.8	94.8	94.8	94.2	65.9	97.1*	93.1
Ç_D_A-1000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	87.9	89	85.3	87.1	88.2	90.1	51.1	93.8	92.3	90.4	75.4	
S_Katılımcı-2	99.2	97.7	96.9	97.3	97.7	98.1	50.8	98.9	99.2	98.9	50.8	
S_Katılımcı-3	94.7	95.9	67.5	94.7	95.3	95.9	50.3	97.6	96.4	97.6	50.3	
C_Katılımcı-4	93.7	94.8	90.8	93.7	94.3	96	48.9	98.3	97.7	97.7	48.9	
C_Katılımcı-5	93.6	89.6	82.7	92.5	89	93.1	50.9	95.4	93.1	97.7*	64.7	
C_Katılımcı-6	91.3	91.9	82.1	90.2	89	90.8	50.9	90.8	95.4	93.6	57.8	

Tablo 63. Sedanter ve cimnastik katılımcıların, Ç_D_A-1000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-1000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Linear SVM	94.1	92	96	96	.03	.05	93
S_Katılımcı-2	Cubic SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Cubic SVM	98.2	97	100	100	0	.01	98
C_Katılımcı-4	Quadratic SVM	99.4	96	96	96	.03	.03	96
C_Katılımcı-5	Subspace KNN	97.7	95	98	98	.01	.03	96
C_Katılımcı-6	M. Gaussian SVM	97.1	93	91	91	.08	.07	91

Tablo 64. Sedanter ve cimnastik katılımcıların, Ç_D_A-1500 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-1500	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	91.7	91.7	91.7	93.9	94.4	96.1	97.2*	96.1	95.6	56.1	97.2*	93.3
S_Katılımcı-2	98.3	98.3	98.3	98.8	100*	100*	100*	100*	100*	75.7	99.4	98.3
S_Katılımcı-3	94.7	94.7	94.7	95.9	94.7	97.6	96.4	98.2*	98.2*	71	97.6	96.4
C_Katılımcı-4	98.9	98.9	98.9	97.7	97.7	98.9	98.9	99.4*	98.9	60.3	97.7	97.7
C_Katılımcı-5	87.9	87.9	87.3	91.3	92.5	96.5	94.8	96.5	96	56.1	95.4	90.8
C_Katılımcı-6	84.4	84.4	85	85.5	86.7	94.8	94.8	94.8	94.2	65.9	97.1*	93.1
Ç_D_A-1500	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	93.3	92.2	86.1	90.6	91.7	93.9	51.1	96.1	95	95.6	51.1	
S_Katılımcı-2	98.8	98.3	96	98.3	98.3	98.3	50.9	99.4	100*	100*	50.9	
S_Katılımcı-3	94.7	95.9	67.5	94.7	95.3	95.9	50.3	97.6	96.4	97.6	50.3	
C_Katılımcı-4	93.7	94.8	90.8	93.7	94.3	96	48.9	98.3	97.7	97.7	48.9	
C_Katılımcı-5	93.6	89.6	82.7	92.5	89	93.1	50.9	95.4	93.1	97.7*	64.7	
C_Katılımcı-6	91.3	91.9	82.1	90.2	89	90.8	50.9	90.8	95.4	93.6	57.8	

Tablo 65. Sedanter ve cimnastik katılımcıların, Ç_D_A-1500 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-1500	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	97.2	96	97	97	.02	.02	96
S_Katılımcı-2	Cubic SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Cubic SVM	98.2	96	100	100	0	.01	97
C_Katılımcı-4	Quadratic SVM	99.4	100	98	98	.01	0	98
C_Katılımcı-5	Subspace KNN	97.7	95	100	100	0	.02	97
C_Katılımcı-6	M. Gaussian SVM	97.1	97	96	96	.03	.02	96

Tablo 66. Sedanter ve cimnastik katılımcıların, Ç_D_A-2000 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-2000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	97.8	97	98	98	.01	.02	97
S_Katılımcı-2	Cubic SVM	100	100	100	100	0	0	100
S_Katılımcı-3	Subspace KNN	99.2	100	98	98	.01	0	98
C_Katılımcı-4	Linear SVM	100	100	100	100	0	0	1
C_Katılımcı-5	M. Gaussian SVM	99.2	98	100	100	0	0	98
C_Katılımcı-6	Logis Reg	98.5	98	98	98	.01	.01	98

Tablo 67. Sedanter ve cimnastik katılımcıların, Ç_D_A-2000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-2000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	M. Gaussian SVM	97.8	97	98	98	.01	.02	97
S_Katılımcı-2	Cubic SVM	100	1	1	1	0	0	1
S_Katılımcı-3	Subspace KNN	99.2	1	98	98	.01	0	98
C_Katılımcı-4	Linear SVM	100	1	1	1	0	0	1
C_Katılımcı-5	M. Gaussian SVM	99.2	98	1	1	0	0	98
C_Katılımcı-6	Logis Reg	98.5	98	98	98	.01	.01	98

Tablo 68. Sedanter ve cimnastik katılımcıların, Ç_D_A-3000 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-3000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	94.3	94.3	94.3	96.6	98.9	100*	100*	96.6	95.5	59.1	97.7	95.5
S_Katılımcı-2	98.8	98.8	98.8	100*	100*	100*	100*	100*	100*	81.2	100*	100*
S_Katılımcı-3	97.6	97.6	97.6	95.2	98.8*	98.8*	97.6	98.8*	98.8*	77.1	98.8*	96.4
C_Katılımcı-4	98.8	98.8	98.8	97.7	98.8	98.8	100*	98.8	98.8	57	100*	100*
C_Katılımcı-5	94.1	94.1	94.1	97.6	96.5	98.8	98.8	98.8	98.8	63.5	98.8	96.5
C_Katılımcı-6	92.9	92.9	92.9	90.6	91.8	100*	100*	98.8	100*	60	97.6	91.8
Ç_D_A-3000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	93.2	90.9	51.1	88.6	93.2	95.5	51.1	98.9	100*	100*	58	
S_Katılımcı-2	100*	98.8	47.1	97.6	98.8	100*	47.1	100*	100*	100*	47.1	
S_Katılımcı-3	95.2	96.4	50.6	96.4	96.4	97.6	50.6	97.6	96.4	98.8*	50.6	
C_Katılımcı-4	95.3	95.3	47.7	95.3	94.2	97.7	47.7	98.8	98.8	98.8	58.1	
C_Katılımcı-5	98.8	96.5	47.1	96.5	94.1	97.6	47.1	95.3	97.6	100*	47.1	
C_Katılımcı-6	97.6	91.8	47.1	87.1	92.9	94.1	47.1	92.9	100*	96.5	47.1	

Tablo 69. Sedanter ve cimnastik katılımcıların, Ç_D_A-3000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-3000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Logis Reg	100	100	100	100	0	0	100
S_Katılımcı-2	Logis Reg	100	100	100	100	0	0	100
S_Katılımcı-3	Logis Reg	98.8	100	97	97	.02	.01	98
C_Katılımcı-4	Linear SVM	100	100	100	100	0	0	100
C_Katılımcı-5	Subspace KNN	100	100	100	100	0	0	100
C_Katılımcı-6	Linear SVM	100	100	100	100	0	0	100

Tablo 70. Sedanter ve cimnastik katılımcıların, Ç_D_A-4000 durumuna ait sınıflandırma sonuçları (%)

Ç_D_A-4000	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
S_Katılımcı-1	100*	100*	100*	96.9	98.5	98.5	95.4	96.9	98.5	56.9	95.4	95.4
S_Katılımcı-2	100*	100*	100*	100*	98.4	100*	100*	100*	100*	85.9	100*	100*
S_Katılımcı-3	91.8	91.8	91.8	98.4	98.4	98.4	98.4	98.4	98.4	68.9	100*	98.4
C_Katılımcı-4	96.8	96.8	96.8	98.4	100	96.8	96.8	96.8	95.2	66.1	100*	96.8
C_Katılımcı-5	88.7	88.7	88.7	96.8	100*	91.9	93.5	96.8	96.8	82.3	95.2	95.2
C_Katılımcı-6	93.7	93.7	93.7	95.2	95.2	98.4	100*	100*	100*	68.3	100*	96.8
Ç_D_A-4000	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
S_Katılımcı-1	92.3	93.8	46.2	92.3	93.8	95.4	46.2	100*	100*	95.4	46.2	
S_Katılımcı-2	100*	98.4	46.9	98.4	98.4	100*	46.9	100*	98.4	100*	46.9	
S_Katılımcı-3	96.7	91.8	50.8	96.7	88.5	98.4	50.8	98.4	98.4	98.4	50.8	
C_Katılımcı-4	100*	91.9	48.4	91.9	93.5	98.4	48.4	100*	100*	95.2	48.4	
C_Katılımcı-5	96.8	96.8	48.4	95.2	96.8	95.2	48.4	96.8	95.2	100*	48.4	
C_Katılımcı-6	98.4	93.7	47.6	93.7	95.2	98.4	47.6	100*	100*	100*	54	

Tablo 71. Sedanter ve cimnastik katılımcıların, Ç_D_A-4000 durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)

Ç_D_A-4000	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
S_Katılımcı-1	Bagged Trees	100	100	100	100	0	0	100
S_Katılımcı-2	M. Gaussian SVM	100	100	100	100	0	0	100
S_Katılımcı-3	M. Gaussian SVM	100	100	100	100	0	0	100
C_Katılımcı-4	M. Gaussian SVM	100	100	100	100	0	0	100
C_Katılımcı-5	Subspace KNN	100	100	100	100	0	0	100
C_Katılımcı-6	M. Gaussian SVM	100	100	100	100	0	0	100

4.2. Tüm Katılımcılardan Oluşan Veri Seti, Yaklaşık Entropi Sınıflandırması

Tüm katılımcıların tek bir veri seti içinde olduğu ve tüm zaman pencereleri için -250, 500, 750, 1000, 1500, 2000, 3000, 4000- yaklaşık entropi değerinin hesaplandığı bu kısım dört alt kısma ayrılmaktadır: İlk kısım tüm katılımcıların çıkarma görevini dünya ve ay koşulunda gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Tüm Katılımcılar_Çıkarma_Dünya_Ay (TK_Ç_D_A) Durumu’, ikinci kısım tüm katılımcıların göz kapalı görevini dünya ve ay koşulunda gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Tüm Katılımcılar_Göz Kapalı_Dünya_Ay (TK_GK_D_A) Durumu’, üçüncü kısım tüm katılımcıların dünya koşulunda çıkarma ve göz kapalı görevini gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Tüm Katılımcılar_Dünya_Çıkarma_Göz kapalı (TK_D_Ç_GK) Durumu’, son olarak tüm katılımcıların ay koşulunda çıkarma ve göz kapalı görevini gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Tüm Katılımcılar_Ay_Çıkarma_Göz kapalı (TK_A_Ç_GK) Durumu’ şeklindedir.

4.2.1. Tüm Katılımcılar_Çıkarma_Dünya_Ay (TK_Ç_D_A) Durumu

Tüm katılımcıların, çıkarma görevini dünya ve ay yerçekimi pozisyonunda gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırma algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların dünya ve ay koşulunda çıkarma görevini ayırma başarısında artış olduğu **Tablo 72.** de, sınıflandırma performans sonuçları ise **Tablo 73.** de gösterilmektedir. Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 23.-30.**’ da gösterilmiştir.


Ortalama ve standart sapma entropi şekillerinde dikkat çeken ve sınıflandırıcı performansına önemli ölçüde etki ettiği düşünülen F3 ve C3 kanalı için tez çalışmasından bağımsız yapılan frekans bantlarına ait analiz sonucu tezin EK3 bölümünde sunulmaktadır.

