

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**BULANIKLIK, KONTRAST VE PARLAKLIĞIN GÖRSEL  
DİKKAT ÜZERİNDEKİ ETKİLERİNİN ÇOKLU NESNE  
İZLEME YÖNTEMİ İLE DEĞERLENDİRİLMESİ VE  
MODELENMESİ**

**DOKTORA TEZİ**

**Mehmet Toyanç YAZGAN**

**İş Sağlığı ve Güvenliği Anabilim Dalı  
İş Sağlığı ve Güvenliği Doktora Programı**

**MAYIS 2024  
İSTANBUL**

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**BULANIKLIK, KONTRAST VE PARLAKLIĞIN GÖRSEL  
DİKKAT ÜZERİNDEKİ ETKİLERİNİN ÇOKLU NESNE  
İZLEME YÖNTEMİ İLE DEĞERLENDİRİLMESİ VE  
MODELENMESİ**

**DOKTORA TEZİ**

**Mehmet Toyanç YAZGAN  
191215001  
0000-0003-3846-4399**

**İş Sağlığı ve Güvenliği Anabilim Dalı  
İş Sağlığı ve Güvenliği Doktora Programı**

**Tez Danışmanı: Dr. Öğr. Üyesi Mustafa YAĞIMLI**

**İstanbul 2024**



T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Jüri Tez Onay Formu

17.05.2024

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ

Bu çalışma 17.05.2024 tarihinde aşağıdaki jüri tarafından İş Sağlığı ve Güvenliği Anabilim Dalı, İş Sağlığı ve Güvenliği (Doktora) Programı Doktora Tezi olarak kabul edilmiştir.

TEZ JÜRİSİ

Dr. Öğr. Üyesi Mustafa YAĞIMLI

Danışman

İstanbul Gedik Üniversitesi

Prof. Dr. Hakan TOZAN

Üye (İmza)

İstanbul Medipol Üniversitesi

Dr. Öğr. Üyesi Aytaç Uğur YERDEN

Üye (İmza)

İstanbul Gedik Üniversitesi

Prof. Dr. Bahaddin SİNSOYSAL

Üye (İmza)

İstanbul Gedik Üniversitesi

Dr. Öğr. Üyesi Taner KARASOY

Üye (İmza)

İstanbul Okan Üniversitesi

## YEMİN METNİ

Doktora Tezi olarak sunduđum “Bulanıklık, Kontrast ve Parlaklıđın G3rsel Dikkat 3zerindeki Etkilerinin oklu Nesne İzleme Y3ntemi ile Deđerlendirilmesi ve Modellenmesi” bařlıklı bu alıřmanın, bilimsel ahlak ve geleneklere uygun řekilde tarafımdan yazıldıđını, bu tezdeki b3t3n bilgileri akademik ve etik kurallar iinde elde ettiđimi, yararlandıđım eserlerin tamamının kaynaklarda g3sterildiđini ve alıřmamın iinde kullanıldııkları her yerde bunlara atıf yapıldıđını, patent ve telif haklarını ihlal edici bir davranıřımın olmadıđını belirtir ve bunu onurumla dođrularım (17/05/2024).

Mehmet Toyan YAZGAN

*Bu tez, insanlık var olduđu srece deęerini koruyacak olan hayatın sonsuz ęrenme srecine adanmıřtır. Aynı zamanda, benimle birlikte bu eęitim yolculuęunda olan ve sevgi, sabır ve anlayıřlarını asla esirgemeyen aileme ithaf edilmiřtir.*



## ÖNSÖZ

Doktora yolculuğumun başından bu yana geçen süre, hayatımın en zorlu, fakat aynı zamanda en öğretici ve tatmin edici dönemini oluşturmuştur. Bu tez çalışmasını tamamlamak, uzun ve çoğunlukla meşakkatli olan bu yolculuğun sonunu temsil ederken, aynı zamanda yeni başlangıçların kapısını da aralamaktadır. Bu süreç boyunca, sadece akademik bilgi birikimim değil, aynı zamanda kararlılık, sabır ve azmin önemi konusunda da bilincim arttı.

Tezim, Bulanıklık, Kontrast ve Parlaklık gibi faktörlerin Görsel Dikkat üzerindeki etkilerinin Çoklu Nesne İzleme yöntemiyle incelenmesi ve modellenmesi üzerine yoğunlaşıyor. Bu konuyu seçmemin ana sebebi, görsel dikkat dinamiklerini etkileyebilecek faktörlerin detaylıca araştırılmasına olan ilgidir. Bu, bana insanların kendi dikkatlerini nasıl yönlendirebildiklerini ve görsel dikkatin nesnenin özelliklerinden nasıl etkilenebileceğini daha derinlemesine kavrama fırsatı veriyor.

Bu detaylı araştırma, sadece kişisel bilgi ve anlayış seviyemi geliştirmeye yardımcı olmakla kalmayıp, aynı zamanda akademik dünya ve toplum için de değerli bir katkı sağlamayı hedefliyor. Bu çalışmanın, görsel dikkat ve algının derinliklerine dair yeni ve önemli bilgileri ortaya çıkararak, bu alanda bilim ve toplumun ilerlemesine katkı sağlamasını umuyorum.

Bu tez çalışmasının tamamlanması sürecinde birçok kişinin desteğini aldım. Başta, danışmanım Dr. Öğr. Üyesi Mustafa Yağımlı'ya, bu yolculuk boyunca bana sürekli destek olduğu ve rehberlik ettiği için sonsuz teşekkürlerimi sunarım. Bilgi birikimi, sabrı ve anlayışı, bu tezin tamamlanmasında büyük bir rol oynamıştır.

Ayrıca, tez komitemin diğer üyeleri Prof. Dr. Hakan Tozan ve Dr. Öğr. Üyesi Aytaç Uğur YERDEN ile İstanbul Gedik Üniversitesi İş Sağlığı ve Güvenliği Anabilim Dalı'ndaki tüm hocalarıma, bana yardımcı oldukları, eleştirel geri bildirimler verdikleri ve çalışmalarımın gelişmesine yardımcı oldukları için teşekkür etmek isterim. Bunun yanı sıra, aileme ve arkadaşlarıma bu süreçte bana vermiş oldukları destek ve sevgi için minnettarım. Özellikle Annem Emine Nuran Yazgan, Babam Mahmut Necdet Yazgan, kardeşim Aslı Sinem Yazgan, akrabalarım ve arkadaşlarıma ve özellikle Mikail Tunç arkadaşıma ve kedim Sunny'e zor zamanlarda moral verme ve sürekli beni motive etme çabaları için teşekkür ederim. Bu bilimsel çalışmada desteklerini esirgemeyen Harvard Üniversitesi'nden Prof. Dr. Jeremy M. Wolfe, Geneseo Üniversitesi'nden Doç. Dr. Jason Ozubko, York Üniversitesi'nden Dr. Shaiyan Keshvari ve Bristol Üniversitesi'nden Dr. Veronika Hadjipanayi'ye minnettarım.

Bu doktora tezi, zorlukları, başarısızlıkları, zaferleri ve sürekli öğrenme arzusunu içeren bir yolculuğun sonucudur. Bu süreçte birçok defa hata yaptım, fakat her hata daha fazla bilgi ve anlayış sağladı. Dolayısıyla, hatalarımı ve başarısızlıklarımı bir öğrenme süreci olarak görme yeteneğimi geliştirdim.

Son olarak, tezimin bu haliyle okurlarımın karşısına çıkıyor olması, benim için büyük bir onur ve ayrıcalıktır. Bu çalışmanın, okuyan herkes için değerli ve ilgi çekici olmasını dilerim.

Haziran 2024

Mehmet Toyanç YAZGAN

---



## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖNSÖZ</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>viii</b>
<b>KISALTMALAR</b> .....	<b>xiii</b>
<b>ÇİZELGELER LİSTESİ</b> .....	<b>xiv</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>xv</b>
<b>SEMBOLLER</b> .....	<b>xx</b>
<b>ÖZET</b> .....	<b>xxi</b>
<b>ABSTRACT</b> .....	<b>xxii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Arka Plan ve Motivasyon .....	1
1.1.1 Bulanıklık .....	1
1.1.2 Kontrast .....	1
1.1.3 Parlaklık .....	2
1.2 Çoklu Nesne Takibi .....	2
1.2.1 Ekran tabanlı ortamlarda çoklu nesne takibi .....	2
1.2.2 ÇNT performansını etkileyen görsel faktörler .....	2
1.2.3 Psikoloji ve iş sağlığı ve güvenliği üzerindeki etkiler .....	3
1.3 Ekran Tabanlı Ortamlarda Görsel Dikkatin Gerçek Dünya Uygulamaları .....	3
1.4 Çoklu Nesne Takibi Araştırma Soruları ve Amaçlar .....	4
1.4.1 Araştırma sorusu 1 .....	4
1.4.2 Araştırma sorusu 2 .....	4
1.4.3 Araştırma sorusu 3 .....	5
1.4.4 Araştırma sorusu 4 .....	5
1.4.5 Araştırma sorusu 5 .....	5
1.4.6 Araştırma sorusu 6 .....	5
1.5 Kapsam ve Sınırlamalar .....	6
1.5.1 Kapsam .....	6
1.5.2 Sınırlamalar .....	6
1.6 Tez İçeriği .....	7
<b>2. LİTERATÜR İNCELEMESİ</b> .....	<b>9</b>
2.1 Çoklu Nesne Takibini Etkileyen Görsel Faktörler .....	9
2.2 Bulanıklık, Kontrast ve Parlaklığın Çoklu Nesne Takibi Üzerindeki Etkileri..	10
2.2.1 Bulanıklık .....	10
2.2.2 Kontrast .....	10
2.2.3 Parlaklık .....	11
2.3 Çoklu Nesne Takibinde Psikolojik Faktörler .....	11
2.4 Ekran Tabanlı Görevlerde İş Sağlığı ve Güvenliği Sorunları .....	12
2.4.1 Görsel ergonomi .....	12
2.4.2 Ara vermeler ve iş yükü yönetimi .....	12
2.4.3 Eğitim ve beceri geliştirme .....	13
2.4.4 Çalışma alanı tasarımı .....	13

2.5 Çoklu Nesne Takibi İçin Mevcut Modeller .....	13
2.5.1 Görsel indeksleme teorisi (GİT) .....	13
2.5.2 Çoklu kaynak kuramı (ÇKK) .....	14
2.5.3 Dinamik dikkat modeli (DDM) .....	14
2.5.4 Olasılıksal takip modeli (OTM) .....	15
<b>3. METODOLOJİ.....</b>	<b>17</b>
3.1 Değişkenler .....	17
3.2 Deney 1 .....	18
3.2.1 Tasarım.....	18
3.2.2 Katılımcılar.....	19
3.2.3 Cihaz ve uyarıcılar .....	20
3.2.4 Prosedür.....	22
3.3 Deney 2 .....	33
3.3.1 Tasarım.....	33
3.3.2 Katılımcılar.....	33
3.3.3 Cihaz ve uyarıcılar .....	33
3.3.4 Prosedür.....	34
3.4 Analiz Planı.....	40
3.4.1 Deney 1 analizi .....	40
3.4.2 Deney 2 analizi .....	41
3.5 Beklenen Sonuçlar.....	41
3.5.1 Deney 1 sonuçları .....	41
3.5.2 Deney 2 sonuçları .....	42
3.6 Potansiyel Problemler ve Alternatif Yaklaşımlar.....	43
3.6.1 Potansiyel problemler .....	43
3.6.2 Alternatif yaklaşımlar .....	43
<b>4. DENEYSEL SONUÇLAR .....</b>	<b>45</b>
4.1 Deney 1 Bulanıklığın Çoklu Nesne Takibi Üzerindeki Etkileri .....	45
4.1.1 Deney 1 bulanıklık için doğrusal karma modelinin analiz sonuçları.....	45
4.1.1.1 KMOY ile uygulanan doğrusal karma model (DKM) .....	45
4.1.1.2 Yakınsama için KMOY kriteri.....	46
4.1.1.3 Ölçeklendirilmiş artıklar .....	46
4.1.1.4 Rassal etkiler .....	48
4.1.1.5 Sabit etkiler .....	50
4.1.1.6 Sabit etkilerin korelasyonu .....	52
4.1.2 Bulanıklık düzeyleri için deney 1 sonrası yapılan test (Post-Hoc).....	59
4.2 Deney 2 Bulanıklığın Çoklu Nesne Takibi Üzerindeki Etkileri .....	62
4.2.1 Deney 2 için bulanıklık doğrusal karma model analizi sonuçları .....	62
4.2.1.1 KMOY ile uygulanan doğrusal karma model(DKM) .....	62
4.2.1.2 Yakınsama için KMOY kriteri.....	62
4.2.1.3 Ölçeklendirilmiş artıklar .....	62
4.2.1.4 Rassal etkiler .....	64
4.2.1.5 Sabit etkiler .....	66
4.2.1.6 Sabit etkilerin katsayısı.....	67
4.2.2 Bulanıklık düzeyleri için deney 2 sonrası yapılan test (Post-Hoc).....	72
4.3 Deney 1 Kontrastın Çoklu Nesne Takibi Üzerindeki Etkileri .....	73
4.3.1 Deneysel 1 Kontrast İçin Doğrusal Karma Modelinin Analiz Sonuçları...73	
4.3.1.1 KMOY ile uygulanan doğrusal karma model (DKM) .....	73
4.3.1.2 Yakınsama için KMOY kriteri.....	74
4.3.1.3 Ölçeklendirilmiş artıklar .....	74

4.3.1.4	Rassal etkiler .....	76
4.3.1.5	Sabit etkiler .....	79
4.3.1.6	Sabit etkilerin korelasyonu .....	81
4.3.2	Kontrast düzeyleri için deney 1 sonrası yapılan test (Post-Hoc).....	85
4.4	Deney 2 Kontrastın Çoklu Nesne Takibi Üzerindeki Etkileri .....	86
4.4.1	Deney 2 Kontrast İçin Doğrusal Karma Modelinin Analiz Sonuçları .....	86
4.4.1.1	KMOY ile uygulanan doğrusal karma model (DKM) .....	86
4.4.1.2	Yakınsama için KMOY kriteri.....	86
4.4.1.3	Ölçeklendirilmiş artıklar .....	87
4.4.1.4	Rassal etkiler .....	88
4.4.1.5	Sabit etkiler .....	91
4.4.1.6	Sabit etkilerin katsayısı.....	92
4.4.2	Kontrast düzeyleri için deney sonrası yapılan test(Post-Hoc).....	97
4.5	Deney 1 Parlaklığın Çoklu Nesne Takibi Üzerindeki Etkileri.....	99
4.5.1	Deney 1 Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları .....	99
4.5.1.1	KMOY ile uygulanan doğrusal karma model (DKM) .....	99
4.5.1.2	Yakınsama için KMOY kriteri.....	100
4.5.1.3	Ölçeklendirilmiş artıklar .....	100
4.5.1.4	Rassal etkiler .....	103
4.5.1.5	Sabit etkiler .....	106
4.5.1.6	Sabit etkilerin korelasyonu .....	107
4.5.2	Parlaklık düzeyleri için deney 1 sonrası yapılan test (Post-Hoc) .....	111
4.6	Deney 2 Parlaklığın Çoklu Nesne Takibi Üzerindeki Etkileri.....	112
4.6.1	Deney 2 Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları .....	112
4.6.1.1	KMOY ile uygulanan doğrusal karma model (DKM) .....	112
4.6.1.2	Yakınsama için KMOY kriteri.....	113
4.6.1.3	Ölçeklendirilmiş artıklar .....	113
4.6.1.4	Rassal etkiler .....	115
4.6.1.5	Sabit etkiler .....	117
4.6.1.6	Sabit etkilerin katsayıları .....	120
4.6.2	Parlaklık düzeyleri için deney 2 sonrası yapılan test (Post-Hoc) .....	125
4.7	Deney 1 Bulanıklık, Kontrast ve Parlaklık Arasındaki Etkileşimler.....	126
4.7.1	Deney 1 Bulanıklık, Kontrast ve Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları .....	126
4.7.1.1	KMOY ile uygulanan doğrusal karma model (DKM) .....	126
4.7.1.2	Yakınsama için KMOY kriteri.....	126
4.7.1.3	Ölçeklendirilmiş artıklar .....	127
4.7.1.4	Rassal etkiler .....	129
4.7.1.5	Sabit etkiler .....	131
4.7.1.6	Sabit etkilerin korelasyonu .....	133
4.7.2	Bulanıklık, kontrast ve parlaklık düzeyleri için deney 1 sonrası yapılan test (Post-Hoc) .....	134
4.8	Deney 2 Bulanıklık, Kontrast ve Parlaklık Arasındaki Etkileşimler.....	136
4.8.1	Deney 2 Deney 1 Bulanıklık, Kontrast ve Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları .....	136
4.8.1.1	KMOY ile uygulanan doğrusal karma model (DKM) .....	136
4.8.1.2	Yakınsama için KMOY kriteri.....	137
4.8.1.3	Ölçeklendirilmiş artıklar .....	137
4.8.1.4	Rassal etkiler .....	139
4.8.1.5	Sabit etkiler .....	140

4.8.1.6 Sabit etkilerin katsayısı.....	142
4.8.2 Bulanıklık, kontrast ve parlaklık düzeyleri için deney 2 sonrası yapılan test (Post-Hoc).....	145
<b>5. PSİKOLOJİK SONUÇLAR.....</b>	<b>147</b>
5.1 Psikolojik Etkilerin Genel Bakışı.....	147
5.2 Bilişsel Yük ve Çoklu Nesne Takibi Performansı.....	148
5.2.1 Bulanıklık manipülasyonları ve bilişsel performans.....	149
5.2.2 Kontrast manipülasyonları ve bilişsel performans.....	149
5.2.3 Parlaklık manipülasyonları ve bilişsel performans.....	149
5.2.4 Bulanıklık, kontrast ve parlaklık etkileşimi.....	150
5.3 Algı ve Performanstaki Bireysel Farklılıklar.....	151
5.4 Dikkat Kaynakları, Çalışma Belleği, Nesne Tanıma, Görev Karmaşıklığı, Motivasyon ve Katılımın Rolü.....	151
5.5 Algı ve Performans Verilerindeki Aykırı Değerler.....	153
5.6 Bulanıklık, Kontrast ve Parlaklıktaki Değişikliklere Adaptasyon.....	154
5.7 Görsel Özelliklerin Etkileşimi.....	154
5.8 Sonradan Yapılan Analiz Sonuçları (Post-Hoc): Gruplar Arasındaki Farklılıkların Yorumlanması.....	155
5.9 Algı ve Performans Çalışmalarında Gelecek Araştırma Yönleri.....	157
5.10 Daha Geniş Psikolojik Teorilerle Entegrasyon.....	158
5.11 Gelecekteki Psikolojik Araştırmalar için Çıkarımlar.....	159
5.12 Sonuçlar.....	160
<b>6. İŞ SAĞLIĞI VE GÜVENLİĞİ SONUÇLARI.....</b>	<b>163</b>
6.1 Genel Bakış ve Giriş.....	163
6.2 İş Güvenliğinde Görsel Manipülasyonun Rolü.....	164
6.3 İş Yerinde Görsel Koşulları Optimize Etme Stratejileri.....	165
6.3.1 Görsel karmaşıklığı azaltma.....	165
6.3.2 Kontrast seviyelerini ayarlama.....	165
6.3.3 Aydınlatma koşullarını yönetme.....	165
6.3.4 Görsel ortamları kişiselleştirme.....	165
6.3.5 Düzenli görme değerlendirmeleri.....	166
6.4 İş Güvenliğinde Yaşın Etkisi.....	166
6.5 İş Güvenliğinde Cinsiyetin Rolü.....	167
6.6 Bireysel Değişkenlik ve İş Güvenliği.....	168
6.7 İş Sağlığı ve Güvenliği: Azaltma Stratejileri ve Öneriler.....	169
6.8 Gerçek Dünya Çalışma Ortamlarına Bulguların Uygulanması: Vaka Çalışmaları.....	170
6.9 Önleme Stratejileri ve Politika Etkileri.....	171
6.10 İş Sağlığı ve Güvenliği Önlemlerinin Değerlendirilmesi ve İyileştirilmesi.....	172
6.11 Sonuçlar.....	174
<b>7. ÇOKLU NESNE İZLEME PERFORMANSININ MODELLENMESİ.....</b>	<b>176</b>
7.1 Model Geliştirme.....	176
7.2 Model Doğrulama.....	177
7.3 Deney 1 Bulanıklık Modellemesi.....	178
7.4 Deney 1 Kontrastın Modellemesi.....	185
7.5 Deney 1 Parlaklığın Modellemesi.....	190
7.6 Deney 1 Bulanıklık, Kontrast ve Parlaklığın Etkileşiminin Modellemesi.....	195
7.7 Deney 2 Bulanıklık Modellemesi.....	200
7.8 Deney 2 Kontrast Modellemesi.....	205
7.9 Deney 2 Parlaklık Modellemesi.....	210

7.10 Deney 2 Bulanıklık, Kontrast ve Parlaklığın Etkileşimini Modelleme .....	216
7.11 İstatistiksel Analizler ve Bulgular .....	220
7.12 Modelin Sonuçları .....	223
<b>8.SONUÇLAR VE TARTIŞMA.....</b>	<b>225</b>
8.1 Değerlendirme Bulgularının Özeti .....	225
8.1.1 Birincil araştırma bulgularının özeti .....	225
8.1.2 Bireysel değişkenliğin önemi .....	225
8.1.3 Görsel manipülasyonlar ve demografik özellikler arasındaki etkileşimler .....	225
8.1.4 Yüksek görsel doğruluk görevlerinin sonuçlarının içerdiği anlamlar .....	226
8.2 Değerlendirmenin Sınırlılıkların Ele Alınması .....	226
8.2.1 Laboratuvar vs. gerçek dünya koşulları .....	226
8.2.2 Demografik değişkenlerin genişletilmesi.....	226
8.2.3 Görsel koşulların kapsamının genişletilmesi.....	226
8.2.4 Bireysel değişkenliğe daha derinlemesine bakış .....	227
8.3 Modelin Bulgularının Etkileri .....	227
8.3.1 Psikoloji araştırmalarını geliştirme .....	227
8.3.2 İş Sağlığı ve güvenliğini geliştirme .....	228
8.3.3 İnsan-Bilgisayar ilişkisindeki tasarımları yönlendirme .....	228
8.3.4 Eğitimi ve yetenek gelişimini iyileştirme .....	228
8.4 Model Sınırlamaları ve Gelecek Araştırmalar .....	229
8.5 İş Sağlığı ve Güvenliğinde Gelecek Yönelimler.....	231
8.5.1 Kişiselleştirilmiş iş güvenliği yaklaşımları .....	231
8.5.2 Görsel sağlığa vurgu .....	231
8.5.3 Eğitimin önemi .....	232
8.5.4 Güvenlik stratejilerinde çalışanların katılımının artması .....	232
8.5.5 Uzun süreli etkileri anlamak için uzun dönemli çalışmalar .....	232
8.5.6 Çok disiplinli perspektiflerin entegrasyonu .....	232
8.5.7 Küresel işbirliği .....	233
8.5.8 Araştırma kapsamının genişlemesi .....	233
8.6 Öğrenilen Dersler ve Geleceğe Dair Beklentiler .....	233
8.7 Sonuç .....	234
<b>KAYNAKLAR.....</b>	<b>236</b>
<b>ÖZGEÇMİŞ .....</b>	<b>246</b>

## KISALTMALAR

<b>ÇNT</b>	: Çoklu Nesne Takip
<b>GİT</b>	: Görsel İndeksleme Teorisi
<b>ÇKK</b>	: Çoklu Kaynak Kuramı
<b>DDM</b>	: Dinamik Dikkat Modeli
<b>OTM</b>	: Olasılıksal Takip Modeli
<b>DKM</b>	: Doğrusal Karma Modeli
<b>KMOY</b>	: Kısıtlanmış Maksimum Olabilirlik Yöntemi
<b>MOY</b>	: Maksimum Olabilirlik Yöntemi
<b>SH</b>	: Standart Hata
<b>SD</b>	: Serbestlik Derecesi
<b>SS</b>	: Standart Sapma
<b>KKE</b>	: Kişisel Koruyucu Ekipman
<b>APG</b>	: Anahtar Performans Göstergeleri
<b>İSG</b>	: İş Sağlığı ve Güvenliği
<b>ÇAA</b>	: Çeyrekler Arası Aralık
<b>AKKK</b>	: Ara Kümülatif Korelasyon Katsayıları
<b>OKH</b>	: Ortalama Karesel Hata
<b>OMH</b>	: Ortalama Mutlak Hata
<b>DVM</b>	: Destek Vektör Makinesi
<b>DM</b>	: Doğrusal Model
<b>RO</b>	: Rastgele Orman
<b>DVM</b>	: Destek Vektör Makinesi
<b>KA</b>	: Karar Ağacı
<b>YSA</b>	: Yapay Sinir Ağı
<b>YZ</b>	: Yapay Zeka

## ÇİZELGELER LİSTESİ

### Sayfa

Çizelge 4.1: Deney 1 Bulanıklık için Ölçeklendirilmiş Artıklar .....	48
Çizelge 4.2: Deney 1 Bulanıklık için Rassal Etkiler .....	49
Çizelge 4.3: Deney 1 Bulanıklık için Sabit Etkiler.....	51
Çizelge 4.4: Deney 1 Bulanıklık için Sabit Etkilerin Korelasyonu .....	53
Çizelge 4.5: Deney 2 Bulanıklık için Ölçeklendirilmiş Artıklar .....	63
Çizelge 4.6: Deney 2 Bulanıklık için Rassal Etkiler .....	64
Çizelge 4.7: Deney 2 Bulanıklık için Sabit Etkilerin Katsayısı .....	68
Çizelge 4.8: Deney 1 Kontrast için Ölçeklendirilmiş Artıklar .....	76
Çizelge 4.9: Deney 1 Kontrast için Rassal Etkiler .....	77
Çizelge 4.10: Deney 1 Kontrast için Sabit Etkiler.....	80
Çizelge 4.11: Deney 1 Kontrast için Sabit Etkiler Korelasyonu .....	81
Çizelge 4.12: Deney 2 Kontrast için Ölçeklendirilmiş Artıklar .....	87
Çizelge 4.13: Deney 2 Kontrast için Rassal Etkiler .....	89
Çizelge 4.14: Deney 2 Kontrast için Sabit Etkilerin Katsayıları.....	93
Çizelge 4.15: Deney 1 Parlaklık için Ölçeklendirilmiş Artıklar .....	101
Çizelge 4.16: Deney 1 Parlaklık için Rassal Etkiler .....	104
Çizelge 4.17: Deney 1 Parlaklık için Sabit Etkiler .....	106
Çizelge 4.18: Deney 1 Parlaklık için Sabit Etkilerin Korelasyonu .....	108
Çizelge 4.19: Deney 2 Parlaklık için Ölçeklendirilmiş Artıklar .....	114
Çizelge 4.20: Deney 2 Parlaklık için Rassal Etkiler .....	116
Çizelge 4.21: Deney 2 Parlaklık için Sabit Etkiler .....	118
Çizelge 4.22: Deney 2 Parlaklık için Sabit Etkilerin Katsayıları .....	121
Çizelge 4.23: Deney 1 Bulanıklık, Kontrast ve Parlaklık için Ölçeklendirilmiş Artıklar .....	128
Çizelge 4.24: Deney 1 Bulanıklık, Kontrast ve Parlaklık için Rassal Etkiler .....	130
Çizelge 4.25: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Ölçeklendirilmiş Artıklar .....	137
Çizelge 4.26: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Rassal Etkiler .....	139
Çizelge 4.27: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Sabit Etkiler .....	141
Çizelge 4.28: Deney 2 için Bulanıklık, Kontrast ve Parlaklık için Sabit Etkilerin Katsayısı.....	143
<u>7.</u>	
Çizelge 7.1: Deney 1 Bulanıklık için OKH, OMH ve $R^2$ 'e göre Model Çizelgesi ..	179
Çizelge 7.2: Deney 1 Kontrast için OKH, OMH ve $R^2$ 'e göre Model Çizelgesi .....	185
Çizelge 7.3: Deney 1 Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Çizelgesi.....	191
Çizelge 7.4: Deney 1 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Tablosu .....	196
Çizelge 7.5: Deney 2 Bulanıklık için OKH, OMH ve $R^2$ 'e göre Model Tablosu ....	201
Çizelge 7.6: Deney 2 Kontrast için OKH, OMH ve $R^2$ 'e göre Model Tablosu .....	206
Çizelge 7.7: Deney 2 Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Tablosu.....	211
Çizelge 7.8: Deney 2 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Tablosu .....	216

## ŞEKİLLER LİSTESİ

Sayfa

<u>3.</u>	
Şekil 3.1: Güç Analizi.....	19
Şekil 3.2: Deneyde kullanılan diskler .....	21
Şekil 3.3: Nesne Özellik Heterojenliği .....	23
Şekil 3.4: Deney 1 %50 Bulanık Evresi (6 px için).....	24
Şekil 3.5: %100 Bulanık Evresi (6 px için).....	25
Şekil 3.6: %50 Kontrast Evresi (-70 için) .....	26
Şekil 3.7: %100 Kontrast Evresi (-70 için) .....	27
Şekil 3.8: %50 Parlaklık Evresi (-70 için).....	28
Şekil 3.9: %100 Parlaklık Evresi (-70 için).....	29
Şekil 3.10: %50 Bulanıklık için 8px,10px,12px,14px .....	30
Şekil 3.11: %100 Bulanıklık için 8px,10px,12px,14px .....	30
Şekil 3.12: %50 Kontrast için -30, 10, 50, 90 .....	31
Şekil 3.13: %100 Kontrast için -30, 10, 50, 90 .....	31
Şekil 3.14: %50 Parlaklık için -30, 10, 50, 90.....	32
Şekil 3.15: %100 Parlaklık için -30, 10, 50, 90.....	32
Şekil 3.16: Bulanıklığın zamansal değişimi .....	35
Şekil 3.17: Kontrastın zamansal değişimi .....	35
Şekil 3.18: Parlaklığın zamansal değişimi .....	36
Şekil 3.19: %50 Bulanıklık Değişim Örneği (6-8-10 px) .....	37
Şekil 3.20: %100 Bulanıklık Değişim Örneği (6,8,10,12,14 px) .....	38
Şekil 3.21: %50 Kontrast Değişim Örneği (-70, -30, 10, 50, 90).....	38
Şekil 3.22: %100 Kontrast Değişim Örneği (-70, -30, 10, 50, 90).....	39
Şekil 3.23: %50 Parlaklık Değişim Örneği (-70, -30, 10, 50, 90).....	39
Şekil 3.24: %100 Parlaklık Değişim Örneği (-70, -30, 10, 50, 90) .....	40
<u>4.</u>	
Şekil 4.1: Deney 1 Bulanıklık için Artıklar ve Tahmin Edilen Değerler .....	46
Şekil 4.2: Deney 1 Bulanıklık için Artıkların QQ plotu .....	47
Şekil 4.3: Deney 1 Bulanıklık için Rassal Etkilerin Histogramı .....	49
Şekil 4.4: Deney 1 Bulanıklık için Rassal Etkilerin Yoğunluk Grafiği .....	50
Şekil 4.5: Deney 1 Bulanıklık Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl (mod_type/Cinsiyet) .....	54
Şekil 4.6: Deney 1 Bulanıklık Ortalama Doğru Tıklamalar(mod_type/Cinsiyet).....	55
Şekil 4.7: Deney 1 Bulanıklık Ortalama Doğru Tıklamaların Yoğunluğu (mod_type/Cinsiyet) .....	56
Şekil 4.8: Deney 1 Bulanıklık Tüm, Sol ve Sağ mod_field'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet).....	57
Şekil 4.9: Deney 1 Bulanıklık Yaş'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	58
Şekil 4.10: Deney 1 Bulanıklık için Çoklu nesne izleme performansının mod_type'a göre grafiği (Cinsiyet).....	59

Şekil 4.11: Deney 1 Bulanıklık için Önemli İkili Karşılaştırmalar- Tahmini.....	61
Şekil 4.12: Deney 2 Bulanıklık için Artıklar ve Tahmin Edilen Değerler.....	63
Şekil 4.13: Deney 2 Bulanıklık için Artıkların QQ plotu .....	64
Şekil 4.14: Deney 2 Bulanıklık için Rassal Etkilerin Histogramı .....	65
Şekil 4.15: Deney 2 Bulanıklık için Rassal Etkilerin Yoğunluk Grafiği .....	66
Şekil 4.16: Deney 2 Bulanıklık Ortalama Doğru Tıklamaları Tahmin Edilen / Asıl (mod_type/Cinsiyet) .....	69
Şekil 4.17: Deney 2 Bulanıklık Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) ...	70
Şekil 4.18: Deney 2 Bulanıklık Ortalama Doğru Tıklamaların Yoğunluğu (mod_type/Cinsiyet) .....	70
Şekil 4.19: Deney 2 Bulanıklık için mod_type'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	71
Şekil 4.20: Deney 2 Bulanıklık Yaş'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	71
Şekil 4.21: Deney 2 Bulanıklık için Çoklu nesne izleme performansının mod_type'a göre grafiği (Cinsiyet).....	72
Şekil 4.22: Deney 2 Bulanıklık için Önemli İkili Karşılaştırmalar- Tahmini.....	73
Şekil 4.23: Deney 1 Kontrast için Artıklar ve Tahmin Edilen Değerler.....	75
Şekil 4.24: Deney 1 Kontrast için Artıkların QQ plotu .....	75
Şekil 4.25: Deney 1 Kontrast için Rassal Etkilerin Histogramı .....	77
Şekil 4.26: Deney 1 Kontrast için Rassal Etkilerin Yoğunluk Grafiği .....	78
Şekil 4.27: Deney 1 Kontrast için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl(mod_type/Cinsiyet) .....	82
Şekil 4.28: Deney 1 Kontrast için Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	83
Şekil 4.29: Deney 1 Kontrast için Ortalama Doğru Tıklamaların Yoğunluğu (mod_type/Cinsiyet) .....	83
Şekil 4.30: Deney 1 Kontrast için yaş'a göre Ortalama Doğru Tıklamalar(mod_type/Cinsiyet).....	84
Şekil 4.31: Deney 1 Kontrast için Çoklu nesne takip performansının mod_type'a göre grafiği (Cinsiyet).....	84
Şekil 4.32: Deney 1 Kontrast için Önemli İkili Karşılaştırmalar- Tahmini.....	85
Şekil 4.33: Deney 2 Kontrast için Artıklar ve Tahmin Edilen Değerler.....	87
Şekil 4.34: Deney 2 Kontrast için Artıkların QQ plotu .....	88
Şekil 4.35: Deney 2 Kontrast için Rassal Etkilerin Histogramı .....	90
Şekil 4.36: Deney 2 Kontrast için Rassal Etkilerin Yoğunluk Grafiği .....	91
Şekil 4.37: Deney 2 Kontrast için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl (mod_type/Cinsiyet) .....	95
Şekil 4.38: Deney 2 Kontrast için Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	95
Şekil 4.39: Deney 2 Kontrast için Ortalama Doğru Tıklamaların Yoğunluğu (mod_type/Cinsiyet) .....	96
Şekil 4.40: Deney 2 Kontrast için mod_type'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	96
Şekil 4.41: Deney 2 Kontrast için Yaş'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	97
Şekil 4.42: Deney 2 Kontrast için Çoklu nesne izleme performansının mod_type'a göre grafiği (Cinsiyet).....	97
Şekil 4.43: Deney 2 Kontrast için Önemli İkili Karşılaştırmalar- Tahmini.....	98
Şekil 4.44: Deney 1 Parlaklık için Artıklar ve Tahmin Edilen Değerler .....	102

Şekil 4.45: Deney 1 Parlaklık için Artıkların QQ plotu.....	102
Şekil 4.46: Deney 1 Parlaklık için Rassal Etkilerin Histogramı .....	104
Şekil 4.47: Deney 1 Parlaklık için Rassal Etkilerin Yoğunluk Grafiği .....	105
Şekil 4.48: Deney 1 Parlaklık için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl(mod_type/Cinsiyet).....	109
Şekil 4.49: Deney 1 Parlaklık için Ortalama Doğru Tıklamalar(mod_type/Cinsiyet) .....	109
Şekil 4.50: Deney 1 Parlaklık için Ortalama Doğru Tıklamaların Yoğunluğu (mod_type/Cinsiyet) .....	110
Şekil 4.51: Deney 1 Parlaklık için Yaş'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	110
Şekil 4.52: Deney 1 Parlaklık için Çoklu nesne izleme performansının mod_type'a göre grafiği (Cinsiyet).....	111
Şekil 4.53: Deney 1 Parlaklık için Önemli İkili Karşılaştırmalar- Tahmini .....	112
Şekil 4.54: Deney 2 Parlaklık için Artıklar ve Tahmin Edilen Değerler .....	114
Şekil 4.55: Deney 2 Parlaklık için Artıkların QQ plotu.....	115
Şekil 4.56: Deney 2 Parlaklık için Rassal Etkilerin Histogramı .....	116
Şekil 4.57: Deney 2 Parlaklık için Rassal Etkilerin Yoğunluk Grafiği .....	117
Şekil 4.58: Deney 2 Parlaklık için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl (mod_type/Cinsiyet).....	122
Şekil 4.59: Deney 2 Parlaklık için Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	122
Şekil 4.60: Deney 2 Parlaklık için Ortalama Doğru Tıklamaların Yoğunluğu (mod_type/Cinsiyet) .....	123
Şekil 4.61: Deney 2 Parlaklık için mod_type'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	123
Şekil 4.62: Deney 2 Parlaklık için Yaş'a göre Ortalama Doğru Tıklamalar (mod_type/Cinsiyet) .....	124
Şekil 4.63: Deney 2 Parlaklık için Çoklu nesne izleme performansının mod_type'a göre grafiği (Cinsiyet).....	124
Şekil 4.64: Deney 2 Parlaklık için Önemli İkili Karşılaştırmalar- Tahmini .....	125
Şekil 4.65: Deney 1 Bulanıklık, Kontrast ve Parlaklık için Modifikasyon Alanına göre Ortalama .....	129
Şekil 4.66: Deney 1 Bulanıklık, Kontrast ve Parlaklık için Ortalama Frekans.....	133
Şekil 4.67: Deney 1 Bulanıklık, Kontrast ve Parlaklık için Tukey Düzeltmeleri ile Tahmini Marjinal Ortalamalar.....	135
Şekil 4.68: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Modifikasyon Alanına göre Ortalama .....	138
Şekil 4.69: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Ortalama Frekans.....	142
Şekil 4.70: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Tukey Düzeltmeleri ile Tahmini Marjinal Ortalamalar.....	146
<u>7</u>	
Şekil 7.1: Deney 1 Bulanıklık için OKH, OMH ve R <sup>2</sup> 'e göre Model Karşılaştırması .....	181
Şekil 7.2: Deney 1 Bulanıklık için Model Performans Metrikleri .....	181
Şekil 7.3: Deney 1 Bulanıklık için OKH, OMH ve R <sup>2</sup> 'e göre Herbir Modelin Ayrı Grafiği .....	182
Şekil 7.4: Deney 1 Bulanıklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri.....	183

Şekil 7.5: Deneysel Bulanıklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler.....	184
Şekil 7.6: Deneysel Bulanıklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı.....	185
Şekil 7.7: Deneysel Kontrast için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması	187
Şekil 7.8: Deneysel Kontrast için Model Performans Metrikleri .....	187
Şekil 7.9: Deneysel Kontrast için OKH, OMH ve $R^2$ 'e göre Herbir Modelin Ayrı Grafiği .....	188
Şekil 7.10: Deneysel Kontrast için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri.....	188
Şekil 7.11: Deneysel Kontrast için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler.....	189
Şekil 7.12: Deneysel Kontrast için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı .....	189
Şekil 7.13: Deneysel Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması .....	191
Şekil 7.14: Deneysel Parlaklık için Model Performans Metrikleri .....	192
Şekil 7.15: Deneysel Parlaklık için OKH, OMH ve $R^2$ 'e göre Her bir Modelin Ayrı Grafiği .....	192
Şekil 7.16: Deneysel Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri.....	193
Şekil 7.17: Deneysel Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler.....	194
Şekil 7.18: Deneysel Parlaklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı.....	195
Şekil 7.19: Deneysel Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması.....	197
Şekil 7.20: Deneysel Bulanıklık, Kontrast ve Parlaklık için Model Performans Metrikleri.....	197
Şekil 7.21: Deneysel Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve $R^2$ 'e göre Her bir Modelin Ayrı Grafiği .....	198
Şekil 7.22: Deneysel Bulanıklık, Kontrast ve Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri.....	198
Şekil 7.23: Deneysel Bulanıklık, Kontrast ve Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler .....	199
Şekil 7.24: Bulanıklık, Kontrast ve Parlaklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı .....	200
Şekil 7.25: Deneysel Bulanıklık için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması .....	202
Şekil 7.26: Deneysel Bulanıklık için Model Performans Metrikleri .....	202
Şekil 7.27: Deneysel Bulanıklık için OKH, OMH ve $R^2$ 'e göre Her bir Modelin Ayrı Grafikleri .....	203
Şekil 7.28: Deneysel Bulanıklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri.....	204
Şekil 7.29: Deneysel Bulanıklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler.....	204
Şekil 7.30: Deneysel Bulanıklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı .....	205
Şekil 7.31: Deneysel Kontrast için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması .....	207

Şekil 7.32: Deneş 2 Kontrast için Model Performans Metrikleri .....	208
Şekil 7.33: Deneş 2 Kontrast için OKH, OMH ve $R^2$ 'e göre Her bir Modelin Ayrı Grafiđi .....	208
Şekil 7.34: Deneş 2 Kontrast için kullanılan Modellerin Gerçek/Tahmin Edilen Deđerleri.....	209
Şekil 7.35: Deneş 2 Kontrast için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Deđerler.....	209
Şekil 7.36: Deneş 2 Kontrast için kullanılan Gerçek/Tahmin Edilen Deđerlerin Sayısı .....	210
Şekil 7.37: Deneş 2 Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması .....	212
Şekil 7.38: Deneş 2 Parlaklık için Model Performans Metrikleri .....	212
Şekil 7.39: Deneş 2 Parlaklık için OKH, OMH ve $R^2$ 'e göre Herbir Modelin Ayrı Grafiđi .....	213
Şekil 7.40: Deneş 2 Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Deđerleri.....	214
Şekil 7.41: Deneş 2 Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Deđerler.....	215
Şekil 7.42: Deneş 2 Parlaklık için kullanılan Gerçek/Tahmin Edilen Deđerlerin Sayısı.....	215
Şekil 7.43: Deneş 2 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve $R^2$ 'e göre Model Karşılaştırması.....	217
Şekil 7.44: Deneş 2 Bulanıklık, Kontrast ve Parlaklık için Model Performans Metrikleri.....	217
Şekil 7.45: Deneş 2 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve $R^2$ 'e göre Her bir Modelin Ayrı Grafiđi .....	218
Şekil 7.46: Deneş 2 Bulanıklık, Kontrast ve Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Deđerleri.....	219
Şekil 7.47: Deneş 2 Bulanıklık, Kontrast ve Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Deđerler .....	219
Şekil 7.48: Deneş 2 Bulanıklık, Kontrast ve Parlaklık için kullanılan Gerçek/Tahmin Edilen Deđerlerin Sayısı .....	220

## SEMBOLLER

$\eta^2_p$  : Değişkenlerin Etki Büyüklüğü  
 $R^2$  : Düzeltilmiş R Kare(R\_kare)



# BULANIKLIK, KONTRAST VE PARLAKLIĞIN GÖRSEL DİKKAT ÜZERİNDEKİ ETKİLERİNİN ÇOKLU NESNE İZLEME YÖNTEMİ İLE DEĞERLENDİRİLMESİ VE MODELLENMESİ

## ÖZET

Bulanıklık, kontrast ve parlaklık gibi görsel manipülasyonlar, görme keskinliğini etkileyerek, insan algısını değiştirebilir. Görme keskinliğindeki bu tür azalmaların, doğru ve hassas eylemlerin yönlendirilmesinde kritik olan görsel algının önemini dikkate alırsak, uçan topları yakalamak veya bir bilgisayar ekranında hareketli nesnelere izlemek gibi dinamik nesnelere takip etme yeteneğimizi de etkilemesi beklenir.

Gerçek dünya senaryolarında, nesnelere yüzey özellikleri bazen hareket ettikçe değişir, bu da nesne sürekliliğini bozar. Bu çalışma, görsel sistemimizin, bulanıklık, parlaklık ve kontrast gibi dinamik değişikliklere nasıl uyum sağladığına dair varsayımlar yapmayı hedeflemektedir.

Günümüzde, birçok işlem bilgisayarlar aracılığıyla gerçekleştirilmekte olup, bunun sonucunda, önemli maddi ve sağlık riskleri ortaya çıkabilir. Bu riskleri önlemek, daha güvenli çalışma ortamları oluşturmak için hayati önem taşımaktadır.

Bu çalışma, ekran üzerindeki görsel dikkati olumlu etkileyen faktörlere odaklanmayı ve olumsuz etkileri önlemek için alınabilecek önlemler önermeyi hedeflemektedir. Ayrıca, bu faktörlerle ilgili sağlık ve güvenlik endişelerini ele almak ve bu konularda gereken eylemleri tartışmak da çalışmanın amaçları arasındadır.

**Anahtar Kelimeler:** *Çoklu Nesne İzleme, Görsel Dikkat, Bulanıklık, Kontrast, Parlaklık*

# EVALUATION AND MODELING OF THE EFFECTS OF BLURDER, CONTRAST AND BRIGHTNESS ON VISUAL ATTENTION BY MULTIPLE OBJECT TRACKING METHOD

## ABSTRACT

Visual manipulations such as blur, contrast, and brightness can affect human perception by altering visual acuity. Given the importance of precise visual perception in guiding accurate actions, such decreases in visual acuity are expected to affect our ability to track dynamic objects, such as catching flying balls or monitoring moving objects on a computer screen.

In real-world scenarios, the surface features of objects sometimes change as they move, disrupting object continuity. This study aims to make assumptions about how our visual system adapitates to dynamic changes involving blur, brightness, and contrast.

In today's world, many processes are performed via computers, which can potentially lead to significant financial and health risks. Preventing these risks is vital for creating safer work environments.

This study aims to focus on the factors that positively affect visual attention on the screen and to suggest precautions that can be taken to prevent negative effects. Additionally, it aims to discuss the necessary actions to address health and safety concerns related to these factors.

**Keywords:** *Multiple Object Tracking, Visual Attention, Blur, Contrast, Brightness*

# 1. GİRİŞ

## 1.1 Arka Plan ve Motivasyon

Çoklu Nesne Takibi (ÇNT) hava trafik kontrolü, sağlık uygulamaları, sürüş, spor ve sürekli olarak birden fazla hareketli nesnenin izlenmesini gerektiren iş ortamları gibi çeşitli alanlarda kritik bir beceridir (Pylyshyn & Storm, 1988; Oksama & Hyönä, 2008). Birden fazla nesneyi doğru ve etkili bir şekilde takip etme yeteneği, durumsal farkındalığın korunması ve uygun kararların alınması için gereklidir ve nihayetinde psikolojik süreçleri ve iş sağlığı ve güvenliğini etkiler. Bilgisayar monitörleri, dijital ekranlar ve dokunmatik ekranlar gibi ekran tabanlı ortamlar günlük yaşamda ve iş ortamlarında giderek yaygınlaşmaktadır. Bu ortamlarda ÇNT performansını etkileyen faktörleri araştırmak, etkili ara yüzlerin tasarlanması ve kullanıcı deneyiminin geliştirilmesi açısından gereklidir. Bulanıklık, kontrast ve parlaklık gibi görsel faktörler, görsel bilginin algılanması ve işlenmesini etkileyebilir (Bex & Makous, 2002; Owsley, 2011). Önceki araştırmalar, bu faktörlerin nesne tanıma ve görsel arama gibi temel görsel görevler üzerindeki etkilerini incelemiştir (Wolfe, 2014; Rosenholtz, Huang & Ehinger, 2012). Bununla birlikte, bu faktörlerin ekran tabanlı ortamlarda ÇNT performansı üzerindeki etkisi daha az anlaşılmaktadır.

### 1.1.1 Bulanıklık

Bir nesnenin sınırları belirsiz veya belirgin olmadığında bulanıklık meydana gelir ve uzamsal ayrımı algısını etkiler (Webster, Georgeson & Webster, 2002). Bulanıklığın nesne tanımayı olumsuz etkilediği gösterilmiştir (Bennett & Vuong, 2006) ve ayrıca nesnelere arasındaki ayrım yeteneğini azaltarak ÇNT performansını da olumsuz etkileyebilir (Lappi, 2016).

### 1.1.2 Kontrast

Kontrast, bir nesne ile çevresi arasındaki parlaklık veya renk farkını ifade eder (Campbell & Robson, 1968). Azalan kontrast, nesnelere ayırt etmeyi

zorlaştırarak ÇNT performansını azaltabilir (Landy, Maloney, Johnston & Young, 1995; Huang, Pashler & Junge, 2004).

### **1.1.3 Parlaklık**

Parlaklık, bir nesne veya çevresi tarafından yayılan ışığın algılanan yoğunluğunu ifade eder (Bartleson, 1960). Parlaklık düzeylerindeki değişiklikler, nesnelerin görünürlüğünü etkileyebilir ve potansiyel olarak ÇNT performansını etkileyebilir (Fernandez-Duque & Thornton, 2000).

Bu çalışma, bulanıklık, kontrast ve parlaklığın ekran tabanlı ortamlarda ÇNT performansı üzerindeki etkilerini sistematik olarak değerlendirmeyi ve modellemeyi amaçlamaktadır. Bu etkilerin anlaşılması, temel psikolojik süreçler hakkında değerli bilgiler sunmanın yanı sıra daha etkili görsel ekranların geliştirilmesine iş sağlığı ve güvenliği için rehberlik sağlamaya da yardımcı olacaktır.

## **1.2 Çoklu Nesne Takibi**

### **1.2.1 Ekran tabanlı ortamlarda çoklu nesne takibi**

Çoklu nesne takibi (ÇNT) araştırmasının kökenleri, Pylyshyn ve Storm (1988) tarafından ilk olarak tanımlanan dikkatli takip çalışmasına dayanır. Katılımcıların, ekrandaki rastgele hareket eden benzer dikkat dağıtıcılar arasında birden fazla hedefi takip etmeleri istendiği bir paradigma geliştirmişlerdir. Bu paradigma daha sonra farklı ÇNT yönlerini incelemek için çeşitli şekillerde uyarlanmış ve genişletilmiştir (Cavanagh & Alvarez, 2005; Scholl, 2009).