Tablo 72. Tüm zaman pencereleri için TK_Ç_D_A durumuna ait sınıflandırma sonuçları (%)


TK_Ç_D_A	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	66.6	65.2	62.5	63.9	66	69	68.9	72.3	72.9	66.8	75.1*	70.1
500	73.4	70.5	69.7	68.9	72.6	75.9	76	81.1	83.4	77.3	84	77.1
750	80.3	76.1	71.4	69.6	75.1	78.6	78.2	85.8	86.1	82.2	88.1	78.2
1000	82.4	79.3	74.3	70.8	75.6	80.9	80.3	86.9	89.1	79.8	89.2	88.4
1500	81.5	81.8	73.9	71.6	75.9	82.5	82.4	89.5	90.4	87.6	91.5	79.3
2000	85.5	86.4	75.7	71.5	76.3	82.9	82.2	91.7	93.6	93.6	93.1	78.2
3000	84.6	85	75.4	71.2	77.1	85.5	85.7	93.4	94.7	90.6	94	78.8
4000	83.6	83.3	71.7	72.3	74.7	86.3	85.4	94.9	96.1	91.4	96.4	78.9
TK_Ç_D_A	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	67.5	70.8	72	72	70.1	71.8	69.3	73.3	68.5	71.9	65.2	
500	79.7	83.5	80.8	82.5	82.8	84.8*	78	82.6	74.1	83.5	70.5	
750	87.6	87.5	84.5	85.8	86.4	89.1*	85	88.3	76.1	89	75.7	
1000	83.3	87.8	87.5	90.6	85.9	90.6	85.9	90.6	77.7	91.4*	79.2	
1500	93.1	90.5	81.1	89.2	89.8	92.3	88.2	90.7	79	93.2*	80.7	
2000	95.1	92.1	73.7	91	91.5	93.9	91.2	91.8	78.7	95.9*	85.9	
3000	97.2	93.8	67.5	92.9	92.5	95.9	91.5	92.7	80.1	97.4*	84.8	
4000	97.3	94.6	65.5	92.9	93.8	97	83.6	94.9	81	98.5*	84.2	

Tablo 73. Tüm zaman pencereleri için TK_Ç_D_A durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


TK_Ç_D_A	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	75.1	73	76	75	23	24	73
500	Weighted KNN	84.8	84	85	85	14	15	84
750	Weighted KNN	89.1	87	90	90	.09	10	88
1000	Subspace KNN	91.4	88	94	93	.05	.08	87
1500	Subspace KNN	93.2	90	96	95	.03	.06	92
2000	Subspace KNN	95.9	95	96	96	.03	.04	95
3000	Subspace KNN	97.4	97	97	97	.02	.02	97
4000	Subspace KNN	98.5	98	98	98	.01	.01	98




Şekil 23. Tüm kanallar için TK_Ç_D_A-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 24. Tüm kanallar için TK_Ç_D_A-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 25. Tüm kanallar için TK_Ç_D_A-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 26. Tüm kanallar için TK_Ç_D_A-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 27. Tüm kanallar için TK_Ç_D_A-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 28. Tüm kanallar için TK_Ç_D_A-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 29. Tüm kanallar için TK_Ç_D_A-3000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 30. Tüm kanallar için TK_Ç_D_A-4000 durumuna ait ortalama ve standart sapma entropi değeri

4.2.2. Tüm Katılımcılar_Göz Kapalı_Dünya_Ay (TK_GK_D_A) Durumu

Tüm katılımcıların, göz kapalı görevini dünya ve ay yerçekimi pozisyonunda gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların dünya ve ay koşulunda göz kapalı görevini ayırma başarısında artış olduğu **Tablo 74.** de, sınıflandırma performans sonuçları ise **Tablo 75.** de gösterilmektedir.

Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 31.-38.**’ de gösterilmiştir. Ortalama ve standart sapma entropi şekillerinde dikkat çeken ve sınıflandırıcı performansına önemli ölçüde etki ettiği düşünülen F3 ve C3 kanalı için tez çalışmasından bağımsız yapılan frekans bantlarına ait analiz sonucu tezin EK3 bölümünde sunulmaktadır.

4.2.3. Tüm Katılımcılar_Dünya_Çıkarma_Göz kapalı (TK_D_Ç_GK) Durumu

Tüm katılımcıların, dünya yerçekimi pozisyonunda çıkarma ve göz kapalı görevini gerçekleştirdiği sırada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların dünya koşulunda, göz kapalı ve çıkarma görevini ayırma başarısında artış olduğu **Tablo 76.** de, sınıflandırma performans sonuçları ise **Tablo 77.** de gösterilmektedir.


Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 39.-46.**’ de gösterilmiştir.

Tablo 74. Tüm zaman pencereleri için TK_GK_D_A durumuna ait sınıflandırma sonuçları (%)


TK_GK_D_A	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	65.5	64.4	60.7	62.4	64.5	66.6	66.7	71.5	72	61.5	73.4*	69.5
500	74.5	72.5	70.7	68.1	70.4	75.4	75.6	81.5	82.7	72.0	84*	78
750	81.1	78.8	73.5	70.2	72.9	79.4	79.6	86.3	87.5	80.1	88.8	81.5
1000	83.1	80.2	76.6	70.5	73	81.8	81.8	89	90.2	84.7	91	83.3
1500	85.5	81.2	75.2	71.4	73	84	84.3	90.8	92	87.9	92.5	86.3
2000	86	82.5	75.4	72.2	73.5	85.5	85.2	92.7	93.9	91.1	93.9	86.5
3000	89.1	86.6	74.8	72.8	73.2	86.8	87	94.3	94.8	93.7	95	88.4
4000	89.2	85.8	75.7	72.9	73.5	86.9	87.5	95.2	95.7	93.2	95.2	87.9
TK_GK_D_A	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	65.5	69.8	71.2	70.8	69.7	70.2	67.6	71.1	66.1	70.3	64.4	
500	79.2	82.6	82.2	83.2	82.2	83.3	78.1	82.6	74.3	82.4	72.5	
750	87.3	88.4	87.4	88.3	88.1	89.4	84.5	87.7	79.1	89.7*	78.8	
1000	90.3	91.5	89.3	90.3	90.7	92.4*	86.4	89.9	80.5	92.3	80.2	
1500	93	93.3	90.6	92.2	92.6	94	89.4	92.4	83.8	94.7*	81.2	
2000	94.8	94.9	91.7	93.2	93.7	95.5	91.6	93.9	84.5	96.3*	82.3	
3000	96.4	95.8	93.5	95.2	95	96.4	93.5	95.1	86.8	97.8*	86.1	
4000	97.6	96.7	92	96.1	95.7	97.5	94.3	96.4	85.9	98.7*	85.4	

Tablo 75. Tüm zaman pencereleri için TK_GK_D_A durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


TK_GK_D_A	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	73.4	78	68	71	31	26	74
500	M. Gaussian SVM	84	85	82	83	17	15	83
750	Subspace KNN	89.7	93	91	91	.08	.07	91
1000	Weighted KNN	92.4	93	95	95	.04	.05	93
1500	Subspace KNN	94.7	95	96	96	.03	.03	95
2000	Subspace KNN	96.3	97	98	98	.01	.02	97
3000	Subspace KNN	97.8	98	98	98	.01	.01	98
4000	Subspace KNN	98.7	98	98	98	.01	.01	98




Şekil 31. Tüm kanallar için TK_GK_D_A-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 32. Tüm kanallar için TK_GK_D_A-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 33. Tüm kanallar için TK_GK_D_A-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 34. Tüm kanallar için TK_GK_D_A-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 35. Tüm kanallar için TK_GK_D_A-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 36. Tüm kanallar için TK_GK_D_A-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 37. Tüm kanallar için TK_GK_D_A-3000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 38. Tüm kanallar için TK_GK_D_A-4000 durumuna ait ortalama ve standart sapma entropi değeri

Tablo 76. Tüm zaman pencereleri için TK_D_Ç_GK durumuna ait sınıflandırma sonuçları (%)


TK_D_Ç_GK	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	59.2	57.9	59.5	58.7	59.9	62.2	61.8	64.9	64.4	62.2	67.3*	63.1
500	67.7	67.2	66.9	62.7	62.6	67.7	67.7	72.9	74	67.7	76.2*	68.1
750	72.2	69.4	67.5	62.6	63.3	69	68.8	77.4	79.9	75.8	81.2	69.4
1000	74.9	69.2	67.7	63.5	64	69.7	70.3	78.6	81.4	78.3	82.8	70.6
1500	78.4	75.5	70.9	64.5	64.3	68	68.8	83.4	85.5	79.4	84.2	71.2
2000	81.1	77.5	70.9	63.8	64.5	68.9	70.1	83.9	85.3	84.6	86.6	70.5
3000	82.1	82.3	70.9	63.7	64.1	68.6	67.9	87.6	88.2	84.6	88.7	71.2
4000	80.4	80.4	74.1	63.4	63.7	70.2	70.2	87.2	90.8	87.5	87.2	70.5
TK_D_Ç_GK	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	62	64.7	65.7	66.5	64	65.7	61.6	64.1	61.4	64.5	58	
500	72.7	74	73.3	74.1	73.1	75	69.9	74.2	66.7	75	67.2	
750	83.6	80	75.6	81.3	79.7	82.2	73.1	79	67.6	83.8*	69.4	
1000	83.5	81.9	76.5	81.2	81.5	83.5	76.5	80.5	68.8	85.6*	69.5	
1500	86	85.8	74.4	82.6	84.6	86.7	81.6	84.6	70.3	88.9*	72.9	
2000	89.8	86.2	73.3	84.2	84.7	89	84.5	85	70.2	91.5*	76.8	
3000	91.5	87	69.9	85	86.5	87.8	85.9	87.4	69.4	91.9*	78.4	
4000	92.9	86.3	65.8	84.2	84.8	91.4	88.7	91.1	69.6	94.9*	81	

Tablo 77. Tüm zaman pencereleri için TK_D_Ç_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


TK_D_Ç_GK	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	67.3	69	65	66	34	32	67
500	M. Gaussian SVM	76.2	76	76	76	23	23	76
750	Subspace KNN	83.8	83	84	84	15	16	83
1000	Subspace KNN	85.6	84	86	86	13	14	84
1500	Subspace KNN	88.9	89	88	88	11	11	88
2000	Subspace KNN	91.5	92	90	90	.09	.08	90
3000	Subspace KNN	91.9	91	92	92	.07	.08	91
4000	Subspace KNN	94.9	94	95	95	.04	.05	94




Şekil 39. Tüm kanallar için TK_D_Ç_GK-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 40. Tüm kanallar için TK_D_Ç_GK-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 41. Tüm kanallar için TK_D_Ç_GK-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 42. Tüm kanallar için TK_D_Ç_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 43. Tüm kanallar için TK_D_Ç_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 44. Tüm kanallar için TK_D_Ç_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 45. Tüm kanallar için TK_D_Ç_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 46. Tüm kanallar için TK_D_Ç_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri

4.2.4. Tüm Katılımcılar_Ay_Çıkarma_Göz kapalı (TK_A_Ç_GK) Durumu

Tüm katılımcıların, Ay yerçekimi pozisyonunda çıkarma ve göz kapalı görevini gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların ay koşulunda, göz kapalı ve çıkarma görevini ayırma başarısında artış olduğu **Tablo 78.** de, sınıflandırma performans sonuçları ise **Tablo 79.** de gösterilmektedir.

Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 47.-54.**’ de gösterilmiştir.

4.3. Cimnastik ve Sedanter Grubun Oluşturduğu Veri Seti, Yaklaşık Entropi Sınıflandırması


Cimnastik ve sedanter iki grubun oluşturduğu veri setinde, tüm zaman pencereleri için -250, 500, 750, 1000, 1500, 2000, 3000, 4000- yaklaşık entropi değerinin hesaplandığı bu bölüm dört alt kısma ayrılmaktadır: İlk kısım dünya yerçekimi pozisyonunda cimnastik ve sedanter grubun göz kapalı görevini gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Dünya_Cimnastik_Sedanter_Göz Kapalı(D_C_S_GK) Durumu’, ikinci kısım ay yerçekimi pozisyonunda cimnastik ve sedanter grubun göz kapalı görevini gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Ay_Cimnastik_Sedanter_Göz Kapalı (A_C_S_GK) Durumu’, üçüncü kısım dünya yerçekimi pozisyonunda cimnastik ve sedanter grubun zihinden çıkarma görevini gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Dünya_Cimnastik_Sedanter_Çıkarma (D_C_S_Ç) Durumu’, son olarak ay yerçekimi pozisyonunda cimnastik ve sedanter grubun zihinden çıkarma görevini gerçekleştirdiği durumda yaklaşık entropi değerinin hesaplanarak sınıflandırıldığı ‘Ay_Cimnastik_Sedanter_Çıkarma (D_C_S_Ç) Durumu’ şeklindedir.

Tablo 78. Tüm zaman pencereleri için TK_A_Ç_GK durumuna ait sınıflandırma sonuçları (%)


TK_A_Ç_GK	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	57.7	57.5	56.2	56	56.7	58.4	58.5	64.8	63.8	57.6	66.7*	60.3
500	64.1	62	59.9	57.3	57.8	61.1	61.2	71.1	72.3	68.9	74.9*	63.4
750	65.7	61.9	57.9	57.2	58.7	63.4	63	75.3	77.9	74	79.6	65.9
1000	68.7	67.2	62.4	58.7	57.7	65	65.2	78.1	79.8	75.6	82.1	66.8
1500	72.6	69.2	63.9	59.6	59.2	67.8	66.2	81.6	85.5	80	84.9	66.2
2000	72.9	70.9	63.4	59.6	61.3	71.3	70.6	85.6	87.9	81.1	86.6	66.8
3000	81.4	81.6	69.7	61.1	62.2	73.7	73.3	87.8	91.5	86.5	91	67.5
4000	78.6	78	68.2	60.4	62.8	73.8	74.7	88.7	92	85.7	92.6	66.4
TK_A_Ç_GK	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	60.1	62.4	62.5	64.3	62.2	63.5	60.3	63.4	57.9	63.7	57.5	
500	70.1	70.7	68.5	71.9	70.9	72.8	68.3	72.6	60.9	73.1	62	
750	78.5	77.6	72	77.3	77	78.4	69.2	77.5	63.8	81.1*	61.7	
1000	79.5	79	73.2	79.3	78.7	81.4	72.5	79.6	64.4	83.5*	66.8	
1500	85	83.3	74.1	85	83.4	85.7	75	82.3	66	87.7*	67.8	
2000	89.1*	85.9	67.5	84.3	85.9	87.4	79.7	85.9	67.2	88.6	70.8	
3000	92.3	87.8	59.2	88.2	87.8	91.2	87.6	90	70.9	93.2*	79.1	
4000	94.6	89.6	55.7	89	88.7	92	86	89.3	67.9	94.9*	80.1	

Tablo 79. Tüm zaman pencereleri için TK_A_Ç_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


TK_A_Ç_GK	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	66.7	69	63	65	36	33	63
500	M. Gaussian SVM	74.9	75	73	74	26	25	74
750	Subspace KNN	81.1	79	82	81	17	18	79
1000	Subspace KNN	83.5	83	83	83	16	16	83
1500	Subspace KNN	87.7	85	89	89	10	12	86
2000	Fine KNN	89.1	88	89	89	10	10	88
3000	Subspace KNN	93.2	91	94	94	.05	.06	92
4000	Subspace KNN	94.9	94	95	95	.04	.05	94




Şekil 47. Tüm kanallar için TK_A_Ç_GK-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 48. Tüm kanallar için TK_A_Ç_GK-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 49. Tüm kanallar için TK_A_Ç_GK-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 50. Tüm kanallar için TK_A_Ç_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 51. Tüm kanallar için TK_A_Ç_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 52. Tüm kanallar için TK_A_Ç_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 53. Tüm kanallar için TK_A_Ç_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 54. Tüm kanallar için TK_A_Ç_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri

4.3.1. Dünya_Cimnastik_Sedanter_Göz Kapalı (D_C_S_GK) Durumu

Dünya yerçekimi pozisyonunda, cimnastik ve sedanter grubun göz kapalı görevini gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır. Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların dünya koşulunda, cimnastik ve sedanter grubun göz kapalı görevini ayırma başarısında artış olduğu **Tablo 80.** ve **Tablo 81.** de gösterilmektedir.

Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 55.-62.**’ de gösterilmiştir.

4.3.2. Ay_Cimnastik_Sedanter_Göz Kapalı (A_C_S_GK) Durumu

Ay yerçekimi pozisyonunda, cimnastik ve sedanter grubun göz kapalı görevini gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması kullanılarak sınıflandırılmıştır.

Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların ay koşulunda, cimnastik ve sedanter grubun göz kapalı görevini ayırma başarısında artış olduğu **Tablo 82.** de, sınıflandırma performans sonuçları ise **Tablo 83.** de gösterilmektedir.

Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 63.-70.**’ de gösterilmiştir.

4.3.3. Dünya_Cimnastik_Sedanter_Çıkarma (D_C_S_Ç) Durumu

Dünya yerçekimi pozisyonunda, cimnastik ve sedanter grubun çıkarma görevini gerçekleştirdiği esnada ölçülen EEG sinyalleri; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinin yarısına denk örtüşmeli olacak şekilde bölünmüş, yaklaşık entropi değeri hesaplanarak farklı sınıflandırıcı algoritmaları kullanılarak sınıflandırma işlemi yapılmıştır.

Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların dünya koşulunda, cimmastik ve sedanter grubun çıkarma görevini ayırma başarısında artış olduğu **Tablo 84.** de, sınıflandırma performans sonuçları ise **Tablo 85.** de gösterilmektedir.

Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 71.-78.**' de gösterilmiştir.




Tablo 80. Tüm zaman pencereleri için D_C_S_GK durumuna ait sınıflandırma sonuçları (%)


D_C_S_GK	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	81	79.1	74.7	75.2	76.3	82.2	82.3	86.1	86.4	67.6	87.9*	83.4
500	87.4	86.5	82.6	81.2	81.9	88.9	88.8	93.5	93.9	73.6	94.6*	89.7
750	91	91.1	84.9	84.2	84.9	92.5	92.3	96.1	96.7	80.4	97.1*	92.5
1000	91.7	91.8	87.4	85.5	85.8	94.1	94.2	97.4	98*	82.3	97.8	94
1500	95.4	94.8	91.7	80.2	81.5	95.8	95.7	98.3	98.4	89.7	98.4	95.9
2000	94.8	94.5	90	84.5	86.7	96.9	96.6	98.8	99.2*	85.5	99.2*	95.8
3000	95.4	95.4	92.9	85.3	87.5	98.2	98.3	99.3	99.3	87.5	99.4	97.3
4000	96.4	96.4	93.9	86	87.5	99.1	98.9	99.6	99.4	87.7	99.6	97
D_C_S_GK	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	80.8	84.5	81.9	85	84.1	84.9	83.8	85.6	81.3	85.2	79.1	
500	91.1	91.9	88.3	92.4	91.6	92.4	92	93	87.2	93.2	86.5	
750	96.2	95.7	91.7	95.7	94.7	96.2	94.9	95.4	90.7	96.7	91	
1000	97.9	96.6	92.6	96.5	96	97.4	95.9	96.3	91.6	97.7	91.8	
1500	98.5	97.8	94.5	98	97.4	98.3	97.8	98.7	95	99.5*	95	
2000	98.5	98	94.3	98	98	98	95.4	97.7	95	99.2*	94.8	
3000	99.3	98.3	94	99	98.3	98.6	68.3	99	96.1	99.9*	77.9	
4000	99.8*	98.3	92.6	99.4	98.5	99.8*	49.8	98.5	97	99.8*	59.5	

Tablo 81. Tüm zaman pencereleri için D_C_S_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


D_C_S_GK	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	87.9	87	88	88	11	12	87
500	M. Gaussian SVM	94.6	94	95	95	.04	.05	94
750	M. Gaussian SVM	97.1	96	97	97	.02	.02	96
1000	Cubic SVM	98	97	98	98	.01	.01	97
1500	Subspace KNN	99.5	99	99	99	0	0	99
2000	M. Gaussian SVM	99.2	98	99	99	0	0	98
3000	Subspace KNN	99.9	99	100	100	0	0	99
4000	Subspace KNN	99.8	100	99	99	0	0	99




Şekil 55. Tüm kanallar için D_C_S_GK-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 56. Tüm kanallar için D_C_S_GK-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 57. Tüm kanallar için D_C_S_GK-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 58. Tüm kanallar için D_C_S_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 59. Tüm kanallar için D_C_S_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 60. Tüm kanallar için D_C_S_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 61. Tüm kanallar için D_C_S_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 62. Tüm kanallar için D_C_S_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri

Tablo 82. Tüm zaman pencereleri için A_C_S_GK durumuna ait sınıflandırma sonuçları (%)


A_C_S_GK	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	73.7	71.3	66.6	69.2	71.6	72.7	73	80.1	81.2	63.5	82.1*	75.8
500	79.4	78.8	71.3	74.1	77.1	76.7	77.7	87.1	88.7	66.8	88.9*	80.8
750	84.8	83.5	77.3	76.7	80.3	81.4	81.2	92.3	93.2*	73.3	92.9	83.4
1000	86.9	85.9	80	78.2	81.5	82.2	82.2	93.3	94.5*	78.2	94.4	84.7
1500	91.5	91.2	87.9	78.7	82.2	83.4	84.7	94.8	95.7	79.7	95.7	87.2
2000	89.9	88	84.9	80.4	85.1	83.5	84.3	96.5	96.6	85.3	96.7	86
3000	93.3	93.7	87.4	81.1	87.5	86.8	87.5	96.8	97.6	84.7	96.8	87.3
4000	93.8	93.9	87.1	81.8	88.3	87.3	87.9	97.7	97.7	86.2	98.1	88.6
A_C_S_GK	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	75.6	78.8	77.3	79.9	78.4	79.5	76.9	79.5	72.8	80.1	71.4	
500	84.9	86	83.2	87.3	85.5	86.7	84.7	86.6	77.1	87.7	78.8	
750	91.5	90.2	87.3	91.5	89.6	91.3	88.8	90.8	80.3	92.7	83.6	
1000	93.6	92.1	88.7	93.4	91.5	93.4	91.3	92.8	80.9	94.4	85.9	
1500	95.3	94.1	91.6	94.9	93.2	96	95.5	96.4	83	96.8*	91.2	
2000	96.7	95.2	91.6	94.7	94.8	96.6	95	95.6	83.4	97.9*	88	
3000	98.3	95.9	91.3	95	94.8	96.6	94	96.5	85	98.5*	93.3	
4000	98.5	95.8	91.1	96	95.6	97.5	67.4	97	86.6	98.7*	67.4	

Tablo 83. Tüm zaman pencereleri için A_C_S_GK durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


A_C_S_GK	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	82.1	81	82	82	17	17	81
500	M. Gaussian SVM	88.9	87	90	90	.09	11	88
750	Cubic SVM	93.2	92	93	93	.06	.06	92
1000	Cubic SVM	94.5	94	94	94	.05	.05	94
1500	Subspace KNN	96.8	96	97	97	.02	.03	96
2000	Subspace KNN	97.9	96	99	99	0	.02	97
3000	Subspace KNN	98.5	96	100	100	0	.01	98
4000	Subspace KNN	98.7	98	99	99	0	.01	98




Şekil 63. Tüm kanallar için A_C_S_GK-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 64. Tüm kanallar için A_C_S_GK-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 65. Tüm kanallar için A_C_S_GK-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 66. Tüm kanallar için A_C_S_GK-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 67. Tüm kanallar için A_C_S_GK-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 68. Tüm kanallar için A_C_S_GK-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 69. Tüm kanallar için A_C_S_GK-3000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 70. Tüm kanallar için A_C_S_GK-4000 durumuna ait ortalama ve standart sapma entropi değeri

Tablo 84. Tüm zaman pencereleri için D_C_S_Ç durumuna ait sınıflandırma sonuçları (%)


D_C_S_Ç	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	74.5	72.8	69.7	70.6	72.2	77.2	77	82.7	83.1	64.6	85.3*	78.5
500	81.5	81	74.6	75.7	77.1	88.1	88.1	91.6	93	72.4	93.1*	88.2
750	85.8	85.5	79.4	77.8	80.5	91.7	91.6	93.2	95	78.3	95.1	90.2
1000	87.1	87.5	81.5	80.5	82.2	92.7	92.9	94.3	95	78.9	96.6	91.2
1500	88.2	88	82.7	81	83.5	94.7	94.3	97	97.5	79.3	98.3	93.5
2000	88.1	88.1	81.4	82.2	85.3	94.1	96	97.5	98.9*	80.5	98	94.1
3000	86.3	86.3	81.2	82.5	83.8	94.9	96.2	99.1	98.3	85.9	99.6*	92.3
4000	90.5	90.5	86.3	85.1	87.5	95.2	96.4	97.6	97	83.9	99.4*	91.1
D_C_S_Ç	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	77.4	80.7	77.2	83.2	79.9	82.2	80.2	81.7	76.7	82.3	72.6	
500	88.2	90.2	85.1	90.8	88.6	91.1	90	90.6	86.1	92.5	81.7	
750	94.3	93.4	85.4	94.4	92.6	94.2	91.5	93.4	89.8	96.6*	85.4	
1000	95.9	94.7	85.6	97.1	94	95.9	93.1	94	90.3	97.3*	87.7	
1500	97.5	95.4	82.7	95.1	94.9	97.3	92.6	93.7	93.7	98.9*	89	
2000	98.3	95.8	76.8	94.9	94.9	98	72	94.9	94.4	98.3	73.2	
3000	99.1	97	68.8	96.2	95.7	98.7	49.1	92.7	95.3	98.7	49.1	
4000	98.8	96.4	66.7	95.2	93.5	98.2	49.4	96.4	95.2	99.4*	49.4	

Tablo 85. Tüm zaman pencereleri için D_C_S_Ç durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


D_C_S_Ç	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	85.3	84	85	85	14	14	84
500	M. Gaussian SVM	93.1	93	92	92	.07	.06	92
750	Subspace KNN	96.6	94	98	98	.01	.03	95
1000	Subspace KNN	97.3	96	98	98	.01	.02	96
1500	Subspace KNN	98.9	98	99	99	0	.01	98
2000	Cubic SVM	98.9	97	100	100	0	.01	98
3000	M. Gaussian SVM	99.6	99	100	100	0	0	99
4000	M. Gaussian SVM	99.4	98	100	100	0	0	98




Şekil 71. Tüm kanallar için D_C_S_Ç-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 72. Tüm kanallar için D_C_S_Ç-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 73. Tüm kanallar için D_C_S_Ç-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 74. Tüm kanallar için D_C_S_Ç-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 75. Tüm kanallar için D_C_S_Ç-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 76. Tüm kanallar için D_C_S_Ç-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 77. Tüm kanallar için D_C_S_Ç-3000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 78. Tüm kanallar için D_C_S_Ç-4000 durumuna ait ortalama ve standart sapma entropi değeri

4.3.4. Ay_Cimnastik_Sedanter_Çıkarma (A_C_S_Ç) Durumu

Ay yerçekimi pozisyonunda, cimnastik ve sedanter grubun çıkarma görevini gerçekleştirdiği esnada; 250, 500, 750, 1000, 1500, 2000, 3000, 4000 ms lik zaman pencerelerinde yaklaşık entropi değeri hesaplanmış ve 23 farklı sınıflandırıcı algoritması ile sınıflandırılmıştır.