### **1.2.2 ÇNT performansını etkileyen görsel faktörler**

Bulanıklık, kontrast ve parlaklık, insan algısı ve performansını önemli ölçüde etkileyebilen görsel özelliklerdir. Görsel bulanıklığın hareket ve derinlik algısını bozduğu gösterilmiştir (Burr & Morgan, 1997; Owsley, 2011), kontrast ise kenarların ve nesne sınırlarının algılanmasında kritik bir rol oynar (Geisler, 2008). Parlaklık, nesnelere ve ayrıntıları farklı aydınlatma koşullarında ayırt etme yeteneğini etkileyen önemli bir görme yönüdür (Bex & Makous, 2002; Owsley, 2011). Bex ve Makous (2002) tarafından yapılan bir çalışma, bulanıklığın, kontrastın ve parlaklığın insan algısı ve performansı üzerinde nasıl etkili olduğunu anlamayı amaçlamıştır. Bu

görsel özelliklerin, nesnelere tanıma ve ayrıntıları farklı aydınlatma koşullarında ayırt etme yeteneğini önemli ölçüde etkileyebileceğini bulmuşlardır.

Araştırmacılar, bu faktörlerin görsel algı üzerindeki etkilerini anlamının önemini vurgulamışlar, çünkü ekran tabanlı ortamlarda etkili ekranlar ve ara yüzler tasarlamak için kritik olduğunu belirtmişlerdir. Bulanıklık, kontrast ve parlaklık etkilerini dikkate alarak birden fazla hareketli nesnenin sürekli olarak izlendiği görevlerde performansı optimize eden daha kullanıcı dostu ve erişilebilir görsel sistemler oluşturulabilir.

### **1.2.3 Psikoloji ve iş sağlığı ve güvenliği üzerindeki etkiler**

Görsel faktörlerin ÇNT performansı üzerindeki etkilerini anlamak hem psikoloji araştırmaları hem de gerçek dünya uygulamaları için geniş kapsamlı sonuçları vardır. Psikoloji alanında bu faktörlerin incelenmesi, görsel dikkatin ve algının temel mekanizmalarına ışık tutmaya yardımcı olabilir (Cavanagh & Alvarez, 2005). Ayrıca, bu araştırmalar görsel netliği optimize etmeyi ve bilişsel yükü azaltmayı sağlayabilir (Wickens, 2002).

İş sağlığı ve güvenliği açısından, görsel faktörlerin ÇNT performansını nasıl etkilediğini anlamak, görsel izleme üzerine yoğun şekilde dayalı endüstriler için kılavuzların ve en iyi uygulamaların geliştirilmesine katkıda bulunabilir. İyileştirilmiş kılavuzlar potansiyel olarak hataların ve kazaların riskini azaltabilir, işyeri güvenliğini ve verimliliğini artırabilir (Endsley, 2000; Stanton, 2017).

## **1.3 Ekran Tabanlı Ortamlarda Görsel Dikkatin Gerçek Dünya Uygulamaları**

Özellikle bulanıklık, kontrast ve parlaklık gibi faktörlerle ilgili olarak görsel dikkatin anlaşılması, çeşitli gerçek dünya ortamlarında derin etkilere sahiptir. Bu tezde, çeşitli etki alanlarındaki belirli uygulamalara ışık tutması açısından iş yaşamına etkisi olabilecek bazı konular detaylandırılmıştır.

*Sürüş Güvenliği:* Otomotiv tasarımında ve yol güvenliğinde, görsel dikkat üzerine yapılan araştırmalar, gösterge paneli ekranlarının ve yol işaretlerinin geliştirilmesini sağlar. Sürücülerin farklı koşullar altında görsel bilgileri nasıl işlediğinin daha iyi anlaşılması, daha güvenli araç ara yüzleri ve yollar sağlar.

*İş Sağlığı ve Güvenliği:* Uzun süreli ekran kullanımını içeren meslekler için, ekran görüntü ayarlarının optimize edilmesi görsel yorgunluğu azaltabilir ve dikkati artırabilir, böylece hem performansı hem de güvenliği artırabilir.

*Kullanıcı Arayüzü Tasarımı:* Görsel dikkat ilkeleri, yazılım ve web tasarımında erişilebilir ve verimli kullanıcı arayüzleri oluşturmanın ayrılmaz bir parçasıdır. Bu, özellikle özel kontrast ve parlaklık ayarlarının kullanılabilirliği önemli ölçüde artırabileceği görme bozukluğu olan kullanıcılar için çok önemlidir.

*Eğitim Teknolojisi:* E-öğrenme ortamlarında, görsel dikkatin ekran görüntü özelliklerinden nasıl etkilendiğini anlamak, daha etkili dijital eğitim araçlarının tasarımına rehberlik ederek öğrenme sonuçlarını iyileştirebilir.

*Tıbbi Teşhis:* Tıbbi görüntüleme, görsel dikkat araştırmasının uygulanması, netlik ve kontrastın önemli olduğu X-ışınları veya MRI'lar gibi görüntülerden elde edilen teşhislerin doğruluğunu artıran görüntüleme protokollerinin tasarlanmasına yardımcı olur.

Bu örneklerin her biri, ekran tabanlı ortamlarda görsel dikkati anlamının pratik önemini vurgulayarak, bu araştırmanın geniş kapsamlı etkisini göstermektedir.

## **1.4 Çoklu Nesne Takibi Araştırma Soruları ve Amaçlar**

### **1.4.1 Araştırma sorusu 1**

Görsel bulanıklık ekran tabanlı ortamlarda ÇNT performansını nasıl etkiler?

Amaç 1: Farklı bulanıklık düzeylerinin ÇNT performansı üzerindeki etkisini ölçmek. Ancak, ekran tabanlı ortamlarda görsel bulanıklığın ÇNT performansını nasıl etkilediği konusunda sınırlı araştırmalar mevcuttur.

### **1.4.2 Araştırma sorusu 2**

Kontrast, ekran tabanlı ortamlarda ÇNT performansını nasıl etkiler?

Amaç 2: Farklı kontrast düzeylerinin ÇNT performansı üzerindeki etkisini araştırmak. Görsel algıdaki kontrastın rolü hakkında önemli miktarda araştırma bulunmasına rağmen, ÇNT performansı üzerindeki spesifik etkileri hala araştırılmaktadır.

### **1.4.3 Araştırma sorusu 3**

Parlaklık, ekran tabanlı ortamlarda ÇNT performansını nasıl etkiler?

Amaç 3: Farklı parlaklık düzeylerinin ÇNT performansı üzerindeki etkisini değerlendirmek. Parlaklık, görsel algı için önemli bir yön olarak, farklı aydınlatma koşullarında nesnelere ve ayrıntıları ayırt etme yeteneğini etkiler (Bex & Makous, 2002). Bunun ÇNT üzerindeki etkisinin daha fazla araştırılmaya ihtiyacı vardır.

### **1.4.4 Araştırma sorusu 4**

Ekran tabanlı ortamlarda bulanıklık, kontrast ve parlaklık gibi faktörlerin birleşik etkileri ÇNT performansını nasıl etkiler?

Amaç 5: Farklı bulanıklık, kontrast ve parlaklık düzeylerinin bir araya geldiği senaryolarda ÇNT performansının nasıl değiştiğini belirlemek. Bu, görsel faktörlerin kombinasyonunun ÇNT performansı üzerindeki karmaşık etkilerini anlamamıza yardımcı olabilir.

### **1.4.5 Araştırma sorusu 5**

Bu bulguların psikoloji, iş sağlığı ve güvenliği açısından potansiyel etkileri nelerdir?

Amaç 4: Sonuçların ekranların, ara yüzlerin tasarımı ve görsel izlemeye dayalı endüstriler için rehberlik oluşturması konusunda tartışmak. Görsel faktörlerin ÇNT performansı üzerindeki etkilerini anlamak hem psikoloji araştırmaları hem iş sağlığı ve güvenliği uygulamaları açısından için geniş kapsamlı sonuçları vardır.

### **1.4.6 Araştırma sorusu 6**

Görsel bulanıklık, kontrast ve parlaklık gibi faktörlerin Çoklu Nesne Takibi performansını nasıl etkilediğini belirlemek için hangi modelin kullanılması gerektiğini araştırmak.

Amaç 6: Çoklu Nesne Takibi performansını tahmin etmek için bir model geliştirmek. Bu model, görsel bulanıklık, kontrast ve parlaklık gibi faktörlerin etkilerini dikkate alarak, ekran tabanlı ortamlarda insanların nesnelere takip etme yeteneklerini tahmin etmeyi amaçlamaktadır. Bu çalışma, pratik uygulamalara ve endüstriyel çözümlere ışık tutabilir.

## **1.5 Kapsam ve Sınırlamalar**

Bu çalışma, ekran tabanlı ortamlarda bulanıklık, kontrast ve parlaklığın Çoklu Nesne Takibi (ÇNT) performansı üzerindeki etkilerini değerlendirmeyi ve modellemeye odaklanmaktadır. ÇNT performansını etkileyen görsel faktörlerin anlaşılmasına önemli bir katkı yapmayı hedefleyen bu araştırma, kapsamını ve sınırlamalarını kabul etmek önemlidir.

### **1.5.1 Kapsam**

Bu çalışma aşağıdaki konulara odaklanacaktır:

Ekran tabanlı ortamlarda bulanıklık, kontrast ve parlaklık faktörlerinin ÇNT performansı üzerindeki bireysel ve birleşik etkilerinin araştırılması (Bex & Makous, 2002; Owsley, 2011).

Farklı bulanıklık, kontrast ve parlaklık koşullarında ÇNT performansını tahmin etmek için bir hesaplama modeli geliştirme ve doğrulama (Rosenholtz vd.2012; Wolfe, 2014).

### **1.5.2 Sınırlamalar**

Çalışmanın bulgularının genelleme yapılabilirliği, deneyler için seçilen belirli popülasyon ve ortamlar tarafından sınırlanabilir. Sonuçların yorumlanması sırasında kültürel, yaşa ve bireysel farklılıkların ÇNT performansı üzerindeki potansiyel etkilerini dikkate almak önemlidir (Liu vd.2017; Oksama & Hyönä, 2016).

Deneysel düzen, hava trafik kontrolörleri veya uzaktan çalışanlar gibi gerçek dünya ekran tabanlı ortamların karmaşıklığını ve dinamiklerini tam olarak yansıtamayabilir. Bulguların belirli mesleki bağlamlarda doğrulanması için daha fazla araştırmaya ihtiyaç duyulabilir (Baker vd.2020; Grant & Davis, 2015).

Bu çalışma, görüntü kalitesi faktörlerinin ÇNT performansı üzerindeki etkilerine odaklanmasına rağmen, dikkat kaynakları ve çalışma belleği gibi diğer bilişsel faktörlerin de performansı etkileyebileceğini kabul etmek önemlidir (Alvarez & Franconeri, 2007; Scholl, 2009).

## 1.6 Tez İeriđi

Bu tez, arařtırma sorularını ve amalarını sistematik bir Őekilde ele almak iin birkaç blmden oluřmaktadır. İerik Őu Őekildedir:

*Blm 1: Giriř* Bu blmde tezin genel giriři ve arka planı aıklanır. Bulanıklık, kontrast ve parlaklık gibi grsel faktrlerin oklu nesne takibi üzerindeki ve psikoloji, iř sađlıđı ve gvenliđi üzerindeki potansiyel etkileri incelenir ve ekran tabanlı ortamlarda grsel dikkatin gerek dnya uygulamaları aıklanır. Ayrıca arařtırma soruları ve hedefler belirlenir, kapsam ve sınırlamalar aıklanır ve tez ieriđi zeti sunulur.

*Blm 2: Literatr İncelemesi* Bu blmde oklu nesne takibini etkileyen grsel faktrler, bulanıklık, kontrast ve parlaklık gibi faktrler ayrıntılı olarak incelenir. Bu faktrlerin oklu nesne takibi performansı üzerindeki etkileri ve psikolojik faktrlerle iliřkisi arařtırılır. Ayrıca ekran tabanlı grevlerde iř sađlıđı ve gvenliđi sorunlarına deđinilir ve mevcut oklu nesne takibi modelleri tanıtılır.

*Blm 3: Metodoloji* Bu blmde kullanılan deđiřkenler, deneylerin tasarımı, katılımcılar, cihazlar ve prosedrler detaylı bir Őekilde aıklanır. Ayrıca analiz planı ve beklenen sonular belirtilir.

*Blm 4: Deneysel Sonular* Bu blmde bulanıklık, kontrast ve parlaklıđın oklu nesne takibi üzerindeki ayrı ayrı ve birleřik etkileri incelenir. Her deney iin dođrusal karma analizi sonuları, istatistiksel analizler ve bulgular sunulur.

*Blm 5: Psikolojik Sonular* Bu blmde, grsel maniplasyonların biliřsel performans üzerindeki etkileri incelenir. zellikle, parlaklık, kontrast ve bulanıklık gibi grsel faktrlerin biliřsel yk ve dikkat tahsisine olan etkileri üzerinde durulur. Ayrıca, grsel iřlemede bireysel farklılıklar ve demografik zelliklerin bu etkileri nasıl etkilediđi incelenir. Ayrıca psikoloji aısından sonular ve gelecek arařtırmalar ve uygulamalar üzerindeki etkiler tartıřılır.

*Blm 6: İř Sađlıđı ve Gvenliđi Sonuları* Bu blmde, grsel maniplasyonların iř sađlıđı ve gvenliđi üzerindeki etkileri ele alınır. İř yerinde performans ve gvenliđe olan etkileri incelenirken, yař, cinsiyet ve diđer demografik deđiřkenlerin rol gz nne alınır. Ayrıca, iř gvenliđinde grsel maniplasyonun nemi vurgulanırken, bireysel deđiřkenliklerin ve iřyeri ayarlarının nasıl etkilediđi

üzerinde durulur. Gelecekteki araştırma yönelimleri ve iş sağlığı ve güvenliği açısından etkileri de ele alınır.

*Bölüm 7: Modelleme* Bu bölümde geliştirilen modellerin ayrıntıları açıklanır. Deneylemlerin sonuçlarına dayanarak bulanıklık, kontrast ve parlaklık etkilerini içeren modeller geliştirilir ve doğrulanır. Model uygulamaları, istatistiksel analizler ve bulgular tartışılır. Sınırlamalar ve gelecek araştırmalar da ele alınır.

*Bölüm 8: Genel Sonuçlar* Bu bölümde, araştırmanın ana bulguları ve önerileri sunulacaktır. Tezin teorik ve pratik bağlantıları gözden geçirilecek ve gelecek araştırmalar için önerilerde bulunulacaktır. Son olarak, tezin genel sonuçları ve gelecek perspektifler özetlenecektir.

*Referanslar:* Bu bölüm, tez boyunca atıfta bulunulan referansların tam listesini sağlar.

## 2. LİTERATÜR İNCELEMESİ

### 2.1 Çoklu Nesne Takibini Etkileyen Görsel Faktörler

ÇNT performansını etkileyen çeşitli görsel faktörler bulunmaktadır ve bu faktörlerin anlaşılması, iş ortamlarında ekran tabanlı ortamları optimize etmek için önemlidir.

*Nesne Hızı:* ÇNT performansının, hareketli nesnelerin hızından etkilendiği gösterilmiştir. Daha hızlı hareket eden nesneler genellikle sınırlı işleme kapasitesi nedeniyle takibi zorlaştırır (Alvarez & Franconeri, 2007; Franconeri vd.2008).

*Nesne Yoğunluğu:* Nesnelerin yoğunluğu veya aralığı da ÇNT performansını etkiler. Nesneler birbirine daha yakın olduğunda, örtüşme veya yaklaşma olasılıkları artar, bu da takip zorluğunu artırır (Franconeri vd.2008; Horowitz & Cohen, 2010).

*Nesne Boyutu ve Şekli:* Nesnelerin boyutu ve şekli, ÇNT performansını etkileyebilir. Daha büyük veya daha belirgin nesneler genellikle izlemeyi kolaylaştırır, çünkü daha görsel olarak dikkat çekicidirler (Alvarez & Franconeri, 2007; Scholl, 2009).

*Hareket Yönü:* Nesne hareketinin yönü de takip performansını etkileyebilir. Düzgün, öngörülebilir hareket izini takip etmek genellikle ani veya rastgele yönlü değişiklikleri takip etmekten daha kolaydır (Yantis, 1992; Horowitz & Cohen, 2010).

*Nesne Gizliliği:* Nesnelerin kısmen veya tamamen diğer nesneler veya çevre tarafından gizlenmesi durumunda, sürekli görsel bilgi eksikliği nedeniyle takip daha zor hale gelir (Franconeri vd.2008; Scholl, 2009).

*Görüntü Kalitesi Faktörleri:* Bulanıklık, kontrast ve parlaklık gibi faktörler, görsel algı ve dikkati etkileyebilir ve ÇNT performansını da etkileyebilir (Wickens vd.2015). Örneğin, kontrastı azaltılmış veya bulanıklığı artırılmış görüntüler, nesneler arasında ayırım yapmayı zorlaştırabilir ve bu da takip performansını etkileyebilir (Liu vd.2017). Yüksek parlaklık seviyeleri, dolaylı olarak ÇNT

performansını olumsuz etkileyebilecek göz yorgunluđuna ve görsel rahatsızlıđa neden olabilir, çünkü izleyicinin hareketli nesnelere odaklanma ve dikkati sürdürme yeteneđini azaltabilir (Hedge vd.,2016).

Görüntü kalitesi faktörlerinin ÇNT performansı üzerindeki etkisi, ekran tabanlı çalışma ortamlarının tasarımında pratik uygulamalara sahiptir. Örneđin, kontrast, parlaklık ve netlik gibi görüntü ayarlarını optimize etmek, takip performansını geliştirebilir ve görsel yorgunluk veya rahatsızlıđın riskini azaltarak iş sađlıđı ve güvenliđi sonuçlarını iyileştirebilir (Hedge vd.,2016; Wickens vd.,2015).

Görüntü kalitesi faktörlerinin ÇNT performansı üzerindeki etkisini daha iyi anlamak için, farklı bulanıklık, kontrast ve parlaklık seviyeleri ile birlikte ÇNT'i etkileyen diđer görsel faktörlerin kombinasyonları gibi çeşitli koşullar altında etkilerini sistematik olarak araştıran daha fazla araştırmaya ihtiyaç vardır. Bu araştırma, ÇNT performansı üzerinde görüntü kalitesi faktörlerinin olumsuz etkilerini en aza indiren ekran tabanlı ortamların tasarımı için rehberler sađlamaya yardımcı olacaktır ve iş ortamlarında daha etkili ve verimli görsel bilgi işleme desteđi sađlayacaktır.

## **2.2 Bulanıklık, Kontrast ve Parlaklıđın Çoklu Nesne Takibi Üzerindeki Etkileri**

Çoklu nesne takibi (ÇNT) performansı, içsel faktörlerin yanı sıra bulanıklık, kontrast ve parlaklık gibi görsel özellikler gibi çeşitli faktörlerden etkilenmektedir. Bu bölüm, ÇNT performansını etkileyen görsel faktörler üzerine literatürü, insan algısı ve performansı üzerindeki etkilerini gözden geçirmektedir.

### **2.2.1 Bulanıklık**

Bulanıklıđın ÇNT performansı üzerindeki etkilerini doğrudan inceleyen araştırmalar sınırlı olsa da bulanıklıđın dikkat ve görsel arama görevlerini etkilediđi çalışmalar bulunmaktadır (McGowan vd.,1998), bu da ÇNT üzerinde potansiyel bir etkisi olduđunu düşündürmektedir.

### **2.2.2 Kontrast**

Yüksek kontrast, nesne tanıma ve takip performansını iyileştirebilirken, düşük kontrast nesnelere ayırt etmeyi ve takip etmeyi zorlaştırabilir (Geisler, 2008).

Bazı çalışmalar, kontrastın ÇNT görevindeki rolünü araştırmış ve kontrastın azaltılmasının performansı olumsuz etkileyebileceğini göstermiştir (Lu & Doshier, 1998).

### 2.2.3 Parlaklık

Araştırmalar, parlaklığın nesne tanıma ve mekânsal çözünürlük gibi çeşitli görsel algı yönlerini etkilediğini göstermiştir (Bex & Makous, 2002; Owsley, 2011). Bununla birlikte, parlaklık ile ÇNT performansı arasındaki ilişki literatürde yeterince araştırılmamıştır.

## 2.3 Çoklu Nesne Takibinde Psikolojik Faktörler

Görsel faktörlerin yanı sıra, çeşitli psikolojik faktörler de çoklu nesne takibi (ÇNT) performansını etkilemektedir. Bu faktörlerin anlaşılması özellikle iş sağlığı ve güvenliği açısından çoklu nesne takibini gerektiren görevlerde performansın öngörülmesi ve iyileştirilmesi için önemlidir.

*Dikkat Kaynakları:* ÇNT, birden fazla nesnenin konumlarını takip etmek ve güncellemek için dikkat kaynaklarını tahsis etmeyi gerektiren bir görevdir (Alvarez & Franconeri, 2007; Cavanagh & Alvarez, 2005). Nesnelere takip etme yeteneği, mevcut dikkat kapasitesi tarafından sınırlanabilir ve bu kapasite, bireysel farklılıklar, bilişsel yük ve yorgunluk gibi faktörlerden etkilenebilir (Tombu & Seiffert, 2008).

*Çalışma Belleği:* ÇNT performansı, nesnelere konumları ve kimlikleri hakkındaki bilgileri koruma ve güncelleme gerektirdiği için çalışma belleği kapasitesi ile yakından ilişkilidir (Allen vd.,2006; Fougne & Marois, 2006). Çalışma belleği kapasitesindeki bireysel farklılıklar, ÇNT performansını etkileyebilir (Oksama & Hyönä, 2016).

*Nesne Kimliği:* Birden fazla nesneyi takip etme yeteneği, nesnelere farklı özelliklere veya niteliklere sahip olduğu durumlarda da etkilenebilir (Horowitz & Cohen, 2010; Oksama & Hyönä, 2016). Görev, katılımcıların nesnelere takip etmenin yanı sıra belirli nesne özelliklerini hatırlama ve rapor etme gerektirdiğinde, takip performansı azalabilir (Pelli & Aw, 2013).

*Görev Karmaşıklığı:* ÇNT görevinin karmaşıklığı da performansı etkileyebilir. Örneğin, üç boyutlu hareket eden nesnelere veya hareket sırasında

görünümünü deęiřtiren nesnelere takip etmek gerektiğinde, takip performansı azalabilir (Liu vd.,2017; Scholl, 2009).

*Motivasyon ve Katılım:* ÇNT performansı, bireyin motivasyonu ve göreve katılımı tarafından etkilenebilir (Wickens vd.,2015). Örneęin, daha yüksek motivasyon seviyeleri, artan odaklanma ve azalan dikkat sapmaları nedeniyle daha iyi takip performansına yol açabilir (Baldassi vd.,2006).

## **2.4 Ekran Tabanlı Görevlerde İş Sağlığı ve Güvenlięi Sorunları**

Ekran tabanlı görevler, birçok meslekte önemli bir bileşen haline gelmiş olup çalışanlar önemli bir süre dijital ekranlarla etkileşim halindedir. Çalışanların sağlık ve güvenliğini sağlamak, refahı ve üretkenlięi teşvik etmek açısından önemlidir. Bu bölümde, ekran tabanlı görevlerde iş sağlığı ve güvenlięi sorunları ile ilgili literatür gözden geçirilmekte olup, çoklu nesne takibi ile ilgili konulara odaklanılmaktadır.

### **2.4.1 Görsel ergonomi**

Görsel ergonomi, görsel unsurların iş ortamında tasarımı ve düzenlenmesini içeren görsel yorgunluęu azaltma ve performansı artırma konusunda çalışır (Rosenfield, 2011). Ekran tabanlı görevlerde, ekran parlaklıęı, kontrast ve çözünürlük gibi faktörler, görsel konforu ve görev performansını etkileyebilir (Hedge & James, 2018). Bu faktörleri uygun şekilde ayarlamak, göz yorgunluęunu ve yorgunluęu en aza indirebilir, özellikle çoklu nesne takibini gerektiren görevlerde önemli olabilir (Rosenfield, 2011).

### **2.4.2 Ara vermeler ve iş yükü yönetimi**

Ekran tabanlı görevlere uzun süreli katılım, görsel ve bilişsel yorgunluęa neden olabilir ve ÇNT gibi görevlerde performansı olumsuz etkileyebilir (Krupinski vd.,2012). Düzenli ara vermeler ve iş yükü yönetimi stratejileri, çalışanların dinlenmelerine ve iyileşmelerine yardımcı olarak bu sorunları hafifletebilir (McLean vd.,2017). Örneęin, kısa ara vermeler veya görev taleplerindeki deęişiklikler, yorgunluęun ÇNT performansı üzerindeki etkisini azaltabilir (McLean vd.,2017).

### **2.4.3 Eğitim ve beceri geliştirme**

Eğitim ve beceri geliştirme programları, ÇNT gerektiren ekran tabanlı görevlerde performansı artırabilir (Ericsson vd.,1993). Eğitim, dikkat kaynaklarını daha etkili bir şekilde tahsis etme, bilişsel yükü yönetme, nesne bireyselleştirme ve segmentasyonu iyileştirme stratejilerinin geliştirilmesini içerebilir (Van Meeuwen vd.,2014). Özel eğitim programları ile çoklu nesne takibini gerektiren görevlerde performansı optimize edebiliriz (Van Meeuwen vd.,2014).

### **2.4.4 Çalışma alanı tasarımı**

Ekran tabanlı görevleri içeren çalışma alanlarının tasarımı, iş sağlığı ve güvenliği açısından çalışanların sağlığını ve güvenliğini etkileyebilir, özellikle çoklu nesne takibini gerektiren görevlerde aydınlatma, ekran konumu ve oturma düzeni gibi faktörler, görsel konforu, duruşu ve genel refahı etkileyebilir (Hedge & James, 2018). Ergonomik olarak tasarlanmış bir çalışma alanı, çoklu nesne takibi performansı ile ilgili potansiyel sorunları azaltabilir ve daha sağlıklı bir çalışma ortamı sağlayabilir.

Özetlemek gerekirse, ekran tabanlı görevlerde iş sağlığı ve güvenliği sorunları, görsel ergonomi, ara vermeler ve iş yükü yönetimi, eğitim-beceri geliştirme ve çalışma alanı tasarımı gibi konuları içermektedir. Bu faktörlerin ele alınması, çoklu nesne takibini gerektiren görevlerde çalışanların performansını ve refahını artırabilir.

## **2.5 Çoklu Nesne Takibi İçin Mevcut Modeller**

Çoklu nesne takibi (ÇNT) performansını açıklayan mekanizmaları anlamak için çeşitli hesaplamalı modeller önerilmiştir. Bu bölümde, en etkili modellerden bazılarının literatürü ve ÇNT'daki bilişsel süreçleri anlama konusundaki sonuçları gözden geçirilmektedir.

### **2.5.1 Görsel indeksleme teorisi (GİT)**

Görsel İndeksleme Teorisi (GİT), Pylyshyn ve Storm (1988) tarafından önerilen en eski ve en tanınmış ÇNT modellerinden biridir. Bu modele göre, bireyler nesnelere izlemek için sınırlı sayıda "işaretçi"yi nesnelere tahsis ederek aynı anda birden fazla nesneyi takip edebilirler. Bu işaretçiler özelliklerini korusalar veya

değiştirse bile nesne izleme sürekliliğini korumaya yardımcı olur. GİT modeli, takip performansının mevcut işaretçi sayısı ile sınırlı olduğunu önermektedir, bu sayı yaklaşık dört veya beş olabilir (Pylyshyn, 2001).

GİT modeli, görsel işleme sürecinde dikkatin nasıl kullanıldığını açıklar. Bu model, insanların karmaşık bir görsel ortamda birden fazla nesneyi nasıl izlediklerini açıklamada kullanışlıdır. Özellikle, GİT modeli, takip performansının sınırlı dikkat kaynaklarına dayandığını ve bu kaynakların belirli bir kapasiteye sahip olduğunu vurgular. Bu kapasitenin sınırlılığı, insanların aynı anda izleyebilecekleri nesne sayısını etkiler ve bu da ÇNT sürecinin sınırlılığını belirler.

### **2.5.2 Çoklu kaynak kuramı (ÇKK)**

Wolfe'un (1994) Çoklu Kaynak Kuramı (ÇKK), dikkatin farklı işleme kaynaklarına görev taleplerine bağlı olarak tahsis edildiğini öne sürer. ÇNT bağlamında, bu kuram, takip performansının dikkat kaynaklarının mevcudiyeti ve dağılımı tarafından etkilenebileceğini öne sürer. Örneğin, takip edilen nesnelere daha hızlı hareket eder veya ekran kalabalıklaşarsa, performans ek dikkat kaynakları gerektirdiği için azalabilir (Alvarez & Franconeri, 2007).

Bu kurama göre, dikkatin belirli görevlerde kullanılabilirlik durumu, görevin zorluğuna ve gereksinimlerine bağlı olarak değişebilir. Özellikle, ÇNT bağlamında, izleme performansı, dikkat kaynaklarının mevcudiyeti ve dağılımı tarafından etkilenir. Örneğin, daha hızlı hareket eden veya daha fazla nesnenin izlendiği durumlarda, izleme performansının düşmesi muhtemeldir çünkü bu durumlar ek dikkat kaynakları gerektirebilir.

Alvarez ve Franconeri'nin (2007) belirttiği gibi, ek dikkat kaynaklarının gerekliliği, izlemenin zorluğu veya gereksinimleri arttıkça artabilir. Bu, ÇKK'nin izleme performansının dikkat kaynakları tarafından belirlenmesi ve sınırlanması açısından önemli bir model olduğunu gösterir. Bu kuram, izleme görevlerinde dikkatin nasıl dağıldığını ve kullanıldığını anlamamıza yardımcı olur ve izleme performansının çeşitli faktörlere nasıl bağlı olduğunu açıklar.

### **2.5.3 Dinamik dikkat modeli (DDM)**

Cavanagh ve Alvarez (2005) tarafından önerilen Dinamik Dikkat Modeli (DDM), hareketli nesnelerin izlenmesinde dikkatin rolünü vurgular. Bu modele göre,

dikkat, nesnelere hız ve yönelim gibi hareket özelliklerine dayalı olarak tahsis edilir. DDM, izleme performansının dikkati sürdürme yeteneği tarafından belirlendiğini öne sürer.

DDM'e göre, dikkatin hareketli nesnelere üzerinde sürdürülmesi, izleme performansını belirler. Dikkatin hareketli nesnelere uygun şekilde tahsis edilmesi, izleme yeteneğini artırabilir. Ancak, model aynı zamanda nesnelere hareket özelliklerinin karmaşıklığı veya öngörülemezliğinin izleme performansını olumsuz etkileyebileceğini öne sürer. Yani, nesnelere hareketi daha karmaşık veya öngörülemez hale geldikçe, dikkatin bu nesnelere üzerinde sürdürülmesi zorlaşabilir ve izleme performansı azalabilir.

Bu model, izleme sürecinde dikkatin nasıl çalıştığını ve dikkatin hareketli nesnelere takipte nasıl bir rol oynadığını anlamamıza yardımcı olur. Ayrıca, izleme performansının hareket özelliklerinin karmaşıklığına ve öngörülemezliğine nasıl duyarlı olduğunu da vurgular. Bu bilgi, izleme görevlerinin tasarımı ve insan dikkati ile ilgili çalışmalarda önemli bir rol oynar.

#### **2.5.4 Olasılıksal takip modeli (OTM)**

Vul, Frank ve Alvarez (2009), ÇNT performansını nesnelere konumunu ve hareketini tahmin edebilme yeteneğine dayanan bir OTM önermiştir. Bu model, gözlemcinin nesnelere konumları ve hızları hakkındaki içsel belirsizlikleri ve ekran üzerindeki dış gürültüyü (örneğin, bulanıklık, kontrast, parlaklık gibi faktörler) dikkate alır.

Bu modele göre, performansı iyileştirmek için iki ana yaklaşım önerilir:

1. *Görüntü ayarlarını iyileştirmek*: Dış gürültüyü azaltmak veya nesnelere daha net görünmesini sağlamak gibi görüntü ayarlarını düzenleyerek belirsizliği azaltabiliriz. Örneğin, görüntü netliğini artırmak veya kontrastı iyileştirmek gibi ayarlar yapılabilir.
2. *Nesne hareketini tahmin yeteneğini artırmak*: Gözlemcinin nesne hareketlerini daha doğru bir şekilde tahmin edebilmesi için algoritma veya stratejiler geliştirilebilir. Bu, nesnelere gelecekteki konumlarını daha kesin bir şekilde tahmin etmeye ve bu tahminleri ÇNT performansını iyileştirmek için kullanmaya olanak tanır.

Bu yaklaşımların her ikisi de ÇNT performansını artırabilir ve nesnelere izlenmesi veya takibi gibi görsel işlemlerde daha etkili sonuçlar elde edilmesine yardımcı olabilir.

Sonuç olarak, ÇNT performansını açıklamak için çeşitli modeller önerilmiştir, bunlar arasında GİT modeli, ÇKK, DDM ve OTM yer alır. Bu modeller bir araya getirildiğinde, ÇNT performansını anlamamanın ve iyileştirmenin çoklu bir yaklaşım gerektirdiğini görüyoruz. Görsel İndeksleme Teorisinin (GİT) dikkatin sınırlılığını vurgulayan temel bir çerçeve sağladığını, Çoklu Kaynak Kuramının (ÇKK) dikkatin kaynaklara nasıl bölündüğünü ve bu bölünmenin izleme performansını nasıl etkilediğini açıkladığını, Dinamik Dikkat Modeli'nin (DDM) dikkatin hareketli nesnelere nasıl dağıldığını ve bu dağılımın izleme performansını nasıl etkilediğini, Olasılıksal Takip Modeli'nin (OTM) ise içsel belirsizlikleri ve dış gürültüyü dikkate alarak izleme performansını nasıl iyileştirebileceğimizi vurguladığını görüyoruz. Bu modeller bir araya getirildiğinde, çoklu nesne takibi performansını anlamamanın ve optimize etmenin daha kapsamlı bir çerçeve içinde gerçekleşebileceğini söyleyebiliriz. Bu modeller, ÇNT'deki bilişsel süreçleri anlamamıza katkıda bulunur ve çoklu nesne takibini gerektiren görevlerde performansını nasıl iyileştirebileceğimize dair bilgiler sağlayabilir.

### 3. METODOLOJİ

#### 3.1 Değişkenler

Bu bölüm, çalışmada yer alan değişkenlerin ayrıntılı bir genel bakışını sunar. Bağımsız değişkenler, bağımlı değişkenler, değişkenlerin operasyonelleştirilmesi, değişkenlerin ölçülmesi ve kontrol edilmesi gereken olası yabancı değişkenler belirtilmektedir.

**Bağımsız Değişkenler:** Çalışmada bağımsız değişkenler şunları içerir:

a) Deney 1:

Deney 1’de nesne değişken özelliği (bulanıklık, kontrast ve parlaklık) için 4 (özellik sabit, özellik %50 sağ, %50 sol değiştirilmiş ve özellik %100 değiştirilmiş)  $\times$  4 (nesne özellik heterojenliği: iki benzersiz, dört benzersiz, sekiz benzersiz ve homojen) tasarımı incelenmiştir.

b) Deney 2:

Deney 2’de 4 (nesne değişken özelliğinin zamansal değişimi)  $\times$  4 (nesne özellik heterojenliği) tasarımı incelenmiştir.

Diğer bir deyişle, Deney 1 ve Deney 2 için iki faktörlü katılımcı içi tasarımıyla örneklem büyüklüğü tahmini, tek faktörlü katılımcı içi tasarımına dönüştürülmüştür.

**Bağımlı Değişkenler:** Çalışmadaki bağımlı değişken, takip doğruluğudur ve ortalama olarak doğru şekilde tanımlanan hedeflerin oranı olarak ölçülmektedir. Bu ölçüm, katılımcıların verilen deneysel koşullarda nesnelere doğru bir şekilde takip etme yeteneklerine ilişkin bilgi sağlar.

**Değişkenlerin Operasyonelleştirilmesi:** Tutarlılık sağlamak ve katılımcılar arası değişkenliği ortadan kaldırmak için katılımcılar, çalışmada rastgele bir faktör olarak dahil edilir. Nesne değişken özellikleri (bulanıklık, kontrast, parlaklık) nedeniyle dikkatin kaybını doğru bir şekilde ölçmek için yaş ve cinsiyeti olası etkileyen faktörler olarak değerlendirir. Bu değişkenler, ekrandaki en belirgin

özellikler oldukları için gerçek yaşam senaryolarında bilgisayar kullanımı sırasında görsel dikkati etkileme olasılığı yüksektir.

*Değişkenlerin Ölçülmesi:* Değişkenleri ölçmek için, psychopy kütüphanesini kullanarak katılımcılara etkileşimli testler uygulanır. Bu kütüphane aracılığıyla geliştirilen uygulama, katılımcıların dikkat yeteneklerini çeşitli görsel dikkat dağıtıcı kombinasyonlarını internet üzerinden uygulayarak ölçer. Amaç, kullanılan parametrelere bağlı olarak dikkat kaybının hangi koşullar altında meydana geldiğini belirlemek ve katılımcılar arasındaki temel farklılıkları tespit etmektir.

*Kontrol Edilmesi Gereken Olası Yabancı Değişkenler:* Çalışma renk sıcaklığı, ton, keskinlik ve doygunluğu potansiyel yabancı değişkenler olarak kontrol etme gereğini kabul eder. Bu değişkenler, sonuçları karıştırma olasılığı olan etkilerini ortadan kaldırmak için dikkate alınabilir.

Değişkenlerin açık bir şekilde belirtilmesiyle, bu bölüm, araştırılan temel faktörlerin kapsamlı bir anlayışını sağlar ve tezin sonraki bölümleri için temel atmaktadır.

### **3.2 Deney 1**

Bu bölüm, Deney 1'in ayrıntılı bir açıklamasını, tasarımı, katılımcıları, kullanılan cihazı ve uyarıcıları ve izlenen prosedürü içerir.

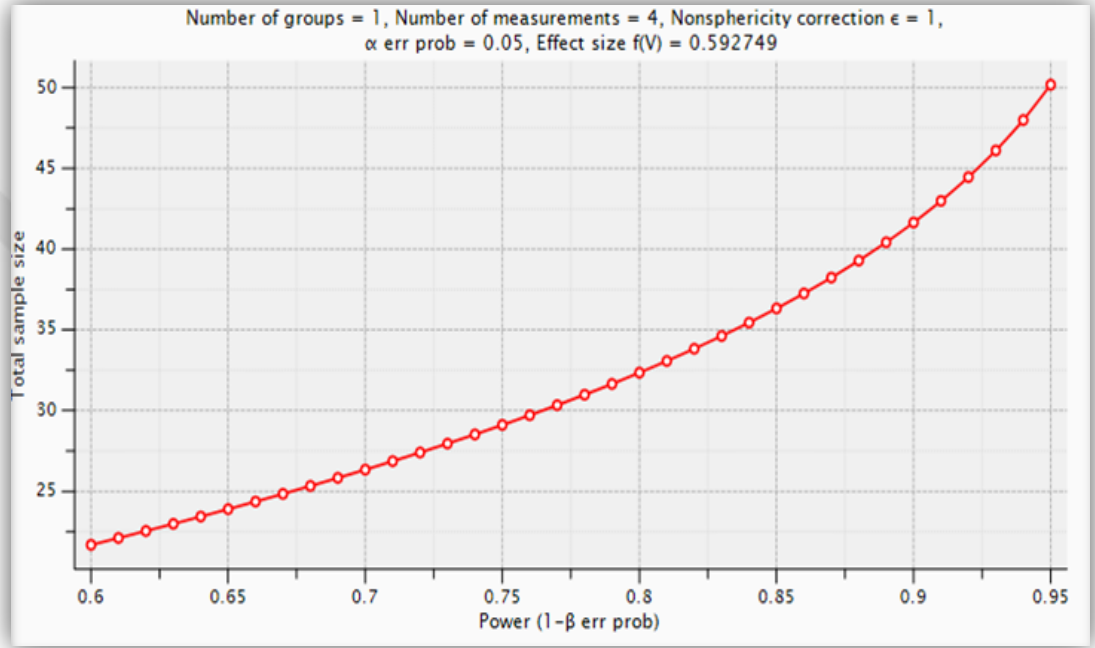
#### **3.2.1 Tasarım**

Hedefler ve çeldiriciler için nesne özellik heterojenliği ile nesne değişken özelliğinin (bulanıklık kontrast ve parlaklık) izleme performansı ile görsel dikkat üzerindeki etkilerinin ne olduğunu tespit etmek için testler yapıldı. Dört düzeyde nesne özellik heterojenliği (yani, yüksek düzeyde nesne özellik heterojenliği, orta düzeyde nesne özellik heterojenliği, düşük düzeyde nesne özellik heterojenliği ve homojen özellik seviyesi/temel seviye) gerçekleştirilmiştir. Nesne değişken özelliği dinamik değişikliklerini (özellik değiştirme koşulu) karşılaştırmak ve özellik değişikliklerinin izleme performansı üzerindeki zararlı etkisini göstermek için temel olarak kararlı nesne değişken özellikleri (özellik sabit durumu) belirlendi. Bu durumda nesnelere üzerinde bulanıklık, kontrast ve parlaklık özellikleri uygulanmadı.

Daha sonraki 3 farklı (%50 sağ, %50 sol özellik değiştirilmiş ve %100 özellik değiştirilmiş) özellik uygulanmasıyla sonuçlar karşılaştırıldı.

### 3.2.2 Katılımcılar

Örneklem büyüklüğü tahmini için istatistiksel güç analizi kullanıldı. Katılımcıların sayısını belirlemek için G\*Power sürüm 3.1'deki konfigürasyon parametreleri aşağıdaki gibidir (Faul vd., 2007).



**Analysis:** A priori: Compute required sample size

**Input:**

Effect size $f(V)$	= 0.5927490
$\alpha$ err prob	= 0.05
Power (1- $\beta$ err prob)	= 0.95
Number of groups	= 1
Number of measurements	= 4
Nonsphericity correction $\epsilon$	= 1

**Output:**

Noncentrality parameter $\lambda$	= 17.9189202
Critical F	= 2.6649070
Numerator df	= 3.0000000
Denominator df	= 150
Total sample size	= 51
Actual power	= 0.9533219

Şekil 3.1: Güç Analizi

Bu etkileşimin öngörülen kısmi  $\eta^2p$ 'si, Makovski ve Jiang'ın benzer şekilde tasarlanmış deneylerinin önsel sonuçlarından daha katı olduğu düşünülerek 0.26 olarak tespit edilirken (2009, Deney 3a, b, etkileşimin kısmi  $\eta^2p$ 'si sırasıyla 0.71 ve 0.40 idi), iki kuyruklu alfa seviyesi 0.05'e ve güç değeri 0.95'e ayarlandı. Grup sayısı ve küresellik doğrulama 1 olarak seçildi ve ölçüm sayısı 4 olarak belirlendi (Şekil 3.1).

Deney 1'deki nesne değişken özelliği ve nesne özellik heterojenitesinin etkisi göz önüne alınarak etki büyüklüğü hesaplanmıştır. Bu analize göre, 51 katılımcıdan oluşan bir örneklem büyüklüğü gerektiği belirlenmiştir. Bununla birlikte, çalışma için yeterli bir örneklem sağlamak için yaş gruplarındaki çalışma yaşındaki nüfusun farklı yaş gruplarını yansıtan çeşitli katılımcıları içeren toplam 64 katılımcı (32 kadın ve 32 erkek) işe alınmıştır.

Deneyde OECD verilerinde bulunan istihdam oranları 18-64 yaş aralığı seçilmiştir. Bu demografikler, çalışma yaşındaki nüfusun farklı yaş gruplarını yansıtmak için seçilmiştir.

Tüm katılımcılar normal veya düzeltilmiş-normal görme ve normal renk algısına sahip kişilerden seçilmiştir.

Tüm katılımcılar deneyden önce onay verdiler. Bu çalışma İstanbul Gedik Üniversitesi Etik Kurulu tarafından onaylanmıştır.


### 3.2.3 Cihaz ve uyarıcılar

Deneyin uygulanması için genel olarak  $1.024 \times 768$  piksel çözünürlüğe ve 60-90 Hz yenileme hızına sahip 14 ile 17 inç arası CRT monitöre sahip masaüstü bilgisayar, dizüstü bilgisayar veya tablet yeterlidir. Bunun dışındaki bilgisayarlarda ve tabletlerde kullanılmasında da herhangi bir sorun çıkmamıştır.

Bulanıklık, kontrasyon ve parlaklık özelliklerinin her biri 5 farklı değer değiştirilerek uygulanmıştır. Photoshop'un gauss bulanıklaştırma, weber kontrastı ve fotometrik parlaklık aracı kullanılarak ayrı ayrı manipüle edilen beş farklı bulanıklık, kontrast ve parlaklık seviyesinde sunulmuştur. Bu seviyeler belirgin farkların ortaya çıkması için eşit aralıklarda ve artan sayısal değerlerin belirlenmesi ile sağlanmıştır.

Ölçülmesi için kullanılan değerler bulanıklık için(6,8,10,12,14px), kontrast için (-70,-30,10,50,90), parlaklık için(-70,-30,10,50,90) olarak belirlendi. Görsel

olarak hareket eden diskler içinse renkler tanımlandı. Bu renkler yüzey özellikleri olarak ortası siyah[RGB (0, 0, 0), (w:1.27 cm, h:1.27 cm)] yanları 8 farklı renk olarak belirlendi. Bu renklerin kırmızı, yeşil, mavi (RGB) boşluk parametreleri Kırmızı [RGB (255, 0, 0)], Yeşil [RGB (0, 128, 0)], Mavi [RGB (0, 0, 255)], Sarı [RGB (255, 255, 0)], Mor [RGB (128, 0, 128)], Turuncu [RGB (255, 165, 0)], Akuamarin [RGB (127, 255, 170)], Kraliyet Mavisi [RGB (65,105,225)] Şekil 3.2’de gösterilmiştir.



**Şekil 3.2:** Deneyde kullanılan diskler

Deney için renkler seçilirken Makovski ve Jiang(2009), Wang vd.(2019) ile Zhao vd.(2020) araştırmaları incelenerek renk ayırt ediciliği sağlamak için değerlendirildi. Her denemede toplam sekiz renkli disk(hareketli nesne)(0,65° yarıçap) kullanıldı ve her nesnenin rengi, mevcut denemenin ait olduğu belirli koşullara bağlıydı. Nesnelerin yarısı, ana hatları çizilmiş bir siyah daire [0.80° yarıçap, 0.09° genişlik ve RGB (0, 0, 0)] tarafından hedef olarak gösterildi. Deney alanı 800 × 600 piksel (25° × 18.75°) ortalanmış dikdörtgen bir alanla sınırlandırıldı.

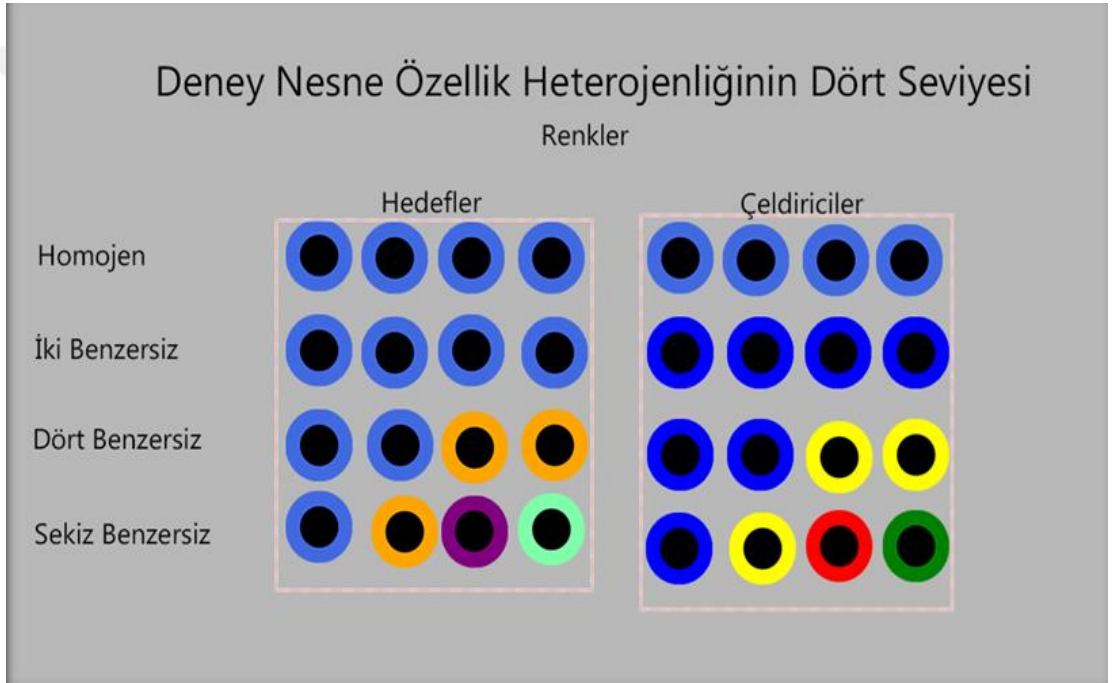
Örnek çalışmalar referans alınarak deney boyunca arka plan rengi gri [RGB (128, 128, 128)] seçilmiştir (Zhao vd.,2020). Her denemenin başında, disklerin (hareketli nesne) başlangıç konumları ve hareket yönleri rastgele seçilmiştir. Hareket eden disklerin (hareketli nesne) başlangıç hızı 20°/s olarak ayarlanmıştır. Hareket sırasında, bu disklerin (hareketli nesne) hareket hızı, gözlemcilerin nesnelere konumlarını tahmin etmelerini önlemek için her 500 ms'de bir başlangıç hızının  $\pm\%4$ 'i aralığında rastgele değişmiştir. Diskler (hareketli nesne) dikdörtgen sınırın kenarından sıçramışlardır ve kesiştiklerinde birbirlerini itmişlerdir.