Sınıflandırma sonuçları incelendiğinde zaman penceresi büyüdükçe sınıflandırıcıların ay koşulunda, cimnastik ve sedanter grubun çıkarma görevini ayırma başarısında artış olduğu **Tablo 86.** ve **Tablo 87.** de gösterilmektedir.


Tüm EEG kanalları için her bir zaman penceresindeki yaklaşık entropi değerinin ortalama ve standart sapma değeri hesaplanmış olup ve **Şekil 79.-86.**’ de gösterilmişti

Tablo 86. Tüm zaman pencereleri için A_C_S_Ç durumuna ait sınıflandırma sonuçları (%)


A_C_S_Ç	Complex Tree	Medium Tree	Simple Tree	Linear Dis	Quadratic Dis	Logis Reg	Linear SVM	Quadratic SVM	Cubic SVM	F. Gaussian SVM	M. Gaussian SVM	C. Gaussian SVM
250	73.8	71.8	67.6	70.8	71.2	73.6	73.7	80.2	80.4	66	82.1*	75.1
500	78.5	77.8	74.2	76.6	77.5	79.4	79.6	89.1	89.1	72.4	90.4*	81.4
750	83.3	84.7	83	78.6	81.8	85.1	85.4	93.5	92.9	76.9	93.8	86
1000	84.3	84.6	84.2	79.7	82.2	87.3	87.4	94.3	94.8	77.5	95	87.5
1500	86.3	86.1	87.6	81.6	84.2	90.7	89	97.7	97.9*	81	97.3	88.4
2000	88.1	88.1	84.5	81.6	86.7	92.1	93.2	97.7	98.3	79.7	98	89.8
3000	90.6	90.6	87.6	83.3	85.5	93.2	96.2	97.9*	96.6	80.3	97.4	91
4000	92.9	92.9	92.3	84.5	88.7	97	96.4	97.6	98.2*	85.7	98.2*	91.7
A_C_S_Ç	Fine KNN	Medium KNN	Coarse KNN	Cosine KNN	Cubic KNN	Weighted KNN	Boosted Trees	Bagged Trees	Subspace Dis	Subspace KNN	Rusboosted Trees	
250	75.4	76.8	71.9	79.9	76.5	77.9	77.4	80.1	73.4	80.9	72	
500	88.7	86.1	78.2	88.5	85.7	87	84.8	88.6	79.6	89.8	77.8	
750	92.7	91.1	84.9	92.9	90.4	91.4	88.6	91.2	85	94*	84.9	
1000	95.1*	92.6	84.9	94	93.6	93.7	91.5	92.7	86.6	95.1*	84.9	
1500	97.7	94.3	83.8	94.9	93.2	95.8	90.5	93.7	87.8	96.6	87.8	
2000	98.6*	94.6	78.8	96	94.4	97.2	49.4	94.9	91.5	97.5	58.2	
3000	97	94	75.6	95.3	94.9	96.6	49.1	97.4	93.6	97	49.1	
4000	98.2*	94.6	68.5	95.8	95.2	95.8	49.4	94.6	95.2	98.2*	49.4	

Tablo 87. Tüm zaman pencereleri için A_C_S_Ç durumuna ait en iyi sınıflandırıcı ve sınıflandırma performans sonuçları (%)


A_C_S_Ç	Sınıflandırıcı	Doğruluk	Duyarlılık	Özgünlük	Kesinlik	Yanlış Pozitif Oranı	Hata Oranı	F1 Puanı
250	M. Gaussian SVM	82.1	81	83	82	16	17	81
500	M. Gaussian SVM	90.4	89	90	90	.09	.09	89
750	Subspace KNN	94	93	94	94	.05	.06	93
1000	Subspace KNN	95.1	94	96	96	.03	.04	94
1500	Cubic SVM	97.9	97	98	98	.01	.02	97
2000	Fine KNN	98.6	97	99	99	0	.01	97
3000	Quadratic SVM	97.9	95	100	100	0	.02	97
4000	M. Gaussian SVM	98.2	97	98	98	.01	.01	97




Şekil 79. Tüm kanallar için A_C_S_Ç-250 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 80. Tüm kanallar için A_C_S_Ç-500 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 81. Tüm kanallar için A_C_S_Ç-750 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 82. Tüm kanallar için A_C_S_Ç-1000 durumuna ait ortalama ve standart sapma entropi değeri




Şekil 83. Tüm kanallar için A_C_S_Ç-1500 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 84. Tüm kanallar için A_C_S_Ç-2000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 85. Tüm kanallar için A_C_S_Ç-3000 durumuna ait ortalama ve standart sapma entropi değeri



Şekil 86. Tüm kanallar için A_C_S_Ç-4000 durumuna ait ortalama ve standart sapma entropi değeri

5. Tartışma ve Sonuç

Sunulan tez çalışmasında cimnastik ve sedanter katılımcıların; Dünya-Ay pozisyonunda göz kapalı ve çıkarma görevlerini gerçekleştirdiği esnada 1000 Hz örnekleme frekansına sahip 16 kanallı EEG aracılığı ile kaydedilen elektriksel aktivite makine öğrenimi için girdi olarak kullanıldı. Girdi setlerindeki öznitelikler, 16 kanaldan ölçülen elektriksel sinyale Yaklaşık entropi uygulanarak oluşturuldu. Ayırmak istenen; pozisyon (Dünya-Ay), katılımcı (cimnastik- sedanter) ve görev (göz kapalı- çıkarma) grup koşullarının sınıflandırılması için 23 farklı sınıflandırıcı algoritması kullanıldı.

Sonuçlar tüm katılımcıların oluşturduğu veri seti için incelendiğinde, Dünya-Ay yerçekim pozisyonunun: En dar zaman penceresi olan 250 ms de; çıkarma görevi icrası sırasında M. Gaussian SVM algoritmasında %75,1 doğruluk ile sınıflandırıldığı (**Tablo 72**), göz kapalı görevi icrası sırasında, M. Gaussian SVM algoritmasında %73,4 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 74**). En geniş zaman penceresi olan 4000 ms de; çıkarma görevi için Subspace KNN algoritmasında %98,5 doğruluk ile sınıflandırıldığı (**Tablo 72**), göz kapalı görevinin, Subspace KNN algoritmasında %98,7 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 74**). Sonuçlar incelendiğinde, zaman penceresi genişledikçe katılımcıların çıkarma-göz kapalı görevinin icrasını Dünya koşulunda mı yoksa Ay koşulunda mı gerçekleştirdiğinin daha yüksek sınıflandırma doğruluğu ile ayırmadığı görülmektedir.

Literatürde Dünya yerçekiminden farklı mikro yerçekim pozisyonunun deneyimlenmesine olanak tanıyan parabolik uçuş çalışmaları incelendiğinde, mikro yerçekim etkisiyle kan dolaşımının vücuda eşit olarak dağılımının beyinde kan birikmesine neden olduğu (Schneider ve ark. 2013) ve birikimin kafa içi basıncında artışa neden olabileceği düşünülmektedir (Lawley ve ark., 2017). Kan birikiminin üç mekanizmaya bağlı olduğu varsayılmaktadır, bunlar; karotis arterlerin içinde artan kan akışının yanı sıra karotis akışın neden olduğu intrakraniyal akımdaki artış (Ogoh ve diğerleri, 2015), 0G sırasında kardiyak debinin artması (Norsk ve ark, 2006) ve son

olarak 0G' deki hidrostatik gradyan kaybı nedeniyle beyinden kanın drenajı şeklinde sıralanmaktadır (Schneider ve ark., 2013).

Sunulan çalışmada, beyin arterlerindeki kan akışını ve yönünü ölçmek için kullanılan Transkranial Doppler ultrasonografi cihazı bulunmadığından ve sunulan çalışma 0.16 g pozisyonunda gerçekleştirildiğinden bu alandaki açıklamalar spekülatif olsa da serebral kan akışında yaşanan mikro çekim kaynaklı değişikliklerin beyin kortikal aktivitesine yansıdığı ve Dünya-Ay pozisyonunun sınıflandırma başarısına etki edebileceği düşünülmektedir.

Literatürde talamusun duyuşsal bilgi ve bilişsel süreçler için önemli bir temsilci olduğu bilinmektedir. Bu alanda meydana gelen ve değişen beyin aktiviteleri, bilişsel ve davranışsal bozukluklara yol açabilmektedir. Talamusun önemli bir parçası olan medial dorsal nükleusun, yürütücü eylem ve dikkat odağı için önemli ve tamamlayıcı motor alan olan dorsal lateral prefrontal korteks ile iş birliğine sahip olduğu bilinmektedir (Goldman ve Porrino, 1985; Giguere ve Goldman, 1988). Hazlett ve arkadaşları, medial dorsal çekirdeğin, yanıt stratejilerinin planlanmasında yer alan ve yürütücü işlevlerde önemli rol oynayan yüksek kortikal bölgelerle bütünleştiğini öne sürmektedir (Hazlett ve ark., 2008). Benzer şekilde, Zoppelt ve arkadaşları, yürütücü disfonksiyonun, talamusun medial dorsal çekirdeğinin lateral bölümündeki hasarla ilişkili olduğunu göstermektedir (Zoppelt ve ark., 2003). Liao ve arkadaşları, katılımcıların normal ve 72 saat boyunca -6 derecede mikro yerçekimini tecrübe ettikleri pozisyonda gerçekleştirdikleri fMRI çalışmasında; normal pozisyon ile karşılaştırıldığında -6 derecedeki eğik sehpa pozisyonundan sonra sol talamusta düşük frekanslı dalgalanmaların (0.01–0.08 Hz) azalmış genliğini sunmakta ve sonuçların vücut sıvısının yerçekimi değişikliğine bağlı olarak yeniden dağıtılmasının, sol talamusun dinlenme durumundaki işlevini bozabileceğini ve bunun da, mikro yerçekimi ortamında astronotlarda motor kontrol yeteneklerinin azalmasına sebep olabileceği vurgulanmaktadır (Liao ve ark., 2012).

Sunulan çalışmada göz kapalı görev icrası sırasında Ay ve Dünya yerçekim pozisyonu yüksek sınıflandırıcı doğruluğu ile sınıflandırılrsa da bu sonuca talamusun mikro yerçekim pozisyonundan etkilenen işlevinin yansıyabileceği yorumuna varmak oldukça zordur. Yorumların kısıtlanmasındaki önemli bir neden, 16 kanallı EEG' nin

derin beyin yapısını yansıtmak için yetersiz kalabileceği düşüncesidir. Ancak ileriki çalışmalarda, yüksek kanallı EEG ve beyin haritalarının oluşturulmasına yardımcı matematiksel yöntemler kullanmanın talamus ve diğer derin beyin yapıları hakkındaki yorumlarımızı kolaylaştıracağını düşünmekteyiz.