### 3.2.4 Prosedür

Katılımcılar internet üzerinden bireysel olarak test edilmiştir. Monitörden yaklaşık 60 cm uzağa oturmuşlar ve her denemede toplam sekiz nesne arasında dört hedefi izlemeleri sağlanmıştır. Her denemenin başında, sekiz nesne farklı konumlara rastgele atanmıştır ve dört hedef 2.000 ms boyunca halka dairelerle vurgulanmıştır. Daha sonra halkalar kaybolmuş ve tüm nesnelere sunum alanında rastgele ve bağımsız olarak hareket etmişlerdir. Ekranın sol, sağ yarısı ve tamamında bulunan nesnelere bulanıklık, kontrast ve parlaklık özelliği değiştirilmiştir. Tüm hareketli nesnelere, her denemede 16 ile 20 sn arasında değişen bir zaman noktasında hareketlerini sonlandırmış ve hepsi aynı renge(siyaha) dönmüştür. Tüm nesnelere hareket etmeyi bıraktığında, katılımcılardan sınırsız bir süre boyunca fareyi tıklayarak dört hedef seçmeleri istenmiştir. Ayrıca, kararsız olmaları durumunda tahminde bulunmuşlardır. Katılımcılar dört hedef seçtikten sonra, bir sonraki denemeyi başlatmak için farenin sol çubuğuna basmışlardır. Nesne özellik heterojenliği (iki benzersiz, dört benzersiz, sekiz benzersiz ve homojen) ve nesne değişken özelliği (bulanıklık, kontrast, parlaklık(özellik- sabit, %50 sağ, %50 sol ve %100) manipüle edilmiştir.

Nesne değişken özelliğinin sabit olması durumunda nesne değişken özelliğinde bir değişiklik olmamıştır. %50 durumunda bulanık, kontrast ve parlaklık özelliğini kazanmış nesnelere diğer %50 tarafına geçtiğinde normal hallerine dönmüşlerdir. Bulanıklık, kontrast veya parlaklık nesne değişken özelliğinin %50(yani nesnelere ekranın yarısında bulanıklık, kontrast ve parlaklıklarının değişmesi) olması durumunda ve nesne değişken özelliğinin %100 değişmesi (yani nesnelere tüm ekran boyunca bulanıklık, kontrast ve parlaklıklarının değişmesi) bazı nesnelere renklerinde değişime neden olmuştur. İki benzersiz durumda, dört hedef tek bir rengi paylaşır ve dört çeldirici başka bir rengi paylaşır. Dört benzersiz

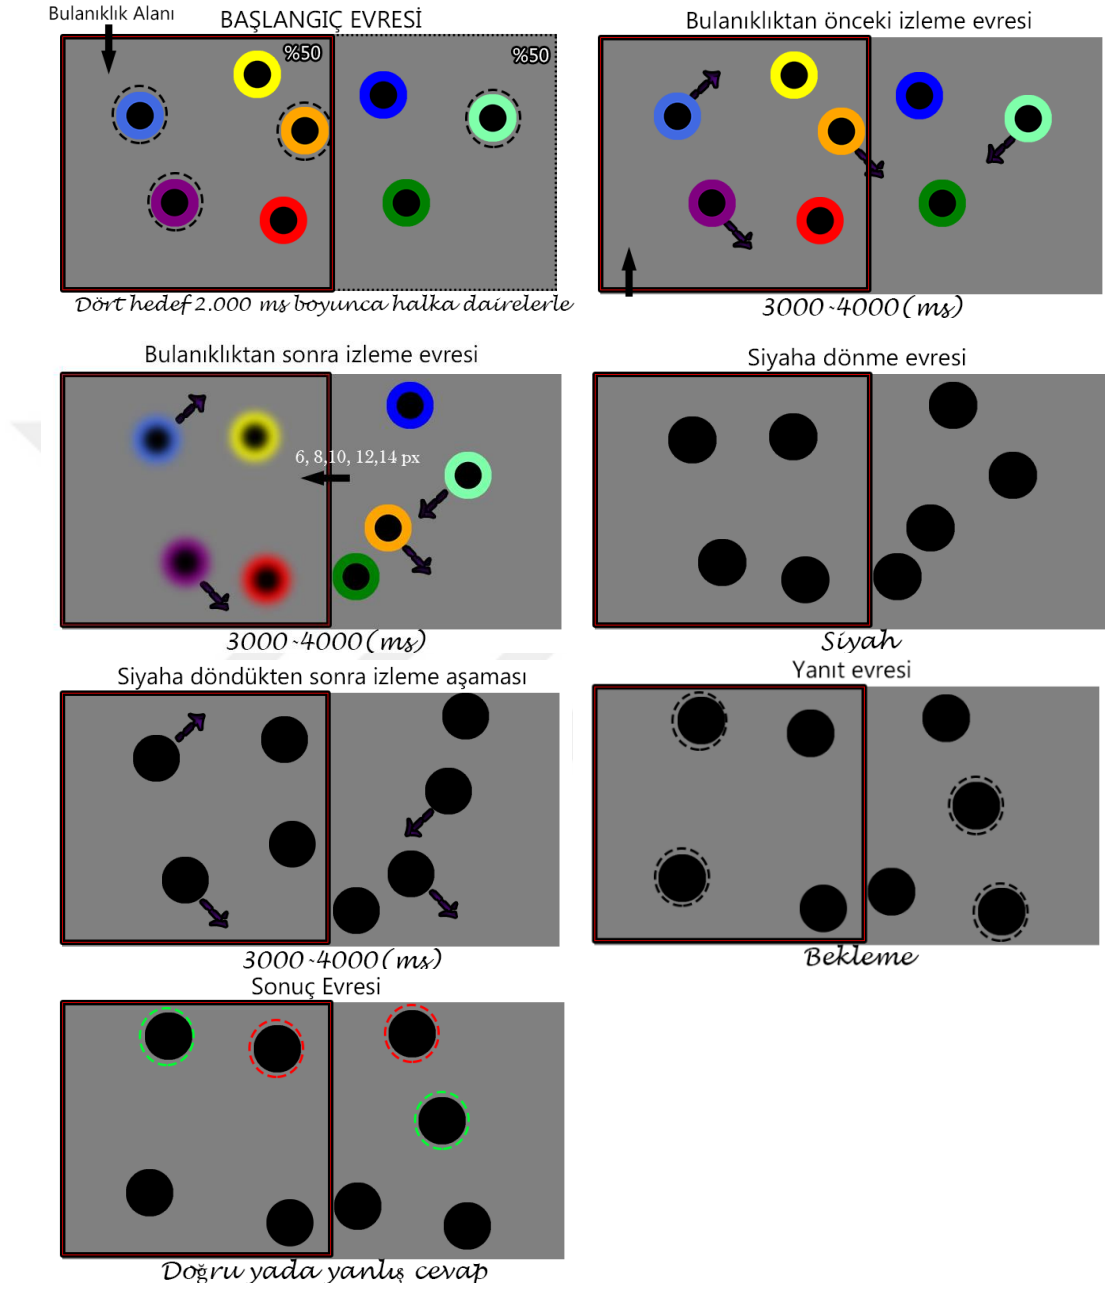
durumda, dört hedef iki çifte bölünmüş ve her hedef çifti bağımsız olarak bir rengi paylaşırken, dört çeldirici de iki çifte bölünmüş ve her çeldirici çifti bağımsız olarak tamamen farklı bir rengi paylaşmıştır. Hedef ve çeldirici çifti sekiz benzersiz durumda, sekiz nesnenin tümü farklı renklindedir. Homojen durumda, sekiz nesnenin tümü aynı renktedir ve bu aynı zamanda temel seviye olarak kabul edilir. Yukarıdaki dört koşul (yani, sekiz-benzersiz, dört-benzersiz, iki-benzersiz ve homojen) sırayla, nesne özellik heterojenliğinin dört hiyerarşik seviyesini (yani, yüksek seviyede nesne özellik heterojenliği, orta seviyede nesne özellik heterojenliği, düşük seviye nesne özellik heterojenliği ve homojen özellik seviyesi/temel seviye) yansıttı (Şekil 3.3).



**Şekil 3.3:** Nesne Özellik Heterojenliği

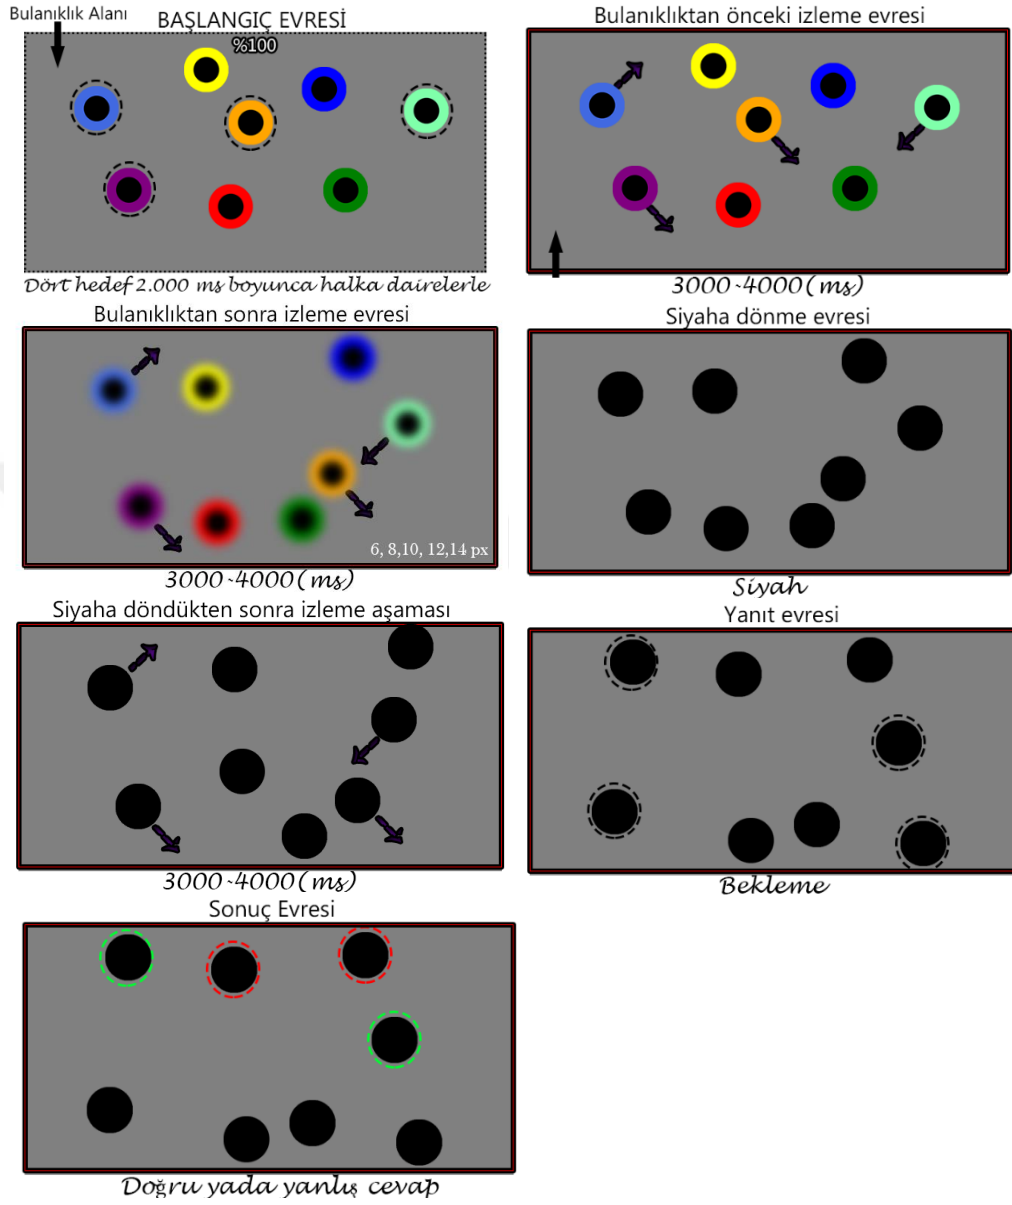
Bulanıklık, kontrast ve parlaklığın her biri için 80 deney aşaması (4 nesne değişken özelliği; her koşulda 20 deneme) tasarlandı. Nesne özellik heterojenliği ve nesne değişken özelliği faktörleri 16 koşulda birleştirilir (4 nesne özellik heterojenliği  $\times$  4 nesne değişken özelliği; her koşulda 20 deneme). 16 koşul için toplam 320 deneme aşaması vardır. Tüm denemeler belli bir sırayla sunulmuştur. Bu denemelerin örnek resimleri aşağıda gösterilmiştir (Şekil 3.4, 3.5, 3.6, 3.7, 3.8, 3.9, 3.10, 3.11, 3.12, 3.13, 3.14, 3.15).

## 50% Bulanıklık Evresi



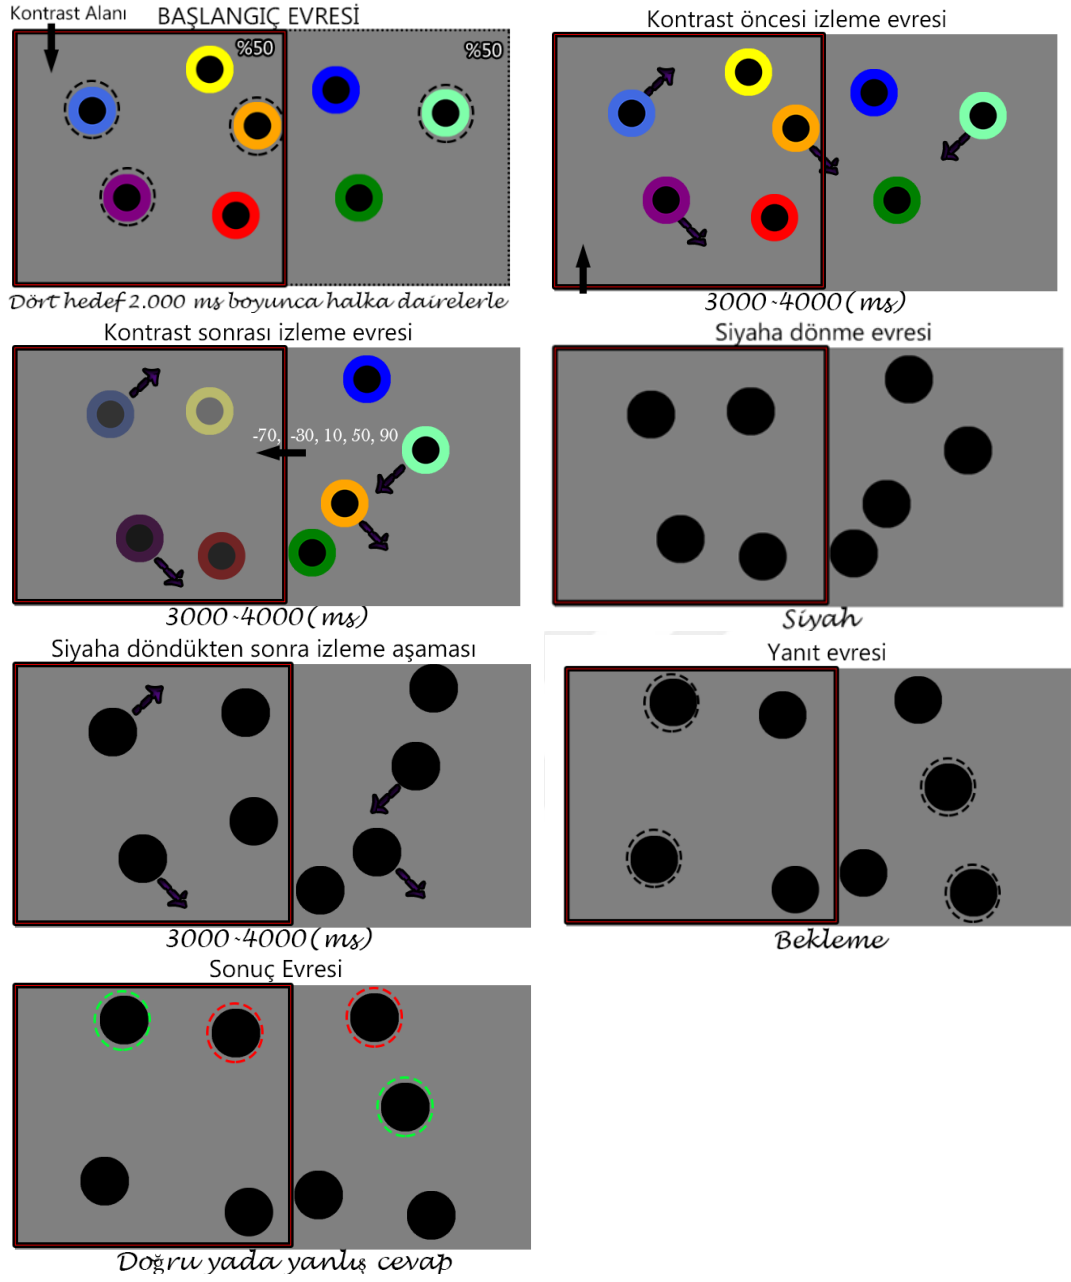
Şekil 3.4: Deney 1 %50 Bulanık Evresi (6 px için)

## 100% Bulanıklık Evresi



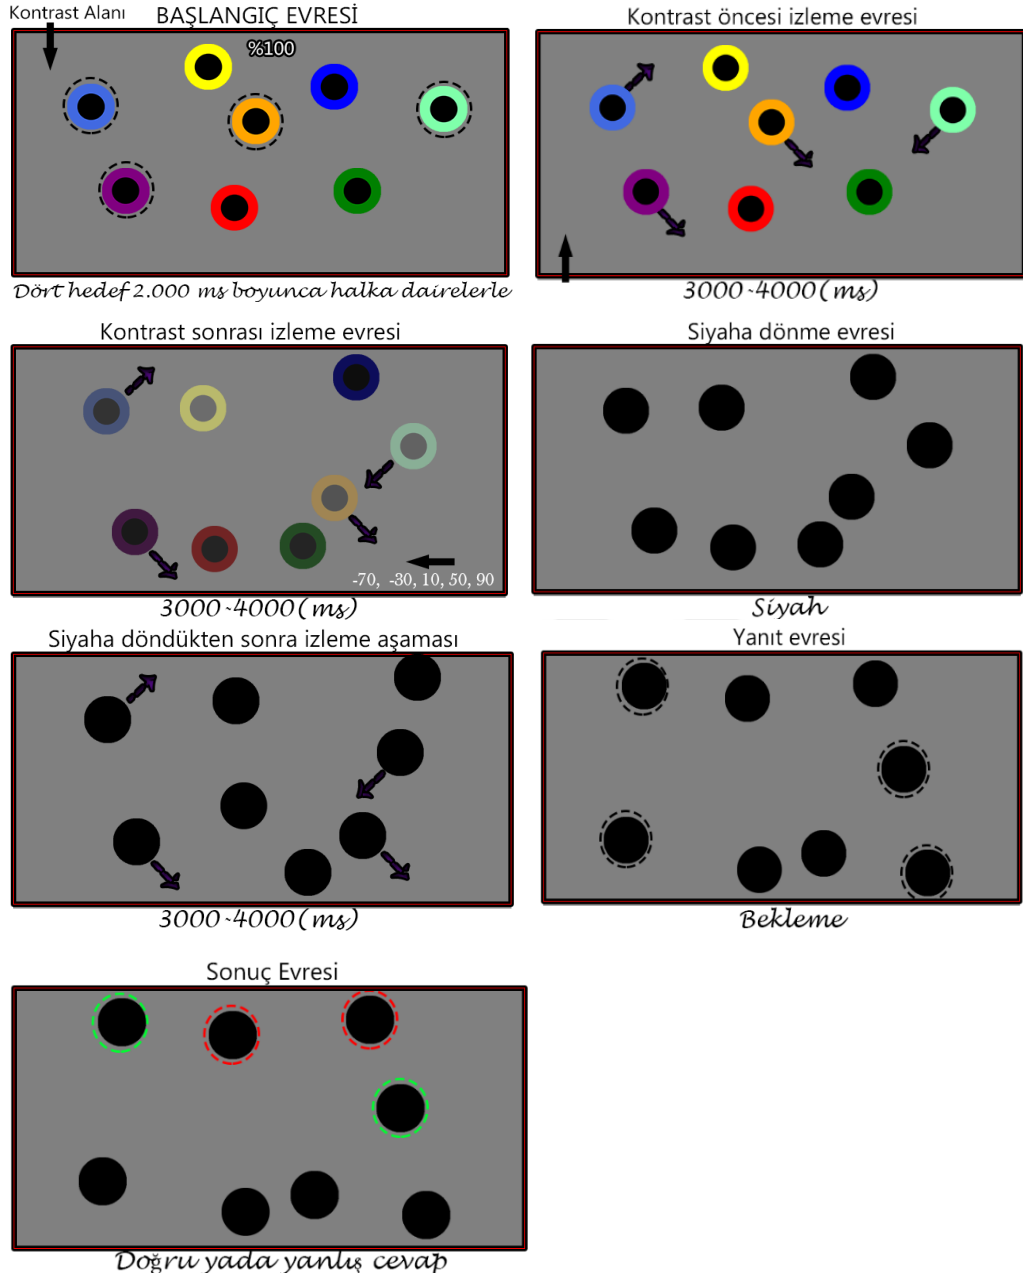
Şekil 3.5: %100 Bulanık Evresi (6 px için)

## 50% Kontrast Evresi



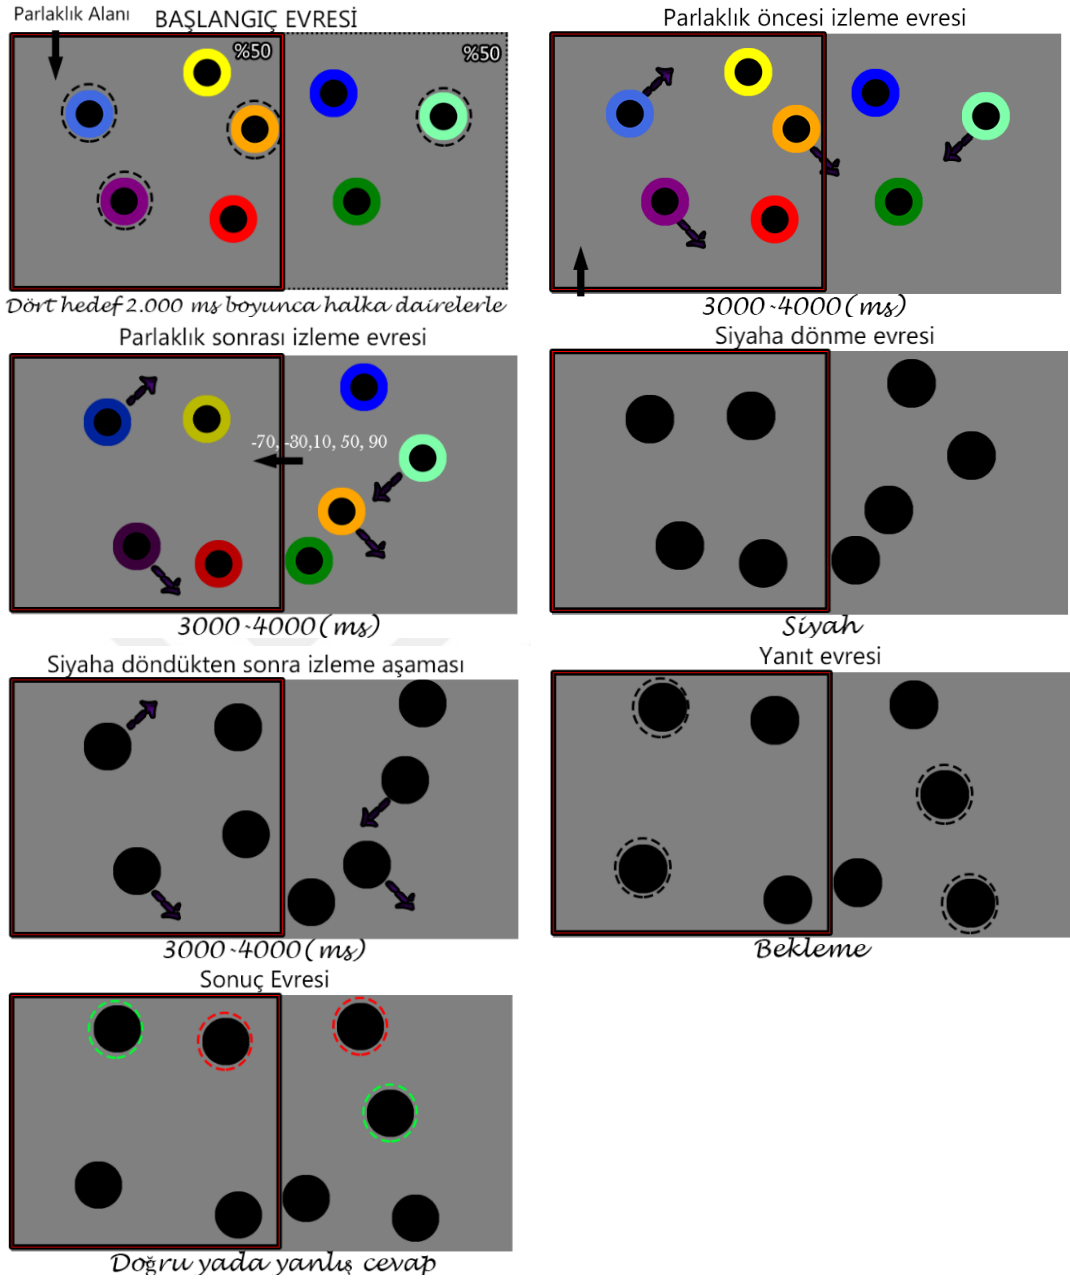
Şekil 3.6: %50 Kontrast Evresi (-70 için)

## 100% Kontrast Evresi



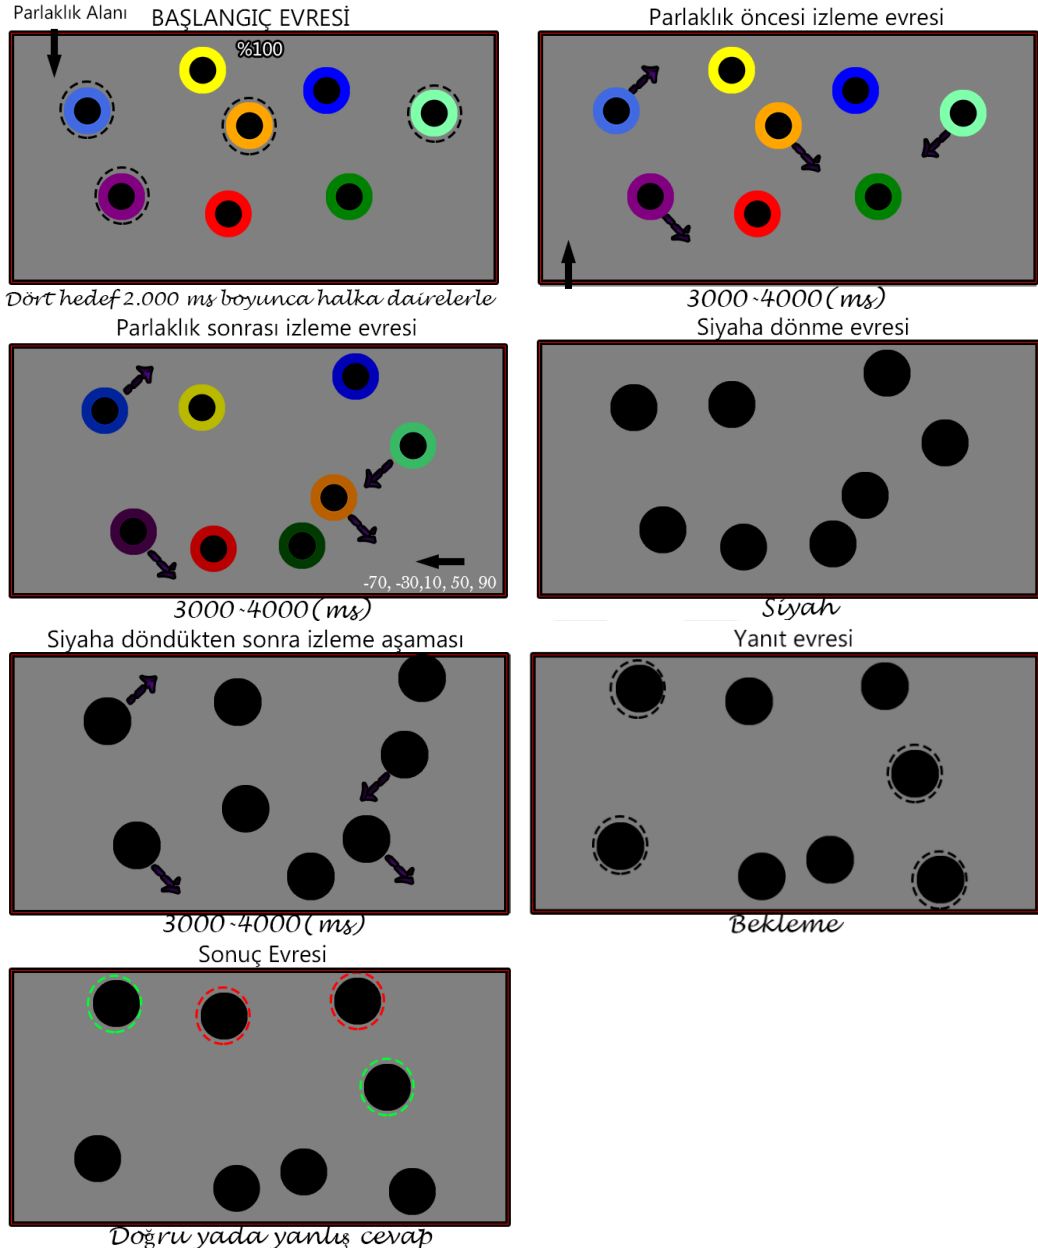
Şekil 3.7: %100 Kontrast Evresi (-70 için)

## 50% Parlaklık Evresi



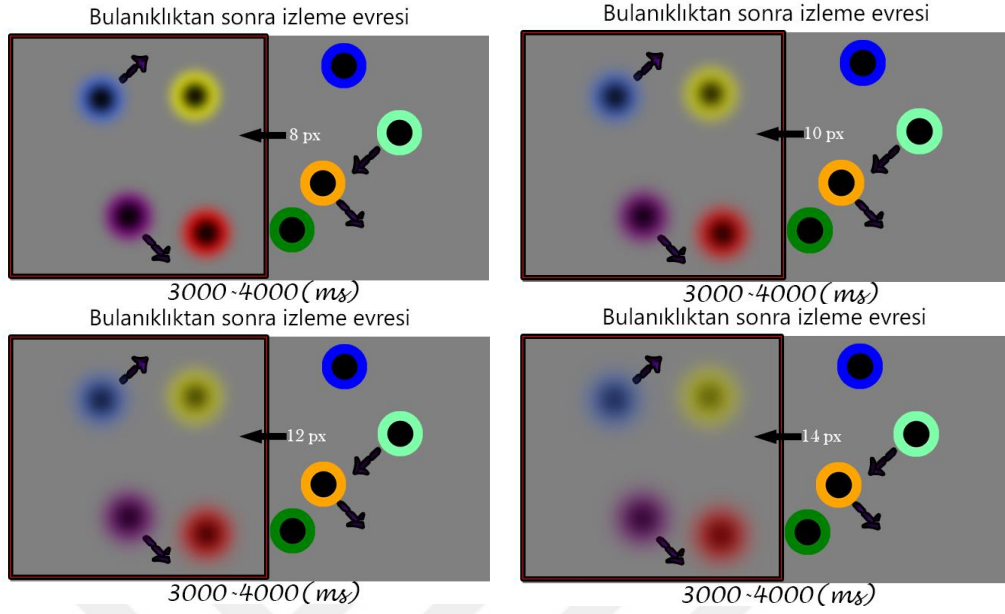
Şekil 3.8: %50 Parlaklık Evresi (-70 için)

## 100% Parlaklık Evresi



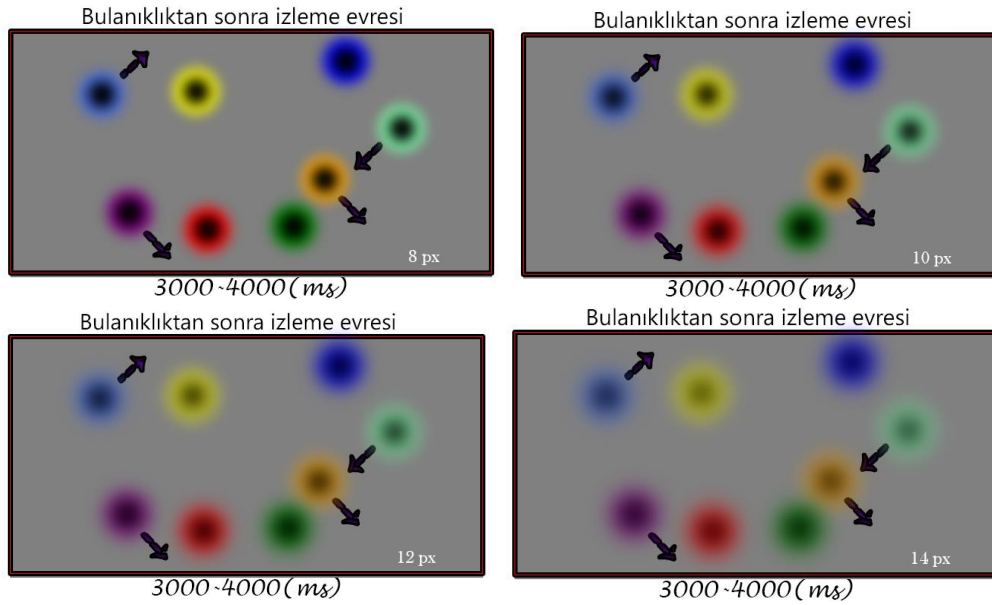
Şekil 3.9: %100 Parlaklık Evresi (-70 için)

## 50% Bulanıklaşma



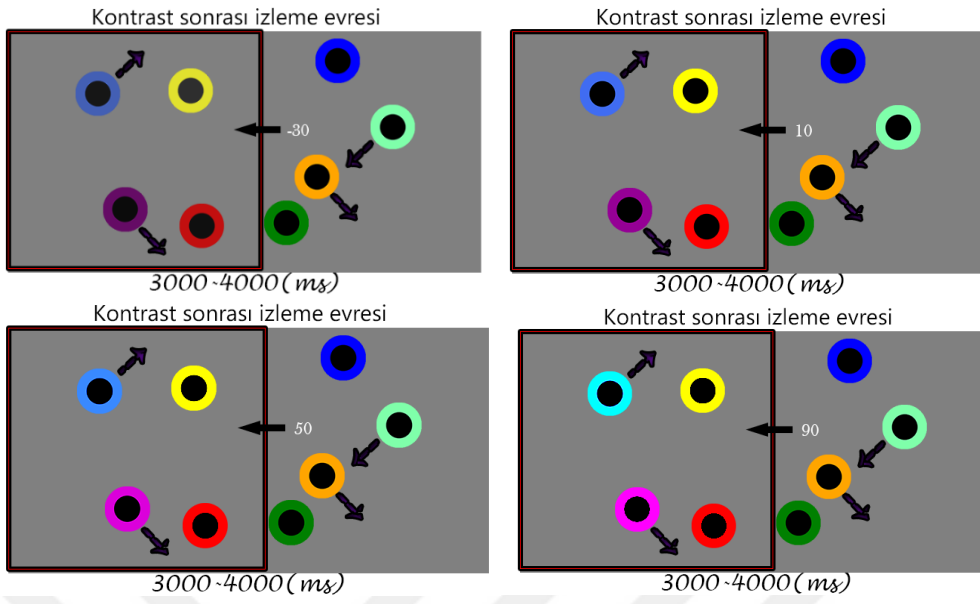
Şekil 3.10: %50 Bulanıklık için 8px,10px,12px,14px

## 100% Bulanıklaşma




Şekil 3.11: %100 Bulanıklık için 8px,10px,12px,14px

## 50% Kontrast



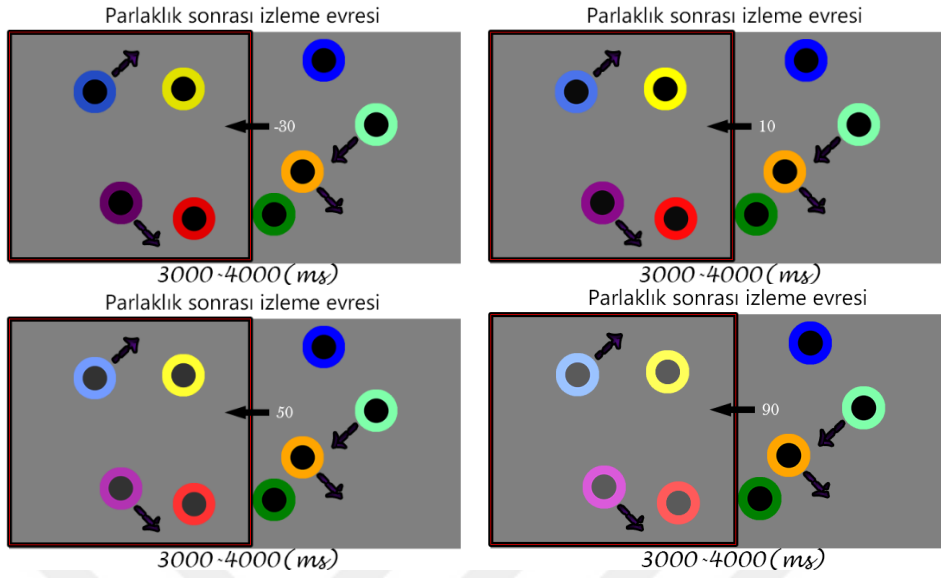
Şekil 3.12: %50 Kontrast için -30, 10, 50, 90

## 100% Kontrast



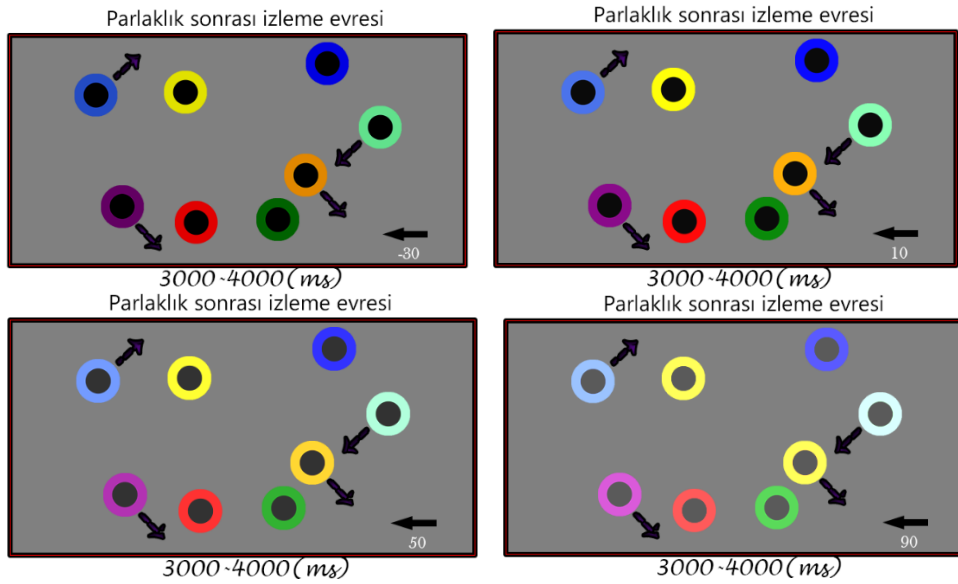
Şekil 3.13: %100 Kontrast için -30, 10, 50, 90

## 50% Parlaklık



Şekil 3.14: %50 Parlaklık için -30, 10, 50, 90

## 100% Parlaklık



Şekil 3.15: %100 Parlaklık için -30, 10, 50, 90

### 3.3 Deney 2

#### 3.3.1 Tasarım

16 koşula ortogonal [yani, 4 (nesne özellik heterojenliği) x 4(nesne değişken özelliğinin zamansal değişimi)] olarak birleştirilen bu deneyde araştırılacak iki faktör, yani nesne özellik heterojenliği ve nesne değişken özelliğinin zamansal değişimi vardır. Nesne heterojenlik özelliği düzeyi, Deney 1'deki gibi dört koşula, yani iki benzersiz, dört benzersiz, sekiz benzersiz ve homojen koşul (temel koşul) olarak bölünmüştür. Nesne değişken özelliğinin zamansal değişim düzeyi, özellik değişikliklerinin çok yüksek[(bulanıklık:6,8,10,12,14px),kontrast (-70, -30,10,50,90), parlaklık(-70,-30,10,50,90)],yüksek[(bulanıklık:6,8,10,12px),kontrast(-70,-30,10,50), parlaklık(-70,-30,10,50)],orta[(bulanıklık:6,8,10px), kontrast (-70, -30,10), parlaklık (-70,-30,10)] ve düşük[(bulanıklık:6,8px), kontrast (-70,-30), parlaklık (-70,-30)] olmak üzere 4 koşula bölünmüştür. Dikkatli izleme sırasında, nesne değişken özelliğinin zamansal değişikliklerinin çok yüksek, yüksek, orta ve düşük sıklığı sırasıyla dört değişikliğe, üç değişikliğe, iki değişikliğe ve bir özellik değişikliğine karşılık gelmiştir.

#### 3.3.2 Katılımcılar

Bu deneyde de Deney 1'in gerçek etki büyüklüğüne bağlı örneklem büyüklüğü türettik. Deney 1'deki nesne özellik heterojenliğinin ve nesne değişken özelliği etki büyüklüğü  $0.26(\eta^2p)$  idi (Cohen, 1988). Bu deneyde de 51'den fazla katılımcıdan oluşan bir örneklem büyüklüğünün mevcut deney tasarımı olarak uygulanabileceğini düşündük. 64 katılımcıdan (32 kadın ve 32 erkek; yaş: 18-64) oluşan bu hedef örnekleme aştığımız gün veri toplamayı durduracağımıza karar verdik. Bu örneklem boyutuyla, etki büyüklüğü  $0.22(\eta^2p)$ 'dir. Deney 2'de elde edilen etki büyüklüğü, Deney 1'deki etki büyüklüğünden daha düşüktür. Bu, Deney 1'de belirlenen nesne özellik heterojenliği ve nesne değişken özelliği etkisinin ötesindeki bir etkiyi yansıtır.

#### 3.3.3 Cihaz ve uyarıcılar

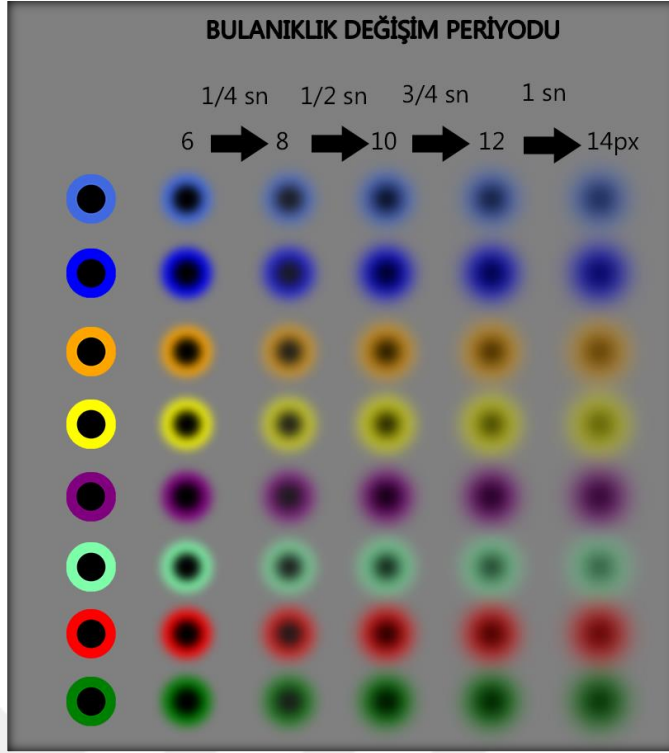
Deney 2 renkte dâhil, uyarıcılar ve aparatlar Deney 1'deki ile aynıydı. Nesnelerin ilk hareket hızı  $19-20^\circ/s$  olarak ayarlandı. Her denemedeki hareket sırasında bu disklerin (hareketli nesne) hızı her 500 ms' de bir başlangıç hızının

$\pm 4\%$ 'i aralığında rastgele değişmiştir (Deney 1'deki ile aynı). Daha önceki çalışmalarda da görüldüğü gibi, hız aralığındaki farklılıklar bazen ortaya çıkabilir (Scholl vd.,2001; Suganuma ve Yokosawa, 2006). Bu nedenle, bu çalışmada  $2^\circ/s$  içindeki hız aralığı mevcut bulguyu etkilemediği düşünülmektedir.


### 3.3.4 Prosedür

Bulanıklık, kontrast ve parlaklığın her biri için 48 deney aşaması (4 nesne değişken özelliğinin zamansal değişimi; yani, her koşulda 12 deneme) tasarlandı. Nesne özellik heterojenliği ve nesne değişken özelliğinin zamansal değişim faktörleri 16 koşulda birleştirilir (4 nesne özellik heterojenliği  $\times$  4 nesne değişken özelliğinin zamansal değişimi; yani, her koşulda 12 deneme). Bu koşullar için 12 denemenin 4'ü  $50\%$  sol tarafında, öteki 4'ü  $50\%$  sağ tarafında nesne değişken özelliğinin zamansal değişimi ve diğer 4'ü  $100\%$  nesne değişken özelliğinin zamansal değişimi şeklinde yapılmıştır. On altı koşul için toplam 192 deneme aşaması vardır. Deney 1 ve Deney 2 için yorgunluk etkisinden kaçınmak için tüm katılımcılar görevi iki farklı oturumda tamamlamıştır.

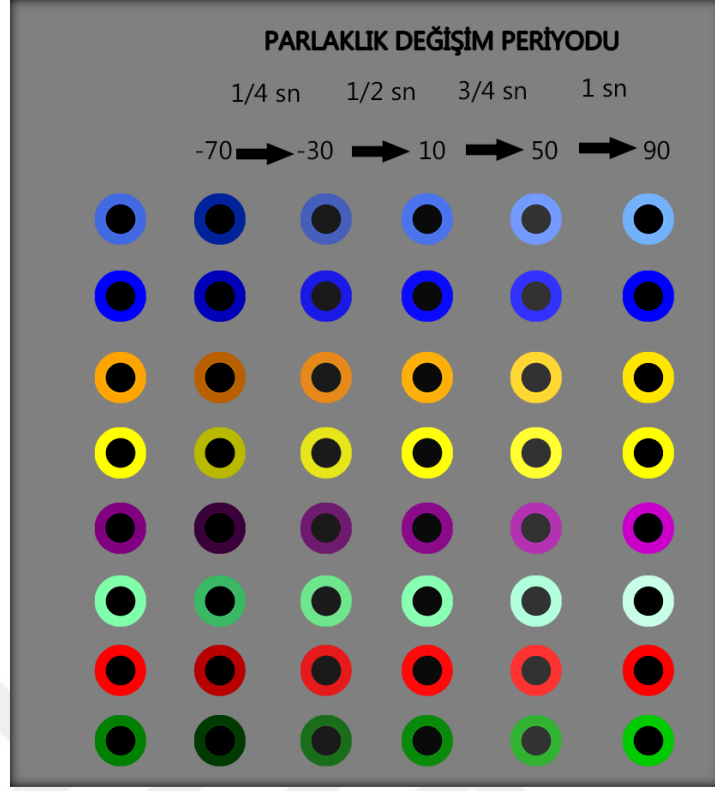
Her koşuldaki bulanıklık, kontrast ve parlaklık değişiminin zamanlaması, tüm hareket periyodu boyunca eşit zaman aralıklarıyla meydana gelmiştir. Tek değişiklik(düşük)[bulanıklık (6,8px), kontrast (-70,-30), parlaklık (-70,-30)] durumunda, tüm hareketli nesnelere bulanıklık, kontrast ve parlaklık özellikleri hareket süresinin ortasında değişecek; iki değişiklik(orta) ([bulanıklık(6,8,10px), kontrast (-70,-30,10), parlaklık(-70,-30,10)] durumunda, hareket süresi 1/3 ve 2/3'ü geçtiğinde bulanıklık, kontrast ve parlaklık özelliklerinde değişik meydana gelecektir. Üçüncü değişim[bulanıklık(6,8,10,12px), kontrast (-70,-30,10,50), parlaklık (-70,-30,10,50)] durumunda tüm hareketin süresi 1/4, 1/2 ve 3/4'ü geçtiğinde bulanıklık, kontrast ve parlaklık özelliklerinde değişim meydana gelecektir. Dördüncü değişim [bulanıklık(6,8,10,12,14px), kontrast (-70,-30,10,50,90), parlaklık (-70,-30,10,50,90)] durumunda tüm hareketin süresi 1/4, 1/2, 3/4 ve 1'i geçtiğinde bulanıklık, kontrast ve parlaklık özellikleri değişimi meydana gelecektir (Şekil 3.16, 3.17, 3.18).