Çalışma sonuçları tüm katılımcıların oluşturduğu veri seti için incelendiğinde, çıkarma-göz kapalı görevi: En dar zaman penceresi olan 250 ms de; Dünya koşulunda M. Gaussian SVM algoritmasında %67,3 doğruluk ile sınıflandırıldığı (**Tablo 76**), ay koşulunda, M. Gaussian SVM algoritmasında %66,7 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 78**). En geniş zaman penceresi olan 4000 ms de ise; Dünya koşulunda Subspace KNN algoritmasında %94,9 doğruluk ile sınıflandırıldığı (**Tablo 76**), Ay koşulunda, Subspace KNN algoritmasında %94,9 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 78**). Sonuçlar incelendiğinde, zaman penceresi genişledikçe katılımcıların Dünya ve Ay koşulunda çıkarma-göz kapalı görevinin icrasını daha yüksek sınıflandırma doğruluğu ile sınıflandırdığı rapor edilmiştir.

Cheron ve arkadaşları, mikro yerçekimi pozisyonunda sensorimotor ve parieto-okspital korteksin, yerçekiminden etkilenen ortak bir ağa sahip olduğunu ileri sürmekte ve etkilenen ağın yerçekimine bağlı duysal girdilerin azalmasıyla bağlantılı olabileceğini öne sürmektedir (Cheron ve ark., 2006).

Sunulan çalışmada katılımcıların, Ay pozisyonunda göz kapalı görev icrasını gerçekleştirdiği sıradaki Ortalama Yaklaşık entropi değerleri incelendiğinde tüm zaman pencerelerinde sensorimotor ve parieto-okspital korteks aktivitesinin yansıdığı düşünülen P3, PZ, P4, O1, O2 ve OZ elektrotlarında Dünya çekiminden az olduğu görülmektedir. Bu sonucun Ay yerçekimine bağlı duysal girdilerin azalması ile birlikte beynin daha az girdinin sonucu olarak daha az karmaşa ile yanıt oluşturabileceği düşünülmektedir (Şekil 31.-38.). Dünya yerçekimi ile karşılaştırıldığında Ay yerçekiminde görülen ortalama düşük Yaklaşık entropi için bir başka yaklaşım ise, sistem için alışılmadık duysal girdilerden kaynaklı alışılmadık işlem yolunun tercih edilebilme olasılığıdır. Çünkü Ay yerçekimi pozisyonu Dünya yerçekiminden farklı olsa da duysal girdilerin varlığını sürdüreceği düşünülmektedir.

Ancak sistemin yeni tecrübe ettiği yerçekimine ait her duyuşal girdiye yanıt vermekte zorlanabileceđi ve kısıtlı sayıdaki duyuşal girdiyi işlemeyi tercih edebileceđi düşünölmektedir. Bu ise çok sayıda yeni duyuşal girdiyi işlemenin getireceđi karmaşadan farklı olarak yeni tecrübe edilen duyuşal girdiler arasından seçilen az sayıda duyuşal girdiyi işlemenin yansıması olabilecek düşük Yaklaşık entropi değeriinin bir açıklaması olabilir.

Manzey ve arkadaşları tek katılımcının dahil olduđu, 8 gün süren 3 farklı bilişsel görevin gerçekleştirildiđi kısa dönem mikro çekim çalışmasında yüksek dikkat gerektiren işlevlerin bozulduđunu rapor etmektedir (Manzey ve ark., 1993). Manzey ve arkadaşları, tek kozmonotun dahil olduđu; 4 uçuş öncesi (87, 34, 3 ve 2 gün) 29 uçuş sırası (4., 5., 6., 11., 12., 19., 20., 27., 34., 41., 48., 68., 69., 96., 97., 185., 186., 193., 199., 208., 216., 244., 326., 348., 363., 398., 413., 420., 427. gün) ve 8 uçuş sonrası (4. gün 2 ölçüm, 5., 6., 11., 12., gün ve 168. gün 2 ölçüm) toplamda 428 gün süren 4 farklı bilişsel görevin gerçekleştirildiđi uzun dönem mikro çekim çalışmasında ise; uçuş öncesi ve sonrası adaptasyon periyodunda dikkat süreçlerinin bozulması ile ilişkilendirilse de uzun süreli uzay görevlerine adaptasyon sağlandıktan sonra bilişsel performans istikrarının Dünya'daki kadar yüksek bir seviyede tutulabileceđini göstermektedir (Manzey ve ark., 1998). Parabolik uçuşun etkisini davranışsal ve nörofizyolojik belirteçler ile değerlendirmeyi amaçlayan Wollseiffen ve arkadaşları, 32 kanallı EEG kullanarak katılımcıları kolay ve zor olarak 2 ayrı alt gruba ayırmıştır. 16 katılımcının yer aldığı kolay grup, nispeten basit olan zihinden aritmetik görevini aynı zorluk seviyesinde olacak şekilde tablet ekranı üzerinde cevaplandırmış, 26 katılımcının yer aldığı zor grup ise artan zorluk seviyesindeki aritmetik görevi gerçekleştirmiştir. Bulgular, mikro çekim koşulunda davranışsal belirteç olan reaksiyon süresi performansında iyileşmenin yanı sıra dikkat, hafıza ve cevap seçimi için bir gösterge olduđu bilinen P2 (Luck ve Hillyard, 1994) EEG genliğinde değışime işaret etmektedir (Wollseiffen ve ark., 2016). Yakın zamanda yayınlanmış bir derlemeden elde edilen sonuçlar ise yetersiz çalışma tasarımları nedeniyle, uzay uçuşunun bilişsel işlev bozukluđu ile nasıl ilişkili olup olmadığı konusunda belirsiz kaldığını vurgulamaktadır (Strangman ve Beyan, 2013). Schneider ve arkadaşları gerçekleştirdikleri parabolik uçuş araştırmalarında, uçuşların görevden bağımsız

olarak stresi tetiklediğini vurgulamaktadır ancak, parabolik uçuş sırasındaki mikro çekimin etkisini stresin etkisinden ayırt etmeye izin verecek bir deney tasarımının stres faktörünü elimine edeceği düşünülmektedir (Schneider ve ark. 2007, 2009). Marušič ve arkadaşları ise mikro çekim çalışmalarını, parabolik uçuş ve uzay uçuşlarının artan stres ile kuru daldırma ve eğik masa deneylerini ise monotonluk ve hareketsizlikten kaynaklanan can sıkıntısı ile ilişkilendirmektedir (Marušič ve ark., 2014).

Çalışmada, Ay analogu için kullanılan sehpanın Dünya koşulu ile karşılaştırıldığında 1/6 oranına denk gelecek bir kan dolaşımı yaratması ve katılımcıların görevleri bu pozisyonda icra etmelerinin katılımcılar için alışılmadık olduğu stres veya hareketsizliğin can sıkıntısına neden olabileceği düşüncesi literatüre destek verecek şekildedir. Tekrarlı ölçümlerin ve davranışsal sonuçların elde edileceği deney tasarımlarında stresin veya olası monotonluk halinin birincil etkisinden kurtulma noktasında yardımcı olacağını düşünmekteyiz.

Literatürde bilişsel görev ile ilgili yapılmış çalışmalar incelendiğinde, bilişsel görev seviyesinin olaya ilişkin potansiyel üzerindeki etkileri genellikle geç bileşenlerde, yani uyaran sunumundan 500 ila 1000 ms sonra gözlemlendiği rapor edilmiştir. Pozitif yavaş potansiyellerin, hesaplama eylemi için gerekli olduğu tartışılmaktadır (Ku ve ark., 2010; Pauli ve ark., 1996). Bu doğrultuda sunulan çalışmada olaya ilişkin potansiyeller incelenmemiş olsa da çıkarma görevi için 1000 ms penceresinden sonra sınıflandırma doğruluğunun %90 ve üzerinde olması çıkarma görevinin sınıflandırıcı sistemler tarafından tanınması için ihtiyaç duyulan zaman penceresi konusunda kritik bir eşiği yansıttırıyor olabileceği düşünülmektedir.

Ortalama Yaklaşık entropi değerinin, çıkarma görevi için Ay koşulunda F3 elektrodunda tüm zaman pencerelerinde (Şekil 47.- 54.) daha yüksek değere sahip olması dikkat çekici bir bulgudur. İçeriğin yeniden düzenlenmesi bir nevi güncellenmesi açısından hem bilgilerin korunması hem de işleme ile ilişkilendirilen sol dorsolateral prefrontal korteksin (Jansma ve diğerleri, 2000; Smith ve Jonides, 1999) F3 elektroduna yansımış olduğu düşünülmektedir. Dünya koşulu ile karşılaştırıldığında Ay koşulunda gözlenen daha yüksek entropi değerinin alışık olunmayan bir pozisyonda gerçekleşen mental görevin beyinde daha çok bilinmezliğe

neden olabileceği fikrini akla getirmektedir. Bu durumun ise Dünya ve Ay koşulunun ayırmsanmasına yardımcı olacak niteliklerden biri olabileceği düşünülmektedir. Fakat çalışmada, çıkarma görevi sırasında herhangi bir davranışsal çıktı alınmamış olması bilişsel performans çıktıları üzerine tartışma yapmayı kısıtlamaktadır.

Sunulan çalışma sonuçları, cimmastik ve sedanter katılımcıların oluşturduğu veri setinde, göz kapalı görevin sınıflandırılma başarısı incelendiğinde: En dar zaman penceresi olan 250 ms de; Dünya pozisyonunda M. Gaussian SVM algoritmasında %87,9 doğruluk ile sınıflandırıldığı (**Tablo 80**), Ay pozisyonunda, M. Gaussian SVM algoritmasında %82,1 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 82**). En geniş zaman penceresi olan 4000 ms de; Dünya koşulunda Subspace KNN algoritmasında %99,8 doğruluk ile sınıflandırıldığı (**Tablo 80**), Ay pozisyonunda, Subspace KNN algoritmasında %98,7 doğruluk ile sınıflandırıldığı görülmüştür (**Tablo 82**). Sonuçlar incelendiğinde, zaman penceresi genişledikçe cimmastik ve sedanter katılımcılar Dünya pozisyonunda göz kapalı görev icrası sırasında daha yüksek sınıflandırma doğruluğu ile ayırmsanmaktadır. Cimmastik ve sedanter katılımcıların oluşturduğu veri setinde, çıkarma görevinin sınıflandırılma başarısı incelendiğinde: En dar zaman penceresi olan 250 ms de; Dünya pozisyonunda M. Gaussian SVM algoritmasında %87,9 doğruluk ile sınıflandırıldığı (**Tablo 84**), Ay pozisyonunda, M. Gaussian SVM algoritmasında %82,1 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 86**). En geniş zaman penceresi olan 4000 ms de; Dünya pozisyonunda Subspace KNN ve M. Gaussian SVM algoritmasında %99,4 doğruluk ile sınıflandırıldığı (**Tablo 84**), Ay pozisyonunda, Subspace KNN ve Cubic SVM algoritmasında %98,2 doğruluk ile sınıflandırıldığı görülmektedir (**Tablo 86**). Sonuçlar incelendiğinde, zaman penceresi genişledikçe cimmastik ve sedanter katılımcılar Dünya pozisyonunda çıkarma görev icrası sırasında daha yüksek sınıflandırma doğruluğu ile ayırmsadığı sonuçlara yansımaktadır.

Uzay uçuşu ve mikro çekim araştırmalarında nöral adaptasyonun oldukça güçlü bir şekilde değiştiği ve demografi, genetik ve fiziksel aktivite gibi çeşitli faktörlerden etkilendiği bilinmektedir (Ombergen ve ark., 2017). Literatürde fiziksel aktivite farklılığı ile ilişkili yapılmış çalışmalar incelendiğinde; Marianha ve arkadaşlarının, sedanter ve karete katılımcı gruplarını motor ve bilişsel testler ile karşılaştırmış ve

karateye katılan çocukların, sedanter çocuklara göre planlama görevlerinde hem görev doğruluğu hem de yürütme zamanında daha iyi performans gösterdiklerini rapor etmiş ve sonuçları egzersiz eğitiminin ön-frontal ve frontal kortekste gri madde hacminde ve miyelinasyonda artışı uyardığı gerekçesine dayandırmaktadır (Best ve Miller, 2010; Leggett ve Hotham, 2011; Barenberg ve ark., 2011).