Şekil 3.16: Bulanıklığın zamansal değişimi



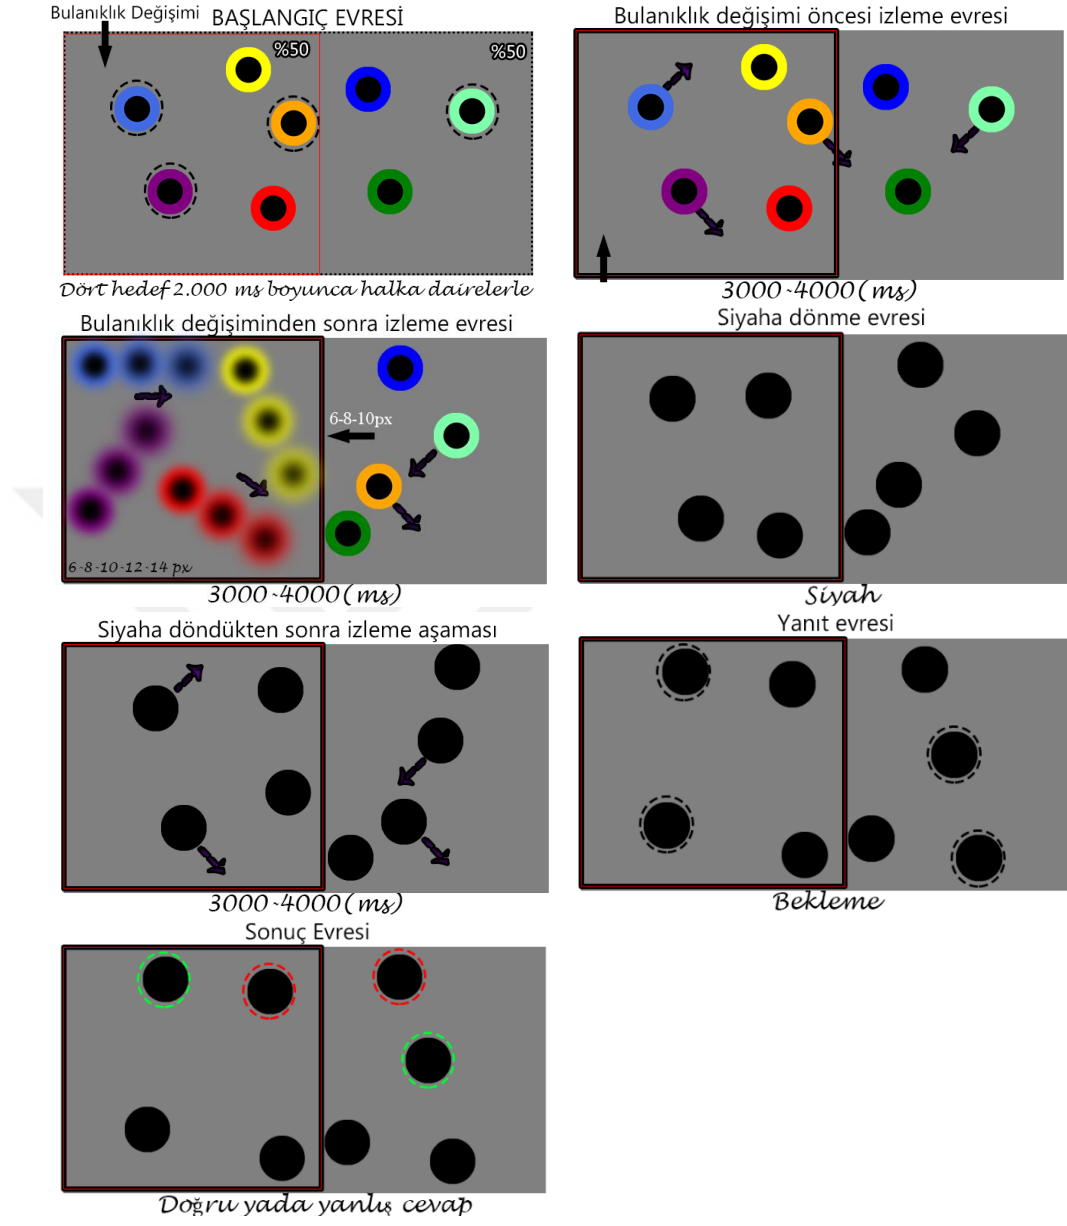
Şekil 3.17: Kontrastın zamansal değişimi



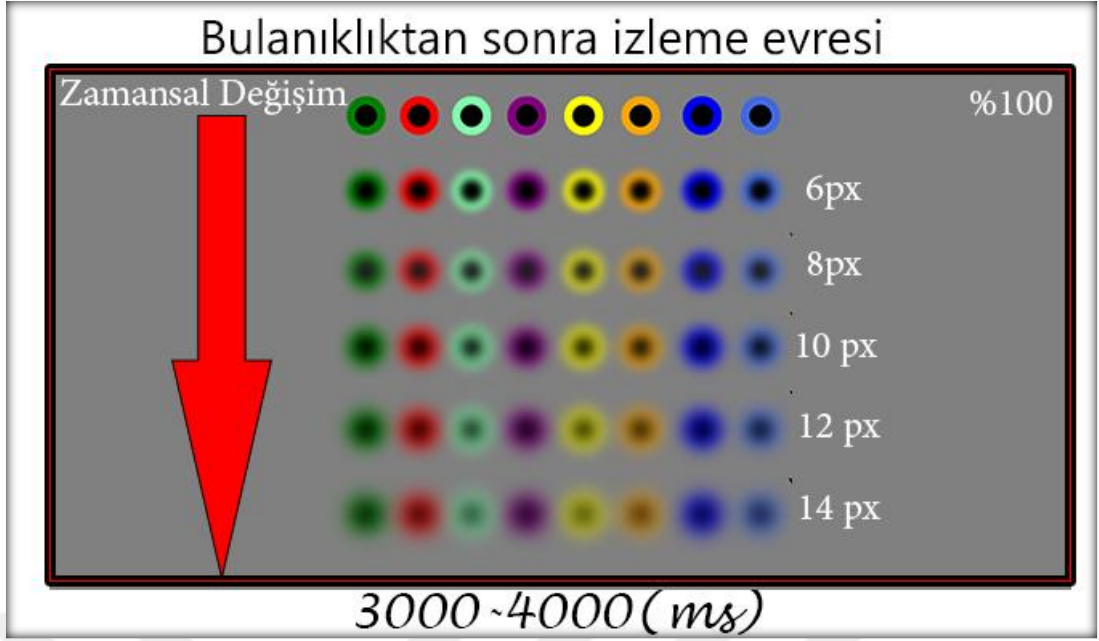
**Şekil 3.18:** Parlaklığın zamansal değişimi

Bu zamansal değişim evrelerinin deneyde nasıl ilerlediğini göstermek için örnek gösterimleri Şekil 3.19, 3.20, 3.21, 3.22, 3.23, 3.24’de sunulmuştur.


## 50% Bulanıklık Değişimi Evresi



Şekil 3.19: %50 Bulanıklık Değişim Örneği (6-8-10 px)



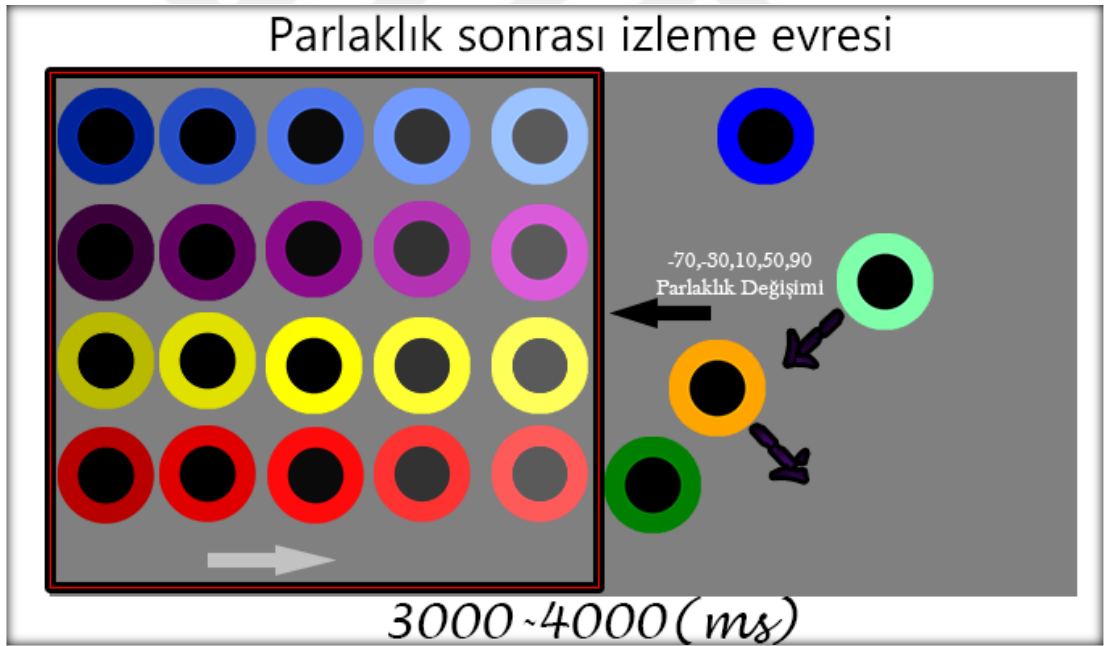
Şekil 3.20: %100 Bulanıklık Değişim Örneği (6,8,10,12,14 px)



Şekil 3.21: %50 Kontrast Değişim Örneği (-70, -30, 10, 50, 90)



Şekil 3.22: %100 Kontrast Değişim Örneği (-70, -30, 10, 50, 90)



Şekil 3.23: %50 Parlaklık Değişim Örneği (-70, -30, 10, 50, 90)



**Şekil 3.24:** %100 Parlaklık Değişim Örneği (-70, -30, 10, 50, 90)

### 3.4 Analiz Planı

Bu bölüm, Deney 1 ve Deney 2'de toplanan verilerin analiz planını sunar. Verilerin analiz edilmesi ve çalışmanın araştırma sorularına cevap vermek için kullanılacak istatistiksel teknikleri ve yöntemleri açıklar.

#### 3.4.1 Deney 1 analizi

Deney 1 için, bağımsız değişkenlerin (nesne değişken özelliği ve nesne özellik heterojenliği) takip doğruluğu üzerindeki etkisini incelemek için doğrusal karma analizi kullanılmıştır. Ortalama takip doğrulukları, nesne değişken özelliği tutarlılık düzeylerini (özelliğin sabit, %50 sağ, %50 sol değişiklik durumu ve %100 değişiklik durumu) ve nesne özellik heterojenliği dört düzeyini (iki farklı, dört farklı, sekiz farklı ve homojen) dikkate alarak analiz edilmiştir.

Nesne değişken özelliği tutarlılık koşullarının her biri içindeki dört nesne özellik heterojenliği koşulu arasındaki farkları değerlendirmek için Tukey düzeltmesi uygulanmıştır. Bu analiz, nesne özellik heterojenliğinin nesne değişken özelliği tutarlılık düzeylerindeki takip doğruluğu üzerindeki belirli etkilerini belirlemeye yardımcı olmuştur.

### **3.4.2 Deney 2 analizi**

Deney 2 için, nesne değişken özelliğinin zamansal değişimi ve nesne özellik heterojenliğinin görsel dikkat üzerindeki etkisini incelemek içinde doğrusal karma analizi kullanılmıştır. Ortalama takip doğrulukları, nesne değişken özelliğinin zamansal değişiminin dört düzeyini (çok yüksek, yüksek, orta ve düşük) ve nesne özellik heterojenliği dört düzeyini (iki farklı, dört farklı, sekiz farklı ve homojen) dikkate alarak analiz edilmiştir.

Deney 1'de olduğu gibi, benzer şekilde, analiz aynı zamanda nesne özellik heterojenliği düzeylerindeki dört nesne değişken özelliğinin zamansal değişimi arasındaki farkları incelenmiştir. Tukey düzeltmesi, nesne değişken özelliğinin zamansal değişiminin nesne özellik heterojenliği farklı düzeylerindeki takip doğruluğu üzerindeki belirli etkilerini araştırmak için kullanılmıştır.

Analizin temelini, dikkati dağıtan faktörlerin etkilerini incelemek ve bu etkileri zamansal değişimle ilişkilendirmek oluşturur. Bu amaçla, nesne değişken özelliğinin zaman içindeki değişimine odaklanılmış ve bu değişimin dikkati dağıtıcıların etkilerini anlamak için bir gösterge olarak kullanıldığı belirtilmiştir.

Bu bölümde tanımlanan analiz planı, Deney 1 ve Deney 2'de toplanan verilerin analiz edilmesi için net bir yol haritası sunar. Bağımlı değişkenler üzerinde bağımsız değişkenlerin etkilerini incelemek için uygun istatistiksel tekniklerin kullanılmasını ve çalışmanın araştırma sorularına cevap verilmesini sağlar.

## **3.5 Beklenen Sonuçlar**

Bu bölüm, çalışmanın tasarımı, değişkenleri ve analiz planı temel alınarak beklenen sonuçlar açıklanır. Araştırma hedefleri ve hipotezlerine ilişkin olarak beklenen bulguların ve bunların sonuçlara etkilerinin bir ön izlemesini sunar.

### **3.5.1 Deney 1 sonuçları**

Deney 1'in tasarımı ve analiz planına dayanarak, nesne değişken özelliği ve nesne özellik heterojenliğinin takip doğruluğu üzerinde önemli etkilere sahip olması beklenmektedir. Nesne değişken özelliklerinin tutarlılık düzeylerinde ve nesne özellik heterojenliği düzeylerindeki ortalama takip doğrulukları analiz edildiğinde önemli bilgiler ortaya çıkacaktır.

İlk olarak, nesne deęişken özelliklerinin (bulanıklık, kontrast ve parlaklık) deęişiklikleri, katılımcıların takip doğruluęunu önemli ölçüde etkileyeceęi düşünölmektedir. Özellikle, nesne deęişken özellikleri tutarlı olduęunda (özellik sabit durumu), katılımcıların takip doğruluęunun nesne deęişken özelliklerinin deęiştii durumlardan (yüzde 50 ve yüzde 100 deęişiklik durumu) daha yüksek olması beklenmektedir. Bu hipotez, tutarlı ekran deęişken özelliklerinin, takip performansını kolaylaştıran stabil görsel ipuçları sağladığı varsayımına dayanmaktadır.

İkinci olarak, nesne özellik heterojenlięinin de takip doğruluęunu etkilemesi beklenmektedir. Nesne özellik heterojenlięinin daha yüksek düzeyleri (örneğin sekiz farklı koşullar), daha düşük heterojenlik düzeylerine (örneğin iki farklı koşullar) kıyasla daha düşük takip doğruluęuna neden olacaęı düşünölmektedir. Bu hipotez, nesne özelliklerindeki artan heterojenlięin hedefleri tanımlama ve takip etme konusunda katılımcılar için daha büyük zorluklar oluşturduęu düşüncesinden kaynaklanmaktadır.

Ayrıca, analiz nesne deęişken özellięi ve nesne özellik heterojenlięi arasındaki etkileşime de ışık tutmaktadır. Nesne deęişken özelliklerinin deęişikliklerinin takip doğruluęu üzerindeki olumsuz etkisi, nesne özellik heterojenlięi daha yüksek düzeylerde olduęunda daha belirgin olacaktır. Bu, deęişen özelliklerin nesnelerin kendilerindeki deęişkenlięin daha yüksek olduęu koşullarda takip performansı üzerindeki etkisinin daha belirgin olacaęı tahmin edilmektedir.

### **3.5.2 Deney 2 sonuçları**

Deney 2'de, beklenen sonuçlar nesne deęişken özellięinin zamansal deęişimi ve nesne özellik heterojenlięinin görsel dikkat üzerindeki etkisine ışık tutmaktadır. Nesne deęişken özellięinin zamansal deęişiminin dört düzeyini (çok yüksek, yüksek, orta ve düşük) ve nesne özellik heterojenlięinin dört düzeyini (iki farklı, dört farklı, sekiz farklı ve homojen) dikkate alarak ortalama takip doğrulukları analiz edilmiştir.

Bu analiz, nesne deęişken özellięinin zamansal deęişimi düzeylerindeki nesne özellik heterojenlięi üzerindeki belirli etkileri belirlemeye yardımcı olacaktır.

Deney 1 ve Deney 2'nin beklenen sonuçları, görsel takip görevleri sırasındaki dikkat süreçleri üzerindeki temel mekanizmaların daha derin bir anlayışına katkıda bulunacaktır.

### 3.6 Potansiyel Problemler ve Alternatif Yaklaşımlar

Bu bölüm, çalışmanın yürütülmesi sırasında ortaya çıkabilecek olası zorlukları veya sorunları tartışılır ve bu sorunları hafifletmek için alternatif yaklaşımlar veya çözümler önerilir. Potansiyel sınırlamaların farkında olma ve bunları ele almak için proaktif bir yaklaşım sergilenir.

#### 3.6.1 Potansiyel problemler

*Katılımcı kaybı:* Çalışmadan çekilebilecek katılımcıların olma olasılığı vardır, bu da örneklem büyüklüğünü ve veri kalitesini etkileyebilir. Çekilmenin nedenleri arasında program çakışmaları, ilgi eksikliği veya teknik zorluklar bulunabilir.

*Teknik sorunlar:* Bilgisayar çökmeleri, yazılım sorunları veya internet bağlantısı sorunları gibi deneysel kurulumla ilgili teknik sorunlar, veri toplamayı sekteye uğratabilir ve sonuçların geçerliliğini tehlikeye sokabilir.

*Katılımcı performansındaki değişkenlik:* Bilişsel yetenekler, dikkat kapasitesi veya deneysel görevlere olan aşinalık gibi bireysel farklılıklar, katılımcı performansında değişkenlik oluşturabilir, bu da bulguların güvenilirliğini ve genelleştirilebilirliğini etkileyebilir.

*Tavan veya taban etkileri:* Ölçümlerde tavan veya taban etkileri riski vardır, burada katılımcılar bağımlı değişkenlerin en düşük veya en yüksek düzeylerinde tutarlı bir performans sergilerler. Bu, veri değişkenliğini sınırlayabilir ve anlamlı etkileri tespit etmeyi zorlaştırabilir.

#### 3.6.2 Alternatif yaklaşımlar

Bu potansiyel problemleri ele almak için aşağıdaki alternatif yaklaşımlar uygulanmıştır:

*Katılımcı seçimi ve teşvikler:* Katılımcı kaybını hafifletmek için, başlangıçta planlanandan daha büyük bir örnekleme büyüklüğü sağladık. Ayrıca, katılımcıları çalışmayı tamamlamaya teşvik etmek için para ödemesi şeklinde teşvikler sunduk.

*Yedek sistemler ve teknik destek:* Online veri depolama hizmetleri kullanarak veri kaybını en asgari düzeyde tutmayı başardık.

*Katılımcı tarama ve randomizasyon:* Katılımcı performansındaki değişkenliği azaltmak için, katılımcıların normal veya düzeltilmiş-normal görüş ve normal renk

algısına sahip olduğunu sağlamak için ön tarama değerlendirmeleri yaptık. Katılımcıları farklı deney koşullarına rastgele atadık, bireysel farklılıkları gruplar arasında daha dengeli bir şekilde dağıtmaya çalıştık.

*Görev uyarlaması ve ek ölçümler:* Tavan veya taban etkileri gözlemlendiği için bazı bağımlı değişkenlerin değerleri değiştirildi. Böylece ölçümlerin hassasiyeti artırılarak katılımcı performansını yakalamak için gerekli düzenlemeler yapılmış oldu.

*Veri analizi teknikleri:* Hiyerarşik modelleme veya gizil değişken modelleme gibi gelişmiş istatistiksel teknikler, bireysel farklılıkları hesaba katmak ve potansiyel karıştırıcı değişkenleri kontrol etmek için kullanıldı. Bu yaklaşımlar, sonuçların sağlamlığını ve güvenilirliğini artırmaya yardımcı oldu.

## 4. DENEYSEL SONUÇLAR

### 4.1 Deney 1 Bulanıklığın Çoklu Nesne Takibi Üzerindeki Etkileri

#### 4.1.1 Deney 1 bulanıklık için doğrusal karma modelinin analiz sonuçları

##### 4.1.1.1 KMOY ile uygulanan doğrusal karma model (DKM)

Doğrusal Karma Modeli (DKM), hem sabit hem de rassal etkileri içeren verilerin analizinde kullanılan istatistiksel bir yöntemdir. Özellikle tekrarlanan ölçümler veya uzun süreli çalışma verileri gibi hiyerarşik veya iç içe geçmiş veri yapılarıyla uğraşırken kullanışlıdır.

Bu bölüm, R'de "lmerTest" paketi kullanılarak gerçekleştirilen doğrusal karma model (DKM) analizinin çıktısını sunar (Kuznetsova, Brockhoff ve Christensen, 2017). Model, "ortalama" yanıt değişkeni ile "mod\_type", "mod\_field", "Cinsiyet" ve "Yaş" gibi birkaç sabit etkiler arasındaki ilişkiyi araştırmayı amaçlar. Model, her katılımcı için rastgele bir kesişim noktasını içerecek şekilde tasarlanmıştır, bu da verilerin tekrarlanan ölçümlerini dikkate alır.

DKM, Kısıtlanmış Maksimum Olabilirlik Yöntemi (KMOY) kullanılarak uygulanır. KMOY yöntemi, doğrusal karma modelinde varyans bileşenlerinin tahmininde yaygın olarak kullanılan bir yaklaşımdır ve özellikle küçük örneklem büyüklükleri için daha az yanlı tahminler üretme eğilimindedir (Harville, 1977). Ayrıca, t-testleri için derece özgürlüğünü hesaplamak için Satterthwaite'in yöntemi kullanılır, bu yöntem küçük örneklem büyüklüklerindeki doğruluk ve dayanıklılığıyla bilinir (Satterthwaite, 1946).

KMOY ile uygulanan DKM psikolojik çalışma için aşağıdaki gibi verilir:

$$\text{Ortalama} \sim \text{mod\_type} + \text{mod\_field} + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.1)$$

Formül 4.1 sabit etkiler(mod\_type, mod\_field, Cinsiyet ve Yaş) ile yanıt değişkeni (Ortalama) arasındaki ilişkiler hakkında daha doğru sonuçlar çıkarması için araştırmacılara olanak tanır. Formül 4.1'de geçen (1 | Katılımcı) değeri ise her katılımcı için rassal etkiyi temsil eder.

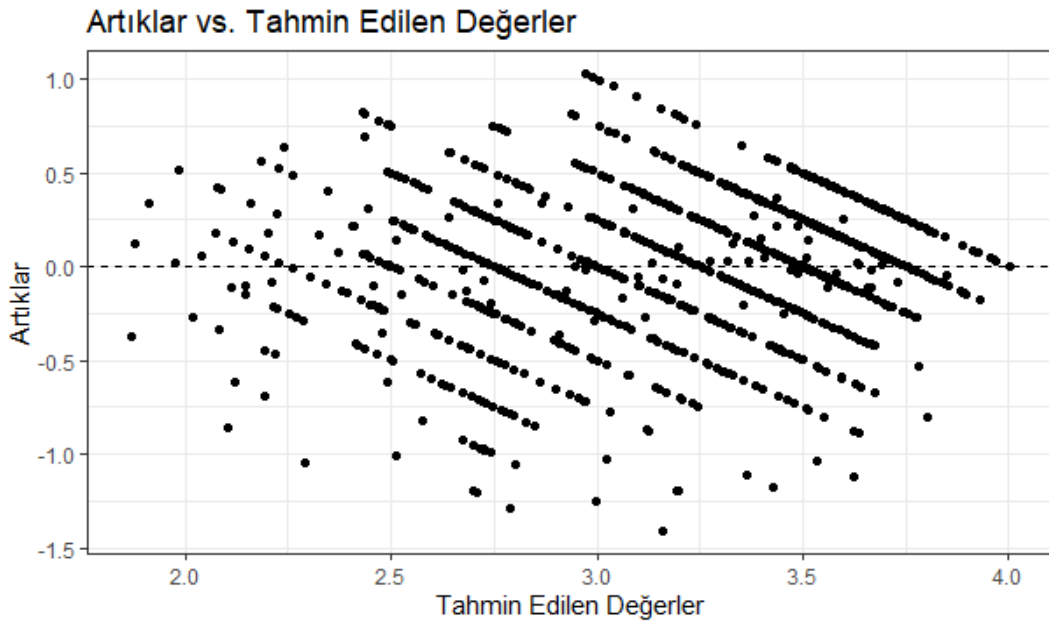
#### 4.1.1.2 Yakınsama için KMOY kriteri

Yakınsamada için KMOY kriteri, Doğrusal Karma modellerinde tahmin edilen varyans bileşenlerinin kalitesini değerlendirmek için kullanılan bir model uyum ölçüsüdür. KMOY yöntemi kullanılarak Doğrusal Karma modeli uygulandığında, bu kriteri en aza indirmek amaçlanır. Daha küçük bir KMOY değeri daha uygun bir modeli gösterir (Verbeke & Molenberghs, 2000).

Kısıtlanmış Maksimum Olabilirlik Yönteminin (KMOY) kriteri, tahmin edilen parametre sayısına bağlı olarak modele bir ceza uygulayan bir model uygunluk ölçütüdür (Bolker vd., 2009). Bu durumda, yakınsama için KMOY kriteri 1225.5 olup, modelin verilere iyi uyduğunu göstermektedir.

#### 4.1.1.3 Ölçeklendirilmiş artıklar


Ölçeklendirilmiş artıklar, doğrusal karma modelin tahmin edilen değerlerinden elde edilen ve gözlemlenen değerler ile standardize edilmiş farklardır. Eş varyanslılık ve hata normalitesi gibi model varsayımlarının ihlallerini teşhis etmek için kullanışlıdır (Gelman ve Hill, 2007). İyi uyan bir model, artıkları yaklaşık olarak normal dağılıma, ortalamaya yakın bir ortalamaya ve tahmin edilen değerlerin aralığı boyunca sabit bir varyansa sahip olmalıdır.



Şekil 4.1: Deney 1 Bulanıklık için Artıklar ve Tahmin Edilen Değerler

Ölçeklendirilmiş artıklar, doğrusal karma modelin varsayımlarının makul bir şekilde karşılandığına dair bazı kanıtlar sunar. Ortanca değerin sıfıra yakın olması, modelin tahminlerinin ortalama olarak doğru olduğunu gösterir. Ortanca etrafında simetrik dağılım, hataların normal dağılıma sahip olabileceğini gösterir (Şekil 4.1).

Ancak, minimum ve maksimum ölçeklendirilmiş artıklarda aşırı değerlerin bulunması, aykırı değerlerin veya modelin varsayımlarıyla ilgili olası sorunların varlığını işaret edebilir. Varsayımları doğrulamak için tanısal grafikleri incelemek ve Shapiro-Wilk testi gibi diğer testleri yapmak önemlidir (Faraway, 2006).



**Şekil 4.2:** Deney 1 Bulanıklık için Artıkların QQ plotu

QQ plotu, gözlemlenen değerlerin teorik normal dağılımın beklenen değerlerine karşı sıralandığı bir grafik olarak çizilir. Eğer noktalar çizginin yakınında düzgün bir şekilde yer alıyorsa, hata terimleri normal dağılıma yakın bir şekilde dağılıyor demektir. Ancak noktalar çizgiden belirgin bir şekilde sapıyorsa, hata terimleri normal dağılıma uymayabilir ve modelde hatalar bulunabilir. Şekilde düzgün bir dağılım görünmektedir (Şekil 4.2)

Sonuç olarak, ölçeklendirilmiş artıklar, doğrusal karma modelin performansı ve varsayımları hakkında değerli bilgiler sağlar. Psikolojik çalışmadaki verilere olan

uyumunu kapsamlı bir şekilde değerlendirmek için diğer tanısal araçlar ve testlerle birlikte yorumlanmalıdır.

Aşağıda, ölçeklendirilmiş artıkların özeti yer almaktadır (Çizelge 4.1):

**Çizelge 4.1:** Deney 1 Bulanıklık için Ölçeklendirilmiş Artıklar

<b>Min.</b>	<b>1.Çeyrek</b>	<b>Ortanca</b>	<b>3.Çeyrek</b>	<b>Mak.</b>
-3.579	-0.549	0.067	0.632	2.610

Ölçeklendirilmiş artıklar, modelin verilere ne kadar iyi uyduğunu gösteren bir ölçü sağlar. Gözlemlenen değerler ile yanıt değişkeninin tahmin edilen değerleri arasındaki farkı, artıkların tahmin edilen standart sapmasıyla standartlaştırarak temsil edilir.

Bu durumda ölçeklendirilmiş artıklar -3.579 ile 2.610 arasında değişmekte olup, ortanca değeri 0.067'dir. Birinci çeyrek değeri -0.549'dır, yani artıkların %25'i bu değerden daha küçüktür. Üçüncü çeyrek değeri 0.632'dir, yani artıkların %75'i bu değerden daha küçüktür ve modelin verilere oldukça iyi uyduğunu göstermektedir (Harrison vd., 2018).

Bununla birlikte, artıkların nispeten geniş bir aralığa sahip olması, bazı aykırı değerlerin veya etkileyici gözlemlerin tahmin edilen değerleri etkilediği olasılığını göstermektedir.

#### **4.1.1.4 Rassal etkiler**

Rassal etkiler, bir gruplama faktörünün (örneğin, bir çalışmadaki katılımcılar) seviyeleri arasındaki bireysel farklılıklara atfedilen sonuçtaki değişkenliği temsil eder. Bu durumda, "katılımcı" gruplandırma faktörüdür ve rassal etki kesişim noktasıdır. Kesişim noktası, sonuç değişkeninin başlangıç seviyesini temsil eder ve katılımcılar arasındaki bireysel farklılıklar nedeniyle değişebilir (Bates vd., 2015). Rassal etkiler, yanıt değişkenindeki değişkenliği, sabit etkilerle açıklanamayanları hesaba katar. Bu modelde iki adet rassal etki bulunmaktadır: her katılımcı için bir rassal kesişim noktası ve artık. Rassal kesişim noktası ve artık için varyans tahminleri sırasıyla 0.1723 ve 0.1553'tür. Rassal kesişim noktasının standart sapması 0.4151'dir, bu da katılımcılar arasında yanıt değişkeninde önemli bir değişkenlik olduğunu göstermektedir (Gelman ve Hill, 2006). Artık için standart sapma

0.3941'dir. Bu, modelin diğer faktörlerle açıklanamayan yanıt değişkenindeki değişkenliği temsil eder. Yani, modelin açıklamadığı rastgele değişkenlik miktarı yaklaşık 0.3941 standart sapma birimindedir(Çizelge 4.2).

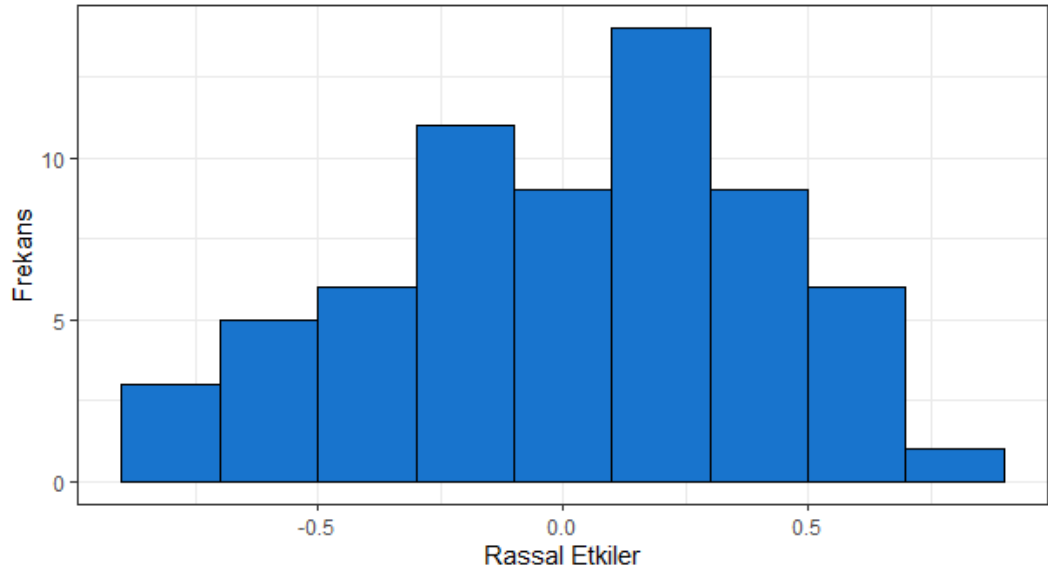
**Çizelge 4.2:** Deney 1 Bulanıklık için Rassal Etkiler

Bileşen	Varyans	Standart Sapma
Rassal Kesişim	0.1723	0.4151
Artık	0.1553	0.3941

Her katılımcı için rassal kesişim noktası, yanıt değişkenindeki varyansın %17.23'ünü ve artığın %15.53'ünü açıklar.

Dikkat edilmesi gereken diğer bir nokta, 1024 gözlem ve 64 katılımcı olduğu ve bu da katılımcı başına ortalama 16 gözlem olduğu anlamına gelir.

**Rassal Etkilerin Histogramı**




**Şekil 4.3:** Deney 1 Bulanıklık için Rassal Etkilerin Histogramı

Varyans bileşenleri, katılımcı düzeyindeki farklılıklardan kaynaklanan sonuçta önemli farklılıklar olduğunu göstermektedir ve bu nedenle çalışmanın sonuçlarını yorumlarken dikkate alınmalıdır

Histogram, doğrusal bir karma modelde rastgele etkilerin dağılımını gösterir. x eksenini rastgele etkileri, y eksenini ise her rastgele etkinin sıklığını temsil eder.

Histogram yaklaşık olarak normaldir; ortalaması 0 ve standart sapması 0,5'tir. Bu, rastgele etkilerin normal şekilde dağıldığını ve rastgele etkilerde orta düzeyde bir değişkenlik olduğunu göstermektedir (Şekil 4.3).



**Şekil 4.4:** Deney 1 Bulanıklık için Rassal Etkilerin Yoğunluk Grafiği

Özet olarak, doğrusal karma modelindeki rassal etkiler, katılımcılar arasındaki bireysel farklılıklardan kaynaklanan değişkenliğe ilişkin değerli bilgiler sağlar. Sabit etkilerle ilgili daha doğru sonuçlar çıkarmamıza yardımcı olur. Bu bilgiler, çalışmanın sonuçlarının yorumlanmasını iyileştirmek, sabit etkiler ve genel bulgular hakkında daha doğru çıkarımlar yapmak için kullanılabilir (Şekil 4.4).

#### 4.1.1.5 Sabit etkiler

Sabit etki tahminleri, modeldeki diğer değişkenlerin kontrol altında tutulduğu bir çerçevede, her bir sabit etkinin yanıt değişkeni ile olan ilişkisini inceler. Analiz sonuçları, belirli bulanıklık seviyeleri ve yaşın yanıt değişkeni üzerinde önemli etkilere sahip olduğunu ortaya koymaktadır (Çizelge 4.3).

Özellikle, 'Blur6' değişkeninin yanıt değişkeni üzerinde negatif ve anlamlı bir etkisi olduğu gözlemlenmiştir ( $p=0.03078$ ), bu da Blur6 bulanıklık seviyesine sahip görsellerin, referans gruba kıyasla yanıt değişkeninde daha düşük değerlerle ilişkili olduğunu göstermektedir. Diğer yandan, 'Blur10' değişkeni yanıt değişkeni üzerinde pozitif ve istatistiksel olarak anlamlı bir etkiye sahiptir ( $p=0.00990$ ), bu da Blur10

bulanıklık seviyesinin yanıt değişkeninde pozitif bir değişimle ilişkilendirildiğini gösterir.

**Çizelge 4.3:** Deney 1 Bulanıklık için Sabit Etkiler

Tahmin	Ortalama	Standart Hata	t-değeri	p-değeri	Anlamlılık
<b>Kesişim Noktası</b>	3.723	0.228	16.337	< 2e-16	Çok Anlamlı
<b>BlurNone</b>					
<b>mod_typeBlur10</b>	0.154	0.059	2.584	0.00990	Anlamlı
<b>mod_typeBlur12</b>	0.106	0.059	1.777	0.07593	Marjinal Anlamlı Olabilir
<b>mod_typeBlur14</b>	0.079	0.059	1.329	0.18407	Anlamlı Olmayabilir
<b>mod_typeBlur6</b>	-0.129	0.059	-2.163	0.03078	Anlamlı
<b>mod_typeBlur8</b>	0.076	0.059	1.286	0.19888	Anlamlı Olmayabilir
<b>mod_fieldleft</b>	-0.041	0.031	-1.317	0.18829	Anlamlı Olmayabilir
<b>mod_fieldright</b>	-0.033	0.031	-1.066	0.28678	Anlamlı Olmayabilir
<b>GenderMale</b>	-0.0004	0.108	-0.004	0.99706	Önemsiz
<b>Yaş</b>	-0.018	0.006	-2.946	0.00455	Anlamlı

'Blur8' ve 'Blur14' bulanıklık seviyelerinin yanıt değişkeni üzerindeki etkileri istatistiksel olarak anlamlı değildir (sırasıyla  $p=0.19888$  ve  $p=0.18407$ ), bu da bu bulanıklık seviyelerinin yanıt değişkeni üzerinde belirgin bir etkiye sahip olmadığını gösterir. 'Blur12' değişkeninin etkisi de marjinal olarak anlamlıdır ( $p=0.07593$ ), bu da belirgin bir etkinin olmadığını gösterir.

'mod\_fieldleft' ve 'mod\_fieldright' değişkenlerinin yanıt değişkeni üzerinde anlamlı bir etkisi yoktur (her ikisinin  $p$ -değeri 0.05'ten büyük), bu da bu mekansal konumlandırma değişkenlerinin yanıt değişkeni üzerinde önemli bir etkiye sahip olmadığını gösterir.

Yaş değişkeni, yanıt değişkeni üzerinde önemli bir negatif etkiye sahiptir ( $p=0.00455$ ), bu da yaşın artmasıyla yanıt değişkeninin değerlerinin düşme

eğiliminde olduğunu gösterir. Bu bulgu, yaşın bilişsel performans üzerindeki olumsuz etkisine dair mevcut literatürle uyumludur.

Bu analiz sonuçları, belirli bulanıklık seviyelerinin (özellikle Blur6 ve Blur10) ve yaşın yanıt değişkeni üzerinde önemli etkilere sahip olduğunu göstermektedir. Diğer yandan, Blur12, Blur14, Blur8, mod\_fieldleft ve mod\_fieltright gibi değişkenlerin yanıt değişkeni üzerinde belirgin bir etkisi görülmemektedir.

Bu bulguların literatürle karşılaştırılması, benzer çalışmalardaki sonuçlarla uyumlu olduğunu göstermektedir. Örneğin, bulanıklık seviyelerinin görsel algılama üzerindeki etkileri, görsel dikkat ve hafıza çalışmalarında sıkça incelenmiş ve bulanıklığın artmasıyla görsel nesnelerin tanınması ve hatırlanmasında olumsuz etkiler gösterilmiştir (Henderson vd., 2007; Levi, Klein & Hariharan, 2002). Yaş faktörünün yanıt değişkeni üzerindeki negatif etkisi, yaşlanma psikolojisi ve nörobilim alanındaki çalışmalarla da uyumludur, zira yaş ile bilişsel performans arasında genellikle negatif bir ilişki bulunmuştur (Salthouse, 2010; Park & Reuter-Lorenz, 2009).

Sonuç olarak, bu deneyin sonuçları görsel algı ve bilişsel işlevler üzerine yapılan önceki çalışmalarla uyumlu görünmektedir. Belirli bulanıklık seviyelerinin ve yaş faktörünün yanıt değişkeni üzerindeki etkileri literatürde bulunan bulgularla desteklenmektedir, bu da deney sonuçlarının geçerliliğini artırır ve bulanıklık seviyeleri ile yaşın bilişsel işlevler üzerindeki etkisine dair mevcut anlayışımızı genişletir. Bu sonuçlar, görsel algı ve bilişsel işlevler üzerine yapılan gelecek çalışmalar için önemli bir temel oluşturabilir.

#### **4.1.1.6 Sabit etkilerin korelasyonu**

Sabit etkilerin korelasyonu, bir doğrusal karma modeldeki sabit etkiler arasındaki korelasyonları gösterir ve korelasyon katsayıları -1 ile 1 arasında değişir. 1, mükemmel pozitif korelasyonu, -1 ise mükemmel negatif korelasyonu temsil eder, 0 ise iki değişken arasında doğrusal bir ilişkinin olmadığını gösterir. Korelasyon matrisinin analizi, modeldeki değişkenlerin birbiriyle nasıl ilişkili olduğunu anlamamıza yardımcı olur ve çoklu doğrusallık gibi potansiyel istatistiksel sorunların tespit edilmesine olanak tanır (James vd., 2013).

*Bulanıklık Değişkenleri Arasındaki Korelasyon:* Bulanıklıkla ilgili değişkenler (Blur10, Blur12, Blur14, Blur6 ve Blur8) arasında gözlemlenen 0.773 değerindeki yüksek pozitif korelasyonlar, bu değişkenlerin birbirleriyle güçlü bir ilişkiye sahip olduğunu gösterir (Cohen, West, & Aiken, 2013) (Çizelge 4.4). Bu, farklı bulanıklık seviyelerinin birbirlerini etkileyebileceğini ve bir değişkendeki artışın diğerlerinde de benzer bir artışa yol açabileceğini gösterir. Bu durum, modeldeki etkileşimleri ve bağımlı değişken üzerindeki potansiyel kombine etkileri anlamak için önemlidir (Hair, Black, Babin, & Anderson, 2010).

**Çizelge 4.4:** Deney 1 Bulanıklık için Sabit Etkilerin Korelasyonu

Tahmin	Kesişim Noktası	Blur10	Blur12	Blur14	Blur6	Blur8	mod_fieldleft	mod_fieldright	Gender Male
<b>Blur10</b>	-0.178	-	0.773	0.773	0.773	0.773	-0.261	-0.261	0.0
<b>Blur12</b>	-0.178	0.773	-	0.773	0.773	0.773	-0.261	-0.261	0.0
<b>Blur14</b>	-0.178	0.773	0.773	-	0.773	0.773	-0.261	-0.261	0.0
<b>Blur6</b>	-0.178	0.773	0.773	0.773	-	0.773	-0.261	-0.261	0.0
<b>Blur8</b>	-0.178	0.773	0.773	0.773	0.773	-	-0.261	-0.261	0.0
<b>mod_field left</b>	0.000	-0.261	-0.261	-0.261	-0.261	-0.261	-	0.500	0.0
<b>mod_field right</b>	0.000	-0.261	-0.261	-0.261	-0.261	-0.261	0.500	-	0.0
<b>Gender Male</b>	-0.396	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-
<b>Yaş</b>	-0.920	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.180

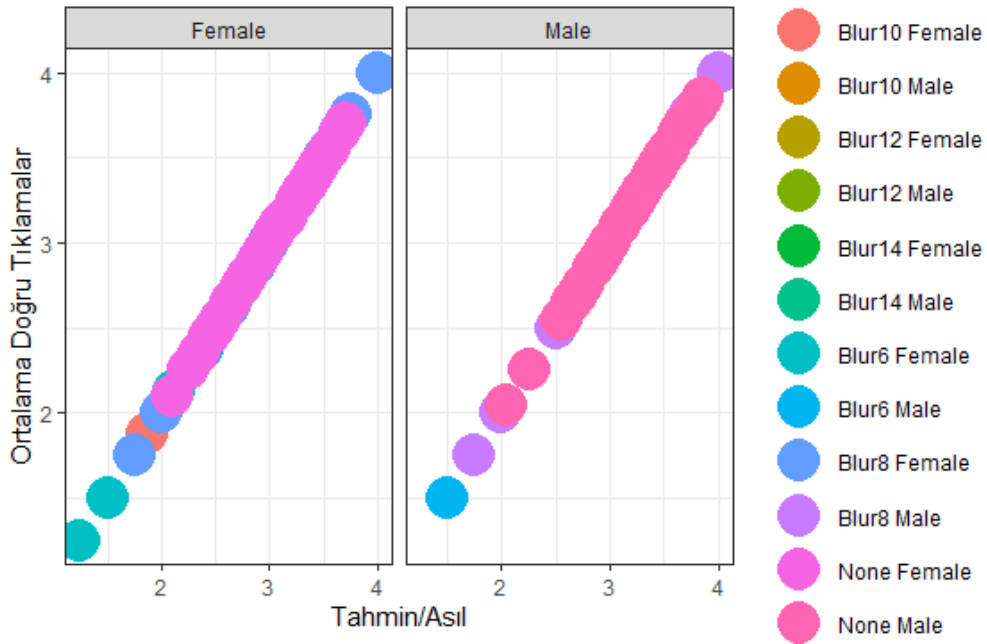
*Mod\_fieldleft ve Mod\_fieldright Arasındaki Korelasyon:* "mod\_fieldleft" ve "mod\_fieldright" değişkenleri arasındaki 0.500 değerindeki orta düzeyde pozitif korelasyon, bu iki değişkenin birbirleriyle ilişkili olduğunu ancak modeldeki diğer değişkenlerle önemli bir ilişkiye sahip olmadığını gösterir (Kutner, Nachtsheim, Neter, & Li, 2004). Bu, modeldeki farklı değişken kategorilerinin etkileşim dinamiklerini anlamak için önemlidir.

*Yaş Değişkeninin Önemi:* Yaş değişkeni ile kesişim -0.920 gibi oldukça yüksek negatif bir korelasyon gösterir. Bu, yaşın artışıyla modelin referans grubu için tahmin edilen sonuçların azalma eğiliminde olduğunu gösterir ve yaşın modelde

önemli bir faktör olduğunu ve sonuç üzerinde belirgin bir etkisi olduğunu vurgular (Salthouse, 2004). Bu bulgu, bilişsel performans ve yaşlanma üzerine yapılan çalışmalarda sıkça gözlemlenen bir trendi yansıtır.

*Genel Korelasyon Yapısı:* Korelasyon matrisi, modeldeki değişkenler arasında genellikle düşük veya sıfıra yakın korelasyonlar olduğunu gösterir, bu da çoklu doğrusallığın önemli bir endişe kaynağı olmadığını işaret eder (James, Witten, Hastie, & Tibshirani, 2013). Ancak, bulanıklık seviyeleri arasındaki korelasyonlar, bu faktörlerin birbirleriyle ilişkili olduğunu ve sonuçların yorumlanmasında dikkate alınması gerektiğini gösterir.

Sonuç olarak, bu korelasyon matrisi, sabit etkilerin birbirleriyle nasıl ilişkili olduğunu ve hangi değişkenlerin modeldeki sonuç üzerinde daha belirgin bir etkiye sahip olabileceğini anlamamıza yardımcı olur. Yaş değişkeninin modeldeki etkisi ve bulanıklık seviyeleri arasındaki ilişki, modelin doğru yorumlanması ve sonuçların anlamının derinlemesine anlaşılması için kritik öneme sahiptir.

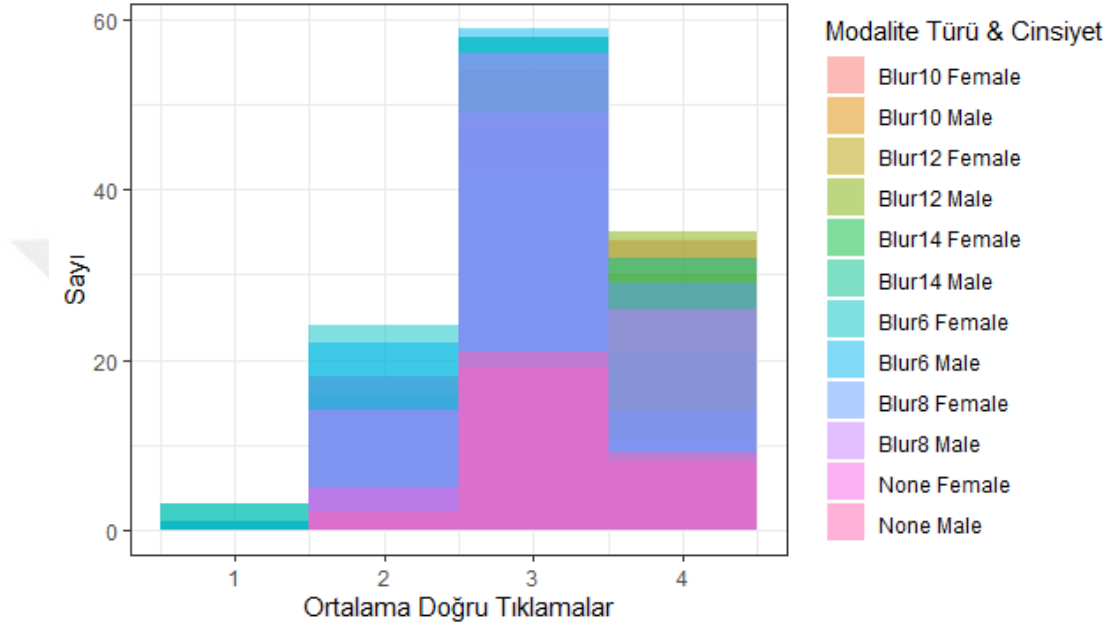


**Şekil 4.5:** Deney 1 Bulanıklık Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl (mod\_type/Cinsiyet)

Bu deneyi grafikselletirdiğimizde her bulanıklaştırma durumu ve her cinsiyet için ayrı bir veri noktası satırıyla hem kadınlar hem de erkekler için tahmin edilen/asıl değerler ile ortalama doğru ilk yanıtlar arasında pozitif bir doğrusal ilişki

göstermektedir. Noktaların bir çizgi boyunca kümelenmesi, bu değişkenler arasında güçlü bir korelasyon olduğunu göstermektedir (Şekil 4.5).

Şekil 4.6'da bir çubuk içindeki her renk bölümünün yüksekliği, söz konusu kategori için ortalama doğru tıklama sayısını temsil eder. Bu görselleştirme, farklı koşullar ve cinsiyetler arasında ortalama doğru tıklamaların sıklığını veya sayısını karşılaştırmak için kullanılır.

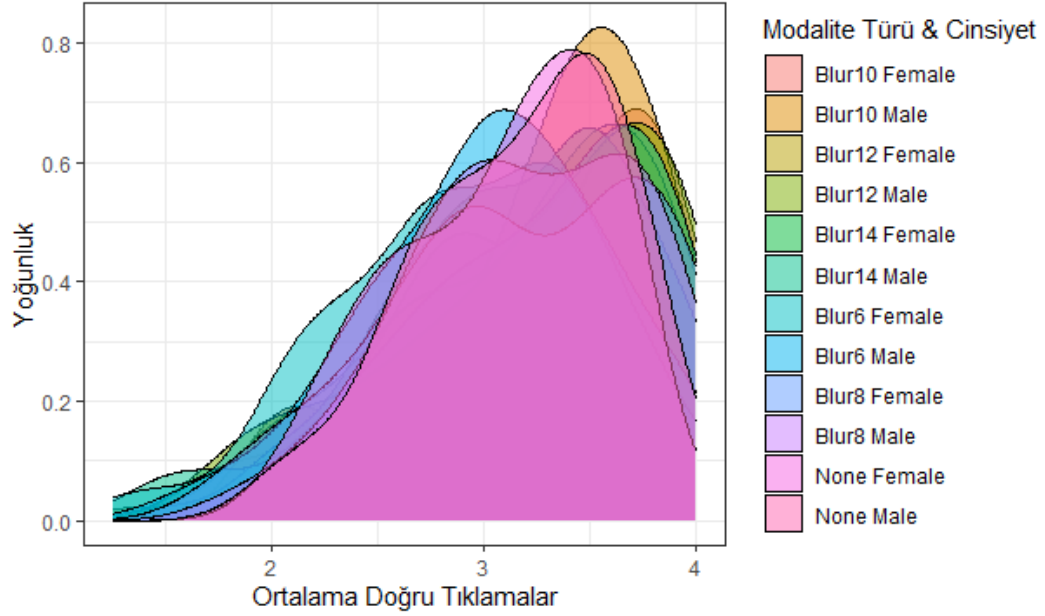


Şekil 4.6: Deneysel 1 Bulanıklık Ortalama Doğru Tıklamalar(mod\_type/Cinsiyet)

Grafik, her iki cinsiyet için de en yüksek ortalama doğru tıklama sayısının "None" kategorisiyle ilişkili olduğunu gösteriyor; bu da katılımcıların herhangi bir bulanıklık etkisi olmadan daha iyi performans gösterdiğini belirtiyor. Her iki cinsiyette de tutarlı olan bulanıklık düzeyi arttıkça sayımlar azalır. Bu, bulanıklaştırmanın, yürütülen görev veya test ne olursa olsun doğru şekilde gerçekleştirilme yeteneğini engellediği anlamına gelebilir.

Çubuklardaki renkleri karşılaştırmak, her cinsiyetin her bulanıklaştırma kategorisinde nasıl performans gösterdiğine dair bize bir fikir verebilir. Örneğin, "Blur12 Male" segmentleri "Blur12 Female" segmentlerinden daha büyükse, ortalama doğru tıklama söz konusu olduğunda bu bazı belirli bulanıklaştırma düzeyinde erkeklerin kadınlardan daha iyi performans gösterdiğini belirtir.

Bu grafik, farklı bulanıklaştırma yöntemleri ve cinsiyetler arasındaki doğru tıklamaların kümülatif sayılarını karşılaştırmak için kullanışlıdır. Yalnızca her modalite türü-cinsiyet kombinasyonunun toplam sayısını değil, aynı zamanda bu sayıların ortalama doğru tıklamaların her düzeyi için toplama nasıl katkıda bulunduğunu da gösterir.



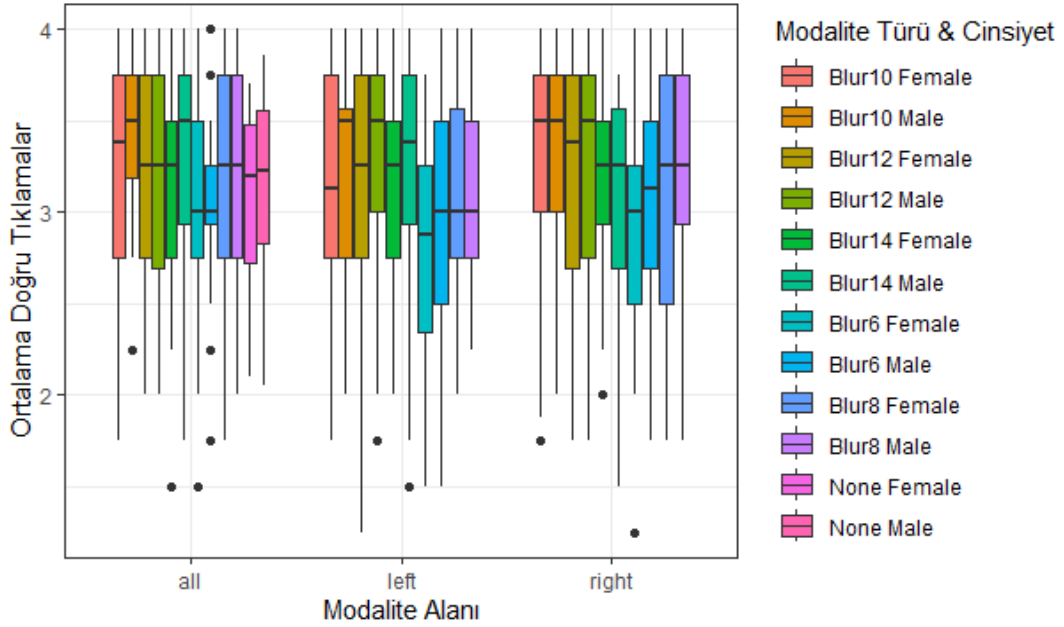
Şekil 4.7: Deney 1 Bulanıklık Ortalama Doğru Tıklamaların Yoğunluğu (mod\_type/Cinsiyet)

Analiz için kullandığımız diğer bir şekli incelediğimizde (Şekil 4.7) görüldüğü gibi:

1. Her iki cinsiyet için de 'None' kategorisi en yüksek yoğunluk zirvelerine sahip; bu da katılımcıların herhangi bir bulanıklık olmadan daha fazla ortalama doğru tıklamaya sahip olduklarını gösteriyor.
2. Bulanıklaştırma düzeyi arttıkça, yoğunluk grafiklerinin tepe noktaları her iki cinsiyet için de sola doğru kayma eğilimi gösterir, bu da daha az ortalama doğru tıklamaya işaret eder.
3. Eğrilerin dağılımı kategoriler arasında farklılık gösteriyor; bu da bazı bulanıklık düzeylerinin katılımcılar arasında daha tutarlı performansa yol açtığını, diğerlerinin ise daha fazla değişkenlik gösterdiğini belirtiyor.

Genel olarak, bu yoğunluk grafiği, farklı bulanıklık düzeylerinin, çalışmadaki kadın ve erkek katılımcılar arasındaki ortalama doğru tıklamaların dağılımını nasıl etkilediğinin karşılaştırılmasına olanak tanır. Bulanıklaştırmanın genellikle ortalama doğru tıklama sayısını azalttığını ve etkinin cinsiyetler arasında benzer olduğunu gösteriyor.

Kutu grafiklerinden, farklı yöntemler ve cinsiyetler arasındaki ortalama doğru başlangıç tepkilerinin merkezi eğilimini ve dağılımını karşılaştırabiliriz. Örneğin, bir kutu diğerinden daha yüksekse bu, grubun ortalama puanının daha yüksek olduğunu gösterir. Benzer şekilde, bir kutunun Çeyrekler Arası Aralık (ÇAA) (veri setinin çeyreklerini temsil eden 1Ç ve 3Ç arasındaki farkı ifade eder) daha büyükse bu, o grubun puanlarında daha fazla değişkenlik olduğunu gösterir.



**Şekil 4.8:** Deney 1 Bulanıklık Tüm, Sol ve Sağ mod\_field'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)

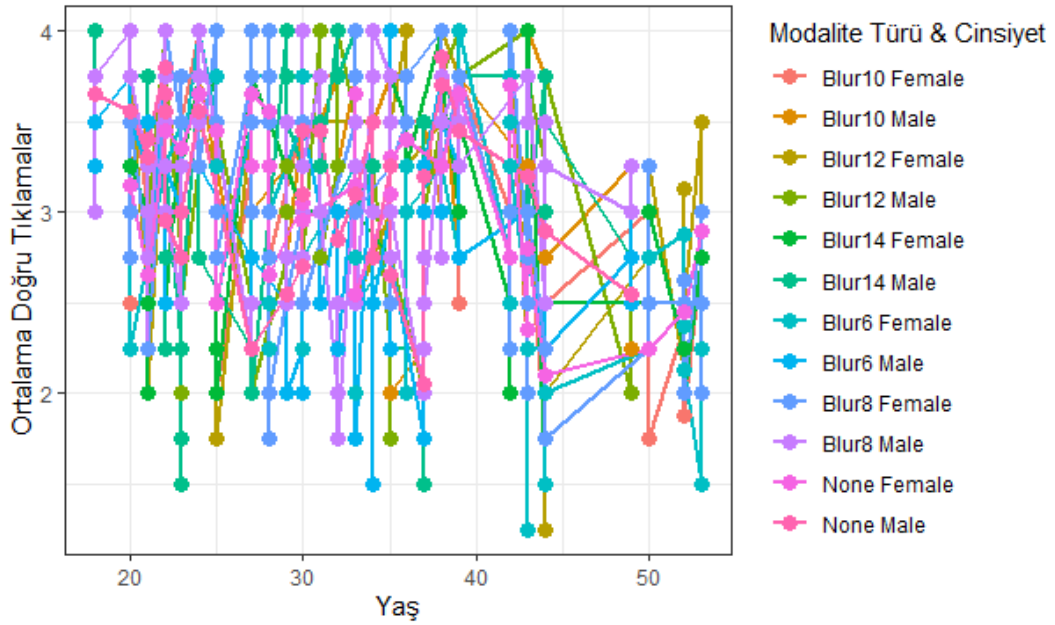
Bazı gözlemler:

- Büyük olasılıkla bulanıklığın olmadığını belirten 'None' kategorisi genellikle daha yüksek ortalama değerlere sahiptir ve bulanıklık olmadan daha iyi performans gösterir.
- ÇAA aralığının gösterdiği gibi, her modalite türü ve cinsiyette bazı farklılıklar vardır.

- Aykırı değerler, verilerin geri kalanıyla karşılaştırıldığında alışılmadık derecede yüksek veya düşük puan örneklerini gösteren çeşitli modalite türlerinde mevcuttur.

Genel olarak, bu kutu grafiği, farklı bulanıklık düzeyleri için ve her modalite türü içindeki cinsiyetler arasındaki ortalama doğru başlangıç yanıtlarının dağılımlarının net bir görsel karşılaştırmasını sağlar (Şekil 4.8).

Şekil 4.9, her modalite türü için yaş ile ortalama doğru ilk yanıtlar arasındaki ilişkiyi gösterir. Veri noktaları, her kategori için çizgilerle birbirine bağlanmıştır ve çizgilerdeki varyasyon, ortalama doğru ilk yanıtların her bir modalite türü ve cinsiyet için yaşa göre nasıl değiştiğini gösterir.



**Şekil 4.9:** Deney 1 Bulanıklık Yaş'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)

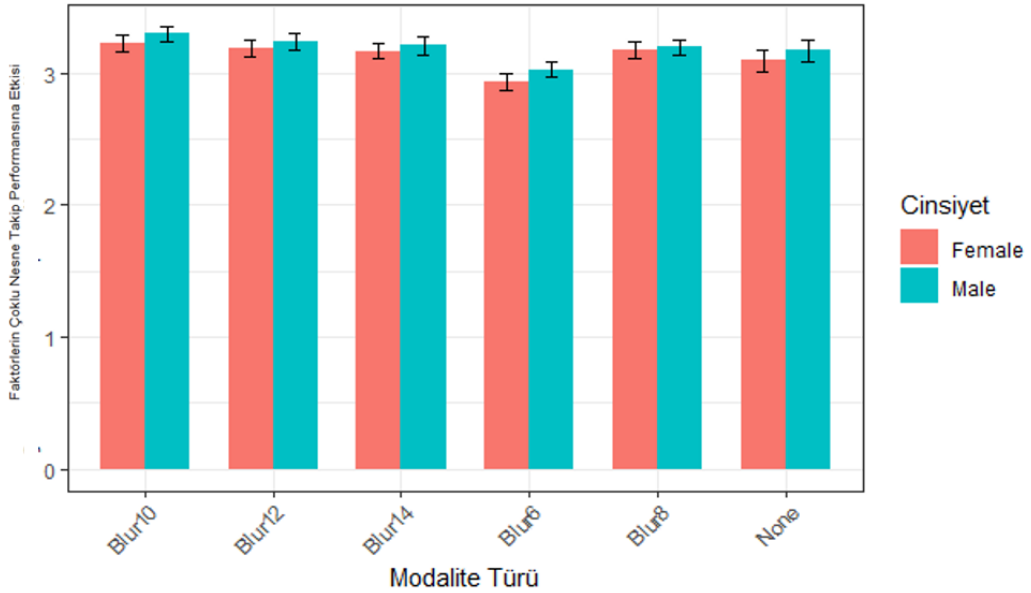
Temel gözlemler şunları içerebilir:

- Her modalite türü ve cinsiyet için farklı yaşlar arasında ortalama doğru ilk yanıtlardaki değişkenliktir.
- Bazı satırlar daha fazla dalgalanma gösteriyor, bu da bu kategorilerdeki farklı yaşlar arasındaki yanıtlarda daha fazla tutarsızlık olduğunu gösterir.

- "None" kategorilerine ilişkin çizgiler, bulanıklaştırmanın, bulanıklaştırma yapılmamasına kıyasla ortalama doğru ilk yanıtları nasıl etkilediğini anlamak için bir temel olarak kullanılabilir.

Böyle bir grafik, farklı görsel netlik koşulları altında ilk denemede doğru tepki verme yeteneği üzerinde yaşın etkisini analiz etmek ve bu etkileri cinsiyetler arasında karşılaştırmak için kullanılabilir.

Aynı yöntem türü içindeki her cinsiyetteki çubukların benzer yükseklikleri, faktörün performans üzerindeki etkisinin, her bulanıklaştırma düzeyi için erkekler ve kadınlar arasında tutarlı olduğunu göstermektedir. Hata çubukları küçük görünüyor, bu da ortalama tahminlerin nispeten kesin olduğunu gösteriyor (Şekil 4.10).



**Şekil 4.10:** Deney 1 Bulanıklık için Çoklu nesne izleme performansının mod\_type'a göre grafiği (Cinsiyet)

#### 4.1.2 Bulanıklık düzeyleri için deney 1 sonrası yapılan test (Post-Hoc)

Bu bölümde, birden fazla karşılaştırma sonucunda ortaya çıkan aile içi hata oranını kontrol altında tutmak amacıyla Tukey düzeltmesi kullanılarak gerçekleştirilen post-hoc analizlerin sonuçlarına detaylı bir bakış sunulmaktadır. Tukey düzeltmesi, grup ortalamaları arasındaki istatistiksel olarak anlamlı farkları belirlemek için kullanılır.

Bu veri seti, belirli bir yaş grubundaki erkek ve kadının farklı bulanıklık düzeylerinin etkilerini karşılaştıran bir dizi karşılaştırma sunar(muhtemelen 31.703125 yaşında, ancak bu alışılmadık derecede belirli bir rakamdır). Karşılaştırmalar, farklı bulanıklık seviyeleri (Blur6, Blur8 vb. gibi sayılarla belirtilmiş) ve farklı yönelimler veya koşullar (örneğin 'tümü', 'sol', 'sağ' gibi) arasında yapılır. Veri seti, her karşılaştırma için etkilerin, standart hataların (SH), serbestlik derecelerinin (SD), t-oranlarının ve p-değerlerinin tahminlerini içerir. İşte sonuçların detaylı bir analizi:

*Etki Büyüklüğü ve İstatistiksel Anlamlılık:* Tahminler, karşılaştırılan koşullar arasındaki farkın büyüklüğünü temsil eder; standart hata ise bu tahminlerin hassasiyetini gösterir. t-oranları ve p-değerleri, her karşılaştırmanın istatistiksel anlamlılığını değerlendirmek için kullanılır. Tipik olarak, 0.05'ten küçük bir p-değeri, gözlemlenen etkinin istatistiksel olarak anlamlı olduğunu gösterir, bu da rastgele varyasyondan kaynaklanması olasılığının düşük olduğu anlamına gelir.

*Yüksek Bulanıklık vs. Düşük Bulanıklık:* Daha yüksek bulanıklık seviyeleri (örneğin, Blur10, Blur12, Blur14) ile düşük bir seviye (Blur6) arasındaki karşılaştırmalara göre pozitif tahminler gösterir ve artan bulanıklık seviyesinin incelenen sonuçlar üzerinde ölçülebilir bir fark oluşturduğunu gösterir.


*Cinsiyete Göre Karşılaştırma:* Veri seti, 'Kadın' ve 'Erkek' için karşılaştırmaları ayırarak, bulanıklığın etkilerinin cinsiyete göre farklılaşp farklılaşmadığını analiz etmeye olanak tanır. Sonuçlar, cinsiyetlere göre benzer gibi görünmektedir ve bulanıklığın etkilerinde dramatik cinsiyet tabanlı farkların belirgin bir göstergesi yoktur.

*Yönel Etkiler ('sol' vs. 'sağ'):* Bazı karşılaştırmalar, 'sol' ve 'sağ'ı ayırır (muhtemelen görüntünün tarafını veya konunun yönelimini belirtir), bu da bulanıklığın tarafının farklı etkilere sahip olabileceğini gösterebilir. Ancak, sonuçlar güçlü bir yönel etkiyi belirten tutarlı bir desen göstermez.

*Negatif Tahminler:* "Blur6 All Female Yaş31.703125 - Blur8 All Female Yaş31.703125" gibi karşılaştırmalar negatif tahminler gösterir, bu da bu durumlarda bulanıklık seviyesinin artmasının (Blur6'dan Blur8'e) incelenen ölçüm üzerinde azaltıcı bir etkiye sahip olabileceğini düşündürür.

*İstatistiksel Anlamlılık:* Neredeyse tüm karşılaştırmalar, 0.05'ten küçük bir p-değeri gösterir, bu da gözlemlenen farklılıkların istatistiksel olarak anlamlı olduğunu ve rastgele varyasyondan kaynaklanmadığını gösterir. Bu, bulanıklığın etkilerinin yanı sıra 'tüm', 'sol' ve 'sağ' koşulları arasındaki farkların anlamlı ve tutarlı olduğunu gösterir.

### Anlamlı Çift Karşılaştırmalar - Tahmin



**Şekil 4.11:** Deney 1 Bulanıklık için Önemli İkili Karşılaştırmalar- Tahmini

*Potansiyel Uygulamalar:* Bu sonuçlar, psikoloji alanında bulanık görüntülerin algısının etkisinin bilişsel işleme ile ilişkili olabileceğini gösterir.

Özetle, bu veri seti, farklı bulanıklık düzeylerinin ve yönelimlerinin belirli bir yaş grubundaki erkek ve kadın görüntülerini nasıl etkilediğine dair kapsamlı bir analiz sunar. İstatistiksel olarak sonuçlar, bu etkilerin ölçülebilir ve anlamlı olduğunu, cinsiyetler arasındaki desenin benzerliği bulguların doğru olabileceğini gösterirken, ayrıntılı istatistiksel veri çıkarılan sonuçların güvenilirliğini destekler (Şekil 4.11).

## 4.2 Deney 2 Bulanıklığın Çoklu Nesne Takibi Üzerindeki Etkileri

### 4.2.1 Deney 2 için bulanıklık doğrusal karma model analizi sonuçları

#### 4.2.1.1 KMOY ile uygulanan doğrusal karma model(DKM)

Bu analizde kullanılan DKM formülü aşağıdaki gibi tanımlanır:

$$\text{Ortalama} \sim \text{mod\_type} + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.2)$$


Formül 4.2'de "Ortalama" bağımlı değişkeni, "mod\_type", "Cinsiyet" ve "Yaş" sabit etkileri ve "katılımcı" rassal etkidir. Sonuçları analiz etmek için, tahmin edilen katsayılar ve sabit etkilerin p-değerlerine odaklanılır. Anlamlı p-değerleri, bağımlı değişkenle ilgili sabit etki arasında anlamlı bir ilişki olduğunu gösterir. Rassal etki, veride açıklanamayan değişkenliği hesaba katarak modelin tahminlerinin doğruluğunu artırır.

#### 4.2.1.2 Yakınsama için KMOY kriteri

Bu analizde, yakınsamada KMOY kriteri 1708,9 olarak tespit edilmiştir. Bu değer tek başına modelin performansı hakkında çok fazla bilgi sağlamaz. Model uyumu daha kesin bir şekilde değerlendirmek için KMOY değerini alternatif modellerle karşılaştırmak faydalı olabilir. Farklı sabit veya rassal etkilere sahip farklı modelleri uygunlaştırarak ve KMOY değerlerini karşılaştırarak bunu yapabilirsiniz. Daha düşük KMOY değerleri daha iyi uyumlu bir modeli, daha yüksek değerler ise daha kötü bir uyumu gösterir (Schabenberger & Gregoire, 1997). Genel itibarıyla model için makul değerdir.

#### 4.2.1.3 Ölçeklendirilmiş artıklar

Ölçeklendirilmiş artıklar, doğrusal karma modellerinde model uyumunu değerlendirmek ve potansiyel aykırı değerleri belirlemek için kullanılır. Ölçeklendirilmiş artıklar, gözlenen ve tahmin edilen değerler arasındaki farkları standart hata değerleriyle bölerek hesaplanır (Verbeke & Molenberghs, 2000). Bu değerler, modeli iyi şekilde temsil edemeyen veri noktalarını belirlemeye yardımcı olur (Şekil 4.12).



**Şekil 4.12:** Deney 2 Bulanıklık için Artıklar ve Tahmin Edilen Değerler


Bu analizde, ölçeklendirilmiş artıklar minimum (Min.), birinci çeyrek (1Ç), ortanca, üçüncü çeyrek (3Ç) ve maksimum (Mak.) olmak üzere beş özet istatistik kullanılarak özetlenir. Bildirilen değerler, artıkların dağılımını anlamak ve olası aykırı değerleri veya olağandışı veri noktalarını belirlemek için yardımcı olur. Büyük artıklar uyumsuz bir uyumu işaret ederken, küçük artıklar modelin verilere daha iyi uyduğunu gösterir. Bu özet istatistikleri incelemek, modelin performansı ve verilere olan uyumu hakkında bilgi sağlar.

İyi uyumlu bir model genellikle sifıra yakın simetrik olarak dağılmış ölçeklendirilmiş artıklara sahiptir ve aşırı değerler içermez. Bu durumda, ortanca ölçeklendirilmiş artık (0.0352), modelin tahminlerinin genellikle doğru olduğunu gösterir. Ancak, minimum ve maksimum ölçeklendirilmiş artıklar (-3.8695 ve 2.8818) potansiyel aykırı değerleri veya etkileyici veri noktalarını işaret eder (Çizelge 4.5).

**Çizelge 4.5:** Deney 2 Bulanıklık için Ölçeklendirilmiş Artıklar

Min.	1. Çeyrek	Ortanca	3. Çeyrek	Mak.
-3.8695	-0.5989	0.0352	0.6364	2.8818

Ölçeklendirilmiş artıkların dağılımını daha iyi anlamak için bir histogram veya QQ plot (nicelle-quantile grafiği) oluşturmak faydalıdır (Cribari-Neto & Zeileis, 2010). Bir QQ grafiği, ölçeklendirilmiş artıkların kuantillerini standart normal dağılımın kuantilleriyle karşılaştırır. Noktaların düz bir çizgi boyunca düzenlenmiş olması, artıkların normal bir dağılımı takip ettiğini gösterir, ki bu, doğrusal karma modelleri için temel bir varsayımdır (Faraway, 2016) (Şekil 4.13).



**Şekil 4.13:** Deney 2 Bulanıklık için Artıkların QQ plotu

Özetlemek gerekirse, ölçeklendirilmiş artıklar potansiyel aykırı değerleri veya etkileyici veri noktalarını belirlemeye yardımcı olur.

#### 4.2.1.4 Rassal etkiler


Bu bölümde, modeldeki rassal etkiler açıklanır, bunlar sabit etkiler tarafından açıklanmayan katılımcıya özgü farklılıkları temsil eder (Şekil 4.14).

Gözlem sayısı ve grup sayısı: Veri setinde 1024 gözlem ve 64 farklı katılımcı bulunmaktadır.

İşte rassal etkilerin bir tablosu (Çizelge 4.6):

**Çizelge 4.6:** Deney 2 Bulanıklık için Rassal Etkiler

Grup	Ad	Varyans	Standart Sapma
Katılımcı	(Sabit)	0.2316	0.4813
Artık		0.2492	0.4992



**Şekil 4.14:** Deney 2 Bulanıklık için Rassal Etkilerin Histogramı


Bu durumda, değişkenliğin iki bileşeni vardır:

*Katılımcılar arası kesişim:* Katılımcılar için rasgele kesişimin varyansı 0.2316 ve standart sapması 0.4813'tür. Bu, farklı katılımcılar arasında kesişimde bazı farklılıklar olduğunu gösterir. Daha büyük bir değer, kesişimlerde daha fazla değişkenliği gösterirken, daha küçük bir değer katılımcıların kesişimlerinin daha benzer olduğunu gösterir.

*Artık değişkenlik:* Artık varyans (0.2492) ve standart sapma (0.4992), modeldeki sabit ve rassal etkiler tarafından açıklanmayan değişkenliği temsil eder. Bu değer, sabit etkileri ve katılımcılar için rasgele kesenleri dikkate aldıktan sonra gözlenen ve tahmin edilen değerler arasındaki farklılıkları hesaba katar.

Bu değerler, modelin verilere olan uyumunu ve verilerin içindeki değişkenliğin ne kadarının model tarafından açıklanabildiğini gösterir. Her iki değer de oldukça yüksek, bu da modelin verilerin içerdiği değişkenliği iyi bir şekilde yakaladığını gösterir.

Sonuç olarak, rassal etki çıktısı, katılımcılar arasındaki kesişimlerin değişkenliği ve modelde açıklanmayan değişkenlik hakkında bilgi sağlar. Bu değerler, katılımcılar arasındaki heterojenlik derecesini ve model tarafından açıklanan varyansın oranını değerlendirmek için kullanılabilir (Şekil 4.15).



**Şekil 4.15:** Deney 2 Bulanıklık için Rassal Etkilerin Yoğunluk Grafiği

#### 4.2.1.5 Sabit etkiler

Sabit etkiler analizi, doğrusal karma modelin çeşitli faktörlerin bağımlı değişken üzerindeki etkilerini nasıl tahmin ettiğini gösterir. Bu analiz, farklı görüntü işleme türleri(modalite türü), cinsiyet ve yaş gibi faktörlerin etkilerini değerlendirir. İşte önemli bulgular:

##### *Görüntü İşleme Türlerinin(Modalite Türlerinin) Etkileri:*

- *Heterojen (1/2-1 Heterogen):* Bu faktör, referans kategoriye kıyasla yanıt değişkeninde anlamlı bir azalma (-0.203,  $p=0.02155$ ) gösterir, bu da heterojen işlemenin etkisinin negatif olduğunu belirtir.
- *Homojen (1/2-1 Homogen):* Bu faktörde daha büyük ve daha anlamlı bir negatif etki (-0.493,  $p<0.00001$ ) görülür, bu da homojen işlemenin referans kategoriye göre daha belirgin bir negatif etkiye sahip olduğunu gösterir.
- *Pozitif etkiler:* 1/3-2/3-1 2Hot (+0.185,  $p=0.03640$ ) ve 1/4-1/2-3/4 2Hot (+0.166,  $p=0.06056$ ) gibi bazı faktörler, referans kategoriye göre yanıt değişkeninde anlamlı bir artış gösterir, bu da bu işleme türlerinin pozitif bir etkiye sahip olduğunu işaret eder.

#### *Cinsiyetin Etkisi:*

- Cinsiyet faktörü (Erkek) bu modelde yanıt değişkeni üzerinde anlamlı bir etkiye sahip değildir (-0.108,  $p=0.39004$ ), bu da cinsiyetin bu bağlamda önemli bir faktör olmadığını gösterir.

#### *Yaşın Etkisi:*

- Yaşın yanıt değişkeni üzerindeki etkisi anlamlı ve negatiftir (-0.018,  $p=0.01755$ ). Bu, yaş arttıkça yanıt değişkeninin azaldığını gösterir, yani yaş ilerledikçe bu bağlamdaki performans düşebilir.

#### *Sonuç:*

Bu sabit etkiler analizi, farklı görüntü işleme türlerinin (*mod\_type*) yanıt değişkeni üzerinde önemli ve farklılaşan etkilere sahip olduğunu gösterir. Hem heterojen hem de homojen görüntü işleme türleri, referans kategoriye kıyasla yanıt değişkeninde anlamlı bir azalma ile ilişkilendirilirken, bazı diğer işleme türleri pozitif bir etki gösterir. Cinsiyetin bu modelde önemli bir etkisi yoktur, ancak yaşın yanıt değişkeni üzerinde negatif bir etkisi vardır. Bu bulgular, görsel işleme türlerinin, yaşın ve cinsiyetin, belirli bir bağlamdaki performans üzerindeki etkilerini daha iyi anlamamıza yardımcı olabilir.

#### **4.2.1.6 Sabit etkilerin katsayısı**

Sabit etkilerin katsayıları, bir regresyon modelinin anlaşılmasında ve yorumlanmasında merkezi bir role sahiptir. Her bir katsayı, bağımsız değişkenlerin yanıt değişkeni üzerindeki spesifik etkisini temsil eder.

Sağlanan bilgilere dayanarak sabit etkilerle ilgili bazı önemli bulgular şunlardır (Çizelge 4.7).

*mod\_type*: Farklı *mod\_type* düzeyleri, ortalama sonuç üzerinde farklı etkilere sahiptir. Örneğin, "mod\_type1/3-2/3-1 Homogen" negatif bir etkiye sahiptir (katsayı = -0.40191), bu da mod\_type1/3-2/3-1 Homogen olduğunda ortalama sonucun referans kategoriye göre daha düşük olduğunu gösterir. Öte yandan, "mod\_type1/3-2/3-1 4Hot" gibi bazı *mod\_type* düzeyleri pozitif etkilere sahiptir (katsayı = 0.10764).


**Çizelge 4.7:** Deney 2 Bulanıklık için Sabit Etkilerin Katsayısı

<b>Sabit</b>	<b>Katsayı</b>
<b>Kesişim Noktası</b>	3.70608
<b>mod_type1/2-1 4Hot</b>	-0.06076
<b>mod_type1/2-1 Heterogen</b>	-0.20313
<b>mod_type1/2-1 Homogen</b>	-0.49306
<b>mod_type1/3-2/3-1 2Hot</b>	0.18490
<b>mod_type1/3-2/3-1 4Hot</b>	0.10764
<b>mod_type1/3-2/3-1 Heterogen</b>	-0.10330
<b>mod_type1/3-2/3-1 Homogen</b>	-0.40191
<b>mod_type1/4-1/2-3/4-1 2Hot</b>	0.27344
<b>mod_type1/4-1/2-3/4-1 4Hot</b>	0.12934
<b>mod_type1/4-1/2-3/4-1 Heterogen</b>	-0.04340
<b>mod_type1/4-1/2-3/4-1 Homogen</b>	-0.64236
<b>mod_type1/4-1/2-3/4 2Hot</b>	0.16580
<b>mod_type1/4-1/2-3/4 4Hot</b>	0.24392
<b>mod_type1/4-1/2-3/4 Heterogen</b>	-0.05469
<b>mod_type1/4-1/2-3/4 Homogen</b>	-0.48785
<b>GenderMale</b>	-0.10764
<b>Yaş</b>	-0.01760


Cinsiyet: GenderMale etkisi negatiftir (katsayı = -0.10764), bu da erkek katılımcıların ortalama sonucunun kadın katılımcılardan daha düşük olduğunu gösterir. Ancak, bu etkinin anlamlılığı tablodan yalnızca bu bilgiyle değerlendirilemez.

Yaş: Yaş negatif bir etkiye sahiptir (katsayı = -0.01760), bu da diğer belirleyiciler sabit tutulduğunda her yıl yaşın birim başına ortalama sonucu azaldığını gösterir.


Sonuç olarak, sabit etkiler analizi, farklı mod\_type düzeylerinin ortalama sonuç üzerinde farklı etkilere sahip olduğunu, cinsiyetin ve yaşın ise ortalama sonucu negatif yönde etkilediğini ortaya koymaktadır. Bu etkilerin önemini değerlendirmek için, standart hatalar, t-değerleri ve p-değerlerini içeren çıktıya başvurmak da gerekebilir. Deney 2’de kullanılan parametrelerin bazılarının sonuçlarını gösteren şekiller aşağıda gösterilmiştir (Şekil 4.16, Şekil 4.17, Şekil 4.18, Şekil 4.19, Şekil 4.20, Şekil 4.21).




**Şekil 4.16:** Deney 2 Bulanıklık Ortalama Doğru Tıklamaları Tahmin Edilen / Asıl (mod\_type/Cinsiyet)




Şekil 4.17: Deney 2 Bulanıklık Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)




Şekil 4.18: Deney 2 Bulanıklık Ortalama Doğru Tıklamaların Yoğunluğu (mod\_type/Cinsiyet)



Şekil 4.19: Deney 2 Bulanıklık için mod\_type'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



Şekil 4.20: Deney 2 Bulanıklık Yaş'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



**Şekil 4.21:** Deney 2 Bulanıklık için Çoklu nesne izleme performansının mod\_type'a göre grafiği (Cinsiyet)

#### 4.2.2 Bulanıklık düzeyleri için deney 2 sonrası yapılan test (Post-Hoc)


Sonradan yapılan test, mod\_type, cinsiyet ve yaş göz önünde bulundurularak farklı insan grupları arasındaki çiftli karşılaştırmaları sağlar. Bu, doğrusal karma modeli bağlamında bu faktörler ile yanıt değişkeni arasındaki ilişkilerin daha derinlemesine anlaşılmasını sağlar. Karşılaştırmalarda bazı istatistiksel olarak anlamlı fark bulunmuştur. Bazı örnekler şunlardır:

(1/4-1/2-3/4-1 Homogen Female Age34.203125) - (1/3-2/3-1 2Hot Male Age34.203125): Fark tahmini -0.720 ve p-değeri 0.0023'dür, bu da ilk grubun ikinci gruptan anlamlı derecede düşük bir değere sahip olduğunu göstermektedir.

(1/4-1/2-3/4 2Hot Female Age34.203125) - (1/4-1/2-3/4 Homogen Female Age34.203125): Fark tahmini 0.654, p-değeri <.0001 olan bu da ilk grubun ikinci gruptan anlamlı derecede daha yüksek bir değere sahip olduğunu göstermektedir.

(1/2-1 2Hot Male Age34.203125) - (1/2-1 Homogen Male Age34.203125): Fark tahmini 0.493, p-değeri <.0001 olan bu da ilk grubun ikinci gruptan anlamlı derecede daha yüksek bir değere sahip olduğunu göstermektedir

#### Anlamli Çift Karşılaştırmalar - Tahmin



**Şekil 4.22:** Deney 2 Bulanıklık için Önemli İkili Karşılaştırmalar- Tahmini

Bu sonuçlar, farklı mod\_type, cinsiyet ve yaş bağlamında karşılaştırılan çeşitli gruplar arasında önemli farklılıklar olduğunu göstermektedir. İstatistiksel olarak anlamlı farklılıklar, araştırmacıların bu faktörlerin yanıt değişkeni üzerindeki etkisini daha iyi anlamalarına ve hangi belirli grupların yanıtında farklılıklar olduğunu belirlemelerine yardımcı olur. Özet olarak sonradan yapılan test, farklı mod\_type, cinsiyet ve yaş arasındaki ilişkiler hakkında önemli içgörüler sunarak gruplar arasındaki farklılıkları ve bu faktörlerin sonuç üzerindeki etkisini daha ayrıntılı bir şekilde ortaya koyar (Şekil 4.22).

### 4.3 Deney 1 Kontrastın Çoklu Nesne Takibi Üzerindeki Etkileri

#### 4.3.1 Deneysel 1 Kontrast İçin Doğrusal Karma Modelinin Analiz

##### Sonuçları

##### 4.3.1.1 KMOY ile uygulanan doğrusal karma model (DKM)

Doğrusal karma model (DKM), hem sabit etkileri hem de rassal etkileri içeren istatistiksel bir modeldir ve öznelilikler arasındaki değişkenliği hesaba katar. DKM'ler özellikle uzun süreli çalışmalar veya küme verilerini analiz etmek için faydalıdır.

Model formülü aşağıdaki gibidir:

$$\text{Ortalama} \sim \text{mod\_type} + \text{Yaş} + (1 \mid \text{Katılımcı}) \quad (4.3)$$

Bu çıktı, R'deki "lmerModLmerTest" işlevi kullanılarak gerçekleştirilen bir doğrusal karma model (DKM) analizinden elde edilmiştir. Formül 4.3'de model, yanıt değişkeni "Ortalama" ile iki sabit etki "mod\_type" ve "Yaş" arasındaki ilişkiyi araştırmayı amaçlamaktadır. Model, her katılımcı için bir rastgele kesimi içermekte ve verinin tekrarlanan ölçümler düzenini dikkate almaktadır. Varyans bileşenlerinin önyargısız tahminlerini elde etmek için KMOY ile aynı önyargıyı sergilemediği için MOY yerine tercih edilir (Patterson ve Thompson, 1971). KMOY, sabit etki tahminlerine bağımlılığı ortadan kaldırarak varyans bileşenlerinin önyargısız ve daha verimli tahminlerini sağlar (Bates vd., 2015).

#### 4.3.1.2 Yakınsama için KMOY kriteri

Ulaşılan KMOY (Kısıtlı Maksimum Olabilirlik Yöntemi) kriteri, modelin tahmin edilen parametre sayısına göre cezalandırılan bir model uyum ölçüsüdür. Bu durumda, ulaşılan KMOY kriteri 1199,8 olarak hesaplanmıştır, bu da modelin verilere iyi uyum sağladığını göstermektedir.

#### 4.3.1.3 Ölçeklendirilmiş artıklar


Ölçeklendirilmiş artıklar, bir istatistiksel modelden elde edilen gözlemlenen değerler ile tahmin edilen değerler arasındaki standartlaştırılmış farklardır. Artıkların dağılımını incelemek, bir modelin uyumunun iyi olup olmadığını değerlendirmek ve model varsayımlarının ihlallerini belirlemek için önemlidir (Crawley, 2007). Bu nedenle aşağıdaki özellikleri içermelidir.

*Doğrusallık:* Modelimiz verilerdeki ilişkinin doğrusal olduğunu varsayıyorsa, artıkların rastgele dağılmış olması gerekir. Eğer bir örüntü varsa (örneğin, U şeklinde bir dağılım), modelimizin doğrusallık varsayımını ihlal ettiği anlamına gelir.

*Bağımsızlık:* Artıklar birbirinden bağımsız olmalıdır. Eğer bir örüntü veya sıralama varsa, gözlemlerimiz arasında bir bağımlılık olabileceğini gösterir.


*Eş varyans:* Artıkların varyansı, özneliklerin farklı değerleri için sabit olmalıdır. Eğer varyans değişiyorsa, modelimizin eş varyans varsayımını ihlal ettiği anlamına gelir.

Artıklar vs. Tahmin Edilen Değerler



Şekil 4.23: Deney 1 Kontrast için Artıklar ve Tahmin Edilen Değerler

Artıkların QQ Plotu



Şekil 4.24: Deney 1 Kontrast için Artıkların QQ plotu

*Normal dağılım:* Artıklar normal dağılıma sahip olmalıdır. Ölçeklendirilmiş artıkların özet istatistiklerini inceleyerek bu varsayımların karşılanıp karşılanmadığını değerlendirebiliriz. Örneğin, ortanca değeri sıfıra yakın olan bir ölçeklendirilmiş artık dağılımının sıfır etrafında simetrik olarak dağıldığını gösterir

ve doğrusallık varsayımını destekler. Bununla birlikte, aşırı değerlerin (minimum ve maksimum) varlığı, model uyumunu ve varsayımlarını etkileyebilecek potansiyel aykırı değerlerin olabileceğini gösterebilir (Şekil 4.23).

Model varsayımlarının daha ileri değerlendirilmesi için histogramlar, çeyrek-çeyrek (QQ) grafikleri veya Artıklar-Tahmin Edilen Değerler grafikleri gibi tanılama grafikleri oluşturulması önerilir (Crawley, 2007) (Şekil 4.24).

**Çizelge 4.8:** Deney 1 Kontrast için Ölçeklendirilmiş Artıklar

<b>Min.</b>	<b>1. Çeyrek</b>	<b>Ortanca</b>	<b>3. Çeyrek</b>	<b>Mak.</b>
-3.8858	-0.5240	0.0905	0.6145	4.3733

Verilen istatistiklere bakarsak, aşağıdaki yorumları yapabiliriz (Çizelge 4.8):

Min değeri (-3.8858) ve Mak değeri (4.3733) arasındaki geniş aralık, modelin bazı gözlemleri çok iyi tahmin edemediğini gösterir. Özellikle, minimum değeri, bir tahminin gerçekte olan değerden oldukça düşük olduğunu belirtirken, maksimum değeri, bir tahminin gerçek değerden oldukça yüksek olduğunu gösterir. Bu geniş aralık, modelin belirli durumlar için düzgün çalışmayabileceğini gösterebilir.

Ortanca değeri (0.0905) neredeyse 0'a yakın, bu da modelin genel olarak gözlemleri oldukça iyi tahmin ettiğini gösterir. Ancak, birinci çeyrek (-0.5240) ve üçüncü çeyrek (0.6145) arasında bir miktar simetri olmasına rağmen, dağılımın biraz çarpık olduğu görülüyor.

İdeal olarak, artıkların dağılımı normal olmalıdır (yani, min., 1Ç, ortanca, 3Ç ve mak. değerleri sırasıyla yaklaşık -3, -1, 0, 1 ve 3 olmalıdır). Ancak, verilen değerlere bakılırsa, bu durum tam olarak gerçekleşmiyor gibi görünüyor.

Modelin genel olarak verileri tahmin etme kabiliyeti makul görünse de belirli durumlar için modelin doğruluğunun önemli ölçüde azaldığını gösteren bazı önemli artıklar da mevcuttur.

#### **4.3.1.4 Rassal etkiler**

Rassal etkiler, DKM'lerde sabit etkilerle açıklanamayan yanıt değişkenindeki değişkenliği hesaplamak için kullanılır. Gözlemler arasındaki ilişki yapısını


modellemek için örneğin, bir uzun süreli çalışmada aynı katılımcılardan alınan tekrarlı ölçümler veya hiyerarşik bir tasarımda yer alan iç içe geçmiş gözlemler (Gelman ve Hill, 2007) gibi kullanılırlar. Bu analizde, rassal etki, katılımcı değişkenidir ve katılımcılar arasındaki değişkenliği hesaba katmamızı sağlar.

**Çizelge 4.9:** Deney 1 Kontrast için Rassal Etkiler

Grup	Ad	Varyans	Standart Sapma
Katılımcı	(Sabit)	0.2350	0.4847
Artık		0.1474	0.3839

Katılımcı rassal etkisiyle ilişkilendirilen varyans bileşeni (0.2350), sabit etkiler (mod\_type ve Yaş) hesaba katıldıktan sonra yanıt değişkenindeki (Ortalama) katılımcılar arasındaki değişkenliği temsil eder. Standart sapma (0.4847), varyansın kareköküdür ve katılımcılar arasındaki değişkenliğin yorumlanabilir bir ölçüsünü sağlar.

**Rassal Etkilerin Histogramı**



**Şekil 4.25:** Deney 1 Kontrast için Rassal Etkilerin Histogramı


Daha büyük bir değer, katılımcılar arasındaki değişkenliğin daha fazla olduğunu gösterirken, daha küçük bir değer katılımcıların daha benzer yanıtlara sahip olduğunu gösterir. Artıkların varyansı (0.1474), ne sabit etkiler ne de rassal etki

tarafından açıklamayan yanıt değişkenindeki katılımcı içi değişkenliği temsil eder. Artık standart sapması (0.3839), bu değişkenliğin yorumlanabilir bir ölçüsünü sağlar (Çizelge 4.9). Daha küçük bir artık varyansı, modelin yanıt değişkenindeki katılımcı içi değişkenliği açıklama konusunda daha başarılı olduğunu gösterir (Şekil 4.25)

Verilen doğrusal karma modelinin çıktısına göre aşağıdaki sonuçları çıkarabiliriz:

Katılımcıların başlangıç değerleri arasında önemli bir değişkenlik olduğunu gösteren "Katılımcı" rassal etkisi, özellikle bireyler arasındaki farklılıkların sonuçları önemli ölçüde etkileyebileceğini göstermektedir. Bu, katılımcıların her birinin başlangıçta farklı bir noktadan geldiğini ve bu farklılıkların sonuçlar üzerinde belirgin bir etkisi olduğunu gösterir.

Artık varyansın değeri, modelin verinin bazı bölümünü açıklamadığını göstermektedir. Bu, modelin bazı önemli etkileri eksik bırakabileceği veya verinin bazı özelliklerini yakalayamayabileceği anlamına gelebilir.



**Şekil 4.26:** Deney 1 Kontrast için Rassal Etkilerin Yoğunluk Grafiği

Genel olarak, bu analiz, modelin bireysel farklılıkları ve genel trendleri bir dereceye kadar açıkladığını, ancak belirli bir miktar artık varyansın hala var olduğunu göstermektedir. Bu, modelin belirli durumları tam olarak tahmin edemediği veya belirli bir varyans miktarının modelin kapsamı dışında olduğu anlamına gelir.

Sonuç olarak, modelin genel performansı iyi gibi görünse de belirli durumları veya bireyler arası farklılıkları daha iyi modellemek için ek değişkenlerin veya etkilerin dahil edilmesini düşünmek faydalı olabilir. Ayrıca, modelin varsayımlarının (örneğin, Rassal Etkilerin normal dağılıma sahip olması ve bağımsız olması) doğru olup olmadığını kontrol etmek de önemlidir. Bu, modelin tahminlerinin güvenilirliğini ve doğruluğunu değerlendirmeye yardımcı olacaktır (Şekil 4.26).

#### 4.3.1.5 Sabit etkiler

Sabit etkiler modelinin analizi, belirli değişkenlerin yanıt değişkeni üzerinde istatistiksel olarak anlamlı etkileri olduğunu ortaya koymuştur. Bu analiz, modeldeki her bir sabit etkinin yanıt değişkeni üzerindeki net etkisini değerlendirirken, diğer değişkenlerin kontrol edildiği bir çerçevede gerçekleştirilmiştir (Çizelge 4.10).

Bu etkilerin bazı sonuçları:

1. *'mod\_typeContrastMinus70'* Değişkeni:

- Katsayı Tahmini: -0.079487
- Standart Hata: 0.054984
- Serbestlik Derecesi: 970.526
- t Değeri: -1.446
- p-Değeri: 0.1486

Bu değişken için p değeri 0.1486 olarak belirlenmiş olup, genel kabul görmüş anlamlılık seviyesi olan 0.05'ten büyük olduğu için, *'mod\_typeContrastMinus70'* değişkeninin yanıt değişkeni üzerinde istatistiksel olarak anlamlı bir etkiye sahip olduğuna dair yeterli kanıt bulunamamıştır. Ancak, negatif katsayı tahmini, bu modun diğerlerine göre yanıt değişkenini azaltma eğiliminde olduğunu gösterir.

2. *'Yaş'* Değişkeni:

- Katsayı Tahmini: -0.013022
- Standart Hata: 0.005355
- Serbestlik Derecesi: 197.802
- t Değeri: -2.432
- p-Değeri: 0.0159

'Yaş' değişkeni için p değeri 0.0159 olarak belirlenmiştir, bu da 0.05 anlamlılık seviyesinin altında olduğu için yaşın yanıt değişkeni üzerinde istatistiksel olarak anlamlı bir negatif etkisi olduğunu gösterir. Bu, yaş arttıkça yanıt değişkeninde beklenen bir azalma olduğunu ifade eder.

3. Diğer 'mod\_type' Değişken Seviyeleri:

- 'Contrast-10', 'Contrast-50', 'Contrast-90', ve 'ContrastMinus30' için p değerleri sırasıyla 0.2256, 0.6081, 0.6748, ve 0.5601 olarak hesaplanmıştır. Bu değerler, 0.05 anlamlılık seviyesinin üzerinde olduğu için, bu değişken seviyelerinin yanıt değişkeni üzerinde istatistiksel olarak anlamlı bir etkisi olduğuna dair yeterli kanıt bulunamamıştır.

**Çizelge 4.10:** Deney 1 Kontrast için Sabit Etkiler

Değişken	Katsayı Tahmini	Standart Hata	Serbestlik Derecesi	t Değeri	p Değeri
(Sabit)	3.673357	0.190594	188.249	19.273	<0.0001
<b>Contrast-10</b>	0.066667	0.054984	970.526	1.212	0.2256
<b>Contrast-50</b>	0.028205	0.054984	970.526	0.513	0.6081
<b>Contrast-90</b>	0.023077	0.054984	970.526	0.420	0.6748
<b>ContrastMinus30</b>	0.032051	0.054984	970.526	0.583	0.5601
<b>ContrastMinus70</b>	-0.079487	0.054984	970.526	-1.446	0.1486
<b>Yaş</b>	-0.013022	0.005355	197.802	-2.432	0.0159

Bu analiz, herbir sabit etkinin yanıt değişkeni üzerindeki net etkisini değerlendirmek için sabit etkiler modelinin kullanımının önemini vurgular. Standart hataların küçük olması, tahminlerin daha hassas olduğunu gösterir, bu da Gelman ve Hill (2007) tarafından da desteklenen bir görüştür. Bu çerçevede, 'Yaş' değişkeni, yanıt değişkeni üzerinde anlamlı bir etkiye sahip olduğu tespit edilen tek değişkendir, bu da yaşın, katılımcıların yanıt değişkeni üzerinde önemli bir etkiye sahip olabileceğini gösterir. Diğer 'mod\_type' seviyeleri için, bu analizde istatistiksel olarak anlamlı bir etki bulunamamıştır. Bu bulgular, katılımcılar arasındaki değişkenliği dikkate alarak, sabit etkiler ve yanıt değişkeni arasındaki ilişkiler hakkında önemli bilgiler sağlar.

#### 4.3.1.6 Sabit etkilerin korelasyonu

DKM'lerde sabit etkiler arasındaki korelasyonlar, katsayı tahminlerinin hassasiyetini ve sonuçların yorumlanmasını etkileyebilecek çoklu doğrusallık sorunlarına neden olabilecek önemli bir faktördür (Gelman ve Hill, 2007). Korelasyon matrisi, modele dahil edilen sabit etkiler arasındaki çift taraflı korelasyonları sunar.

Bu tablo, bir Doğrusal Karma Model (DKM) analizindeki sabit etkiler arasındaki korelasyonları göstermektedir. Korelasyon, iki değişken arasındaki ilişkinin yönünü ve şiddetini ifade eden bir istatistiktir.