Son yıllarda ‘nöral verimlilik’, nörofizyolojik mekanizmayı aydınlatmak için dinlenme EEG alfa ritimlerinin olaya bağlı güç düşüşü indeks olarak görülmektedir (alfa olayı ilişkin desenkronizasyon, ERD) ve yüksek zekâ skorlarına sahip kişilerin çeşitli bilişsel görevler sırasında düşük genlikli alfa ERD sergiledikleri rapor edilmektedir (Neubauer ve ark., 1995; Grabner ve ark., 2004). Benzer sonuçlar, belirli beceriler için yüksek düzeyde eğitilmiş katılımcılar ("uzmanlar") kısa süreli bellek görevlerini yerine getirirken de gözlemlenmektedir bu alfa ERD nin uzman katılımcılarda uzman olmayanlara kıyasla genellikle daha düşük olduğunu desteklemektedir (Grabner ve ark., 2006). Nöral verimlilik ile ilişkili çalışmalar incelendiğinde, Kita ve arkadaşları, elit kendo ve jimnastik atletlerinde atlet olmayanlara kıyasla tamamlayıcı motor ve bilateral sensorimotor alanlarda sağ istemli bilek ekstansiyonunu sırasında ortalama EEG potansiyel genliğinin daha düşük olduğu sunmuştur (Kita ve ark., 2001). Krings ve arkadaşları, karmaşık parmak hareketleri sırasında profesyonel piyano çaralarında kontrol deneklerine kıyasla fMRI-BOLD aktivitesinin genliği daha düşük olduğu rapor edilmiştir (Krings ve ark., 2000).

Sunulan çalışmada cimnastik ve sedanter katılımcı gruplarının birbirinden yüksek doğruluk ile sınıflandırılması ve katılımcı gruplarının D_C_S_GK (Şekil 55.-62.), A_C_S_GK (Şekil 63.-70.), D_C_S_Ç (Şekil 71.-78.) ve A_C_S_Ç (Şekil 79.- 86.) şeklinde incelendiği durumlarda cimnastik sporcularının sedanter katılımcı grubu ile karşılaştırıldığında düşük ortalama Yaklaşık entropi değerleri ile yanıt oluşturmaları, cimnastik katılımcı grubunun antrenmanları dolayısıyla sahip oldukları fiziksel aktivite avantajının mikro yerçekim pozisyonunda nörofizyolojik sinyallere yansımış olabileceğini düşünülmektedir.

Tek katılımcı tabanlı oluşan veri setlerine ait çalışma bulguları incelendiğinde yorum yapmak oldukça zordur. Pletser ve Quadens (2003), parabolik uçuş sırasında değişen

yerçekimi koşullarında görülen beyin elektrokortikal aktivite değişiklikler bireyler arasında oldukça değişken olduğunu, bazı katılımcıların artan EEG aktivitesiyle cevap verirken, bazı katılımcıların mikro yerçekim sırasında beyin elektrokortik aktivitesinde azalma ile yanıt verebileceğini belirtmektedir (Pletser ve Quadens, 2003). Bu yaklaşım tek katılımcı tabanlı veri setine ait bulguların tez içinde sunulup tartışılmamasının temel nedeni haline gelmiştir.

Çalışma içinde tüm koşulların sınıflandırılmasında kullanılan 23 farklı sınıflandırıcı algoritması incelendiğinde diğer sınıflandırıcı algoritmalarına kıyasla en yüksek doğruluk değerini veren sınıflandırıcı algoritmasının DVM olduğu görülmektedir. DVM, EEG sinyallerini sınıflandırmak için popüler bir makine öğrenimi yöntemidir. Bu yöntemin bizim verilerimizde de diğer sınıflandırıcılarla karşılaştırıldığında daha yüksek doğruluk değeri vermesinin nedeninin DVM' nin doğrusal olmayan ayrılabilir sinyallerde farklı çekirdek (kernel) işlevinin hayati bir rol oynamasından kaynaklandığı düşünülmektedir.

Literatürde tez konusu ile ilişkili çalışmalar incelendiğinde bir astronotun seçimi ve seçilen astronotun performansının optimum seviyede tutulmasının, uzay, tıp ve psikoloji araştırmacıları için büyük önem arz ettiği görülmektedir. Yaygın olarak bir astronot performansının; radyasyon, gürültü, değişen sirkadiyen ritim ve mikro yer çekim gibi faktörlerden etkilendiği düşünülmektedir (Eddy ve ark., 1998). Bu faktörler arasında yer alan mikro yerçekim, yaşamını Dünya koşullarında sürdüren biz insanlar için en önemli farklılıklardandır. Literatürde mikro yerçekimin etkilerine dair yapılmış birçok çalışma yer almaktadır (Manzey ve ark., 1993, Newman ve Lathan, 1999, Bock ve ark., 2001; Fisk ve ark., 1993; Sangals ve ark., 1999). Ancak mikro çekimin bilişsel sürece olan etkisi konusunda ortak bir fikre ulaşılmış değildir (Strangman ve Bevan, 2013). Fakat davranışsal ve bilişsel işlevlerdeki bozulmaların uzay araştırmalarında potansiyel risklere neden olabileceği düşünülmektedir. Bu noktada 'insan hatası' son derece önemli bir olgudur, insanlar; yeteneklerine, beceri düzeyine ve uzmanlığına bakılmaksızın her gün hata yapmaktadır. Belirli çalışma ortamlarında meydana geldiğinde, bu tür bir hata potansiyel olarak yaralanma ve ölümleri içeren kazalara yol açabilmektedir. Rasmussen, "insan hatasının, operasyonel bir sistemin talepleri ile

operatörün yaptıkları arasındaki uyumsuzluğu temsil ettiği" şeklinde açıklamaktadır. (Rasmussen, 1987). Dolayısı ile insan faktörü endişesi, olası nedenleri ve etkisini hafifletme yolları; askeri-sivil havacılık (Shappel ve Wiegmann, 2000; Stanton ve ark., 2015), tıp (Sexton ve ark., 2000) ve uzay yolculuğu (Nelson ve ark., 1998) alanında ilgi görmeye başlayan bir konu haline gelmiştir. İnsan hatalarının sebepleri incelendiğinde; dikkatsizlik, zayıf motivasyon, dikkat kaybı, zihinsel aşırı yük ve yorgunluk gibi performansı olumsuz etkileyen anormal zihinsel süreçlerden kaynaklına bilirlği literatürde tartışılmaktadır (Babiloni, 2019).

İnsana ait hata olasılığını azaltmak için, mikro yerçekimindeki davranışsal ve bilişsel performans değişimlerinin mekanizmalarını belirlemek ve bunlara karşılık gelen karşı önlemler geliştirmek büyük önem taşımaktadır. Sunulan tez çalışması, en temelde farklı zaman pencerelerinde hesaplanan EEG sinyallerinin makine öğrenimi algoritmalarında girdi olarak kullanılması ve ulaşılan sınıflandırma başarıları ile; cimnastik sporcuları ve sedanter bireylerin zihinden çıkarma ve göz kapalı görevlerini gerçekleştirdiği esnada mikro yerçekimi etkileri değerlendirilmeye çalışılmıştır.

KAYNAKÇA

- A.C. Neubauer, H.H. Freudenthaler, G. Pfurtscheller, Intelligence and spatio-temporal patterns of event-related desynchronization, *Intelligence* 20 (1995) 249–267.
- Abásolo, D., Hornero, R., Espino, P., Alvarez, D., & Poza, J. (2006). Entropy analysis of the EEG background activity in Alzheimer's disease patients. *Physiological measurement*, 27(3), 241.
- Abásolo, D., Hornero, R., Espino, P., Poza, J., Sánchez, C. I., & de la Rosa, R. (2005). Analysis of regularity in the EEG background activity of Alzheimer's disease patients with Approximate Entropy. *Clinical Neurophysiology*, 116(8), 1826-1834.
- Babiloni, F. (2019, November). Mental Workload Monitoring: New Perspectives from Neuroscience. In *International Symposium on Human Mental Workload: Models and Applications* (pp. 3-19). Springer, Cham.
- Barenberg J, Berse T, Dutke S. Executive functions in learning processes: Do they benefit from physical activity? *Educational Research Review*. 2011;6:208-222.
- Barker, R. A., Cicchetti, F., & Robinson, E. S. (2017). *Neuroanatomy and Neuroscience at a Glance*. John Wiley & Sons.
- Best JR, Miller PH. A Developmental Perspective on Executive Function. *Child Dev*. 2010;81(6):1641-1660.
- Bhati, B. S., & Rai, C. S. (2020). Analysis of support vector machine-based intrusion detection techniques. *Arabian Journal for Science and Engineering*, 45(4), 2371-2383.
- Bock O, Fowler B, Comfort D (2001) Human Sensorimotor Coordination during Spaceflight: An Analysis of Pointing and Tracking Responses during the “Neurolab” Space Shuttle Mission. *Aviat Space Environ Med* 72: 877–883.
- Borghini, G., Astolfi, L., Vecchiato, G., Mattia, D., & Babiloni, F. (2014). Measuring neurophysiological signals in aircraft pilots and car drivers for the

assessment of mental workload, fatigue and drowsiness. *Neuroscience & Biobehavioral Reviews*, 44, 58-75.

- Brunelli, R. (2009). *Template matching techniques in computer vision: theory and practice*. John Wiley & Sons.
- Burioka, N., Miyata, M., Cornélissen, G., Halberg, F., Takeshima, T., Kaplan, D. T., ... & Tomita, Y. (2005). Approximate entropy in the electroencephalogram during wake and sleep. *Clinical EEG and neuroscience*, 36(1), 21-24.
- C. Seiffert, et al., "RUSBoost: A hybrid approach to alleviating class imbalance," *IEEE Transactions on Systems, Man, and CyberneticsPart A: Systems and Humans*, vol. 40, pp. 185-197, 2010.
- Cain, B. (2007). *A review of the mental workload literature*. Defence Research And Development Toronto (Canada).
- Carter, R. (2019). *The Brain Book: An Illustrated Guide to Its Structure, Functions, and Disorders*. Dorling Kindersley Ltd.
- Cheng, D., Zhang, S., Deng, Z., Zhu, Y., & Zong, M. (2014, December). kNN algorithm with data-driven k value. In *International Conference on Advanced Data Mining and Applications* (pp. 499-512). Springer, Cham.
- Chéron, G., Leroy, A., De Saedeleer, C., Bengoetxea, A., Lipshits, M., Cebolla, A., ... & McIntyre, J. (2006). Effect of gravity on human spontaneous 10-Hz electroencephalographic oscillations during the arrest reaction. *Brain research*, 1121(1), 104-116.
- Collura, T. F. (1993). History and evolution of electroencephalographic instruments and techniques. *Journal of clinical neurophysiology*, 10(4), 476-504.
- 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.
- Ducros, A., & Biousse, V. (2015). Headache arising from idiopathic changes in CSF pressure. *The Lancet Neurology*, 14(6), 655-668.
- Duda, R. O., Hart, P. E., & Stork, D. G. (2001). Unsupervised learning and clustering. *Pattern classification*, 517-601.

- Durantin, G., Gagnon, J. F., Tremblay, S., & Dehais, F. (2014). Using near infrared spectroscopy and heart rate variability to detect mental overload. *Behavioural brain research*, 259, 16-23.
- Eddy DR, Schiflett SG, Schlegel RE, Shehab RL (1998) Cognitive performance aboard the life and microgravity spacelab. *Acta Astronautica* 43: 193–210.
- Eggemeier, F. T., Wilson, G. F., Kramer, A. F., & Damos, D. L. (1991). Workload assessment in multi-task environments. *Multiple-task performance*, 207-216.
- Elbert, T., Ray, W. J., Kowalik, Z. J., Skinner, J. E., Graf, K. E., and Birbaumer, N. (1994). Chaos and physiology: deterministic chaos in excitable cell assemblies.
- Endsley, M. R. (2017). From here to autonomy: lessons learned from human–automation research. *Human factors*, 59(1), 5-27.
- Farayola, A. M., Hasan, A. N., & Ali, A. (2018). Efficient photovoltaic MPPT system using coarse gaussian support vector machine and artificial neural network techniques. *International Journal of Innovative Computing Information and Control (IJICIC)*, 14(1).
- Ferizi, U., Besser, H., Hysi, P., Jacobs, J., Rajapakse, C. S., Chen, C., ... & Chang, G. (2019). Artificial intelligence applied to osteoporosis: a performance comparison of machine learning algorithms in predicting fragility fractures from MRI data. *Journal of Magnetic Resonance Imaging*, 49(4), 1029-1038.
- Feyer, A., Williamson, A.M.: Human factors in accident modelling. In: *Encyclopaedia of Occupational Health and Safety* (2011)
- Fisk J, Lackner JR, DiZio P (1993) Gravitoinertial force level influences arm movement control. *Journal of neurophysiology* 69: 504–511.
- Fotiadou, E., Giagazoglou, P., Kokaridas, D., Angelopoulou, N., Tsimaras, V., & Tsorbatzoudis, C. (2002). Effect of rhythmic gymnastics on the dynamic balance of children with deafness. *European journal of special needs education*, 17(3), 301-309.