Tablodaki korelasyonlar, aşağıdaki şekilde yorumlanabilir:

*mod\_type* Değişkenleri Arasındaki Korelasyonlar: 'mod\_type' değişkeninin farklı seviyeleri (örneğin, Contrast-10, Contrast-50, Contrast-90, ContrastMinus30, ContrastMinus70) arasında 0.750 gibi yüksek pozitif korelasyonlar görülmektedir. Bu, 'mod\_type' değişkeninin farklı seviyelerinin birbirleriyle güçlü pozitif ilişkiler içerdiğini gösterir. Bu durum, bu değişken seviyelerinin benzer etkilere sahip olabileceğine işaret edebilir. Yüksek korelasyonlar ayrıca, modeldeki çoklu bağlantı sorunlarına da işaret edebilir ki bu, sabit etkilerin birbirlerine çok yakın olduğunu ve bu durumun katsayı tahminlerinin güvenilirliğini azaltabileceğini gösterir (Belsley, Kuh ve Welsch, 1980).

**Çizelge 4.11:** Deney 1 Kontrast için Sabit Etkiler Korelasyonu

Sabit Etki	Kesişim Noktası	Contrast-10	Contrast-50	Contrast-90	Contrast Minus30	Contrast Minus70	Yaş
Contrast-10	-0.216						
Contrast-50	-0.216	0.750					
Contrast-90	-0.216	0.750	0.750				
ContrastMinus30	-0.216	0.750	0.750	0.750			
ContrastMinus70	-0.216	0.750	0.750	0.750	0.750		
Yaş	-0.915	0.000	0.000	0.000	0.000	0.000	


*Yaş Değişkeni ve Diğer Değişkenler Arasındaki Korelasyonlar:* Yaş değişkeni ve kesişim noktası arasında -0.915 gibi yüksek negatif bir korelasyon görülmektedir. Bu, yaş arttıkça modelin sabitinde (ortalama yanıt değişkeni değeri) bir azalma olduğunu gösterir. Ancak, yaş değişkeni ve 'mod\_type' değişkeninin seviyeleri arasında 0.000 olarak gösterilen korelasyonlar, bu değişkenler arasında

istatistiksel olarak anlamlı bir ilişki olmadığını gösterir. Bu, yaşın 'mod\_type' değişkeninin seviyeleriyle bağımsız olduğunu ve bu değişkenlerin yanıt değişkeni üzerindeki etkilerinin birbirinden bağımsız olarak değerlendirilebileceğini gösterir (Çizelge 4.11).


Bu tür korelasyon analizleri, modeldeki değişkenlerin birbirleriyle olan ilişkilerini değerlendirirken önemlidir ve sabit etkilerin seçiminde ve modelin yorumlanmasında yardımcı olabilir.

Sonuç olarak, sabit etkilerin korelasyon matrisi, sabit etkiler arasındaki ilişkileri ve model tahminlerine olası etkilerini anlamamıza yardımcı olur. Bazı korelasyonlar mevcuttur, ancak bunlar çoklu doğrusallık konusunda önemli endişelere yol açacak kadar büyük değildir. Çoklu doğrusallık, modeldeki sabit etkiler arasında yüksek korelasyon olduğunda ortaya çıkan bir problemdir.


Bununla birlikte, Yaş ve kesişim noktası arasındaki güçlü korelasyon daha fazla araştırmayı gerektirebilir ve gerektiğinde model yeniden parametrelendirilebilir. Aşağıda Deney 1 kontrast için değişik parametreleri gösteren şekiller aşağıda gösterilmiştir (Şekil 4.27, Şekil 4.28, Şekil 4.29, Şekil 4.30, Şekil 4.31, Şekil 4.32).




**Şekil 4.27:** Deney 1 Kontrast için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl(mod\_type/Cinsiyet)




Şekil 4.28: Deney 1 Kontrast için Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



Şekil 4.29: Deney 1 Kontrast için Ortalama Doğru Tıklamaların Yoğunluğu (mod\_type/Cinsiyet)



Şekil 4.30: Deneysel Kontrast için yaş'a göre Ortalama Doğru Tıklamalar(mod\_type/Cinsiyet)




Şekil 4.31: Deneysel Kontrast için Çoklu nesne takip performansının mod\_type'a göre grafiği (Cinsiyet)

#### 4.3.2 Kontrast düzeyleri için deney 1 sonrası yapılan test (Post-Hoc)

Kontrast düzeyleri için Deney 1 sonrası yapılan test analizi sonuçları, "Contrast-Age10: 32.4769230769231" grubu ile "ContrastMinus-Age70: 32.4769230769231" grubu arasında yanıt değişkeni üzerinde istatistiksel olarak anlamlı bir fark olduğunu göstermektedir. İki grup arasındaki tahmin edilen fark 0.146 olarak belirlenmiş, standart hata 0.0445, serbestlik derecesi 320, t-oranı 3.287 ve p-değeri 0.0142 olarak hesaplanmıştır. Bu sonuçlar, p-değerinin 0.05'ten daha düşük olması nedeniyle, iki grup arasında anlamlı bir farkın olduğunu kanıtlamaktadır.

Ayrıca, "ContrastMinus30-Age32.4769230769231" ve "ContrastMinus-Age70: 32.4769230769231" grupları arasında yapılan başka bir kontrast analizi daha bulunmaktadır. Bu analizde tahmin edilen fark 0.112, standart hata 0.0389, serbestlik derecesi 970, t-oranı 2.869 ve p-değeri 0.0482 olarak belirlenmiştir. Bu sonuçlar da bu iki grup arasında yanıt değişkeninin ortalama değerleri arasında istatistiksel olarak anlamlı bir fark olduğunu göstermektedir.



Şekil 4.32: Deney 1 Kontrast için Önemli İkili Karşılaştırmalar- Tahmini

Bu analizler, deneyin bulgularının, kontrast ve yaş faktörlerinin çoklu nesne takibinde önemli etkilere sahip olduğunu ve bu etkilerin gruplar arasında farklılık gösterdiğini ortaya koyduğunu göstermektedir. Özellikle, "Contrast-Age10:32.4769230769231" ile "ContrastMinus-Age70:32.4769230769231"

arasındaki önemli fark ve "ContrastMinus30-Age32.4769230769231" ile "ContrastMinus-Age70:32.4769230769231" arasındaki anlamlı fark, bu değişkenlerin deney sonuçları üzerindeki etkisinin önemini vurgulamaktadır (Şekil 4.32)

#### **4.4 Deney 2 Kontrastın Çoklu Nesne Takibi Üzerindeki Etkileri**

##### **4.4.1 Deney 2 Kontrast İçin Doğrusal Karma Modelinin Analiz Sonuçları**

###### **4.4.1.1 KMOY ile uygulanan doğrusal karma model (DKM)**

DKM aşağıdaki şekilde formüle edilir:

$$\text{Ortalama} \sim \text{mod\_type} + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.4)$$

Formül 4.4'de "Ortalama" değişkeni ortalama değeri temsil ederken, sabit etkiler mod\_type, Cinsiyet ve Yaş'tır. Rassal etki katılımcı değişkenidir ve katılımcılar arasındaki değişkenliği modellemektedir. Model, kısıtlanmış maksimum olabilirlik yöntemi (KMOY) kullanılarak uygulanmıştır.

Cinsiyeti ek bir sabit etki olarak dahil etmek, modelin açıklayıcı gücünü artırabilir ve katılımcıların cinsiyete bağlı olarak yanıt değişkenindeki potansiyel farklılıklara ilişkin içgörüler sağlayabilir.

###### **4.4.1.2 Yakınsama için KMOY kriteri**

KMOY kriterini, artıkların dağılımını incelemek, sabit ve rassal etkileri değerlendirmek ve model varsayımlarını değerlendirmek gibi diğer model tanı araçlarıyla birlikte kullanmak önerilir (Gelman & Hill, 2007). Bu araçları birlikte kullanarak, modelin sonuçlarına daha fazla güvenebilirsiniz.

Modelde t-testleri için Satterthwaite yöntemi kullanılmıştır. Bu yöntem, verilerin eşit olmayan varyanslara ve örnekleme büyüklüklerine sahip olduğu durumlarda t-dağılımı için serbestlik derecelerinin bir yaklaşımını sağlar (Luke, 2017). Bu özellikle DKM'ler için geçerlidir, çünkü serbestlik derecesinin hesaplanması genellikle kolay değildir.

DKM'de, yakınsamada KMOY kriteri değeri 1752'dir. Daha düşük KMOY kriteri değerleri daha uygun modelleri gösterir ve genellikle iç içe geçmiş modelleri

veya farklı sabit ve rassal etki yapılarına sahip modelleri karşılaştırmak için kullanılabilir (Pinheiro & Bates, 2000).


#### 4.4.1.3 Ölçeklendirilmiş artıklar

Ölçeklendirilmiş Artıklar, DKM'nin uyumunu ve varsayımlarını değerlendirmek için önemli bir teşhis aracıdır.

**Çizelge 4.12:** Deneysel Kontrast için Ölçeklendirilmiş Artıklar

Min.	1. Çeyrek	Ortanca	3. Çeyrek	Mak.
-3.2599	-0.5884	0.0794	0.6969	2.5594

Ölçeklenmiş artıkların özet istatistikleri, artıkların dağılımı hakkında değerli bilgileri sağlar (Çizelge 4.12).



**Şekil 4.33:** Deneysel Kontrast için Artıklar ve Tahmin Edilen Değerler


Minimum ve maksimum değerler (-3.2599 ve 2.5594) verilerde potansiyel aykırı değerlerin varlığını gösterir. Bu değerler aşırı değilse de genellikle yaklaşık -2 ile 2 arasındaki tipik aralığın ötesindedir.

Birinci ve üçüncü çeyrek arasındaki fark (-0.5884 ile 0.6969), çoğu artığın ortanca değeri (0.0794) etrafında yoğunlaştığını gösterir ve bu değer sifıra yakındır. Bu genellikle normal dağılımlı artıkların varsayımıyla uyumludur, ancak bu

varsayımı doğrulamak için Shapiro-Wilk testi veya Kolmogorov-Smirnov testi gibi resmi testler yapılabilir veya grafiksel teşhisler yapılmalıdır (Gelman & Hill, 2007).

Sonuç olarak, ölçeklendirilmiş artıklar, DKM'nin uyumu ve varsayımlarının değerlendirilmesi için önemli bir teşhis aracıdır. Özet istatistikler, artıkların dağılımı hakkında bilgi sağlar. Aykırı değerler veya normal dağılımdan sapmalar gibi modellerle ilgili potansiyel sorunları tespit etmede yardımcı olur (Şekil 4.33).

Bu bulgular, modelin genel performansının iyi olduğunu, ancak belirli durumlarda hataların daha büyük olabileceğini göstermektedir. Bu nedenle, modelinizi geliştirmenin yollarını araştırmak faydalı olabilir. Bu, modelinizin hangi tür hatalar yaptığını anlamak için daha derin bir artık analizini içerebilir. Örneğin, belirli bir bağımsız değişkenin değerleri arttıkça hataların artıp artmadığını kontrol etmek isteyebilirsiniz (Şekil 4.34).



Şekil 4.34: Deney 2 Kontrast için Artıkların QQ plotu

#### 4.4.1.4 Rassal etkiler

DKM'de, rassal etkiler yanıt değişkenindeki katılımcılar arasındaki değişkenliği modellemek için kullanılır.

Bu durumda, rassal etki yapısı katılımcıyı rastgele bir kesişim noktası olarak belirler. Rassal etki tahminleri şöyledir: Modelde iki rassal etki bulunmaktadır: katılımcı için kesişim noktası ve artıklar. Katılımcı kesişim noktasının varyansı 0.2207 ve standart sapması 0.4698'dir. Artıkların varyansı 0.2615 ve standart

sapması 0.5113'tür. Rassal etki tahminleri aşağıdaki şekilde yorumlanabilir (Çizelge 4.13).

**Çizelge 4.13:** Deney 2 Kontrast için Rassal Etkiler


Grup	Ad	Varyans	Standart Sapma
Katılımcı	(Sabit)	0.2207	0.4698
Artık		0.2615	0.5113

Katılımcı rassal kesişim noktasının varyansı (0.2207), sabit etkiler (mod\_type, Cinsiyet ve Yaş) hesaba katıldıktan sonra katılımcılar arasındaki ortalama yanıt değişkenindeki değişkenliği temsil eder. Daha büyük bir varyans, katılımcılar arasındaki değişkenliğin daha fazla olduğunu gösterir; bu, sabit etkilerin yalnızca katılımcılar arasındaki yanıt değişkenindeki farklılıkları tam olarak açıklamadığını düşündürebilir. Bu bağlamda, katılımcı rassal kesişim noktasının dahil edilmesi bu değişkenliği açıklamaya yardımcı olur ve modelin açıklayıcı gücünü artırır (Gelman & Hill, 2007).

Artık varyans (0.2615), katılımcıların içindeki değişkenliği veya sabit etkilerin veya rassal kesişim noktasının açıklayamadığı yanıt değişkenindeki değişkenliği temsil eder. Bu tahmin, modelin uyumunu değerlendirmek ve gözlenen değişkenlikleri açıklamada sabit ve rassal etkilerin göreceli katkılarını karşılaştırmak için kullanılabilir (Pinheiro & Bates, 2000).

Katılımcı rassal kesişim noktasının (0.4698) ve artıkların (0.5113) standart sapmaları, ilgili varyansların karekökleridir. Bu değerler, katılımcılar arasındaki içindeki değişkenliğin büyüklüklerini karşılaştırmak ve rassal etki tahminlerini yanıt değişkeniyle aynı ölçekte yorumlamak için kullanılabilir (Gelman & Hill, 2007).

Sonuç olarak, DKM'deki rassal etki tahminleri yanıt değişkenindeki katılımcılar arasındaki değişkenlik hakkında değerli bilgiler sağlar. Modelin performansı ve geçerliliği hakkında kapsamlı bir anlayış elde etmek için rassal etki tahminlerini, sabit etki tahminleri ve diğer model teşhisleriyle birlikte değerlendirmek önemlidir (Şekil 4.35).



**Şekil 4.35:** Deneş 2 Kontrast için Rassal Etkilerin Histogramı

Modelde 1,024 gözlem ve 64 katılımcı grubu bulunmaktadır. Bu, verinin 64 farklı katılımcıdan toplanan 1,024 veri noktasından oluştuğunu gösterir.


Bu doğrusal karma modeli çıktısına dayanarak, aşağıdaki sonuçları çıkarabiliriz:

Eldeki veriler, katılımcılar arasında belirgin farklılıklar olduğunu gösteriyor. Varyans ve standart sapma değerleri, her bireyin kendine özgü bir başlangıç noktasına sahip olduğunu ve bu farklılıkların sonuçları etkilediğini vurguluyor.

Ancak, modelin açıklama gücü sınırlı görünüyor. "Artık" değerleri, modelin verinin önemli bir kısmını açıklayamadığını işaret ediyor. Bu, modelin bazı önemli etkenleri veya özellikleri gözden kaçırdığı anlamına gelebilir.

Sonuç olarak, model genel anlamda iyi performans gösterse de bazı durumlarda önemli hatalar yapabilir. Geliştirme için, daha fazla açıklayıcı değişken eklemek veya belirli durumları daha iyi modellemek faydalı olabilir. (Şekil 4.36).

Ayrıca, modelin güvenilirliği ve doğruluğu için, altında yatan varsayımların kontrol edilmesi kritik önem taşır. Özellikle, rassal etkilerin normal dağılım göstermesi ve birbirinden bağımsız olması gibi varsayımların doğrulanması gerekir. Bu varsayımların ihlal edilmesi, model tahminlerinin geçerliliğini zayıflatabilir.



**Şekil 4.36:** Deney 2 Kontrast için Rassal Etkilerin Yoğunluk Grafiği

#### 4.4.1.5 Sabit etkiler

Her bir sabit etki için tahminleri, standart hataları, serbestlik derecelerini, t-değerlerini ve p-değerlerini göstermektedir. Sonuç değişkeni üzerindeki p-değerlerini dikkate alarak ve tahminlerin büyüklüğünü ve yönünü inceleyerek sonuçları yorumlarız.

*mod\_type1/2-1 Hot:* p-değeri (0.387659), tipik 0.05 alfa düzeyinde istatistiksel olarak anlamlı değildir, bu da bu değişkenin sonuç değişkeni üzerinde anlamlı bir etkisi olmadığını göstermektedir.

*mod\_type1/2-1 Heterogen:* p-değeri (0.000865), istatistiksel olarak anlamlıdır, bu da bu değişkenin sonuç değişkeni üzerinde anlamlı bir etkisi olduğunu gösterir. -0.302083 tahmini negatif bir etkiyi göstermektedir.

*mod\_type1/2-1 Homogen:* p-değeri (3.97e-12), istatistiksel olarak anlamlıdır, bu da bu değişkenin sonuç değişkeni üzerinde anlamlı bir etkisi olduğunu gösterir. -0.635417 tahmini negatif bir etkiyi göstermektedir.

Diğer önemli bazı sonuçları hızlı bir şekilde incelersek;

- *mod\_type1/3-2/3-1 Hot:* Anlamlı ( $p < 0.05$ )
- *mod\_type1/3-2/3-1 Homogen:* Çok anlamlı ( $p < 0.001$ )

- mod\_type1/4-1/2-3/4-1 Hot: Anlamlı ( $p < 0.01$ )
- mod\_type1/4-1/2-3/4-1 Homogen: Çok anlamlı ( $p < 0.001$ )
- mod\_type1/4-1/2-3/4 Hot: Sınırdan anlamlı ( $p < 0.1$ )
- mod\_type1/4-1/2-3/4 Homogen: Çok anlamlı ( $p < 0.001$ )

Kalan mod\_type değişkenleri de sonuç değişkeni üzerinde farklı düzeylerde istatistiksel anlamlılık gösterir, bazıları anlamlı etkilere sahipken diğerleri sahip değildir. Her mod\_type değişkeninin tahminini ve p-değerini dikkate alarak etkilerini anlamak önemlidir.

GenderMale: p-değeri (0.245351), 0.05 alfa düzeyinde istatistiksel olarak anlamlı değildir, bu da sonuç değişkeninde erkek ve kadın katılımcılar arasında anlamlı bir fark olmadığını göstermektedir.

Yaş: p-değeri (0.041042), istatistiksel olarak anlamlıdır, bu da Yaş değişkeninin sonuç değişkeni üzerinde anlamlı bir etkisi olduğunu gösterir. -0.014094 tahmini negatif bir etkiyi gösterir, yani yaş arttıkça sonuç değişkeni azalır.

Sonuç olarak, modeldeki sabit etkiler, bağımsız değişkenler (mod\_type, Cinsiyet ve Yaş) ile sonuç değişkeni hakkında bilgi sağlar. Her sabit etkinin tahminlerini ve p-değerlerini dikkate almak, etkilerini anlamak için önemlidir.

#### 4.4.1.6 Sabit etkilerin katsayısı

Sabit etkilerin katsayıları, bir doğrusal karma modelinde önemlidir çünkü modelin sabit etkilerini belirlerler. Sabit etkiler, tüm denekler veya gruplar arasında sabit olan etkilerdir. Bu etkiler, deneklerin özellikleri veya deneysel koşullar nedeniyle değişmez.

Bununla birlikte, bir katsayının önemi sadece istatistiksel anlamlılığıyla sınırlı değildir. Katsayının büyüklüğü ve yönü de önemlidir çünkü bu, ilgili bağımsız değişkenin sonuç üzerindeki etkisini gösterir. Büyük bir katsayı, ilgili bağımsız değişkenin sonuç üzerinde büyük bir etkiye sahip olduğunu gösterirken, katsayının işareti, etkinin yönünü belirler (pozitif bir katsayı, bağımsız değişkenin sonucu artırdığını, negatif bir katsayı ise azalttığını gösterir).

Sonuç olarak, sabit etkilerin katsayıları hem modelin ne anlattığını anlamak için önemlidir, hem de hangi değişkenlerin sonuçları belirgin bir şekilde etkilediğini belirlemek için önemlidir (Çizelge 4.14).

**Çizelge 4.14:** Deney 2 Kontrast için Sabit Etkilerin Katsayıları

<b>Tahmin</b>	<b>Katsayı</b>
<b>Kesişim Noktası</b>	3.47796
<b>mod_type1/2-1 4Hot</b>	-0.07812
<b>mod_type1/2-1 Heterogen</b>	-0.30208
<b>mod_type1/2-1 Homogen</b>	-0.63542
<b>mod_type1/3-2/3-1 2Hot</b>	0.10938
<b>mod_type1/3-2/3-1 4Hot</b>	0.15625
<b>mod_type1/3-2/3-1 Heterogen</b>	-0.24479
<b>mod_type1/3-2/3-1 Homogen</b>	-0.37500
<b>mod_type1/4-1/2-3/4-1 2Hot</b>	0.15104
<b>mod_type1/4-1/2-3/4-1 4Hot</b>	-0.17187
<b>mod_type1/4-1/2-3/4-1 Heterogen</b>	-0.31771
<b>mod_type1/4-1/2-3/4-1 Homogen</b>	-0.59896
<b>mod_type1/4-1/2-3/4 2Hot</b>	0.17708
<b>mod_type1/4-1/2-3/4 4Hot</b>	-0.04167
<b>mod_type1/4-1/2-3/4 Heterogen</b>	-0.22396
<b>mod_type1/4-1/2-3/4 Homogen</b>	-0.57292
<b>GenderMale</b>	0.14300
<b>Yaş</b>	-0.01409

Sabit etki tahminleri şu şekilde yorumlanabilir:

Keşişim noktası (3.477959), referans grubu için tahmin edilen ortalama yanıtı temsil eder. Bu grup, Yaş ve referans mod\_type düzeyine sahip kadın katılımcılardan oluşur.


mod\_type tahminleri, her bir mod\_type düzeyi ile referans düzeyi arasındaki ortalama yanıt farklarını temsil eder

Örneğin, mod\_type1/2-1 4Hot (-0.078125) tahmini, Cinsiyet ve Yaş'a uyarlama yapıldıktan sonra, 1/2-1 4Hot düzeyinin ortalama yanıtının referans düzeyine göre 0.078125 birim daha düşük olduğunu gösterir. Bu tahminlerin anlamlılığı (p-değerleri tarafından belirtilir), bazı mod\_type düzeylerinin sonuç değişkeni üzerinde anlamlı bir etkiye sahip olduğunu, bazılarının ise olmadığını gösterir.


GenderMale tahmini (0.143001), mod\_type ve Yaş'a uyarlama yapıldıktan sonra erkek ve kadın katılımcılar arasındaki ortalama yanıt farkını temsil eder. Bu tahmin istatistiksel olarak anlamlı değildir (p = 0.245351), bu da diğer sabit etkilere uyarlama yapıldıktan sonra erkek ve kadın katılımcılar arasında ortalama yanıtta anlamlı bir fark olduğuna dair kanıt olmadığını gösterir.

Yaş tahmini (-0.014094), mod\_type ve Cinsiyet'e uyarlama yapıldıktan sonra Yaş'ta meydana gelen bir birimlik artışın ortalama yanıtındaki değişimini temsil eder. Bu tahmin istatistiksel olarak anlamlıdır (p = 0.041042) ve diğer sabit etkilere uyarlama yapıldıktan sonra Yaş ile yanıt değişkeni arasında negatif bir ilişki olduğuna dair kanıt sağlar.


Sabit etki tahminleri, yanıt değişkeni üzerindeki etkilerini anlamak için önemli bilgiler sunar. Bu tahminler, rassal etki tahminleri ve diğer model teşhisleriyle birlikte ele alındığında, modelin performansı ve geçerliliği hakkında kapsamlı bir değerlendirme imkânı sağlar. Değişkenlerin etkilerini görmek için aşağıdaki şekillerde açıklanmıştır (Şekil 4.37, Şekil 4.38, Şekil 4.39, Şekil 4.40, Şekil 4.41, Şekil 4.42).




Şekil 4.37: Deneysel Kontrast için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl (mod\_type/Cinsiyet)




Şekil 4.38: Deneysel Kontrast için Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)




**Şekil 4.39:** Dene 2 Kontrast için Ortalama Doğru Tıklamaların Yoğunluğu (mod\_type/Cinsiyet)



**Şekil 4.40:** Dene 2 Kontrast için mod\_type'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



Şekil 4.41: Deneysel Kontrast için Yaş'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



Şekil 4.42: Deneysel Kontrast için Çoklu nesne izleme performansının mod\_type'a göre grafiği (Cinsiyet)

#### 4.4.2 Kontrast düzeyleri için deney sonrası yapılan test(Post-Hoc)

Sağlanan veriler, farklı yaş ve cinsiyet grupları arasında çeşitli karşılaştırmaları temsil etmektedir, özellikle "Hot" ve "Homogen" kategorilerine odaklanılmaktadır. Genel olarak, bir sonuç anlamlı kabul edilirse p değeri 0.05'in altında olur. Bu durumda, birçok karşılaştırma için p değerleri 0.05'ten küçük olduğundan, gruplar arasında anlamlı farklar olduğunu göstermektedir.

Sonradan Yapılan Test, çalışmada farklı konu kategorileri arasındaki çeşitli karşılaştırmaları sunmaktadır. Kategoriler, farklı cinsiyet kombinasyonları (Kadın ve Erkek), modalite düzeyleri (2Hot, 4Hot) homojenlik ve heterojenlik bakımından ve yaş (31.59375 yaşında) ile ayrılır.

Dikkate değer bazı sonuçlar şunları içerir:


“2Hot Female” ve “Homogen Female” arasında anlamlı bir fark ( $p$  değeri  $< 0.0001$ ) vardır ve tahmin edilen ortalama fark 0.750'dir.

“1/2-1 2Hot Male” ve “1/2-1 Homogen Male” arasında anlamlı bir fark ( $p < 0.05$ ) bulunur ve tahmin edilen ortalama fark 0.635'tir.

“1/3-2/3-1 2Hot Male” ve “1/3-2/3-1 Homogen Male” arasındaki karşılaştırma da anlamlı bir fark ( $p < 0.0001$ ) ortaya koymaktadır ve tahmin edilen ortalama fark 0.484'tür.

"4Hot Female" ve "Homogen Female" popülasyonları arasındaki karşılaştırma da anlamlı bir farklılık gösterir ( $p$  değeri  $< 0.0001$ ).

“Homogen Female” popülasyonu ve “2Hot Male” popülasyonu arasındaki bazı karşılaştırmalar, örneğin "1/2-1 Homogen Female" ile "1/3-2/3-1 2Hot Male" arasındaki karşılaştırma anlamlı farklılıklar gösterir ( $p$  değeri  $< 0.0001$ ).



**Şekil 4.43:** Deney 2 Kontrast için Önemli İkili Karşılaştırmalar- Tahmini

Bu sonuçlar, çeşitli "Hot" ve "Homogen" kadın popülasyonları arasında anlamlı farklılıklar olduğunu ve bazı durumlarda bu kadın gruplarının belirli erkek gruplarıyla karşılaştırıldığında da farklılıklar olduğunu göstermektedir (Şekil 4.43).

Genel olarak, kategoriler arasında çeşitli karşılaştırmalar arasında anlamlı farklılıklar olduğunu gösterir. Bu sonuçları yorumlarken çalışmanın bağlamını, hedeflerini, altta yatan varsayımları ve potansiyel karıştırıcı faktörleri dikkate almak önemlidir. Bu durum, incelenen modalite düzeylerinin, cinsiyetin ve homojenlik/heterojenlik durumunun etkisi olabileceğini düşündürmektedir. Bu bilgi, gelecekteki araştırmaları, müdahale stratejilerini ve çoklu nesne takibi ve bilişsel performansla ilgili eğitim programlarını yönlendirmeye yardımcı olabilir.

#### **4.5 Deney 1 Parlaklığın Çoklu Nesne Takibi Üzerindeki Etkileri**

##### **4.5.1 Deney 1 Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları**

###### **4.5.1.1 KMOY ile uygulanan doğrusal karma model (DKM)**

Doğrusal karma modeller (DKM), hem sabit etkileri hem de rassal etkileri içeren doğrusal regresyon modellerinin bir genişlemesidir (Bates vd.,2015). Sabit etkiler, sonucun ilişkisini tanımlayan popülasyon düzeyindeki parametreleri temsil ederken, rassal etkiler özneye özgü varyasyonları hesaba katar (Gelman ve Hill, 2007). DKM'ler, kümelendirilmiş veya hiyerarşik veri yapılarından kaynaklanabilen korelasyonları ve eş varyanslılığı hesaba katar.

Maksimum olabilirlik (MOY) tahmininden farklı olarak, KMOY sabit etkilerin tahmininde kullanılan serbestlik derecesini hesaba katarak varyans bileşenleri tahminlerindeki aşağı yönlü yanlılığı düzeltir.

Verilen DKM formülü

$$\text{Ortalama} \sim \text{mod\_type} + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.5)$$

Formül 4.5'de sonucun "Ortalama" değeri tahmin edilirken üç sabit etkiyi (mod\_type, Cinsiyet ve Yaş) ve bir rassal etkiyi (Katılımcı) içerir. Bu model, katılımcılar arasındaki gözlemler arasındaki olası korelasyonları, bir rastgele ara terimi (1 | Katılımcı) ekleyerek hesaba katar.

Model uyarlandıktan sonra, modelin uygunluğunu değerlendirmek ve DKM'nin temel varsayımlarını değerlendirmek için çeşitli istatistikler ve tanısal

grafikler kullanılabilir. Örneğin, Akaike Bilgi Kriteri (AIC) ve Bayesian Bilgi Kriteri (BIC), daha düşük değerlerin daha iyi model uyumunu gösterdiği model karşılaştırmaları için kullanılabilir (Burnham ve Anderson, 2004). Ayrıca, artık grafikleri ve normal olasılık grafikleri, normal dağılım ve eş varyanslılık varsayımlarını değerlendirmek için kullanılabilir.

Model değerlendirildikten sonra, tahmin edilen sabit etkiler ve bunlara karşılık gelen standart hatalar, t-değerleri ve p-değerleriyle sonucun ilişkisi hakkında çıkarımlar yapılabilir. Bu çıkarımlar, mod\_type, Cinsiyet ve Yaş etkilerinin ortalamayı etkileme şeklini anlamak için yardımcı olabilir ve katılımcılardan kaynaklanan değişkenliği hesaba katabilir.

#### 4.5.1.2 Yakınsama için KMOY kriteri

KMOY kriteri, tahmin edilen parametre sayısına bağlı olarak modele ceza uygulayan bir model uyum ölçüsüdür. Daha düşük KMOY değerleri, modele daha iyi uyum göstermektedir. Bu durumda, yakınsama için KMOY kriteri 1266,7 'dir, bu da veriye iyi uyum sağlandığının ölçüsüdür.

#### 4.5.1.3 Ölçeklendirilmiş artıklar

Deney 1'in parlaklık ölçümleri için ölçeklendirilmiş artıkların özet istatistikleri, model uyumu ve potansiyel aykırı değerler hakkında önemli bilgiler sunar. Ölçeklendirilmiş artıklar, gözlemlenen veriler ile modelden tahmin edilen değerler arasındaki farkların standart hatalara oranı olarak hesaplanır, bu da modelin performansının ve varsayımlarının değerlendirilmesinde kritik bir rol oynar (Gelman ve Hill, 2006; Bates vd., 2015).

Ölçeklendirilmiş artıkların ideal dağılımı, ortalama değerinin 0'a ve standart sapmasının 1'e yakın olması beklenen normal bir dağılımı takip etmelidir. Verilen özet istatistikler aşağıdaki gibi belirlenmiştir:

- Minimum Değer (-3.2786): Bu, ölçülen artıklar arasındaki en düşük değeri temsil eder ve veri setindeki potansiyel aykırı değerlerin varlığını gösterir.
- 1.Çeyreklik (-0.5950): Veri değerlerinin %25'i bu değerden daha düşüktür, bu da artıkların çeyreğinin -0.5950 değerinden daha az olduğunu gösterir.

- Ortanca (0.0604): Artıkların yarısının bu değerden daha düşük, yarısının ise bu değerden daha yüksek olduğu noktadır. Ortancanın 0'a yakın olması modelin genel uyumunun iyi olduğunu gösterir.
- 3.Çeyreklik (0.6084): Veri değerlerinin %75'i bu değerden daha düşüktür, bu da artıkların çoğunun 0.6084 değerinden daha az olduğunu gösterir.
- Maksimum Değer (3.1363): Ölçülen artıklar arasındaki en yüksek değeri temsil eder ve bu da veri setindeki başka bir potansiyel aykırı değeri işaret edebilir.


Bu özet istatistikler, ölçeklendirilmiş artıkların dağılımının ideal bir normal dağılıma tam olarak uymadığını göstermektedir. Ortancanın 0.0604 olması modelin genel olarak iyi bir uyuma sahip olduğunu gösterse de minimum ve maksimum değerlerin -3 ve +3 aralığında olması ve 1. çeyreklik ile 3. çeyreklik değerlerinin simetrik olmaması, verilerin hafif bir çarpıklığa sahip olabileceğini düşündürmektedir. Bu durum, modelin belirli özellikleri veya bazı aykırı değerleri yeterince iyi yakalayamamış olabileceğine işaret eder ve modelin daha detaylı incelenmesi veya ayarlanması gerekebileceğini gösterir(Çizelge 4.15).

**Çizelge 4.15:** Deney 1 Parlaklık için Ölçeklendirilmiş Artıklar

Min.	1. Çeyrek	Ortanca	3. Çeyrek	Mak.
-3.2786	-0.5950	0.0604	0.6084	3.1363


Bu durumda, modelin belirli bir örüntüyü veya anomalileri kaçırmış olabileceğini gösterir. Bu nedenle, modelinizi yeniden değerlendirmeniz ve gerekirse daha fazla ayarlama yapılması faydalı olabilir.

Sonuç olarak, ölçeklendirilmiş artıkların dağılımı, regresyon modelinin verilerin belirli bir kısmını tam olarak yakalamadığını gösteriyor. Artıkların ideal dağılımının normal (Gauss) dağılımı olması beklenir. Bu, modelinizin bazı düşük değerli gözlemleri aşırı tahmin etme eğiliminde olabileceğini gösterir (Şekil 4.44)



**Şekil 4.44:** Deney 1 Parlaklık için Artıklar ve Tahmin Edilen Değerler

Ayrıca, artıkların çeyreklik aralığı da (1Ç-3Ç) aralığındaki genişlik ise verilerinizin içinde önemli miktarda değişkenlik olduğunu gösterir.



**Şekil 4.45:** Deney 1 Parlaklık için Artıkların QQ plotu

Bir histogram veya QQ grafiği gibi artıkların görsel olarak incelenmesi, normal dağılımdan sapmaları veya sabit olmayan varyansı ortaya çıkarır (Gelman ve Hill, 2006). Bu varsayımların ihlal edildiği durumlarda, geçerli çıkarımların sağlanabilmesi için veri dönüşümleri veya alternatif model özellikleri gerekebilir.

QQ grafiğini incelediğimizde bazı sapmalar olsa da teorik normal dağılım ile gözlenen değerler arasında uyum görülmektedir (Şekil 4.45).

Ölçeklenmiş artıklar, doğrusal karma modellerde model teşhisi ve değerlendirmede önemli bir rol oynar. Verilen özet istatistikler, genel model uyumu, potansiyel aykırı değerler ve normal dağılım ve eş varyanslılık varsayımları hakkında bilgi sağlar. Diğer teşhis araçlarıyla birlikte ölçeklenmiş artıkların kapsamlı bir şekilde incelenmesi, model performansını artırmaya ve geçerli istatistiksel çıkarımlar sağlamaya yardımcı olabilir.

#### 4.5.1.4 Rassal etkiler

Deney 1'in parlaklık ölçümleri için yapılan rassal etkiler analizi, doğrusal karma modellerin grup içi bağımsızlığı ve değişkenliği, örneğin katılımcılar gibi gruplar arasında, dikkate alınmanın önemini vurgular.

Rassal etkilerin özeti iki ana varyans bileşenini içerir:


1. *Katılımcılar için Rassal Ara Kesitlerin Varyansı (0.2900)*: Farklı katılımcıların kesişim noktaları arasındaki değişkenliği ifade eder. Standart sapma (0.5385), katılımcılar arasındaki başlangıç değerlerinde orta düzeyde bir değişkenliği gösterir. Bu, bireysel farklılıkların ve bunların yanıt değişkenine olan potansiyel etkilerinin modelde önemli bir rol oynadığını gösterir (Bates et al., 2015).
2. *Artıkların Varyansı (0.1557)*: Model tarafından açıklanamayan varyansı temsil eder, yani model tahminleri ile gerçek değerler arasındaki farkları gösterir. Standart sapma (0.3946), artıkların yayılımını gösterir ve modelin verileri ne kadar iyi yakaladığını anlamamıza yardımcı olur.

Bu varyans bileşenleri ve standart sapma değerleri, modelin genel uyumuna ve verilerin model tarafından ne kadar iyi temsil edildiğine dair önemli bilgiler sunar. Katılımcıların rassal ara kesitlerinin varyansı, bireysel katılımcıların modelde önemli bir rol oynadığını ve farklı başlangıç noktalarına sahip olduklarını gösterirken, artıkların varyansı, modelin veri setini ne kadar iyi yakaladığını ve kalan değişkenliğin boyutunu ortaya koyar (Bates vd., 2015).

**Çizelge 4.16:** Deney 1 Parlaklık için Rassal Etkiler

Grup	İsim	Varyans	Standart Sapma
Katılımcı	(Sabit)	0.2900	0.5385
Artık		0.1557	0.3946

Ancak katılımcılar arasındaki değişkenliği daha da anlamak ve modelin tahminlerini iyileştirebilmek için modelin daha detaylı incelenmesi gerekebilir. Bu tür bir analiz, veri setinin karmaşıklığını ve hiyerarşik yapısını dikkate alan daha kapsamlı bir modelleme yaklaşımının önemini vurgular (Gelman & Hill, 2006; Bates vd., 2015) (Çizelge 4.16).




**Şekil 4.46:** Deney 1 Parlaklık için Rassal Etkilerin Histogramı

Rassal etkilerin anlaşılması, doğrusal karma modellerde geçerli istatistiksel çıkarımlar yapmak için önemlidir.

Rassal ara kesit varyansı tarafından belirtilen katılımcılar arasındaki anlamlı değişkenlik, sabit etkilerin ve standart hataların önyargısız tahminlerini elde etmek

için bu deęişkenlięi hesaba katmanın önemli olduęunu gösterir (Gelman ve Hill, 2006). Ayrıca, toplam varyansın gruplama yapısına atfedilebilen kısmını hesaplamak için toplam varyansı gruplar arasındaki ve içerisindeki bileşenlere bölmek, ara kümülatif korelasyon katsayılarını (AKKK) hesaplamak ve sonuçların yorumlanmasını ve genelleştirilebilirliğini deęerlendirmek için arařtırmacılara olanak tanır (Bates vd., 2015).

Rassal etkiler, doğrusal karma modellerde, özellikle gruplar arasındaki deęişkenlięi yakalayarak ve geçerli istatistiksel çıkarımlar sağlayarak kritik bir rol oynar. Sunulan rassal etkilerin özeti, gruplar arasındaki ve içerisindeki katılımcı deęişkenlięi hakkında bilgi sağlar ve model seçimi, yorumlanması ve sonuçların genelleştirilebilirlięi konularında bilgi sunabilir (Şekil 4.46).



**Şekil 4.47:** Deney 1 Parlaklık için Rassal Etkilerin Yoęunluk Grafięi

Sonuç olarak, "Katılımcı" olarak adlandırılan grup üzerinde önemli bir rassal etki gözlemlemektedir. Bu, farklı katılımcıların eğilimlerinde önemli miktarda varyans olduęunu gösterir. Yani, katılımcıların yanıtları modelin sonuçları üzerinde önemli bir etkiye sahiptir.

Bunun yanı sıra, artıkların düşük bir varyansa sahip olması, modelin tahminlerinin genellikle gözlenen deęerlere oldukça yakın olduęunu gösterir. Bu da modelinizin genel olarak iyi bir uyum sağladığını gösterir (Şekil 4.47).

#### 4.5.1.5 Sabit etkiler

Doğrusal karma modellerde (DKM) sabit etkiler, modeldeki değişkenlerin yanıt değişkeni üzerindeki ortalama etkisini temsil eder. Bu etkiler, rassal etkiler hesaba katıldıktan sonra, yani gruplar veya kümeler içindeki gözlemlerin bağımsız olmayışı dikkate alındıktan sonra elde edilir. Sabit etkiler, doğrusal regresyon modellerindeki katsayılar gibi yorumlanabilir, ancak DKM'ler sabit ve rassal etkileri aynı anda tahmin ederek daha karmaşık veri yapılarını modelleme yeteneğine sahiptir (Bates vd., 2015; Gelman & Hill, 2006).

Deney 1'in parlaklık ölçümleri için sabit etkilerin özeti aşağıdaki gibidir:

Bu tabloda, 'Yaş' değişkeninin yanıt değişkeni üzerinde istatistiksel olarak anlamlı negatif bir etkisi olduğu görülür ( $p = 0.00656$ ), yani yaş arttıkça yanıt değişkeninde bir azalma beklenir. 'GenderMale' değişkeninin etkisi ise istatistiksel olarak anlamlı değildir ( $p = 0.14441$ ), bu da cinsiyetin bu bağlamda ortalama yanıt üzerinde belirgin bir etkisi olmadığını gösterir.

**Çizelge 4.17: Deney 1 Parlaklık için Sabit Etkiler**

Sabit	Tahmin	Standart Hata	Serbestlik Derecesi	t-değeri	p-değeri
<b>Kesişim Noktası</b>	3.483	0.241	137.2	14.433	< 0.001
<b>Bright-10</b>	0.04282	0.05651	970.7	0.758	0.44880
<b>Bright-50</b>	0.03	0.05651	970.7	0.531	0.59564
<b>Bright-90</b>	0.01333	0.05651	970.7	0.236	0.81353
<b>BrightMinus30</b>	0.0005128	0.05651	970.7	0.009	0.99276
<b>BrightMinus70</b>	-0.06615	0.05651	970.7	-1.171	0.24204
<b>GenderMale</b>	0.2028	0.1371	61.64	1.478	0.14441
<b>Yaş</b>	-0.01803	0.006542	152.3	-2.757	0.00656

Mod\_type deęişkenlerine gelince, hibiri istatistiksel olarak anlamlı bir etki göstermemiştir. Örneęin, BrightMinus70' deęişkeninin etkisi ( $p = 0.24204$ ) istatistiksel olarak anlamlı deęildir, bu da bu koşulun referans grubuna kıyasla yanıt deęişkeni üzerinde anlamlı bir etkisi olmadığını gösterir.

Bu sonuçlar, yaşın yanıt deęişkeni üzerinde önemli bir etkiye sahip olduğunu ve cinsiyetin yanı sıra dięer mod\_type koşullarının etkilerinin daha belirsiz olduğunu göstermektedir. Sabit etkilerin analizi, yanıt deęişkeni üzerindeki ortalama etkileri anlamamızı sağlar ve bu durumda yaşın önemli bir faktör olduğunu gösterirken, cinsiyetin ve dięer koşulların etkileri üzerine daha fazla araştırma yapılması gerektiğini göstermektedir (Çizelge 4.17).

#### 4.5.1.6 Sabit etkilerin korelasyonu

Sabit etkilerin korelasyon analizi, doğrusal karma modeldeki sabit etkiler arasındaki ilişkiler hakkında önemli bilgiler sunar. Bu analiz, sabit etkiler arasındaki korelasyonlar arasındaki doğrusal ilişkileri inceler ve çoklu doğrusallık gibi potansiyel sorunları belirlememize yardımcı olabilir. Çoklu doğrusallık, iki veya daha fazla sabit etkiler arasında yüksek korelasyon olduğunda ortaya çıkar ve bu modelin tahmin yeteneğini olumsuz etkileyebilir.

Çizelge 4.18'de sunulan korelasyon matrisi, modele dahil edilen sabit etkiler arasındaki korelasyonları göstermektedir. Bu matris, korelasyon katsayılarını (-1 ile 1 arasında) içerir ve bu katsayılar, ilgili sabit etki çiftleri arasındaki doğrusal ilişkinin gücünü ve yönünü gösterir.

Bu matriste, çoęu sabit etkilerin düşük korelasyonlara (0'a yakın) sahip olduğu görülmektedir, bu da çoklu doğrusallığın bu modelde önemli bir sorun olmadığını gösterir. Ancak, kesişim noktası ile Yaş deęişkeni arasında -0.895 gibi oldukça yüksek bir negatif korelasyon gözlenmiştir. Bu, bu iki deęişken arasında güçlü bir negatif ilişki olduğunu gösterir.

Bright-10, Bright-50, Bright-90, BrightMinus30 ve BrightMinus70 deęişkenleri arasında 0.750 gibi yüksek korelasyonlar gözlenmektedir, bu da bu tahmin edici deęişkenlerin birbirleriyle güçlü pozitif ilişkiler içerdiğini gösterir. Ancak, bu tahmin edici deęişkenlerin hepsi mod\_type kategorisine ait olduğu için, bu yüksek korelasyonlar beklenen bir durumdur ve genellikle bu tür kategorik deęişkenlerin modeldeki etkilerini değerlendirirken sorun oluşturmaz.


Sonuç olarak, korelasyon matrisi analizi, modelde çoklu doğrusallığın önemli bir sorun oluşturmadığını gösterirken, Yaş ve kesişim noktası arasındaki yüksek negatif korelasyon görülmektedir. Yüksek korelasyon, genellikle sabit etkilerin korelasyonları arasında bir endişe kaynağıdır, ancak kesişim noktası ile diğer tahmin edici değişkenler arasındaki korelasyon genellikle büyük bir sorun teşkil etmez, çünkü bu genellikle sabit etkilerin ve yanıt değişkeninin genel ortalaması arasındaki ilişkiyi yansıtır.

Bu analiz, modelin daha detaylı incelenmesi ve potansiyel olarak ilginç ilişkilerin daha fazla araştırılması için bir temel sağlar.


**Çizelge 4.18:** Deney 1 Parlaklık için Sabit Etkilerin Korelasyonu

	Kesişim Noktası	Bright- 10	Bright- 50	Bright- 90	Bright Minus 30	Bright Minus 70	Gender Male	Yaş
<b>Bright-10</b>	-0.176							
<b>Bright-50</b>	-0.176	0.750						
<b>Bright-90</b>	-0.176	0.750	0.750					
<b>BrightMinus 30</b>	-0.176	0.750	0.750	0.750				
<b>BrightMinus 70</b>	-0.176	0.750	0.750	0.750	0.750			
<b>GenderMale</b>	-0.223	0.000	0.000	0.000	0.000	0.000		
<b>Yaş</b>	-0.895	0.000	0.000	0.000	0.000	0.000	-0.066	

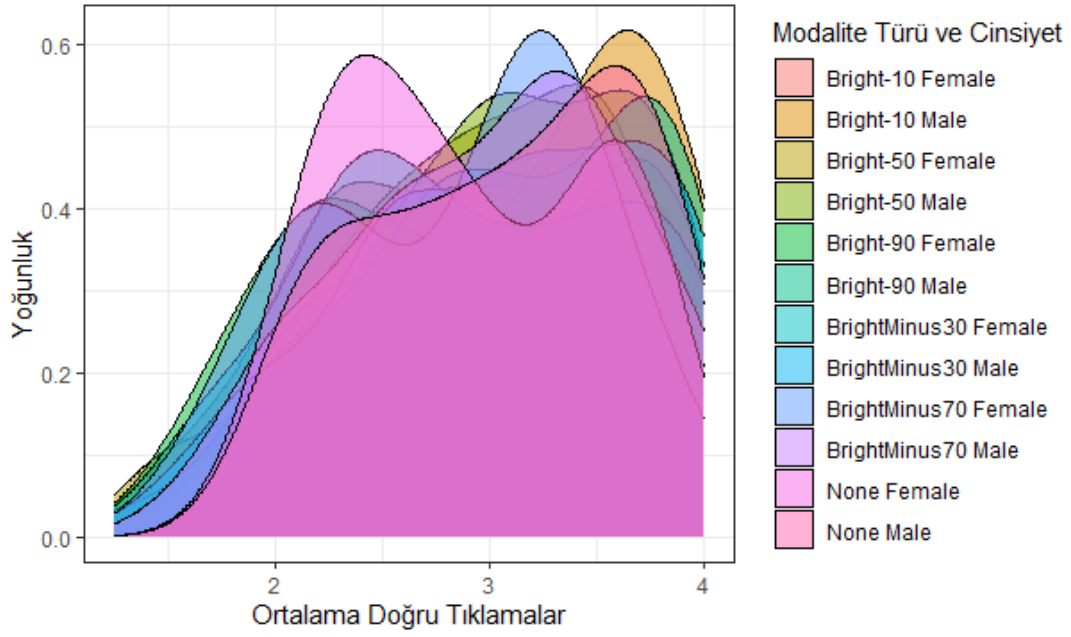
Aşağıda değişik parametrelerin etkilerinin şekilleri aşağıda sunulmuştur (Şekil 4.48, Şekil 49, Şekil 4.50, Şekil 4.51, Şekil 4.52, Şekil 4.53).




Şekil 4.48: Deney 1 Parlaklık için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl(mod\_type/Cinsiyet)




Şekil 4.49: Deney 1 Parlaklık için Ortalama Doğru Tıklamalar(mod\_type/Cinsiyet)



Şekil 4.50: Deney 1 Parlaklık için Ortalama Doğru Tıklamaların Yoğunluğu (mod\_type/Cinsiyet)



Şekil 4.51: Deney 1 Parlaklık için Yaş'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)




**Şekil 4.52:** Deney 1 Parlaklık için Çoklu nesne izleme performansının mod\_type'a göre grafiği (Cinsiyet)

#### 4.5.2 Parlaklık düzeyleri için deney 1 sonrası yapılan test (Post-Hoc)

Bu analiz, belirli bir yaş grubu (yaklaşık 33.65 yaş) için kadın ve erkek katılımcılar arasındaki farklı parlaklık seviyelerinin karşılaştırılmasına odaklanmaktadır. Karşılaştırmalar, parlaklık seviyelerinin yanı sıra cinsiyet farklarını da içermekte ve her bir karşılaştırma için tahmini değerler, standart hata (SH), serbestlik derecesi (SD), t-oranı ve p-değerleri sunulmaktadır.

Bu analizde, çoğu karşılaştırmanın p değerleri 0.05'in üzerindedir, bu da bu gruplar arasında istatistiksel olarak anlamlı bir fark olmadığını gösterir. Örneğin, "Bright-10 Female Age33.6461538461538-BrightMinus70 Female Age33.6461538461538" karşılaştırmasında tahmini fark 0.108974, ancak p değeri 0.2145'tir, bu da farkın istatistiksel olarak anlamlı olmadığını gösterir. Benzer şekilde, diğer karşılaştırmalar da genellikle yüksek p değerleri göstermektedir, bu da gözlemlenen farkların çoğunun istatistiksel olarak anlamlı olmadığını düşündürmektedir.

Başka bir örnek daha vermek gerekirse "BrightMinus30 Female Age33.6461538461538 - BrightMinus70 Female Age33.6461538461538" karşılaştırmasında tahmini fark 0.066667 ve p değeri 0.8822 olarak gözlemlenmiştir, bu da bu özel karşılaştırmada da anlamlı bir fark olmadığını gösterir.



**Şekil 4.53:** Deney 1 Parlaklık için Önemli İkili Karşılaştırmalar- Tahmini

Sonuç olarak, bu yaş grubunda kadın ve erkekler arasında veya parlaklık seviyeleri arasında genel olarak istatistiksel olarak anlamlı bir fark bulunmamaktadır. Bu sonuçlar, parlaklık seviyelerinin veya cinsiyetin, bu özel yaş grubundaki yanıt değişkeni üzerinde önemli bir etkiye sahip olmadığını göstermektedir. Ancak, bu sonuçlar gelecekteki araştırmalar için bir temel oluşturabilir ve yanıt değişkenini etkileyebilecek diğer potansiyel faktörlerin daha ayrıntılı incelenmesini gerektirebilir (Şekil 4.53) (Yazgan, Yağımlı & Ozubko, 2023).

#### 4.6 Deney 2 Parlaklığın Çoklu Nesne Takibi Üzerindeki Etkileri

##### 4.6.1 Deney 2 Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları

###### 4.6.1.1 KMOY ile uygulanan doğrusal karma model (DKM)

Bu analizde, DKM aşağıdaki formül kullanılarak uygulandı:

$$\text{Ortalama} \sim \text{mod\_type} + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.6)$$

Formül 4.6'da Yanıt değişkeni (Ortalama), mod\_type, Cinsiyet ve Yaş olmak üzere üç sabit etkinin bir fonksiyonu olarak modellendi. Ayrıca, her katılımcı için rastgele bir kesişim noktası da dahil edildi, bu da katılımcılar arasındaki değişkenliği hesaba kattı.

#### 4.6.1.2 Yakınsama için KMOY kriteri

Yakınsama, tekrarlayan tahmin sürecinin istikrarlı hale gelmesi ve model parametrelerinin güvenilir tahminlerini sağlaması anlamına gelir. Bu süreç, sonuçlanan modelin geçerliliği ve istikrarı için kritik öneme sahiptir.

Özetle:

- Yakınsamada KMOY kriteri: Kısıtlanmış Maksimum Olabilirlik Yöntemi (KMOY) kriterinin yakınsamadaki değerini gösterir. Bu durumda, değer 1668.3'tür.
- Model yakınsaması: Model yakınsadı, yani rassal etkilerin tahmini başarılı oldu.

#### 4.6.1.3 Ölçeklendirilmiş artıklar

Ölçeklenmiş artıklar, gözlenen değerler ile modelin tahmin edilen değerleri arasındaki farkları, artıkların tahmini standart sapmasıyla standartlaştırılmış olarak ifade eder (Pinheiro & Bates, 2000). Bunlar, doğrusal karma modelinin uyumunu teşhis etmek, potansiyel aykırı değerleri tespit etmek ve modelin varsayımlarını değerlendirmek için gereklidir. Bu, modelin standartlaştırılmış artıklarıdır. Artıkların dağılımı, minimum, 1. çeyrek (1Ç), ortanca, 3. çeyrek (3Ç) ve maksimum değerlerle özetlenir. Bu durumda, ölçeklenmiş artıklar -3.2209 ile 2.7341 arasında değişir. Ölçeklenmiş artıkların çoğu -0.6244 (1Ç) ile 0.6468 (3Ç) arasındadır. İdeal olarak, ölçeklenmiş artıklar sıfır etrafında simetrik olarak dağılır ve normal bir dağılımı takip eder. Ortanca değeri (0.0905) sıfıra yakın olması, modelin tahminlerinin genellikle tarafsız olduğunu gösterir (Ruppert vd.,2003). Ancak, ölçeklenmiş artıkların minimum ve maksimum değerleri (-3.2209 ve 2.7341 sırasıyla), verilerde potansiyel aykırı değerlerin varlığını gösterir (Çizelge 4.19)

Bu aşırı değerler, modelin uyumunda sorunlara veya eş varyanslılık ve hata normalitesi gibi varsayımların ihlallerini işaret eder (Pinheiro & Bates, 2000).


Ölçeklenmiş artıkların dağılımını daha iyi anlamak ve potansiyel sorunları tespit etmek için, histogramlar, QQ grafikleri ve artıkların tahmin edilen değerlere karşı grafikleri gibi tanısal grafikler oluşturmak faydalıdır (Faraway, 2006) (Şekil 4.54).

**Çizelge 4.19:** Deney 2 Parlaklık için Ölçeklendirilmiş Artıklar

Min.	1. Çeyrek	Ortanca	3. Çeyrek	Mak.
-3.2209	-0.6244	0.0905	0.6468	2.7341


Bu grafikler, normal dağılımdan sapmaları, heteroskedastisiteyi ve diğer potansiyel sorunları belirlemeye yardımcı olabilir. Bu sorunlar, modeli iyileştirme veya verileri dönüştürme yoluyla ele alınması gereken sorunlar olabilir.

Sonuç olarak, ölçeklendirilmiş artıkların dağılımı genellikle regresyon modelinizin performansını gösterir. Bu durumda, ortancanın sıfıra oldukça yakın olduğunu gözlemliyoruz, bu genellikle modelin iyi bir uyum sağladığını gösterir (Şekil 4.54).



**Şekil 4.54:** Deney 2 Parlaklık için Artıklar ve Tahmin Edilen Değerler

Ancak, minimum ve maksimum değerlerin -3 ve +3'ün dışında olduğunu da görüyoruz. Bu, modelinizin bazı durumlarda aşırı tahminler yaptığını gösterir. Modelinizin genel performansı iyi gibi görünse de belirli durumlardaki aşırı tahminler modelin performansını ve tahmin güvenilirliğini etkileyebilir (Şekil 4.55).



**Şekil 4.55:** Deneysel Parlaklık için Artıkların QQ plotu

#### 4.6.1.4 Rassal etkiler

Rassal etkiler, doğrusal karma modelinde gözlenemeyen değişkenlerdir ve sabit etkiler tarafından açıklanmayan verilerdeki değişkenliği hesaba katar (Gelman & Hill, 2006). Bu analizde, rassal etkilerin yapısı her katılımcı için bir rassal kesişim noktası içermekte olup, modelin katılımcılar arasındaki değişkenliği yakalamasını sağlar. Bu bulgu, modelin tahminlerinin popülasyondaki tüm bireylerde eşit derecede geçerli olmayabileceği anlamına gelerek, çalışmanın sonuçlarının genellenebilirliği üzerinde etkisi olabilir.

Rassal kesişim noktası varyansı (0.2060), sabit etkiler (mod\_type, Cinsiyet ve Yaş) tarafından açıklanmayan katılımcılar arasındaki değişkenliği temsil etmektedir. Rassal kesişim noktasının standart sapması (0.4538), bireysel katılımcı kesişim noktalarının genel kesişim noktasından ortalama sapmasını ifade eder. Bu değer, modeldeki sabit etkiler tarafından hesaba katılmayan katılımcılar arasında önemli bir değişkenlik olduğunu gösterir.

Artık varyansı (0.2405), sabit ve rassal etkilerin her ikisini de hesaba kattıktan sonra kalan katılımcı içindeki değişkenliği temsil eder. Artıkların standart sapması (0.4904), gözlenen değerlerin modelin tahminlerinden ortalama sapmasını sabit ve rassal etkileri dikkate alarak ölçer (Çizelge 4.20).


Veri setindeki gözlem sayısı 1024'tür ve 64 benzersiz katılımcı bulunmaktadır.

**Çizelge 4.20:** Deney 2 Parlaklık için Rassal Etkiler

Grup	İsim	Varyans	Standart Sapma
Katılımcı	(Sabit)	0.2060	0.4538
Artık		0.2405	0.4904


Modelin sonuçlarını yorumlarken ve çıkarımlar yaparken rassal etkilerin dikkate alınması önemlidir (Gelman & Hill, 2006) (Şekil 4.56).

Varyans değeri, katılımcılar arasında daha düşük bir değişkenlik olduğunu gösterirken, standart sapma, bu değişkenliğin genel büyüklüğünü ifade eder.



**Şekil 4.56:** Deney 2 Parlaklık için Rassal Etkilerin Histogramı

Artıklar modelinizin tahminlerindeki standart hatadır. Bu değer, her bir gözlem için modelin tahminleri ile gerçek değerler arasındaki ortalama farkı ölçer.



**Şekil 4.57:** Deney 2 Parlaklık için Rassal Etkilerin Yoğunluk Grafiği

Bu sonuçlar, modelin katılımcılar arasındaki başlangıç değerlerinde (kesişim noktaları) önemli bir varyasyon olduğunu gösteriyor. Ancak, bu varyasyon, genel model tahmin hatası (artık) ile karşılaştırıldığında daha düşüktür. Bu, modelin farklı katılımcıların eğilimlerini büyük ölçüde yakalayabildiğini, ancak hala tahminlerinde bazı hatalar olduğunu gösterir (Şekil 4.57). Bu hatalar, modelinizin belirli bir gözlemi tahmin etme yeteneği üzerinde önemli bir etkiye sahip olabilir ve modelin genel performansını ve doğruluğunu etkileyebilir.

Modelinizi daha da geliştirmek için, daha fazla açıklayıcı değişken eklemeyi, hiperparametrelerle oynamayı veya modelinizin hangi yönlerinin daha fazla hata ürettiğini belirlemek için daha ayrıntılı bir analiz yapma düşünülebilir. Modelin hatalarını azaltmak için bu bilgileri kullanabiliriz.

#### **4.6.1.5 Sabit etkiler**

Sabit etki analizi, `mod_type`, Cinsiyet ve Yaş gibi değişkenlerin sonuç üzerinde farklı etkilere sahip olduğunu göstermektedir. Anlamlı sabit etkiler, bu değişkenlerin veri üzerindeki değişkenliği açıklamada önemli bir rol oynadığını göstermektedir. Ancak sonuçları yorumlarken ve modelden çıkarımlar yaparken anlamsız etkilerin varlığı ve rassal etkilerin olası etkisi de dikkate alınmalıdır.

**Çizelge 4.21: Deney 2 Parlaklık için Sabit Etkiler**

Sabit	Tahmin	SH	SD	t-değeri	p-değeri
<b>Kesişim Noktası</b>	3.364675	0.260825	67.831379	12.900	< 2e-16
<b>mod_type1/2-1 4Hot</b>	-0.137153	0.086691	945.000002	-1.582	0.113963
<b>mod_type1/2-1 Heterogen</b>	-0.119792	0.086691	945.000002	-1.382	0.167351
<b>mod_type1/2-1 Homogen</b>	-0.439236	0.086691	945.000002	-5.067	4.87e-07
<b>mod_type1/3-2/3-1 2Hot</b>	0.145833	0.086691	945.000002	1.682	0.092855
<b>mod_type1/3-2/3-1 4Hot</b>	0.048611	0.086691	945.000002	0.561	0.575106
<b>mod_type1/3-2/3-1 Heterogen</b>	0.003472	0.086691	945.000002	0.040	0.968059
<b>mod_type1/3-2/3-1 Homogen</b>	-0.289931	0.086691	945.000002	-3.344	0.000857
<b>mod_type1/4-1/2-3/4-1 2Hot</b>	0.237847	0.086691	945.000002	2.744	0.006191
<b>mod_type1/4-1/2-3/4-1 4Hot</b>	-0.043403	0.086691	945.000002	-0.501	0.616725
<b>mod_type1/4-1/2-3/4-1 Heterogen</b>	-0.236111	0.086691	945.000002	-2.724	0.006576
<b>mod_type1/4-1/2-3/4-1 Homogen</b>	-0.472222	0.086691	945.000002	-5.447	6.53e-08
<b>mod_type1/4-1/2-3/4 2Hot</b>	0.256944	0.086691	945.000002	2.964	0.003114
<b>mod_type1/4-1/2-3/4 4Hot</b>	0.123264	0.086691	945.000002	1.422	0.155390
<b>mod_type1/4-1/2-3/4 Heterogen</b>	-0.090278	0.086691	945.000002	-1.041	0.297966
<b>mod_type1/4-1/2-3/4 Homogen</b>	-0.413194	0.086691	945.000002	4.766	2.17e-06
<b>GenderMale</b>	0.239567	0.117674	60.999995	2.036	0.046115
<b>Yaş</b>	-0.014156	0.007797	60.999994	-1.816	0.074347

Doğrusal karma modellerinden sonuçları yorumlarken sabit ve rassal etkileri birlikte dikkate etmek önemlidir.

Modeldeki sabit etkilerin tahmin edilen katsayıları, standart hataları, serbestlik dereceleri, t-değerleri ve p-değerlerini sağlamaktadır. İşte her bir sabit etki için bulguların özeti (Çizelge 4.21):

• *Kesişim noktası (3.364675)*: Referans grubu için tahmin edilen ortalama değeri temsil eder. Bu değer istatistiksel olarak anlamlıdır ( $p < 2e-16$ ) ve kesişim noktası sıfırdan farklıdır.

• *mod\_type değişkeni*: Sonucun üzerinde değişen etkilere sahiptir. "mod\_type1/2-1 Homogen" (Estimate: -0.439236,  $p = 4.87e-07$ ) ve "mod\_type1/4-1/2-3/4-1 Homogen" (Estimate: -0.472222,  $p = 6.53e-08$ ) gibi bazı seviyeler istatistiksel olarak anlamlı etkilere sahiptir.

mod\_type değişkeninin, ortalama yanıt değişkenini tahmin etmede değişen öneme sahip birkaç seviyesi bulunmaktadır. Bazı mod\_type seviyeleri anlamlı veya yüksek derecede anlamlı iken bazıları anlamlı değildir. İşte bazı seviyeler için bulguların özeti:

• mod\_type (çeşitli önemli seviyeler):

mod\_type1/2-1 4Hot: Anlamlı değil

mod\_type1/2-1 Heterogen: Anlamlı ( $p < 0.05$ )

mod\_type1/2-1 Homogen: Yüksek derecede anlamlı ( $p < 0.001$ )

mod\_type1/3-2/3-1 2Hot: Anlamlı ( $p < 0.05$ )

mod\_type1/3-2/3-1 4Hot: Anlamlı değil

mod\_type1/3-2/3-1 Heterogen: Anlamlı değil

mod\_type1/3-2/3-1 Homogen: Yüksek derecede anlamlı ( $p < 0.001$ )

mod\_type1/4-1/2-3/4-1 4Hot: Anlamlı değil

mod\_type1/4-1/2-3/4-1 Heterogen: Anlamlı değil

mod\_type1/4-1/2-3/4-1 Homogen: Yüksek derecede anlamlı ( $p < 0.001$ )

mod\_type1/4-1/2-3/4 2Hot: Marjinal olarak anlamlı ( $p < 0.1$ )

mod\_type1/4-1/2-3/4 4Hot: Anlamlı ( $p < 0.01$ )

mod\_type1/4-1/2-3/4 Heterogen: Anlamlı değil

mod\_type1/4-1/2-3/4 Homogen: Yüksek derecede anlamlı ( $p < 0.001$ )

mod\_type1/4-1/2-3/4-1 2Hot: Anlamlı ( $p < 0.01$ )

- Cinsiyet deęişkeni sonuç üzerinde istatistiksel olarak anlamlı bir etkiye sahiptir (Tahmin: 0.239567,  $p = 0.046115$ ), bu da erkek olmanın kadınlara kıyasla daha yüksek bir ortalama sonuçla ilişkili olduğunu göstermektedir.

- Yaş deęişkeni sonuç üzerinde negatif ancak istatistiksel olarak marjinal olarak anlamlı bir etkiye sahiptir (Tahmin: -0.014156,  $p = 0.074347$ ), bu da yaşın sonuç üzerindeki etkisinin yetersiz olduğunu göstermektedir.

Özet olarak, doğrusal karma modeli, `mod_type`, Cinsiyet ve Yaş deęişkenlerinin ortalama yanıt deęişkenini tahmin etmede farklı önem düzeylerine sahip olduğunu göstermektedir. Bazı `mod_type` seviyeleri anlamlı veya yüksek derecede anlamlıyken bazıları anlamlı değildir. Bu bilgi, çalışmanın sonuçlarına dayalı müdahaleler, politikalar veya öneriler konusunda bilgi sağlamaya yardımcı olabilir.

#### 4.6.1.6 Sabit etkilerin katsayıları

Bu, modelin her bir kategori ve bağımsız deęişkenin bağımlı deęişken üzerindeki etkisini tahmin eder (Çizelge 4.22). İşte bu tahminlere dair birkaç yorum:

*Kesişim Noktası:* Bu katsayı, modeldeki tüm bağımsız deęişkenlerin değeri 0 olduğunda, yani hiçbir etkilerinin olmadığı durumda beklenen bağımlı deęişkenin değeridir. Burada 3.364675 olarak bulunmuştur.

*mod\_type deęişkenleri:* Her bir "mod\_type" deęişkeni için katsayılar, belirli bir "mod\_type" kategorisine ait olmanın bağımlı deęişkene olan etkisini temsil eder. Negatif katsayılar, bağımlı deęişkenin değerinin bu kategoriye dahil olma durumunda düştüğünü gösterir.

*GenderMale:* Bu katsayı, erkek cinsiyetinin bağımlı deęişken üzerindeki etkisini gösterir. Pozitif katsayı (0.239567), erkeklerin bağımlı deęişkene kadınlara kıyasla daha yüksek bir etkisi olduğunu belirtir.


*Yaş:* Bu katsayı, yaşın bağımlı deęişken üzerindeki etkisini temsil eder. Negatif katsayı (-0.014156), yaş arttıkça bağımlı deęişkenin değerinin azaldığını gösterir.

**Çizelge 4.22: Deney 2 Parlaklık için Sabit Etkilerin Katsayıları**


<b>Sabit Etkiler</b>	<b>Tahmin</b>
Kesişim Noktası	3.364675
mod_type1/2-1 4Hot	-0.137153
mod_type1/2-1 Heterogen	-0.119792
mod_type1/2-1 Homogen	-0.439236
mod_type1/3-2/3-1 2Hot	0.145833
mod_type1/3-2/3-1 4Hot	0.048611
mod_type1/3-2/3-1 Heterogen	0.003472
mod_type1/3-2/3-1 Homogen	-0.289931
mod_type1/4-1/2-3/4-1 2Hot	0.237847
mod_type1/4-1/2-3/4-1 4Hot	-0.043403
mod_type1/4-1/2-3/4-1 Heterogen	-0.236111
mod_type1/4-1/2-3/4-1 Homogen	-0.472222
mod_type1/4-1/2-3/4 2Hot	0.256944
mod_type1/4-1/2-3/4 4Hot	0.123264
mod_type1/4-1/2-3/4 Heterogen	-0.090278
mod_type1/4-1/2-3/4 Homogen	-0.413194
GenderMale	0.239567
Yaş	-0.014156

Bu sonuçları değerlendirirken, önemli bir nokta, bunların yalnızca tahminler olduğudur ve bu tahminler gerçek etkileri tam olarak yansıtmayabilir. Tahminlerin hassasiyeti ve güvenilirliği, modelin uyumunun ne kadar iyi olduğuna, verilerin ne kadar temiz ve doğru olduğuna ve seçilen modelin veriye ne kadar uygun olduğuna bağlıdır. Deney 2 parlaklık için kullanılan bağımsız değişkenlerin sonuçlarının


şekilsel gösterimi aşağıda sunulmuştur (Şekil 4.58, Şekil 4.59, Şekil 4.60, Şekil 4.61, Şekil 4.62, Şekil 4.63).




Şekil 4.58: Deney 2 Parlaklık için Ortalama Doğru Tıklamaları – Tahmin Edilen / Asıl (mod\_type/Cinsiyet)




Şekil 4.59: Deney 2 Parlaklık için Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)




**Şekil 4.60:** Deney 2 Parlaklık için Ortalama Doğru Tıklamaların Yoğunluğu (mod\_type/Cinsiyet)



**Şekil 4.61:** Deney 2 Parlaklık için mod\_type'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



**Şekil 4.62:** Deney 2 Parlaklık için Yaş'a göre Ortalama Doğru Tıklamalar (mod\_type/Cinsiyet)



**Şekil 4.63:** Deney 2 Parlaklık için Çoklu nesne izleme performansının mod\_type'a göre grafiği (Cinsiyet)


#### 4.6.2 Parlaklık düzeyleri için deney 2 sonrası yapılan test (Post-Hoc)

Sonradan Yapılan Test özellikle belirli farklı bireysel grupları karşılaştıran bir post-hoc istatistiksel analizin sonuçlarını sunar ve yaşların 31.15625 olarak görüntülendiğini belirtir. Çizelge, bu gruplar arasındaki karşılaştırmaları (farkları), bu farkın tahminini, standart hata (SH), serbestlik derecesini (SD), t oranını ve p değerini sağlar.

Örneğin, "1/2-1 2Hot Female Age31.15625" ve "1/2-1 Homogen Female Age31.15625" değerlerini karşılaştırdığımızda, bu iki grup arasındaki farkın tahmini 0.867945, standart hata 0.439 ve 0 serbestlik derecesidir. t oranı 5.067 ve p değeri 0.0002'dir, bu da istatistiksel olarak anlamlıdır ( $p < 0.05$ )

Bu, söz konusu iki grubun arasındaki farkın toplam varyasyonun yaklaşık %86,79'unu oluşturduğu anlamına geliyor. Diğer bir deyişle, bu iki grup arasındaki fark, incelenen özellikte önemli bir paya sahiptir.

Anamlı Çift Karşılaştırmalar - Tahmin



**Şekil 4.64:** Deney 2 Parlaklık için Önemli İkili Karşılaştırmalar- Tahmini Grafikte:

"Ortalama Fark" sütunu, iki grup arasındaki ortalama farkı temsil ediyor. Burada görülen -0.5 değeri, bu iki grubun ortalamaları arasında 0.5 birimlik bir fark olduğunu gösteriyor.

"Toplamın Yüzdesi" sütunu, karşılaştırma sonuçlarının toplam içindeki yüzdesel ağırlığını göstermektedir. Bu değer, karşılaştırma sonuçlarının göreceli

önemini gösteren bir ölçüttür. Grafikte bu değer 0 ile 30 arasında yer almaktadır. Burada görülen yüksek değer, bu farkın istatistiksel olarak anlamlı olduğunu gösterir (Şekil 4.64).

Bu bilgi, çalışmanın hedefleri bağlamında farklı faktörler arasındaki ilişkileri (örneğin, mod\_type türü ve yaş) belirlemek için değerli olabilir ve bu bulgulara dayanarak sonuçlar çıkarılmasına yardımcı olabilir (Yazgan, Yağımlı & Ozubko, 2023).

## **4.7 Deney 1 Bulanıklık, Kontrast ve Parlaklık Arasındaki Etkileşimler**

### **4.7.1 Deney 1 Bulanıklık, Kontrast ve Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları**

#### **4.7.1.1 KMOY ile uygulanan doğrusal karma model (DKM)**

Bu analizde, Kısıtlanmış Maksimum Olabilirlik (KMOY) tahmin yöntemi kullanılarak Doğrusal Karma Model (DKM) uygulandı. KMOY, küçük örneklem büyüklüğüne veya dengesiz tasarıma sahip olduğunda özellikle varyans bileşenlerinin önyargısız tahminlerini sağladığı için doğrusal karma modeller için tercih edilen bir tahmin yöntemidir (Pinheiro & Bates, 2000).

Modelin formülü şu şekildedir:

$$\text{Ortalama} \sim \text{mod\_type}(\text{Bulanıklık} + \text{Kontrast} + \text{Parlaklık}) + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.7)$$

Formül 4.7'de mod\_type, Cinsiyet ve Yaş'ı sabit etkiler olarak içererek, model ortalama çıktının bu faktörlere sistemli olarak bağlı olarak değişip değişmediğini araştırır. Katılımcılar için rassal etki, her katılımcıya özgü ölçülememiş faktörlerden kaynaklanabilecek çıktı değişkenindeki bireysel farklılıkları hesaba katarak modelin esnekliğini sağlar.

#### **4.7.1.2 Yakınsama için KMOY kriteri**

Kısıtlanmış Maksimum Olabilirlik (KMOY) yakınsama kriteri, doğrusal karma modelin (DKM) veriye uygunluğunu değerlendirirken önemli bir ölçüttür. Bu kriter, modelin iki kat negatif log olabilirlik değeri üzerinden hesaplanır ve modelin

tahmin edilen parametrelerinin veri setine ne kadar iyi uyduğunu gösterir. KMOY değeri, modelin karmaşıklığı ile uyumunun dengesini gösterir.

Patterson ve Thompson (1971) tarafından belirtildiği gibi, KMOY yakınsama kriteri ve diğer uygunluk ölçütleri, modelin verilere ne derecede iyi uyduğunu değerlendirmede kritik öneme sahiptir. Bu değerlendirmeler, modelin yapısal geçerliliği, tahmin edilen parametrelerin anlamlılığı ve modelin genel performansı hakkında önemli bilgiler sağlar. Ayrıca, modelin daha da geliştirilmesi için potansiyel alanları belirlemeye ve araştırmacılara gelecekteki analizler için yön göstermeye yardımcı olur.

Sonuç olarak, 3796.4 KMOY değeri, incelenen modelin verilere orta derece uyum sağladığını ve modelin tahmin edilen parametrelerinin veri setindeki varyansları ve yapıları yaklaşık bir şekilde yakaladığını gösterir. Ancak, bu bulguların diğer uygunluk ölçütleri ve istatistiksel analizlerle desteklenmesi önemlidir. Bu kapsamlı değerlendirme, modelin güvenilirliğini ve araştırma bulgularının geçerliliğini artırır.

#### 4.7.1.3 Ölçeklendirilmiş artıklar

Ölçeklendirilmiş artıklar analizi, doğrusal karma modelin (DKM) verilere ne kadar iyi uyduğunu değerlendirirken önemli bir araçtır. İdeal olarak, bu ölçeklendirilmiş artıkların normal bir dağılıma sahip olması beklenir. Bu, modelin veri setindeki yapıyı başarıyla yakaladığını ve artıklarda yalnızca rastgele varyasyon bıraktığını gösterir.

Çizelge 4.23'te sunulan ölçeklendirilmiş artıkların değerleri, modelin performansına dair önemli bilgiler sağlar:

- *Minimum Değer (-4.3023)*: Bu, modelin tahminlerinin bazı durumlarda gözlemlenen değerlerden önemli ölçüde daha yüksek olduğunu gösterir. Bu kadar düşük bir minimum değer, modelin bazı gözlemleri aşırı derecede düşük tahmin ettiğini ve potansiyel olarak modelde aykırı değerlerin veya veri setindeki belirli yapıların dikkate alınmamasının bir işareti olabilir.
- *Birinci Çeyrek (-0.5522)*: Ölçeklendirilmiş artıkların %25'inin bu değerden daha düşük olduğunu gösterir, bu da artıkların büyük bir kısmının nispeten düşük sapmalara sahip olduğunu gösterir.

- *Ortanca (0.0689)*: Ölçeklendirilmiş artıkların yarısının bu değerden daha düşük, yarısının ise bu değerden daha yüksek olduğunu gösterir. Ortancanın 0'a yakın olması, genel olarak modelin veri setini iyi bir şekilde yakaladığını gösterir, çünkü artıkların çoğu 0 etrafında dağılım gösterir.
- *Üçüncü Çeyrek (0.6197)*: Ölçeklendirilmiş artıkların %75'inin bu değerden daha düşük olduğunu gösterir, bu da artıkların büyük bir kısmının nispeten düşük sapmalara sahip olduğunu tekrar gösterir.
- *Maksimum Değer (4.1788)*: Modelin tahminlerinin bazı durumlarda gerçek değerlerden önemli ölçüde daha düşük olduğunu gösterir. Bu kadar yüksek bir maksimum değer, modelin bazı gözlemleri aşırı derecede yüksek tahmin ettiğini ve potansiyel olarak modelde aykırı değerlerin veya veri setindeki belirli yapıların dikkate alınmamasının bir işareti olabilir.

**Çizelge 4.23:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için Ölçeklendirilmiş Artıklar

<b>Min.</b>	<b>1. Çeyrek</b>	<b>Ortanca</b>	<b>3. Çeyrek</b>	<b>Mak.</b>
-4.3023	-0.5522	0.0689	0.6197	4.1788

Bu değerlerin analizi, modelin genel olarak veri setini iyi bir şekilde yakaladığını ancak bazı durumlarda önemli sapmaların olduğunu gösterir. Minimum ve maksimum değerlerin büyüklüğü, modelin bazı gözlemleri aşırı tahmin ettiğini veya çok düşük tahmin ettiğini gösterir. Bu, modelin belirli veri noktalarında hatalı tahminler yapabileceğini gösterir. Ancak, ortancanın 0'a yakın değeri ve çeyreklik değerlerin nispeten sınırlı bir aralıkta olması, modelin birçok durumda doğru tahminler yaptığını gösterir.

Bu analiz, modelin bazı durumlarda performansını iyileştirmek için daha fazla optimizasyona ihtiyaç duyduğunu gösterir. Özellikle, minimum ve maksimum değerlerde gözlenen aşırı sapmaların incelenmesi ve bu sapmaları azaltacak stratejilerin uygulanması, modelin genel doğruluğunu ve güvenilirliğini artırabilir. Bu, modelin daha kapsamlı bir şekilde değerlendirilmesini ve potansiyel iyileştirmelerin belirlenmesini gerektirir.

Şekil 4.65, farklı resim modifikasyon parametrelerinin "Ortalama" (ortalama) adı verilen bir hedef değişken üzerindeki etkilerinin ısı haritası görselleştirmesini göstermektedir. x eksenini "Modifikasyon Alanı" temsil ederken, y eksenini bulanıklık, kontrast ve parlaklık gibi çeşitli görüntü değiştirme parametrelerini gösterir. Her hücrenin rengi etkinin büyüklüğünü temsil eder; mor, daha güçlü bir pozitif etkiyi, sarı/turuncu ise daha zayıf bir pozitif etkiyi belirtir.

Isı haritası, Blur10, Blur12 ve Contrast-10 gibi belirli görüntü değiştirme parametrelerinin hedef değişken üzerinde istatistiksel olarak anlamlı bir pozitif etkiye sahip olduğunu öne sürüyor. Öte yandan Blur6'nın istatistiksel olarak anlamlı bir olumsuz etkiye sahip olduğu görülüyor. Kontrast-50, Kontrast-90 gibi diğer parametrelerin ve bazı parlaklık ayarlarının etkileri daha az belirgindir veya istatistiksel olarak anlamlı değildir.



Şekil 4.65: Deney 1 Bulanıklık, Kontrast ve Parlaklık için Modifikasyon Alanına göre Ortalama

#### 4.7.1.4 Rassal etkiler

Doğrusal karma modeldeki rassal etkiler, modelin sabit etkileriyle açıklanamayan değişkenliği temsil eder ve bireysel düzeydeki varyansı modellememize olanak tanır. Bu yapı, her katılımcı için bir ara kesit olarak

modellenir, böylece çıktı değişkenindeki bireysel düzeydeki ortalama değişkenliği yakalayabiliriz.

Çizelge 4.24'te sunulan sonuçlar, iki ana varyans kaynağını ortaya koyar: katılımcılara özgü rassal ara kesitler ve artıklar. Bu durumda, katılımcılara özgü rassal ara kesitler için tahmin edilen varyans 0.2278 ve standart sapma 0.4773 olarak hesaplanmıştır. Bu, mod\_type, Cinsiyet ve Yaş gibi sabit etkiler hesaba katıldıktan sonra, katılımcılar arasında çıktıda önemli bir değişkenliğin olduğunu gösterir. Artık varyans ise 0.1612 olarak tahmin edilmiş ve standart sapması 0.4015 olarak bulunmuştur. Artık varyans, modelin sabit ve rassal etkileri hesaba kattıktan sonra veride kalan değişkenliği temsil eder.

**Çizelge 4.24:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için Rassal Etkiler

<b>Grup</b>	<b>Ad</b>	<b>Varyans</b>	<b>Standart Sapma</b>
<b>Katılımcı</b>	(Sabit)	0.2278	0.4773
<b>Artık</b>		0.1612	0.4015

Rassal etkilerin varlığı, doğrusal karma modelin veri seti için uygun olduğunu gösterir çünkü bu, sabit etkilerin yanı sıra bireysel düzeydeki varyansı da modelleyebilmemizi sağlar. Bu, sabit etkilerin tahminlerinin hassasiyetini artırır ve aynı katılımcı içindeki gözlemlerin bağımsız olmayan doğasından kaynaklanabilecek olası önyargıları azaltır. Ayrıca, rassal etkilerin dahil edilmesi, modelin toplam varyansının ne kadarının rassal etkilere atfedilebileceğini ölçen AKKK'nın tahmin edilmesine imkân tanır.

Katılımcılara özgü rassal ara kesitlerin önemli bir varyans payına sahip olması, modelin katılımcılar arasındaki farklılıkları önemli ölçüde açıkladığını gösterir. Ancak, artık varyansın varlığı, modelin hala bazı gözlemleri tam olarak açıklayamadığını gösterir, bu da belirli katılımcıların özelliklerini veya belirli durumları tam olarak yakalayamama olasılığını işaret eder.

Bu sonuçlar, modelin genel olarak iyi bir uyum sağladığını gösterirken, artık varyansın varlığı modelin bazı durumlarda veya belirli katılımcılarla daha fazla çalışılması gerektiğini gösterir. Modelin daha fazla iyileştirilmesi için, özellikle artık

varyansın kaynaklarının daha detaylı incelenmesi ve bu varyansı azaltacak stratejilerin uygulanması önemlidir.

#### 4.7.1.5 Sabit etkiler

Doğrusal karma modelindeki sabit etkiler, bağımsız değişkenlerin çıktı değişkeni üzerindeki ortalama etkilerini temsil eder. Bu durumda, sabit etkiler arasında *mod\_type* kategorileri, Cinsiyet ve Yaş bulunmaktadır. Her bir sabit etkinin etkisi, diğer tüm değişkenler sabit tutulduğunda bağımsız değişkenlerdeki bir birimlik değişimin çıktı değişkeni üzerindeki ortalama etkisini gösterir.

##### *Sabit Etkilerin Analizi:*

*Kesişim Noktası:* Tahmini değer 3.218'dir ve standart hata 0.1202'dir, tüm bağımsız değişkenler referans seviyelerindeyken ortalama sonucu gösterir. Yüksek t-değeri (26.781) ve çok düşük p-değeri ( $< 2e-16$ ) sonucun oldukça anlamlı bir etkiye sahip olduğunu gösterir.

##### *mod\_type Kategorileri:*

- *Blur14, Blur12, Blur10, Blur8 ve Blur6:* Bu seviyeler, referansa göre sonucu artırma eğilimindedir. Arasında *Blur10* (tahmin = 0.1498, p-değeri = 0.00176) ve *Blur12* (tahmin = 0.1016, p-değeri = 0.03378) istatistiksel olarak anlamlıdır, *Blur14* ise değildir (p-değeri = 0.11747). *Blur6* negatif bir tahmin (-0.1334) ve anlamlıdır (p-değeri = 0.00534), sonucun azaldığını gösterir. *Blur8* ise pozitif olsa da istatistiksel olarak anlamlı değildir (p-değeri = 0.13076).
- *Contrast-10, Contrast-50, Contrast-90, ContrastMinus30 ve ContrastMinus70:* *Contrast-10* değeri anlamlıdır (tahmin = 0.1221, p-değeri=0.00831), bu da *Contrast-10* koşulunun referans grubuna göre ortalama çıktıda artışa yol açtığını gösterir ancak *Contrast-50*, *Contrast-90* ve *ContrastMinus30* gibi diğerleri pozitif ancak istatistiksel olarak anlamlı değildir. Ayrıca *ContrastMinus70* kategorisinin tahmini etkisi -0.02408'dir, standart hata 0.04623'tür ve p-değeri 0.60244'tür. Bu tahmin, referans kategorisi ("None") ile karşılaştırıldığında sonuç değişkeni üzerinde minimal negatif bir etkisi olduğunu önerir. Ancak, nispeten büyük p-değeri, bu etkinin

istatistiksel olarak anlamlı olmadığını, bu örneğe dayanarak popülasyonda gerçek bir etkinin olduğunu güvenle söyleyemeyeceğimizi gösterir.

- *Bright-10, Bright-50, Bright-90, BrightMinus30 ve BrightMinus70*: Parlaklık ayarları için tahminler (*Bright-10, Bright-50, Bright-90, BrightMinus30 ve BrightMinus70*), sonuç üzerinde çeşitli etkiler gösterir. *BrightMinus70* anlamlı negatif bir etki gösterir (tahmin = -0.1416, p-değeri = 0.00217) bu da bu koşulun referans grubuna göre ortalama çıktıyı önemli ölçüde azalttığını gösterir.


*Cinsiyet (GenderMale)*: Erkek cinsiyet için pozitif bir katsayı (0.1597) ve anlamlı bir p değeri (0.02889) bulunmaktadır. Bu, diğer faktörler sabit tutulduğunda erkek katılımcıların kadınlara göre ortalama olarak daha yüksek çıktı değerlerine sahip olduğunu gösterir.

*Yaş (Age)*: Yaş için negatif bir katsayı (-0.005493) ve marjinal anlamlılık ( $p = 0.08492$ ) bulunmaktadır. Bu, yaşın artmasıyla ortalama çıktı değerlerinin azaldığını gösterir, ancak bu etki istatistiksel olarak marjinaldir.

Bu sonuçlar, belirli *mod\_type* kategorilerinin (özellikle *Blur6, Blur10, Blur12 Contrast-10 ve BrightMinus70*) yanında cinsiyetin de önemli bir rol oynadığını gösterir ve kısmen yaşın çıktı değişkeni üzerinde anlamlı etkilere sahip olduğunu gösterirken, diğer *mod\_type* kategorilerinin çoğunun çıktı üzerinde anlamlı bir etkiye sahip olmadığını gösterir.

Şekil 4.66'da çubuk grafiği, bulanıklık, parlaklık ve kontrast için en yüksek değerlerin, en uç ayar gibi görünen en sağdaki değişiklik alanında gözlemlendiğini göstermektedir. Diğer değişiklik alanları, bu hedef değişkenlerin değişen düzeylerini gösterir; bazı alanlar, referans grubuyla (en soldaki çubuk) karşılaştırıldığında daha düşük değerlere sahiptir.

Bu bulgular, *mod\_type* kategorileri, Cinsiyet ve Yaş arasındaki ilişkileri daha iyi anlamamıza yardımcı olabilir ve çoklu nesne takibi gibi görevlerde performansı iyileştirmeye yönelik müdahalelerin geliştirilmesine ışık tutabilir.



**Şekil 4.66:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için Ortalama Frekans

#### 4.7.1.6 Sabit etkilerin korelasyonu

Doğrusal karma modeldeki sabit etkiler arasındaki korelasyonlar, etkilerin birbirleriyle nasıl ilişkili olduğunu anlamamıza yardımcı olur. Korelasyon matrisi, bu ilişkileri nicel olarak gösterir ve her bir giriş iki sabit etki arasındaki korelasyon katsayısını içerir. Pozitif bir korelasyon, etkiler arasında doğru orantılı bir ilişki olduğunu, negatif bir korelasyon ise ters orantılı bir ilişki olduğunu gösterir.

##### *Korelasyon Analizi:*

- *Kesişim Noktası ve Mod\_type Kategorileri:* Kesişim noktası ile tüm mod\_type kategorileri arasında küçük negatif korelasyonlar gözlemlenmiştir. Bu, mod\_type kategorilerinin yanıt değişkeni üzerindeki etkisinin, referans kategoriye kıyasla genellikle azaltıcı bir eğilim gösterdiğini işaret edebilir.
- *Mod\_type Kategorileri Arası Korelasyonlar:* Mod\_type kategorileri arasındaki pozitif korelasyonlar, bu kategorilerin yanıt değişkeni üzerinde benzer etkilere sahip olabileceğini gösterir. Ancak, bu korelasyonlar genellikle düşük olduğundan, kategoriler arasındaki etkilerin birbirinden bağımsız olabileceği de düşünülebilir.
- *GenderMale ve Diğer Sabit Etkiler:* GenderMale etkisi ile kesişim noktası arasında küçük bir negatif korelasyon vardır, bu da erkek katılımcıların ortalama olarak referans kategorisine göre daha düşük yanıt değerlerine sahip

olabileceğini gösterir. GenderMale etkisi ile mod\_type kategorileri arasındaki korelasyonlar neredeyse sifıra yakındır, bu da cinsiyetin mod\_type kategorileri arasında anlamlı bir fark oluşturmadığını gösterir.

- *Yaş ve Diğer Sabit Etkiler:* Yaş ile kesişim noktası arasında küçük bir negatif korelasyon gözlemlenmiştir, bu da yaş ilerledikçe ortalama yanıt değerlerinin azalabileceğini gösterir. Yaş ile mod\_type kategorileri ve GenderMale etkisi arasındaki korelasyonlar neredeyse sifıra yakındır, bu da yaşın bu etkilerle anlamlı bir ilişkiye sahip olmadığını gösterir.

Bu korelasyonlar, modeldeki etkilerin birbirleriyle nasıl ilişkili olduğu hakkında önemli bilgiler sunar. Ancak, bu korelasyonların varlığı, doğrudan nedensellik ilişkilerini göstermez ve bulguların yorumlanması araştırmanın bağlamına ve özel koşullarına bağlıdır. Ayrıca, etkiler arasındaki daha detaylı ilişkileri anlamak için ek istatistiksel analizlere ihtiyaç duyulabilir. Bu analiz, sabit etkiler arasındaki ilişkileri daha iyi anlamak için bir başlangıç noktası olarak kullanılabilir ve modelin daha derinlemesine incelenmesine yol açabilir.


#### **4.7.2 Bulanıklık, kontrast ve parlaklık düzeyleri için deney 1 sonrası yapılan test (Post-Hoc)**

Karşılaştırma özeti, belirli gruplar arasındaki farklılıkların istatistiksel önemini değerlendirir. Her satır, belirli bir gruplar çifti arasındaki karşılaştırmayı temsil eder ve bu karşılaştırmaların sonuçları, çeşitli durumlar ve koşullar altında gruplar arasındaki farklılıkları anlamamıza yardımcı olur.

##### *Karşılaştırmaların İstatistiksel Analizi:*

- *Karşılaştırmaların Genel Gözlemleri:* Veriler, çeşitli gruplar arasında bir dizi karşılaştırma sunar. Bu karşılaştırmalar, örneğin farklı mod\_type kategorileri, cinsiyet ve yaş gibi faktörler arasındaki farklılıkları içerir.
- *İstatistiksel Olarak Anlamlı Karşılaştırmalar:* Çoğu karşılaştırma, p değerlerinin 0.05'ten küçük olması nedeniyle istatistiksel olarak anlamlı farklılıklar gösterir. Örneğin, "Blur10 Female Age32.6134020618557 - Blur6 Female Age32.6134020618557" karşılaştırmasında p değeri <.0001'dir, bu da iki grup arasındaki farkın istatistiksel olarak önemli olduğunu gösterir.
- *Öne Çıkan Karşılaştırmalar:*

- "Blur10 Female Age32.6134020618557 - BrightMinus70 Female Age32.6134020618557" karşılaştırmasında p değeri 0.0002'dir, bu da belirgin bir farklılık olduğunu gösterir.
- "Blur10 Female Age32.6134020618557 - None Female Age32.6134020618557" karşılaştırmasında ise p değeri 0.3160'dir, bu da farkın çok fazla olmadığını gösterir.
- *Cinsiyet ve Mod\_type Karşılaştırmaları:* Cinsiyet ve farklı mod\_type kategorileri arasındaki karşılaştırmalarda, "Blur10 Female Age32.6134020618557 - Blur10 Male Age32.6134020618557" gibi, cinsiyetin etkisinin bu kategoriler arasında fark oluşturup oluşturmadığı incelenir. Bazı durumlarda bu farklar istatistiksel olarak anlamlıdır, bazılarında ise değildir.



**Şekil 4.67:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için Tukey Düzeltmeleri ile Tahmini Marjinal Ortalamalar

Genel olarak grafik, farklı mod\_type kategorilerinin, cinsiyetin ve yaşın çıktı üzerindeki tahmin edilen etkilerini göstermektedir. Öne çıkan noktalar:

Blur10, Blur12 ve Blur14 gibi yüksek bulanıklık kategorileri, referans durumuna (None) kıyasla daha yüksek tahmini marjinal ortalama değerleri gösterirken, Blur6 kategorisi daha düşük değerlere sahip.

Kontrast ve parlaklık ayarları için bazı kategoriler (Contrast-10, BrightMinus70 gibi) referansa göre anlamlı farklılıklar gösterirken, diğer kategoriler anlamlı farklılık göstermemektedir.

Cinsiyet açısından, erkekler kadınlara kıyasla daha yüksek tahmini marjinal ortalama değerleri göstermektedir.

Yaş arttıkça, tahmini marjinal ortalama değerlerinde bir azalma eğilimi görülmektedir (Şekil 4.67).

#### *Sonuçlar:*

Bu karşılaştırma özeti, gruplar arasındaki farklılıkların kapsamlı bir değerlendirmesini sağlar. İstatistiksel olarak anlamlı bulgular, belirli faktörlerin (mod\_type, cinsiyet, yaş vb.) etkisinin önemini gösterirken, daha yüksek p değerleri olan karşılaştırmalar, bu faktörlerin etkisinin daha az belirgin veya istatistiksel olarak önemsiz olabileceğini gösterir. Bu analiz, daha derinlemesine araştırma ve değerlendirme yapılması gereken alanları belirlememize yardımcı olur.

### **4.8 Deney 2 Bulanıklık, Kontrast ve Parlaklık Arasındaki Etkileşimler**

#### **4.8.1 Deney 2 Deney 1 Bulanıklık, Kontrast ve Parlaklık için Doğrusal Karma Modelinin Analiz Sonuçları**

##### **4.8.1.1 KMOY ile uygulanan doğrusal karma model (DKM)**

Bu çalışmada, doğrusal karma model, KMOY yöntemi kullanılarak aşağıdaki formülle uygulanır:

$$\text{Ortalama} \sim \text{mod\_type} * (\text{Bulanıklık} + \text{Kontrast} + \text{Parlaklık}) + \text{Cinsiyet} + \text{Yaş} + (1 | \text{Katılımcı}) \quad (4.8)$$

ve veriler combined\_df veri setinden alınır.

Formül 4.8'de bağımlı değişkenin (ortalama) mod\_type ile Bulanıklık, Kontrast ve Parlaklık toplamının etkileşimi, Cinsiyet ve Yaş ile birlikte, bu değişkenlerin sabit etkileri ve katılımcı için rassal bir etkisi olarak modellediğini gösterir. Bu hem sabit etkileri hem de analizdeki katılımcılar arasındaki rassal değişkenliği dikkate almayı sağlar.

#### 4.8.1.2 Yakınsama için KMOY kriteri

Yakınsama için KMOY kriteri, Kısıtlı Maksimum Olabilirlik (KMOY) yöntemi kullanılarak tahmin edilen doğrusal karma modellerin uyumunun bir ölçüsüdür. KMOY kriteri, modeldeki hem sabit hem de rassal etkileri dikkate alan bir olabilirlik tabanlı ölçüdür (Patterson & Thompson, 1971). Kriter değeri, farklı modelleri karşılaştırmak için kullanılabilir ve daha küçük bir değer daha iyi bir uyumlu modeli gösterir.

Bu çıktıda, yakınsama için KMOY kriteri 5097 olarak bulunmuştur, bu da "Orta" model uygunluğuna işaret eder. Bu durum, modelin verilere uyumunun yetersiz olabileceğini veya modelin aşırı karmaşık hale gelmiş olabileceğini gösterir.

#### 4.8.1.3 Ölçeklendirilmiş artıklar

Bu çıktıda, standartlaştırılmış artıkların minimum ve maksimum değerleri görülmektedir. Bu değerler, veride bazı aykırı değerlerin veya etkili gözlemlerin bulunabileceğini göstermektedir (Çizelge 4.25). Aykırı değerler veya etkili gözlemler, modelin varsayımlarını ihlal ettiğini veya öngördüğümüz yapıyı yanılttığını gösterebilir. Bu nedenle, bu aykırı değerlere veya etkili gözlemlere dikkat etmek ve sonuçların yorumlanmasında dikkate almak önemlidir.

**Çizelge 4.25:** Deney 2 Bulanıklık, Kontrast ve Parlaklık için Ölçeklendirilmiş Artıklar

Min.	1. Çeyrek	Ortanca	3. Çeyrek	Mak.
-3.8406	-0.6069	0.0628	0.6894	2.8330

Ölçeklendirilmiş artıkların bu özetine göre;


Min: Ölçeklendirilmiş artıkların minimum değeri -3.8406. Bu değer, modelin bazı gözlemlerini aşırı derecede yüksek tahmin ettiğini gösterir.

Mak: Ölçeklendirilmiş artıkların maksimum değeri 2.8330. Bu, modelin bazı gözlemlerini aşırı derecede düşük tahmin ettiğini gösterir.

Genel olarak, bu istatistikler modelin çoğu durumda nispeten iyi tahminler yaptığını, ancak bazı durumlarda önemli hatalar yaptığını gösterir. Özellikle Min. ve Mak. değerlerinin büyüklüğü, modelin bazı uç değerler ile mücadele ettiğini gösterir.

Bu durumlar modelin doğruluğunu etkileyebilir ve daha fazla inceleme ve düzeltme gerektirebilir.

Mod\_type kategorileri farklı renk yoğunlukları gösteriyor, bu da bu kategorilerin modifikasyon alanı üzerinde farklı etkilere sahip olduğunu ima eder. Örneğin, Bulanıklık kategorileri daha yüksek katsayı değerleri sergilerken, Kontrast ve Parlaklık kategorileri daha düşük değerlere sahiptir (Şekil 4.68).