- Friedman, J. H. (2006). Recent advances in predictive (machine) learning. *Journal of classification*, 23(2), 175-197.
- Giguere M, Goldman-Rakic P (1988) Mediodorsal nucleus: areal, laminar, and tangential distribution of afferents and efferents in the frontal lobe of rhesus monkeys. *The Journal of comparative neurology* 277: 195–213
- Goldman-Rakic PS, Porrino LJ (1985) The primate mediodorsal (MD) nucleus and its projection to the frontal lobe. *The Journal of comparative neurology* 242: 535–560.
- Gopher, D., Donchin, E.: Workload: an examination of the concept. In: Boff, K.R., Kaufman, L., Thomas, J.P. (eds.) *Handbook of Perception and Human Performance. Cognitive Processes and Performance*, vol. 2, pp. 1–49. John Wiley & Sons, Oxford (1986)
- Greensstein, B., & Greenstein, A. (2000). *Color Atlas of Neuroscience*. Stuttgart.
- Guyton, A. C., & Hall, J. E. (2008). *Textbook of medical physiology*. 1996. WB Sanders, Philadelphia.
- Hafez, M. M., Redondo, R. P. D., & Vilas, A. F. (2018, December). A Comparative Performance Study of Naïve and Ensemble Algorithms for E-commerce. In 2018 14th International Computer Engineering Conference (ICENCO)(pp. 26-31). IEEE.
- Han, J., Kamper, M, and Pei, J. *Data mining: Concepts and techniques*, Morgan Kaufmann, 2005.
- Hart, S.G., Staveland, L.E.: Development of NASA-TLX (Task Load Index): results of empirical and theoretical research. In: Hancock, P.A., Meshkati, N. (eds.) *Advances in Psychology*, vol. 52, pp. 139–183. North-Holland, Amsterdam (1988)
- Hazlett EA, Buchsbaum MS, Zhang J, Newmark RE, Glanton CF, et al. (2008) Frontal-striatal-thalamic mediodorsal nucleus dysfunction in schizophrenia-spectrum patients during sensorimotor gating. *Neuroimage* 42: 1164–1177.
- Iatridis, P. G. (1987). Human circulation: Regulation during physical stress. *JAMA*, 258(22), 3316-3316. In: *New Technology and Human Error*, pp. 23–30 (1987)

- Jain, A. K., Duin, R. P. W., & Mao, J. (2000). Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1), 4-37.
- Jain, U., Nathani, K., Ruban, N., Raj, A. N. J., Zhuang, Z., & Mahesh, V. G. (2018, October). Cubic SVM classifier based feature extraction and emotion detection from speech signals. In *2018 International Conference on Sensor Networks and Signal Processing (SNSP)* (pp. 386-391). IEEE.
- Johnson, J. M., & Yadav, A. (2018). Fault detection and classification technique for HVDC transmission lines using KNN. In *Information and Communication Technology for Sustainable Development* (pp. 245-253). Springer, Singapore.
- Kaiser, D. A. (2007). What is quantitative EEG. *Journal of Neurotherapy*, 10(4), 37-52.
- Karakaş, S., &İRkeç, C. (Eds.). (2008). *Kognitif nörobilimler*. MN Medikal & Nobel.
- Kolb, B., & Whishaw, I. Q. (2009). *Fundamentals of human neuropsychology*. Macmillan.
- Kolb, B., Whishaw, I. Q., & Teskey, G. C. (2001). An introduction to brain and behavior (pp. 154-177). New York: Worth.
- Koppelmans, V., Erdeniz, B., De Dios, Y. E., Wood, S. J., Reuter-Lorenz, P. A., Kofman, I., ... & Seidler, R. D. (2013). Study protocol to examine the effects of spaceflight and a spaceflight analog on neurocognitive performance: extent, longevity, and neural bases. *BMC neurology*, 13(1), 205.
- Krings, T., Töpper, R., Foltys, H., Erberich, S., Sparing, R., Willmes, K., & Thron, A. (2000). Cortical activation patterns during complex motor tasks in piano players and control subjects. A functional magnetic resonance imaging study. *Neuroscience letters*, 278(3), 189-193.
- Ku, Y., Hong, B., Gao, X., & Gao, S. (2010). Spectra-temporal patterns underlying mental addition: an ERP and ERD/ERS study. *Neuroscience letters*, 472(1), 5-10.
- Lackner, J. R., & DiZio, P. (1996). Motor function in microgravity: movement in weightlessness. *Current Opinion in Neurobiology*, 6(6), 744-750.

- Lawley, J. S., Petersen, L. G., Howden, E. J., Sarma, S., Cornwell, W. K., Zhang, R., ... & Levine, B. D. (2017). Effect of gravity and microgravity on intracranial pressure. *The Journal of physiology*, 595(6), 2115-2127.
- Leggett C, Hotham E. Treatment experiences of children and adolescents with attention-deficit/hyperactivity disorder. *J Paediatr Child Health*. 2011;47(8):512-517.
- Liao, Y., Zhang, J., Huang, Z., Xi, Y., Zhang, Q., Zhu, T., & Liu, X. (2012). Altered baseline brain activity with 72 h of simulated microgravity—initial evidence from resting-state fMRI. *PloS one*, 7(12), e52558.
- Lotte, F. (2014). A tutorial on EEG signal-processing techniques for mental-state recognition in brain–computer interfaces. In *Guide to Brain-Computer Music Interfacing* (pp. 133-161). Springer, London.
- Mai, J. K., & Paxinos, G. (Eds.). (2011). *The human nervous system*. Academic press.
- Manzey D, Lorenz B, Schiewe A, Finell G, Thiele G (1993) Behavioral aspects of human adaptation to space analyses of cognitive and psychomotor performance in space during an 8-day space mission. *Journal of Molecular Medicine* 71: 725–731
- Manzey, D., Lorenz, B., & Poljakov, V. (1998). Mental performance in extreme environments: results from a performance monitoring study during a 438-day spaceflight. *Ergonomics*, 41(4), 537-559.
- Manzey, D., Lorenz, B., Schiewe, A., Finell, G., & Thiele, G. (1995). Dual-task performance in space: results from a single-case study during a short-term space mission. *Human factors*, 37(4), 667-681.
- Marušić U, Meeusen R, Pišot R, Kavcic V (2014) The brain in micro- and hypergravity: the effects of changing gravity on the brain electrocortical activity. *Eur J Sport Sci* 14(8):813–822
- Marušič, U., Meeusen, R., Pišot, R., & Kavcic, V. (2014). The brain in micro- and hypergravity: the effects of changing gravity on the brain electrocortical activity. *European journal of sport science*, 14(8), 813-822.
- Michalaki, P., Quddus, M. A., Pitfield, D., & Huetson, A. (2015). Exploring the factors affecting motorway accident severity in England using the

generalised ordered logistic regression model. *Journal of safety research*, 55, 89-97.

- MORPA SPOR ANSK. (1997). Morpa Kültür Yayınları Ltd. Şti. İstanbul.
- Mu, Z., Hu, J., & Min, J. (2017). Driver fatigue detection system using electroencephalography signals based on combined entropy features. *Applied Sciences*, 7(2), 150.
- Muñoz-de-Escalona, E., & Cañas, J. J. (2018, September). Latency differences between mental workload measures in detecting workload changes. In *International Symposium on Human Mental Workload: Models and Applications* (pp. 131-146). Springer, Cham.
- Natarajan, K., Acharya, R., Alias, F., Tiboleng, T., and Puthusserypady, S. K. (2004). Nonlinear analysis of EEG signals at different mental states. *Biomed. Eng. Online* 3:7. doi: 10.1186/1475-925X-3-7
- Nelson, W.R., Haney, L.N., Ostrom, L.T., Richards, R.E.: Structured methods for identifying and correcting potential human errors in space operations. *Acta Astronaut.* 43 (3–6), 211–222 (1998)
- Newman DJ, Lathan CE (1999) Memory processes and motor control in extreme environments. *Systems, Man, and Cybernetics, Part C: Applications and Reviews*, IEEE Transactions on 29: 387–394.
- Noback, C. R., Ruggiero, D. A., Demarest, R. J., & Strominger, N. L. (Eds.). (2005). *The human nervous system: structure and function* (No. 744). Springer Science & Business Media.
- Noble, D. K. (1983). *Gymnastics for kids ages 3-7*. Human Kinetics.
- Pardoe, I., Yin, X., & Cook, R. D. (2007). Graphical tools for quadratic discriminant analysis. *Technometrics*, 49(2), 172-183.
- *Physiol. Rev.* 74, 1–48.
- Pincus, S. M. (1991). Approximate entropy as a measure of system complexity. *Proceedings of the National Academy of Sciences*, 88(6), 2297-2301.
- Pletser, V., & Quadens, O. (2003). Degraded EEG response of the human brain in function of gravity levels by the method of chaotic attractor. *Acta astronautica*, 52(7), 581-589.

- Pritchard, W. S., Duke, D. W., and Kriebel, K. K. (1995). Dimensional analysis of resting human EEG II: surrogate-data testing indicates nonlinearity but not low-dimensional chaos. *Psychophysiology* 32, 486–491. doi: 10.1111/j.1469-8986.1995.tb02100.x
- Qin, Z., Wang, A. T., Zhang, C., Zhang, S.: Cost-sensitive classification with nearest neighbors. In: Wang, M. (ed.) KSEM 2013. LNCS, vol. 8041, pp. 112–131. Springer, Heidelberg (2013).
- R.H. Grabner, A. Fink, A. Stipacek, C. Neuper, A.C. Neubauer, Intelligence and working memory systems: evidence of neural efficiency in alpha band ERD, *Brain Res. Cogn. Brain Res.* 20 (2004) 212–225.
- R.H. Grabner, A.C. Neubauer, E. Stern, Superior performance and neural efficiency: the impact of intelligence and expertise, *Brain Res. Bull.* 69 (2006) 422–439.
- Rasmussen, J. (1987). The definition of human error and a taxonomy for technical system design. In *New technology and human error* (pp. 23-30). Wiley.
- Rezek, I. A., & Roberts, S. J. (1998). Stochastic complexity measures for physiological signal analysis. *IEEE Transactions on Biomedical Engineering*, 45(9), 1186-1191.
- Richman, J. S., & Moorman, J. R. (2000). Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology*, 278(6), H2039-H2049.
- Ryali, S., Supekar, K., Abrams, D. A., & Menon, V. (2010). Sparse logistic regression for whole-brain classification of fMRI data. *NeuroImage*, 51(2), 752-764.
- S.J. Luck, S.A. Hillyard, Electrophysiological correlates of feature analysis during visual search, *Psychophysiology* 31 (1994) 291–308.
- Sanei, S., & Chambers, J. A. (2013). *EEG signal processing*. John Wiley & Sons.
- Sangals J, Heuer H, Manzey D, Lorenz B (1999) Changed visuomotor transformations during and after prolonged microgravity. *Experimental brain research* 129: 378–390.

- Schapire, R. E. (2003). The boosting approach to machine learning: An overview. In *Nonlinear estimation and classification* (pp. 149-171). Springer, New York, NY.
- Schneider, S., Abeln, V., Askew, C. D., Vogt, T., Hoffmann, U., Denise, P., & Strüder, H. K. (2013). Changes in cerebral oxygenation during parabolic flight. *European journal of applied physiology*, 113(6), 1617-1623
- Schneider, S., Askew, C. D., Brümmer, V., Kleinert, J., Guardiera, S., Abel, T., & Strüder, H. K. (2009). The effect of parabolic flight on perceived physical, motivational and psychological state in men and women: correlation with neuroendocrine stress parameters and electrocortical activity. *Stress*, 12(4), 336-349.
- Schneider, S., Brümmer, V., Göbel, S., Carnahan, H., Dubrowski, A., & Strüder, H. K. (2007). Parabolic flight experience is related to increased release of stress hormones. *European journal of applied physiology*, 100(3), 301-308.
- Sexton, J.B., Thomas, E.J., Helmreich, R.L.: Error, stress, and teamwork in medicine and aviation: cross sectional surveys. *BMJ* 320(7237), 745–749 (2000)
- Shannon, C. E. (1949). Communication in the presence of noise. *Proceedings of the IRE*, 37(1), 10-21.
- Shappel, S.A., Wiegmann, D.A.: The human factors analysis and classification system- HFACS. In: Federal Aviation Administration, Washington, DC, DOT/FAA/AM-00/7 (2000)
- Sieu, Lim-Anna, Antoine Bergel, Elodie Tiran, Thomas Deffieux, Mathieu Pernot, Jean-Luc Gennisson, Mickaël Tanter, and Ivan Cohen. "EEG and functional ultrasound imaging in mobile rats." *Nature methods* 12, no. 9 (2015): 831-834.
- Siuly, S., & Li, Y. (2012). Improving the separability of motor imagery EEG signals using a cross correlation-based least square support vector machine for brain–computer interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(4), 526-538.
- Siuly, S., Li, Y., & Zhang, Y. (2016). EEG signal analysis and classification. *IEEE Trans Neural Syst Rehabil Eng*, 11, 141-4.

- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- Sokolova, M., Japkowicz, N., & Szpakowicz, S. (2006, December). Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation. In *Australasian joint conference on artificial intelligence* (pp. 1015-1021). Springer, Berlin, Heidelberg
- Squire, L., Berg, D., Bloom, F. E., Du Lac, S., Ghosh, A., & Spitzer, N. C. (Eds.). (2012). *Fundamental neuroscience*. Academic Press.
- Stanton, N.A., et al.: Predicting design induced pilot error using HET (human error template) - A new formal human error identification method for flight decks, 1 February 2006. <https://dspace.lib.cranfield.ac.uk/handle/1826/1158>. Accessed 25 Nov 2015
- Strangman, G., & Bevan, G. (2013, May). Review of human cognitive performance in spaceflight. In *84th Annual Scientific Meeting of the Aerospace Medical Association* (pp. 12-16).
- T. Krings, R. Töpper, H. Foltys, S. Erberich, R. Sparing, K. Willmes, A. Thron, Cortical activation patterns during complex motor tasks in piano players and control subjects. A functional magnetic resonance imaging study, *Neurosci. Lett.* 278 (2000) 189–193.
- Tharwat, A., Gaber, T., Ibrahim, A., & Hassanien, A. E. (2017). Linear discriminant analysis: A detailed tutorial. *AI communications*, 30(2), 169-190.
- Thul, A., Lechinger, J., Donis, J., Michitsch, G., Pichler, G., Kochs, E. F., ... & Schabus, M. (2016). EEG entropy measures indicate decrease of cortical information processing in Disorders of Consciousness. *Clinical Neurophysiology*, 127(2), 1419-1427.
- Van Ombergen, A., Demertzi, A., Tomilovskaya, E., Jeurissen, B., Sijbers, J., Kozlovskaya, I. B., ... & Wuyts, F. L. (2017). The effect of spaceflight and microgravity on the human brain. *Journal of neurology*, 264(1), 18-22.
- Vapnik, V. N. (1995). *The nature of statistical learning. Theory.*

- Wang, Q., Li, Y., & Liu, X. (2018). Analysis of feature fatigue EEG signals based on wavelet entropy. *International Journal of Pattern Recognition and Artificial Intelligence*, 32(08), 1854023.
- Wollseiffen, P., Vogt, T., Abeln, V., Strüder, H. K., Askew, C. D., & Schneider, S. (2016). Neuro-cognitive performance is enhanced during short periods of microgravity. *Physiology & Behavior*, 155, 9-16.
- Xing, X., Jia, X., & Meng, M. H. (2018, July). Bleeding detection in wireless capsule endoscopy image video using superpixel-color histogram and a subspace KNN classifier. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 1-4). IEEE.
- Y. Kita, A. Mori, M. Nara, Two types of movement-related cortical potentials preceding wrist extension in humans, *Neuroreport* 12 (2001) 2221–2225.
- Young, M. S., & Stanton, N. A. (2002). Malleable attentional resources theory: a new explanation for the effects of mental underload on performance. *Human factors*, 44(3), 365-375.
- Zhang, C., Wang, H., & Fu, R. (2013). Automated detection of driver fatigue based on entropy and complexity measures. *IEEE Transactions on Intelligent Transportation Systems*, 15(1), 168-177.
- Zhang, N., & Leatham, K. (2017). Feature selection based on SVM in photo-thermal infrared (IR) imaging spectroscopy classification with limited training samples. *WSEAS transactions on signal processing*, 13(33).
- Zhang, Y., Ji, X., Liu, B., Huang, D., Xie, F., & Zhang, Y. (2017). Combined feature extraction method for classification of EEG signals. *Neural Computing and Applications*, 28(11), 3153-3161.
- Zhang, Z. T., Gao, W. H., Zeng, C. F., Tang, X. Y., & Wu, J. (2020). Evolution of the disintegration breakage of red-bed soft rock using a logistic regression model. *Transportation Geotechnics*, 24, 100382.
- Zhiwei, L., & Minfen, S. (2007, August). Classification of mental task EEG signals using wavelet packet entropy and SVM. In *2007 8th international conference on electronic measurement and instruments* (pp. 3-906). IEEE

- Zoppelt D, Koch B, Schwarz M, Daum I (2003) Involvement of the mediodorsal thalamic nucleus in mediating recollection and familiarity. *Neuropsychologia* 41: 1160–1170.



EKLER

EK 1- GÖNÜLLÜ BİLGİLENDİRME VE ONAY FORMU

GÖNÜLLÜ BİLGİLENDİRME VE ONAY FORMU

Bir araştırma projesine davet edilmektesiniz. Bu araştırmanın yürütülmesi, Marmara Üniversitesi Tıp Fakültesi Bilimsel Araştırmalar Değerlendirme Komisyonu’nun 01.11.2019 tarih ve 09.2019.974 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 çekilebilirsiniz.

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 biraz düşünün.

Araştırmayla İlgili Bilgiler

Araştırmanın Bilimsel Adı: CİMNASTİK SPORCULARI VE SEDANTERLERDE EĞİK MASA KULLANILARAK YARATILAN AY YERÇEKİMİ ANALOGUNDA ARTAN MENTAL İŞ YÜKÜ ETKİSİNİN BEYİN GÖRÜNTÜLEME İLE İNCELENMESİ

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

Araştırmanın Anlaşılabilir Basit Adı: Cimnastik sporcuları ve sedanterlerde eğik masa kullanılarak yaratılan ay yerçekimi analogunda artan mental iş yüküne olan etkisinin sinirsel yanıtlarını beyin görüntüleme ile araştırmak.

Araştırmanın Amacı: Katılımcı Ay yerçekimine denk gelen $9,5^\circ$ de eğik masaya yatırılacak ve açı deney boyunca sabit kalacak şekilde ayarlanacaktır. Ardından katılımcıya sayı sayma ve göz kapalı deneyi uygulanacaktır. Çalışmada, Ay yerçekimi analogu ve Dünya yerçekimi pozisyonunda, cimnastik ve sedanter katılımcıların zihinden çıkarma ve göz kapalı görevlerini gerçekleştirdiği esnada ölçülen EEG sinyallerini Yaklaşık entropi algoritması uygulayarak; pozisyonun, katılımcıların ve görevlerin sınıflandırılması amaçlanmıştır.

Araştırmada Neler ve Nasıl Uygulanacak:

Çalışma kapsamında katılımcılar deneyin yapılacağı Marmara Üniversitesi Sinirbilim Laboratuvarına gelecek ve deney hakkında bilgilendirileceklerdir.

1. Aşama

Ay yerçekimi analogu deneyiminde; katılımcı ay yerçekimi etkisine denk olan ($9,5^\circ$) eğik masaya uzanacaktır. Katılımcıdan ilk olarak 3 dakika olacak şekilde göz kapalı ve göz açık dinlenme durumu referans kayıtları alınacaktır. Ardından katılımcıdan, 1 dakika boyunca gözler kapalı olacak şekilde zihinden çıkartma görevi (örneğin: 900-9) yapmaları istenecektir. Katılımcıya 1 dakika boyunca sayacağı bilgisi verilmemiş olup sadece kendisine durma talimatının deney sırasında verileceği söylenecektir.

2. Aşama

Dünya yerçekimi deneyiminde; katılımcı rahat bir sandalyede dik pozisyonunda olacak şekilde oturtulacaktır. Katılımcıdan yine 3 dakika olacak şekilde göz kapalı ve göz açık dinlenme durumu referans kayıtları alınacaktır. Ardından katılımcıdan, 1 dakika boyunca gözler kapalı olacak şekilde zihinden çıkartma görevi (örneğin: 900-9) yapmaları istenecektir. Katılımcıya 1 dakika boyunca sayacağı bilgisi verilmemiş olup sadece kendisine durma talimatının deney sırasında verileceği söylenecektir.

Her iki aşama arasında 15 dakikalık ara verilecektir. Bu ara katılımcının rahatlaması ve diğer aşamaya hazırlık için kullanılmıştır. Uygulanacak aşamalarının sırası, katılımcıların deneye aşına oluşundan ya da yorgunluk gibi karıştırıcı faktörlerden etkilenmemesi için aşamaların yerleri gruplar arası fark gözetmeden toplam katılımcı sayısının yarısının 1. Aşamadan diğer yarısının 2. Aşamadan başlaması şeklinde kurgulanmıştır.

Araştırmada Uygulanacak Testler ve Ölçümler

Katılımcılara, deney ve ölçümler başlamadan önce araştırma ve elde edilecek sonuçların spor bilimine sağlayabileceği katkılar hakkında bilgi verilerek test protokolü anlatılacaktır. Katılımcılar test öncesinde herhangi bir ilaç, alkol, kafein içeren içecekler almamaları ek olarak karınlarının tok olması, uykusuz deneye katılmamaları ve saçlarının temiz ve jöle gibi herhangi bir kimyasal kullanmamaları konusunda bilgilendirilecektir.

1. Elektroensafalografi

Beynin en önemli bölgelerinden biri olan serebral korteks (beyin kabuğu) sağ ve sol hemisfer olmak üzere 2 bölgeden oluşur. Her iki hemisfer de yer alan frontal (alın lobu), parietel (yan lob), temporal (şakak lobu) ve oksipital (arka lob) alanlar ise yaşadığı sürece sürekli farklı frekans aralıklarında elektrik sinyali üretir. İnsan beynindeki bu değişik frekanslara sahip sinyallerin ölçümü ise ilk kez, Alman bir nöropsikiyatr olan Hans Berger tarafından 1924'te elektroensafologram (EEG) ile ilegerçekleştirilmiştir. Böylelikle beyinde gerçekleşen karmaşıklığın anlaşılması adına ilk adımı atmış olmuştur. Fakat beyindeki elektrik sinyallerinin ölçümü insan beyninin elektrik sinyalinin ölçümünden çok daha eskiye dayanmaktadır. İlk kez Richard Caton 1875 yılında beyindeki elektik sinyallerinin ölçümünü hayvan denekler üzerinde gerçekleştirmiştir (Collura, 1993). EEG ölçümleri saçlı derinin üzerine yerleştirilen elektrotlar aracılığı ile gerçekleşmektedir. Günümüzde pek çok kullanım alanı olan EEG, zamansal çözünürlülüğü sayesinde hassas veriler elde edilmesine olanak sağlamaktadır. EEG sinyalleri, bireylerin farklı beyin durumlarına göre değişik frekanslarda güç üretmektedir. EEG'de farklı ritimde frekansların ortaya çıkmasında bir çok neden vardır yaş ve özellikle kişinin uyku

durumu bu ritimlerin deęişiminde büyük bir etki göstermektedir (Chen ve ark., 2008).



Şekil 1: 1. Elektriksel sinyal güçlendirici, 2. Başlık, 3. Elektrotlar numaralandırılmış olarak gösterilmektedir.

Uygulama Sırasında Karşılaşabileceğiniz Riskler ve Rahatsızlıklar:

Katılımcı hastalık veya isteksizlik vb. durumlarda kendi rızasıyla araştırmadan ayrılabilir. Deney düzeneğinin uygulanamaması veya eksik uygulanması da katılımcının araştırmadan ayrılması için yeterli olacaktır.

Araştırmanın Bilime ve Tıbbı Katkıları:

Çalışmada Ay çekim etkisinin bilişsel süreçler üzerindeki etkisini araştırmak ve bu sürecin cimnastik ve sedanter gruplar arasında nasıl deęiştiğini anlamak yatmaktadır. Mikro çekimin bilişsel süreç üzerine etkisi literatürde nispeten yeni ve tartışmalı bir konu olması nedeniyle buna ek olarak cimnastikçi ve sedanter gruplar üzerinde beyin görüntüleme ile yola çıkarak yapılmış herhangi bir eğik masa çalışması bulunmaması sebebiyle mikro çekim araştırmaları için yenilikçi bir çalışma olma niteliği taşımaktadır.

Araştırmaya Katılması Beklenen Katılımcı Sayısı: Çalışmaya 22 katılımcının katılması hedeflenmektedir.

İkinci bölüm: (Katılımcının/Hastanın Beyanı) (bu bölüm hazırlanan gönüllü olur formunun sonuna eklenmelidir)

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

EK 2- Dünya yerçekimi ve Ay Analöğü Sınıflandırmasında Sınıflandırma Başarısında Önemli Katkısı Olduđu Düşünölen F3 ve C3 Elektrotlarının Frekans Bantlarındaki Genlik Deđerleri


F3 Kanalı



C3 Kanalı



F3 Kanalı



C3 Kanalı