**Şekil 4.68:** Deney 2 Bulanıklık, Kontrast ve Parlaklık için Modifikasyon Alanına göre Ortalama

Birinci çeyrek ve üçüncü çeyrek değerleri arasındaki fark, veri setinizin orta yüzde 50'sinin yayılımını gösterir. Bu durumda, çeyrek değerleri arasındaki fark değeri pozitif ve sınırlı bir aralıktadır, bu da veri setinizin büyük bir kısmının daha dar bir aralıkta toplandığını gösterir.

Ortanca değeri 0.0628 olması, çoğu artığın 0 civarında olduğunu, yani modelin çoğu tahminin gerçek değerlere yakın olduğunu gösterir. Ancak, minimum ve maksimum değerler (-3.8406 ve 2.8330) modelin bazı durumlarda aşırı tahminler yaptığını gösterir. Bu, uç değerlerin (aykırı değerler) varlığını ve modelin bu durumlarla başa çıkmakta zorlandığını belirtir.

Sonuç olarak, ölçeklendirilmiş artıkların analizi, modelin genel olarak iyi bir performans sergilediğini ancak bazı tahminlerde hatalar yaptığını göstermektedir.

#### 4.8.1.4 Rassal etkiler

Bu çıktıda, iki tane rassal etki bulunmaktadır: katılımcı değişkeni için ara kesit ve artıkların varyansıdır.

*Gözlem ve grup sayısı:* Bu çıktıda, veri setindeki gözlem sayısı (3072) ve grup sayısı (183) görülmektedir. Gruplar, katılımcı değişkeni tarafından tanımlanır ve her katılımcının birden fazla gözlemi vardır.

Verilen tablo, doğrusal karma modelindeki rassal etkilerin varyansını ve standart sapmasını göstermektedir. Her bir rassal etki, modelin belirli bir seviyede (burada "katılımcı" seviyesinde) varyansını açıklar (Çizelge 4.26).

**Çizelge 4.26:** Deney 2 Bulanıklık, Kontrast ve Parlaklık için Rassal Etkiler

Grup	Ad	Varyans	Standart Sapma
Katılımcı	(Sabit)	0.2095	0.4577
Artık		0.2566	0.5065

• "Katılımcı" grubu, her bir katılımcı için bir ara kesiti temsil eder ve varyansı 0.2095, standart sapması 0.4577 olarak belirlenmiştir. Bu, `mod_type`, Cinsiyet ve Yaş'ın sabit etkilerinin hesaba katılmasından sonra katılımcılar arasında ortalama sonuçlarda değişkenliğin olduğunu gösterir.

• "Artık" ise sabit etkiler veya katılımcılar için ara kesitler tarafından açıklanmayan veri üzerindeki değişkenliği temsil eder. Artık varyansı 0.2566 ve standart sapması 0.5065 olarak belirlenmiştir. Bu artık varyansı, sabit etkiler veya katılımcılar için ara kesitler tarafından açıklanmayan sonuçlardaki değişkenliği temsil eder.

Bu sonuçlar, katılımcılar arasındaki farklılıkların, modelin genel varyansının önemli bir kısmını açıkladığını göstermektedir. Bu, modelin, tüm katılımcıların eşit olduğunu varsayarak, belirli bir katılımcının özelliklerini tam olarak yakalamadığını gösterebilir. Bu da modelin daha fazla rassal etki içermesi gerektiğine işaret edebilir. Yine de bu sonuçların kesin bir değerlendirmesi, modelin genel uyumu ve diğer istatistiklerin dikkate alınmasıyla sağlanabilir.

#### 4.8.1.5 Sabit etkiler

Sabit etkisi tahminleri, standart hatalar, serbestlik dereceleri, t-değerleri ve p-değerleri şu şekildedir:

*Kesişim Noktası:* Sabit terim (kesişim noktası) regresyon doğrusunun y eksenini kestiği noktadır. Bu durumda, 3.506 değeri, diğer tüm bağımsız değişkenler sıfır olduğunda bağımlı değişkenin beklenen değeridir. Yüksek t-değeri (23.984) ve çok düşük p-değeri ( $<0.0001$ ), sabit terimin istatistiksel olarak anlamlı olduğunu gösterir. Kesişim noktası, başvuru grubu için tahmin edilen ortalama sonucu temsil eder (Çizelge 4.27).

*mod\_type Kategorileri:*

Örneğin, mod\_type1/2-1 4Hot için tahmini, bu mod\_type düzeyi için ortalama sonucun başvuru düzeyine göre 0.092 birim daha düşük olduğunu gösterir, ancak bu fark istatistiksel olarak sınırlı derecede anlamlıdır ( $p = 0.075202$ ).

mod\_type sabit etkisi tahminleri, her bir mod\_type düzeyi ile başvuru düzeyi arasındaki ortalama sonuç farklılıklarını temsil eder.

Modelde yer alan diğer mod\_type'ın sabit etkiler şunlardır:

- mod\_type1/2-1 Heterogen: son derece anlamlı ( $p$ -değeri  $< 0.001$ )
- mod\_type1/2-1 Homogen: son derece anlamlı ( $p$ -değeri  $< 0.001$ )
- mod\_type1/3-2/3-1 2Hot: son derece anlamlı ( $p$ -değeri = 0.004576)
- mod\_type1/3-2/3-1 4Hot: anlamlı ( $p$ -değeri = 0.044003)
- mod\_type1/3-2/3-1 Heterogen: anlamlı ( $p$ -değeri = 0.026358)
- mod\_type1/3-2/3-1 Homogen: son derece anlamlı ( $p$ -değeri  $< 0.001$ )
- mod\_type1/4-1/2-3/4-1 2Hot: son derece anlamlı ( $p$ -değeri  $< 0.001$ )
- mod\_type1/4-1/2-3/4-1 4Hot: anlamlı değil ( $p$ -değeri = 0.579546)
- mod\_type1/4-1/2-3/4-1 Heterogen: son derece anlamlı ( $p$ -değeri = 0.000120)
- mod\_type1/4-1/2-3/4-1 Homogen: son derece anlamlı ( $p$ -değeri  $< 0.001$ )


Çizelge 4.27: Deney 2 Bulanıklık, Kontrast ve Parlaklık için Sabit Etkiler

Tahmin Edilen Değişken	Tahmin	SH	t-değeri	p-değeri
Kesişim Noktası	3.506	0.1462	23.984	< 0.0001
mod_type1/2-1 4Hot	-0.09201	0.05170	-1.780	0.0752
mod_type1/2-1 Heterogen	-0.2083	0.05170	-4.030	< 0.0001
mod_type1/2-1 Homogen	-0.5226	0.05170	-10.108	< 0.0001
mod_type1/3-2/3-1 2Hot	0.1467	0.05170	2.838	0.0046
mod_type1/3-2/3-1 4Hot	0.1042	0.05170	2.015	0.0440
mod_type1/3-2/3-1 Heterogen	-0.1149	0.05170	-2.222	0.0264
mod_type1/3-2/3-1 Homogen	-0.3556	0.05170	-6.879	< 0.0001
mod_type1/4-1/2-3/4-1 2Hot	0.2208	0.05170	4.271	< 0.0001
mod_type1/4-1/2-3/4-1 4Hot	-0.02865	0.05170	-0.554	0.5795
mod_type1/4-1/2-3/4-1 Heterogen	-0.1991	0.05170	-3.851	0.0001
mod_type1/4-1/2-3/4-1 Homogen	-0.5712	0.05170	-11.049	< 0.0001
mod_type1/4-1/2-3/4 2Hot	0.1999	0.05170	3.868	0.0001
mod_type1/4-1/2-3/4 4Hot	0.1085	0.05170	2.099	0.0359
mod_type1/4-1/2-3/4 Heterogen	-0.1230	0.05170	-2.379	0.0174
mod_type1/4-1/2-3/4 Homogen	-0.4913	0.05170	-9.504	< 0.0001
GenderMale	0.07695	0.07016	1.097	0.2742
Yaş	-0.01465	0.004109	-3.565	0.0005

- mod\_type1/4-1/2-3/4 2Hot: son derece anlamlı (p-değeri = 0.000112)
- mod\_type1/4-1/2-3/4 4Hot: anlamlı (p-değeri = 0.035912)
- mod\_type1/4-1/2-3/4 Heterogen: anlamlı (p-değeri = 0.017436)
- mod\_type1/4-1/2-3/4 Homogen: son derece anlamlı (p-değeri < 0.001)

*Cinsiyet (GenderMale):* "GenderMale" değişkeninin p-değeri 0.2742 olduğu için, cinsiyetin (erkek olma durumu) bağımlı değişken üzerinde istatistiksel olarak anlamlı bir etkisi olduğunu söylemek zordur.

*Yaş (Age)*: Ancak, "Yaş" değişkeni istatistiksel olarak anlamlıdır ( $p=0.0005$ ), bu da yaşın bağımlı değişken üzerinde önemli bir etkiye sahip olduğunu gösterir.



**Şekil 4.69:** Deney 2 Bulanıklık, Kontrast ve Parlaklık için Ortalama Frekans

Bu sabit etkiler, doğrusal karma modelindeki ilgi duyulan ana belirleyicileri temsil etmektedir. Çıktı, bu belirleyiciler ile sonuç değişkeni arasındaki ilişkilerin anlamlılığını ve büyüklüğünü hakkında bilgi sağlar (Şekil 4.69).

#### 4.8.1.6 Sabit etkilerin katsayısı

Verilen matris, büyük olasılıkla bir kovaryans veya korelasyon matrisi gibi yoğun simetrik bir matrisi temsil etmektedir. Matris 18 satır ve sütundan oluşur, her biri bir değişkeni temsil eder (Çizelge 4.28).

Diyagonal elemanlar her bir değişkenin varyansını temsil ederken, diyagonal olmayan elemanlar değişken çiftleri arasındaki kovaryans veya korelasyonu temsil eder. Bu matristeki belirli değerler küçüktür, bu da değişkenler arasında zayıf ilişkilerin olduğunu gösterebilir.

**Çizelge 4.28:** Deney 2 için Bulanıklık, Kontrast ve Parlaklık için Sabit Etkilerin Katsayısı

<b>Sabit Etkiler</b>	<b>Tahmin</b>
Kesişim Noktası	3.506
mod_type1/2-1 4Hot	-0.09201
mod_type1/2-1 Heterogen	-0.2083
mod_type1/2-1 Homogen	-0.5226
mod_type1/3-2/3-1 2Hot	0.1467
mod_type1/3-2/3-1 4Hot	0.1042
mod_type1/3-2/3-1 Heterogen	-0.1149
mod_type1/3-2/3-1 Homogen	-0.3556
mod_type1/4-1/2-3/4-1 2Hot	0.2208
mod_type1/4-1/2-3/4-1 4Hot	-0.02865
mod_type1/4-1/2-3/4-1 Heterogen	-0.1991
mod_type1/4-1/2-3/4-1 Homogen	-0.5712
mod_type1/4-1/2-3/4 2Hot	0.1999
mod_type1/4-1/2-3/4 4Hot	0.1085
mod_type1/4-1/2-3/4 Heterogen	-0.1230
mod_type1/4-1/2-3/4 Homogen	-0.4913
GenderMale	0.07695
Yaş	-0.01465

İşte matrisin ilk birkaç değişkenine dayalı olarak basitleştirilmiş bir yorum:

Bu durumda,

Kesişim noktası (kırpma veya sabit) katsayısı, diğer tüm değişkenlerin değeri sıfır olduğunda modelin tahmin ettiği sonucun değeridir. Burada, kırpma değeri 3.506'dır.

mod\_type1/2-1 4Hot, mod\_type1/2-1 Heterogen, mod\_type1/2-1 Homogen ve benzeri katsayılar, belirli bir "mod\_type" değeri için sonuca olan etkilerini gösterir. Örneğin, mod\_type1/2-1 4Hot değişkeni bir birim değiştiğinde, sonuç değişkeninin değeri -0.09201 (veya -9.201e-02) birim değişir. Yani, bu değişkenin etkisi negatiftir.

Sonuç olarak, bu regresyon modeli, çeşitli değişkenlerin sonuç üzerindeki etkilerini gösterir. mod\_type değişkenlerinin çoğu, sonucu azaltma eğiliminde olan negatif katsayılara sahiptir. Bu, mod\_type değişkenlerinin değerleri arttıkça, modelin tahmin ettiği sonucun genellikle azalacağını gösterir. Bununla birlikte, mod\_type1/3-2/3-1 2Hot, mod\_type1/3-2/3-1 4Hot, mod\_type1/4-1/2-3/4-1 2Hot ve mod\_type1/4-1/2-3/4 2Hot değişkenlerinin pozitif katsayıları vardır, bu da bu değişkenlerin değerlerinin artmasının sonucu artıracığını gösterir.

Diğer değişkenler, "mod\_type" içindeki farklı alt kategoriler altında farklı bir desen izler. Ayrıca, cinsiyeti temsil eden "GenderMale" ve yaşa karşılık gelen "Yaş" olmak üzere iki değişken daha bulunmaktadır.

GenderMale değişkeninin katsayısı pozitif olduğuna göre, cinsiyetin erkek olması sonuç değişkenini 0.07695 (veya 7.695e-02) birim artırır. Cinsiyetin erkek olması modelin tahmin ettiği sonucu artırır.

Yaşın katsayısı negatif, bu da yaşın artmasıyla bağımlı değişkenin ortalama olarak her bir yaş için -0.01465 birim azaldığını gösterir.

Korelasyon matrisi, doğrusal karma modelindeki sabit etkiler arasındaki ilişkiler hakkında bilgi sağlar. Genel olarak, sabit etkiler arasındaki yüksek korelasyon, kararlı olmayan tahminler ve güvenilir olmayan sonuçlara yol açabilen çoklu doğrusallığı işaret eder. Ancak, bu matristeki küçük değerler, bu modelde çoklu doğrusallığın önemli bir sorun olmayabileceğini göstermektedir.


Sonuç olarak, korelasyon matrisi, doğrusal karma modelindeki sabit etkiler arasındaki ilişkileri aydınlatır. mod\_type kategorileri arasında bazı ilişkiler gözlemlenirken, cinsiyet ve yaşın bağımlı değişkenle önemli korelasyonları olmadığı görülmektedir. Sonuçların tam olarak anlaşılması ve modeldeki en anlamlı tahmincilerin belirlenmesi için daha fazla analiz gerekmektedir.

#### 4.8.2 Bulanıklık, kontrast ve parlaklık düzeyleri için deney 2 sonrası yapılan test (Post-Hoc)

Sonuçlar, mod\_type, cinsiyet ve yaş faktörlerinin çeşitli kombinasyonlar arasındaki farklılıkları karşılaştıran bir dizi testi göstermektedir. Her karşılaştırma, bir grup arasındaki ortalama farkı, standart hatayı, t-oranını ve p-değerini içerir. Anlamlı bulgular (genellikle  $p < 0.05$  olarak kabul edilir) belirli gruplar arasında anlamlı farklılıklar olduğunu gösterir.

İşte bazı önemli sonuçlar:

- *(1/2-1 2Hot Female Age32.3177083333333) - (1/2-1 Homogen Female Age32.3177083333333)*: Bu karşılaştırma, 2Hot ve Homogen işlem türleri arasında kadın katılımcılar için önemli bir fark olduğunu göstermektedir. Ortalama fark 0.522569'dur ve p-değeri  $<.0001$ 'dir, bu da Homogen grubunun 2Hot grubuna göre anlamlı derecede daha yüksek bir değere sahip olduğunu gösterir.
- *(1/2-1 2Hot Female Age32.3177083333333) - (1/3-2/3-1 Homogen Female Age32.3177083333333)*: Bu karşılaştırma, 1/2-1 2Hot ve 1/3-2/3-1 Homogen işlem türleri arasında kadın katılımcılar için önemli bir fark olduğunu gösterir. Ortalama fark 0.355613'dir ve p-değeri  $<.0001$ 'dir, bu da 1/3-2/3-1 Homogen grubunun 1/2-1 2Hot grubuna göre anlamlı derecede daha yüksek bir değere sahip olduğunu gösterir.
- *(1/2-1 2Hot Female Age32.3177083333333) - (1/4-1/2-3/4-1 Homogen Female Age32.3177083333333)*: Bu karşılaştırma, 1/2-1 2Hot ve 1/4-1/2-3/4-1 Homogen işlem türleri arasında kadın katılımcılar için önemli bir fark olduğunu göstermektedir. Ortalama fark 0.571181'dir ve p-değeri  $<.0001$ 'dir, bu da 1/4-1/2-3/4-1 Homogen grubunun 1/2-1 2Hot grubuna göre anlamlı derecede daha yüksek bir değere sahip olduğunu gösterir.



**Şekil 4.70:** Deneş 2 Bulanıklık, Kontrast ve Parlaklık için Tukey Düzeltmeleri ile Tahmini Marjinal Ortalamalar

Bu sonuçlar, mod\_type ve cinsiyet faktörlerinin yanıt değişkeni üzerinde önemli etkileri olduğunu ve belirli işlem türlerinin (özellikle Homogen) diğerlerine göre belirgin bir avantaj sağlayabileceğini göstermektedir. Özellikle, Homogen işleme türünün diğer türlere göre genellikle daha iyi performans gösterdiği görülmektedir. Bu bulgular, araştırmacılara bu faktörlerin sonuçlar üzerindeki etkisini daha iyi anlama ve belirli koşullar altında hangi işlem türlerinin daha etkili olabileceğini belirleme konusunda rehberlik edebilir (Şekil 4.70).

## 5.PSİKOLOJİK SONUÇLAR

### 5.1 Psikolojik Etkilerin Genel Bakışı

Bu bölüm, bulanıklık, kontrast ve parlaklık gibi faktörlerin ayarlanması yoluyla Çoklu Nesne Takibi (ÇNT) performansı üzerindeki psikolojik sonuçları incelemektedir. Bu faktörlerin insan psikolojisi ve dikkat mekanizmaları üzerindeki etkileri, Scholl (2009), Carrasco (2006), Alvarez & Franconeri (2007) ve Cavanagh & Alvarez (2005) tarafından yapılan önemli çalışmaların bulgularını entegre ederek değerlendirilmektedir.

*Bulanıklık:* Alvarez & Franconeri (2007), artan bulanıklığın dikkati dağıtıcı etkileri ve nesnelere takip etme yeteneğinin azalması arasındaki ilişkiyi araştırmışlardır. ÇNT görevlerinde, bireylerin aynı anda birden fazla nesneyi takip etmeleri gerektiğinden, her bir nesnenin bulanıklığı, bu nesnelere birbirinden ve arka plandan ayırt etmeyi daha zor hale getirebilir. Bu, özellikle hareketli nesnelere arasında hızlı geçişler sırasında dikkat dağınıklığına ve takip hatalarına yol açabilir.

*Kontrast:* Carrasco (2006) ve meslektaşları, yüksek kontrastın görsel dikkati artırabileceğini ve böylece bilişsel süreçleri etkileyebileceğini belirtmiştir. ÇNT görevlerinde, yüksek kontrast, bireylerin takip ettikleri nesnelere arka plandan ayırt etmelerini kolaylaştırabilir, takip etkinliğini iyileştirebilir. Bu, yüksek kontrastın görsel alandaki birden fazla nesne arasında dikkati daha hızlı ve daha doğru bir şekilde tahsis etmeye yardımcı olabileceğini öne sürmektedir.

*Parlaklık:* Scholl (2009) tarafından yapılan çalışmalar, artan parlaklığın dikkati çekme yeteneğini artırdığını göstermiştir. ÇNT görevlerinde, takip edilen nesnelere parlaklığı, onları daha dikkat çekici hale getirebilir, böylece takibini kolaylaştırabilir. Ancak, aşırı parlaklık göz yorgunluğuna veya dikkatin dağılmasına yol açabilir, performansı olumsuz etkileyebilir.

Özetle, ÇNT performansı görsel manipülasyonlardan önemli ölçüde etkilenmektedir. Bulanıklık, kontrast ve parlaklık gibi faktörler, bir bireyin birden fazla nesneyi etkili bir şekilde takip etme yeteneğini doğrudan etkileyebilir. Bu

faktörlerin optimizasyonu, daha verimli dikkat mekanizmalarına ve dolayısıyla ÇNT görevlerinde daha yüksek performansa yol açabilir.

## 5.2 Bilişsel Yük ve Çoklu Nesne Takibi Performansı

Deneysel kanıtlara dayanarak bulanıklık, kontrast ve parlaklığın ÇNT performansı üzerindeki etkileri, Sweller (1988) tarafından ilk kez önerilen bilişsel yük kavramı bağlamında değerlendirilmektedir. Bu, bireylerin bilişsel işleme sırasında sınırlı bir çalışma belleği kapasitesine sahip olduğunu öne sürer, "çeşitli talepler" veya "yükler" ile sınırlanır.

Çalışmamız, bulanıklık, kontrast ve parlaklıktaki değişikliklerin, birden fazla nesneyi takip etme ile ilişkili bilişsel yükü nasıl etkileyebileceğini araştırdı. Örneğin, görsel bilgileri ayırt etmek daha zor hale geldiğinde, yüksek bulanıklık veya düşük kontrast nedeniyle, bilişsel kaynaklara olan talepler artabilir, birden fazla nesneyi takip etmek için daha az kapasite bırakabilir.

Bu kavram, Lavie'nin (2005) algısal yük teorisine uyumludur, bu teori görev taleplerinin dikkat kaynaklarının tahsisini belirleyebileceğini öne sürmektedir. Yüksek algısal yüklü görevlerde, tüm dikkat kaynaklar tükenir, alakasız uyarıcıların işlenme olasılığı azalır. Buna karşılık, düşük yüklü görevlerde, yedek dikkat kaynakları çevresel ve alakasız uyarıcıları işlemek için kullanılabilir.

Bulanıklık, kontrast ve parlaklığın deneysel olarak manipüle edilerek, görevlerin algısal yükünü etkili bir şekilde manipüle ettiğimizde, yüksek algısal yük koşulları altında (yüksek bulanıklık, düşük kontrast), katılımcılar dikkat kaynakları üzerinde artan talepler nedeniyle birden fazla nesneyi takip etmekte daha zorlanmış olabilirler.

Parlaklıkla ilgili bulgularımız ilgi çekicidir. Parlaklık, nesne algısını kolaylaştırabilir ve bilişsel yükü azaltabilirken, aşırı yüksek parlaklık rahatsızlık veya parıltı yaratabilir, bilişsel yükü artırabilir. Bulgularımız bu hassas dengeyi yansıtıyor gibi görünmektedir.

Bu gözlemler, gelecekteki çalışmaların, özellikle zorlu görsel koşullar altında ÇNT görevlerini tasarlarırken ve yorumlarırken bilişsel ve algısal yükü ana değişkenler olarak dikkate alması gerektiğini öne sürmektedir, çünkü bunlar, birden fazla nesneyi takip etme ile ilgili bilişsel süreçleri daha iyi anlamamıza yardımcı olabilir.

Bu bölüm, araştırmamızdan 4.1'den 4.8'e kadar olan bölümlerde sunulan bulgular üzerine inşa edilmiştir. Bulanıklık, kontrast ve parlaklık manipülasyonlarının özellikle ÇNT ile ilgili önemli bilişsel işlevler üzerindeki etkilerini daha ayrıntılı bir şekilde incelemektedir.

### **5.2.1 Bulanıklık manipülasyonları ve bilişsel performans**

Çalışmamızda, artan bulanıklığın ÇNT performansını önemli ölçüde etkilediğini bulduk. Bulanıklık seviyesi arttıkça, katılımcılar birden fazla nesneyi takip etmekte daha fazla zorluk yaşadı. Bu bulgu, bulanıklığın görsel arama görevleri ve çevresel nesne tanıma üzerindeki olumsuz etkilerini gösteren önceki araştırmalar Rosenholtz (2011) ve Kwon vd. (2014) ile tutarlıdır. Bu sonuçlar, bulanıklığın beynin bilgiyi etkin bir şekilde işleme yeteneğini karmaşıktırarak görsel uyaranlara bağlı bilişsel görevlerin doğruluğunu ve hızını azaltabileceğini öne sürmektedir.

### **5.2.2 Kontrast manipülasyonları ve bilişsel performans**

Analizimiz ayrıca, kontrast manipülasyonlarının ÇNT performansını etkilediğini ortaya koydu. Nesne kontrastındaki bir azalma, katılımcıların birden fazla nesneyi etkili bir şekilde takip etme yeteneklerini bozdu. Bu gözlem, düşük kontrastın görsel ayrıntıları ayırt etme ve nesnelere tanıma yeteneğini azaltabileceğini öne süren önceki çalışmaları (örneğin, Owsley vd., 2001; Pelli vd., 2004) yansıtmaktadır. Bu bulgular, kontrastın görsel olarak zorlu görevlerde optimal bilişsel işlevselliği sürdürmek için kritik bir öge olduğunu göstermektedir.

### **5.2.3 Parlaklık manipülasyonları ve bilişsel performans**

Çalışmamız ayrıca parlaklığın ÇNT performansı üzerindeki etkisini değerlendirdi. Hem aşırı yüksek hem de düşük parlaklık seviyelerinin ÇNT performansını olumsuz etkilediği gözlemlendi. Bu bulgu, parlaklık değişikliklerinin görsel arama görevlerindeki etkileri üzerine yapılan önceki araştırmalarla (örneğin, Rea vd., 2005; Ekstrom vd., 2008) tutarlıdır. Sonuçlar, görsel işlemeye dayalı görevlerin aşırı ve yetersiz parlaklık tarafından engellenebileceğini öne sürmektedir.

#### 5.2.4 Bulanıklık, kontrast ve parlaklık etkileşimi

Denelerimiz bulanıklık, kontrast ve parlaklık arasındaki karmaşık etkileşimin ÇNT performansı üzerindeki etkisini gösterdi. Her faktör bağımsız olarak bilişsel performansı etkilerken, birleşik etkileri belirli görev ve görsel koşullara bağlı olarak değişebilir. Bu bulgu, görsel faktörlerin etkileşiminin, basit harf tanıma görevlerinden karmaşık görsel arama görevlerine kadar çeşitli görevlerde bilişsel performansı etkileyebileceğini gösteren Legge vd.(1987) ve Barbur vd.(1992) tarafından yapılan araştırmalarla tutarlıdır. Bu etkileşimleri anlamak eğitimden, insan-bilgisayar etkileşimine kadar çeşitli uygulamalar için daha etkili görsel ekranlar ve ortamların geliştirilmesine katkıda bulunabilir.

Araştırma bulgularımız, bulanıklık, kontrast ve parlaklık gibi faktörlerdeki değişikliklerin bilişsel performansı önemli ölçüde etkileyebileceğini göstermektedir. Bulanıklık arttıkça veya kontrast ve parlaklık azaldıkça, görsel netlik azalır, bilişsel yük artabilir ve görev performansı potansiyel olarak etkilenebilir. Verilerimiz, Galy vd.(2012) gibi çalışmalarda gösterildiği gibi, yüksek görsel dikkat gerektiren görevlerde performansın görsel netlikteki bir azalmadan olumsuz etkilenebileceğini öne sürmektedir.

Performansı etkileyen faktörlerin sadece bulanıklık, kontrast veya parlaklıkta bireysel değişiklikler olmadığını anlamak önemlidir. 4.1'den 4.8'e kadar olan bölümlerde incelendiği gibi, bu faktörlerin birleşik etkileri karmaşık ve doğrusal olmayabilir ve bilişsel performansı, her faktörü izole bir şekilde anlasak bile kolayca tahmin edilemeyen yollarla etkileyebilir. Örneğin, yüksek kontrast ve parlaklığın birleşimi, artan bulanıklığın bazı olumsuz etkilerini hafifletebilir. Bu karmaşık etkileşimler, işyeri ayarlarında görsel koşulların kapsamlı bir değerlendirilmesi ve yönetilmesi gerekliliğini vurgulamaktadır.

Özetle çalışmamız, görsel manipülasyonların bilişsel performans üzerindeki etkilerine daha derin bir anlayış sağlar. Önceki araştırmalara dayanarak, görsel olarak bağımlı bilişsel görevlerde performansı etkileyen bulanıklık, kontrast ve parlaklığın etkileşimlerini inceleriz ve kullanıcı arayüzleri, eğitim programları ve diğer uygulamalar için değerli içgörüler sunarız.

### **5.3 Algı ve Performanstaki Bireysel Farklılıklar**

Bulanıklık, kontrast ve parlaklığın ÇNT performansı üzerindeki etkilerini inceleyen bu çalışmada, algı ve performanstaki bireysel farklılıkları dikkate almak kritik önem taşımaktadır. Deneysel bulgularda yaş ve cinsiyetin önemli etkileri gözlemlendi.

Görsel algıda yaşın önemli bir rol oynadığını destekleyen çok sayıda çalışma bulunmaktadır. Yaşlanma, kontrast duyarlılığı (Owsley, 2011), renk algısı (Werner, 1992) ve dinamik görsel keskinlik (Habak & Faubert, 2000) gibi çeşitli görsel alanlardaki düşüşlerle ilişkilendirilmiştir. Bu bağlamda, yaşlı katılımcıların ortalama olarak daha düşük puanlar alması -özellikle değişken bulanıklık, kontrast ve parlaklık gibi daha zorlayıcı koşullar altında birden fazla nesneyi takip etmekte daha zorlanmaları- geniş bilimsel literatürle tutarlıdır. Bu, yaşla ilişkili görsel algıda düşüşlerin bir sonucu olarak beklenen bir durumdur.

Cinsiyet farklılıkları söz konusu olduğunda, bulgularımız erkek katılımcıların ortalama olarak kadın katılımcılardan daha yüksek puanlar aldığını göstermektedir. Ancak, bilimsel literatür ÇNT performansı üzerinde cinsiyetin etkisi konusunda karışık sonuçlar sunmaktadır. Bazı çalışmalar, erkeklerin belirli mekânsal görevlerde kadınlardan daha iyi performans gösterebileceğini öne sürerken (Voyer, & Bryden, 1995), diğerleri önemli cinsiyet farklılıkları bulamamış veya yalnızca minimal bulgular rapor etmiştir (Faubert, 2013). Çalışmamızda gözlemlenen cinsiyet farklılıklarının ardındaki nedenler çok yönlü olabilir ve daha fazla araştırma gerektirir.

Görsel algı üzerine çalışmalar tasarlarırken ve yorumlarırken bu bireysel farklılıkları dikkate almak önemlidir. Algı ve performansı etkileyebilecek faktörler olan yaş ve cinsiyet gibi faktörleri kabul etmek, birden fazla nesneyi takip etme ve gerçek dünya uygulamalarını daha nüanslı bir şekilde anlamamıza yardımcı olabilir.

### **5.4 Dikkat Kaynakları, Çalışma Belleği, Nesne Tanıma, Görev Karmaşıklığı, Motivasyon ve Katılımın Rolü**

Dikkat kaynakları, çalışma belleği, nesne tanıma, görev karmaşıklığı, motivasyon ve katılımın rolü gibi birçok faktör ÇNT performansında önemli roller oynamaktadır. İşte bilimsel literatürle karşılaştırmalarımız:

*Dikkat Kaynakları:* Dikkat, ÇNT görevlerinde, görevin taleplerine bağlı olarak tahsis edilen kritik bir kaynaktır (Cavanagh & Alvarez, 2005). Bulgularımız, farklı bulanıklık, kontrast ve parlaklık koşullarının başarılı nesne takibi için farklı dikkat seviyeleri gerektirdiğini öne sürerek, bu görsel faktörlerin dikkat kaynaklarının tahsisini önemli ölçüde etkileyebileceği fikrini desteklemektedir.

*Çalışma Belleği:* Çalışma belleği kapasitesi, nesnelere takip ederken bilgiyi tutma ve işleme yeteneği, ÇNT performansını etkileyebilir (Oksama & Hyönä, 2016). Çalışmamız doğrudan çalışma belleğini ölçmemesine rağmen, koşullar arasındaki performans farklılıkları dolaylı olarak katılımcıların çalışma belleği kapasitelerini yansıtır olabilir.

*Nesne Tanıma:* Araştırmalar, nesnelere ayırt edilebilir ve tanımlanabilir olduğunda ÇNT'nin daha kolay olduğunu göstermektedir (Horowitz vd., 2007). Ancak, çalışmamızda, bulanıklık, kontrast ve parlaklık koşulları altında nesnelere ayırt edilebilirliği azalmış olabilir, bu da takip performansının azalmasına yol açmış olabilir.

*Görev Karmaşıklığı:* Görev karmaşıklığı, bilişsel kaynakların tahsisini ve dolayısıyla performansını etkileyebilir (Puma vd., 2018). Çalışmamızda, bulanıklık, kontrast ve parlaklık manipülasyonlarının eklenmesi, takip görevine ek karmaşıklık getirdi ve performans varyasyonlarına yol açtı. Bu görsel değişiklikler, görev karmaşıklığını artırabilir, ek bilişsel kaynaklar gerektirebilir, algısal işlemeyi karmaşıklatabilir ve takip performansını azaltabilir.

*Motivasyon:* Bir görevde iyi performans gösterme konusunda daha motive olan bireyler genellikle daha iyi performans sonuçları elde eder. Bu etki, motivasyonun artan konsantrasyon, ısrar ve çaba ile ilişkilendirilmesinden kaynaklanabilir (Murayama, Pekrun, & Fiedler, 2014). Böylece, motivasyon, bireylerin bir göreve ne kadar dikkat ve çaba harcayacakları üzerinde etkili olabilir, ÇNT görevlerindeki performansını etkileyebilir.

*Katılımın Rolü:* Katılım da önemlidir çünkü katılım seviyesi performans sonuçlarını etkileyebilir. Çalışmalar, daha yüksek görev katılımının performans iyileşmelerine yol açabileceğini öne sürmektedir. Bireyler bir göreve aktif olarak katıldıklarında, başarılı performans için gerekli bilişsel kaynakları yatırım yapma olasılıkları daha yüksektir, bu da daha iyi sonuçlara yol açar (Rosen, 2006).

Bulgularımız, 4.1'den 4.8'e kadar olan bölümlerden yapılan gözlemleri yansıtmaktadır. Farklı görsel değişikliklerin takip performansı üzerindeki etkilerini analiz ederken, katılımcıların motivasyon ve katılım seviyeleri önemli katkıda bulunan faktörler olabilir. Görevlere daha motive ve aktif olarak katılan bireyler, daha karmaşık görsel koşullar altında bile nesnelere takip etmede daha iyi performans gösterebilir.

### **5.5 Algı ve Performans Verilerindeki Aykırı Değerler**

Algı ve performans verilerindeki aykırı değerlerin çalışma sonuçları ve yorumları üzerinde önemli etkileri olabilir.

Aykırı değerler, ölçüm hataları, bireysel farklılıklar ve alışılmadık deneysel koşullar gibi çeşitli faktörlerden kaynaklanabilir. İstatistiksel sonuçlar üzerinde önemli etkileri olabilir, ortalama değerleri çarpıtabilir ve değişkenliği artırabilir. Doğru şekilde ele alınmazsa, bu yanıltıcı sonuçlara yol açabilir (Rousseuw & Leroy, 2005).

Psikoloji ve algı çalışmalarında, aykırı değerler genellikle gerçek bireysel farklılıkları temsil eder. Bazı bireyler, benzersiz bilişsel veya algısal yetenekler nedeniyle bir görevde önemli ölçüde daha iyi veya daha kötü performans gösterebilir. Bu aykırı değerleri hemen dışlamak yerine, insan yeteneklerinin aralığı ve dağılımı hakkında değerli içgörüler sağlayabilecekleri için dikkate alınmalıdır (Crawford & Howell, 1998).

4.1'den 4.8'e kadar olan bölümlerden yapılan analizlerle belirlenen aykırı değerler, ÇNT görevlerinde özellikle başarılı veya zorlanan katılımcıları temsil edebilir. Bunlar, algısal yetenekler, bilişsel kaynaklar veya katılım ve motivasyon seviyeleri açısından bireysel farklılıklardan kaynaklanabilir. Bulguları yorumlarken ve gelecekteki çalışmaları planlarken bu olasılıkları dikkate almak önemlidir.

Aykırı değerler, belirli mod\_type koşullarının alışılmadık performans sonuçlarına yol açması sonucu da ortaya çıkabilir. Bu aykırı değerlerin tam nedenlerini anlamak için daha fazla araştırmaya ihtiyaç vardır.

## 5.6 Bulanıklık, Kontrast ve Parlaklıktaki Değişikliklere Adaptasyon

Algısal adaptasyon, algısal sistemlerin çevresel değişikliklere uyum sağlama yeteneğini ifade eder. Bu, değişken koşullar altında kararlı ve doğru algıyı sürdürmek için hayati öneme sahiptir.

*Bulanıklığa Adaptasyon:* Araştırmalar, görsel sistemin bulanık görüşe adapte olabileceğini göstermektedir (Webster vd., 2002). Bu, bulanık görüntülere maruz kaldıktan sonra, gözlemcilerin daha az bulanık görüntüleri gerçekte olduklarından daha keskin olarak algılayabilecekleri anlamına gelir. ÇNT bağlamında, katılımcılar bulanık koşullara adapte olabilir, bu da zamanla takip performanslarını etkileyebilir.

*Kontrasta Adaptasyon:* Görsel sistem ayrıca kontrast değişikliklerine de adapte olur (Bex vd., 1995). Bu, düşük kontrastlı görüntülere maruz kaldıktan sonra, gözlemcilerin normal kontrastlı görüntüleri gerçekte olduklarından daha yüksek kontrasta sahip olarak algılayabilecekleri anlamına gelir. Araştırma perspektifinden, bu, katılımcıların farklı kontrast koşulları altında nesnelere ayırt etme ve takip etme şeklini etkileyebilir.

*Parlaklığa Adaptasyon:* Benzer mekanizmalar parlaklığa adaptasyon için de geçerlidir (Fairchild & Reniff, 1995). Parlak veya loş koşullara uzun süre maruz kalmak, nötr koşulların sırasıyla daha parlak veya daha loş olarak algılanmasına neden olabilir. Bu, katılımcıların farklı parlaklık koşulları altında takip performanslarını potansiyel olarak etkileyebilir.

Çalışma sonuçlarını yorumlarken algısal adaptasyonu dikkate almak önemlidir. Farklı mod\_type koşulları altında takip performansındaki değişiklikler, katılımcıların algısal sistemlerinin bu koşullara adapte olmasından kaynaklanıyor olabilir. Gelecekteki çalışmalar, bu olasılığı daha doğrudan keşfedebilir, takip görevinden önce ve sonra katılımcıların algılarını ölçebilir veya göreve başlamadan önce bir adaptasyon dönemi içerebilir.

## 5.7 Görsel Özelliklerin Etkileşimi

Bulanıklık, kontrast ve parlaklık gibi görsel özelliklerin etkileşimi, bilişsel ve algısal görevler üzerinde önemli etkileri olan karmaşık bilişsel ve algısal etkilere sahiptir. Görsel algı alanındaki araştırmalar, beyin bu görsel özellikleri izole bir

şekilde değil, bütünsel olarak yorumladığını ve nesne tanıma, dikkat tahsisi ve ÇNT gibi görevleri etkilediğini öne sürmektedir.

*Bulanıklık ve Görsel Algı:* Araştırmalar, görüntü bulanıklığının derinlik, mekânsal düzen ve hareket algısını etkileyebileceğini bulmuştur (O'Shea vd., 1997; Pantle vd., 2000). ÇNT bağlamında, bulanıklık birden fazla nesnenin netliğini azaltabilir, bu da onları etkili bir şekilde takip etme yeteneğini potansiyel olarak bozabilir.

*Kontrast ve Bilişsel Yük:* Yüksek kontrast genellikle artan görünürlük ve azaltılmış bilişsel yük ile ilişkilendirilirken, düşük kontrast koşulları görsel görevlerin zorluğunu artırabilir (Pelli vd., 2004). ÇNT görevinde, kontrast değişiklikleri nesnelerin ayırt edilebilirliğini etkileyebilir, böylece takip performansını etkileyebilir.

*Parlaklık ve Dikkat Tahsisi:* Parlaklık değişiklikleri dikkati çekebilir ve nesnelerin algılanan önemini değiştirebilir; daha parlak nesneler genellikle daha önemli veya dikkat çekici olarak algılanır (Carrasco vd., 2004). Bu, katılımcıların bir ÇNT görevinde dikkatlerini nasıl tahsis ettiklerini etkileyebilir.

*Görsel Özelliklerin Etkileşimi:* Son araştırmalar, bu görsel özellikler arasındaki karmaşık etkileşimi vurgulamaktadır. Örneğin, bulanıklık ve kontrast birlikte derinlik algısını etkileyebilir (Watt & Morgan, 1983), kontrast ve parlaklık algılanan nesne boyutunu etkileyebilir (Anstis vd., 1978). Bu özelliklerin kombinasyonlarının ÇNT performansı üzerindeki etkilerini anlamak önemli bir araştırma alanıdır.

Tüm bu bilimsel bulgular bulanıklık, kontrast ve parlaklık değişikliklerinin hem bireysel hem de etkileşimli olarak, ÇNT performansını önemli ölçüde etkileyebileceğini göstermektedir. Bu etkileri anlamak, görsel görevlerde bilişsel ve algısal süreçlere ilişkin değerli içgörüler sağlayabilir.

## **5.8 Sonradan Yapılan Analiz Sonuçları (Post-Hoc): Gruplar Arasındaki Farklılıkların Yorumlanması**

Bu araştırmada sonradan yapılan analiz sonuçları, farklı gruplar arasındaki çoklu nesne takibi performansında önemli farklılıklar olduğunu ortaya koymuştur.

Bu, farklı gruplar arasında bilişsel ve algısal işleme mekanizmalarının heterojen doğasını vurgulamaktadır.

Bu bulguların temel psikolojik etkileri şunları içerebilir:

*Bilişsel Yük:* Gruplar arasında ÇNT performansında önemli farklılıklar, bu gruplar arasındaki bilişsel yük farklılıklarını yansıtıyor olabilir. Örneğin, yaşlı katılımcılar veya zorlu görsel koşullar altında olanlar (örneğin, yüksek bulanıklık, düşük kontrast veya aşırı parlaklık) daha yüksek bilişsel yüklerle sahip olabilir, bu da takip görevlerinde daha kötü performansa yol açabilir.

*Dikkat Tahsisi:* Birden fazla nesneyi aynı anda takip etme yeteneği büyük ölçüde dikkat kaynaklarına bağlıdır. Bazı gruplar üstün performans sergiliyorsa, bu, bireysel özellikler veya görsel işlemedeki farklılıklar nedeniyle daha etkili dikkat tahsisi stratejilerine veya daha fazla dikkat kaynağına sahip olduklarını gösterebilir.

*Algısal Duyarlılık:* Bireyler, bulanıklık, kontrast ve parlaklık gibi görsel özelliklerdeki değişikliklere farklı duyarlılıklara sahip olabilir. Örneğin, bazı insanlar parlaklık değişikliklerine daha duyarlı olabilirken, diğerleri kontrast veya bulanıklık farklılıklarından daha fazla etkilenebilir. Bu algısal farklılıklar, gruplar arasındaki takip performansı varyasyonlarına katkıda bulunabilir.

*Motivasyon ve Katılım:* Performans farklılıkları ayrıca gruplar arasındaki motivasyon ve katılım seviyeleriyle de ilişkili olabilir. Bazı gruplar göreve daha motive veya katılımlı olabilir, bu da üstün performansa yol açabilir.

*Deneyim ve Öğrenme:* Performanstaki farklılıklar ayrıca deneyim veya öğrenme farklılıklarını da yansıtabilir. Görevler ile ilgili daha fazla pratik yapma veya maruziyet, bazı gruplara görsel zorlukları daha etkili bir şekilde yönetmeyi öğretebilir, performanslarını artırabilir.

Bu bulgular, görsel takip görevlerinde performansı iyileştirmeyi amaçlayan müdahaleleri tasarlarırken bilişsel, algısal, motivasyonel ve deneyimsel gibi geniş bir faktör yelpazesini dikkate almanın önemini vurgulamaktadır.

## 5.9 Algı ve Performans Çalışmalarında Gelecek Araştırma Yönleri

ÇNT performansı üzerindeki görsel manipülasyonların psikolojik sonuçları üzerine yapılan bu çalışma, algı ve performans alanında gelecekteki araştırmalar için birkaç potansiyel yönlendirme sunmaktadır:

*Görsel özelliklerde daha fazla değişkenliği keşfetme:* Bu araştırma, bulanıklık, kontrast ve parlaklık değişikliklerinin ÇNT performansı üzerindeki etkilerini araştırdı. Gelecek çalışmalar renk, hareket veya mekânsal frekans gibi diğer görsel özelliklerin etkilerini inceleyebilir.

*Çoklu görsel özelliklerin etkileşimini inceleme:* Görsel özelliklerin etkileşimi, bilişsel süreçler ve algı üzerindeki etkisi karmaşık bir konudur. Gelecek araştırmalar, farklı görsel özellik kombinasyonlarının nesne takip görevlerinde algı ve performansı nasıl etkilediğini daha ayrıntılı bir şekilde inceleyebilir.

*Çalışmayı çeşitli popülasyonlara genişletme:* Gelecek araştırmalar ayrıca çalışmayı çocuklar, yaşlı yetişkinler veya Dikkat Eksikliği ve Hiperaktivite Bozukluğu veya görsel engellilik gibi belirli durumları olan bireyler gibi farklı popülasyonlara genişletebilir ve algı ve performanslarının nasıl farklılık gösterebileceğini keşfedebilir.

*Dikkat ve çalışma belleğinin rolünü daha kapsamlı inceleme:* Bu çalışma, ÇNT görevlerinde dikkat ve çalışma belleğinin önemli rollerini vurguladı. Gelecek araştırmalar, bu bilişsel süreçlerin rollerini ve bu tür görevlerde nasıl etkileşime girdiklerini daha derinlemesine inceleyebilir.

*Performansı iyileştirme stratejilerini keşfetme:* Daha fazla araştırma, nesne takip görevlerinde performansı iyileştirmek için farklı stratejiler veya müdahaleleri araştırabilir. Bu, eğitim programları, görsel yardımcıları veya dikkat tahsisini optimize etme tekniklerini içerebilir.

*Öğrenme ve adaptasyonun rolünü inceleme:* Gelecek araştırmalar ayrıca ÇNT görevlerinde öğrenme ve adaptasyonun rolünü de keşfedebilir. Görevlere tekrarlanan maruziyetin performansı nasıl değiştirdiği ve insan algısal sisteminin zaman içinde görsel özelliklerdeki değişikliklere nasıl adapte olduğu incelenebilir.

Bu yönlendirmeleri takip etmek, insan algısı ve performansı hakkında daha zengin bir anlayışa katkıda bulunabilir ve eğitim, bilişsel psikoloji, ergonomi ve insan-bilgisayar etkileşimi gibi alanlar için değerli içgörüler sunabilir.

### 5.10 Daha Geniş Psikolojik Teorilerle Entegrasyon

ÇNT performansı üzerindeki görsel manipülasyonların incelenmesi, bilişsel yük teorisi, dikkat kaynakları teorileri ve görsel bilgi işleme modelleri gibi daha geniş psikolojik teorilerle entegrasyon fırsatları sunar. Bu entegrasyon, psikolojik araştırmanın kapsamını genişletebilir, bilişsel işlevler ve dikkat süreçleri hakkında daha derin bir anlayış sağlayabilir. Entegrasyon için potansiyel yollar şunları içerebilir:

*Bilişsel yük teorisi ile uyum:* Görsel manipülasyonların bilişsel yüke etkilerini araştırmak, bilişsel yük teorisi ile uyumludur. Görsel özelliklerin netlik, parlaklık ve kontrast gibi görsel özelliklerin bilişsel işlemeyi nasıl etkilediğini anlamak, bilgi işleme kapasitesini optimize etme modellerine katkıda bulunabilir, eğitimde, kullanıcı arayüzü tasarımında ve bilgi görselleştirmede etkili stratejiler geliştirilebilir.

*Dikkat kaynakları teorileri ile entegrasyon:* Görsel manipülasyonların dikkat dağıtımını ve yönetimi üzerindeki etkileri, dikkat kaynakları teorileri ile entegre edilebilir. Bu entegrasyon, özellikle görsel olarak zengin ortamlarda, dikkat kaynaklarının nasıl tahsis edildiği, korunduğu ve görevler arasında bölüdüğü hakkında daha iyi bir anlayış sunabilir, etkili dikkat yönetimi stratejileri üzerine ışık tutabilir.

*Görsel bilgi işleme modelleri ile uyum:* Görsel manipülasyonların algı ve işleme üzerindeki etkilerini araştırmak, görsel bilgi işleme modelleri ile entegre edilebilir. Bu, görsel algı, kodlama, depolama ve geri çağırma süreçleri hakkında daha derin içgörüler sağlayabilir, bireysel farklılıkların görsel bilgi işleme stratejilerini netleştirebilir.

*Nöropsikoloji ve sinirbilimle bağlantılar:* Görsel manipülasyonların bilişsel ve dikkat etkilerini araştırmak, nöropsikoloji ve sinirbilimle bağlantılar kurabilir. Bu bağlantılar, bilişsel işlevler ve dikkat süreçlerinin altında yatan nöral mekanizmalar hakkında içgörüler sunabilir.

*Uygulamalı psikolojiye katkılar:* Bu teorik entegrasyon, özellikle insan faktörleri mühendisliği, eğitimsel psikoloji ve klinik psikoloji gibi alanlarda, görsel tasarım ve sunuma dayalı pratik uygulamaları bilgilendirebilir, insan performansı, öğrenme ve refahı artırmaya yönelik stratejiler sunabilir.

Bu daha geniş teorik entegrasyon, bilişsel psikolojiyi daha kapsamlı ve etkili modeller ve teoriler geliştirerek ilerletebilir, görsel ortamların insan psikolojisi üzerindeki etkilerini daha iyi anlamamızı sağlar ve teknoloji, eğitim, sağlık hizmetleri ve günlük yaşamın çeşitli yönlerinde önemli uygulamalara sahip olabilir.

### **5.11 Gelecekteki Psikolojik Araştırmalar için Çıkarımlar**

Görsel manipülasyonların ÇNT performansı üzerindeki psikolojik etkilerinin incelenmesi, dikkat, algı ve bilişsel süreçlerimizi ilerletme potansiyeline sahiptir. Gelecek araştırmalar şunları keşfedebilir:

*Görsel stresörlerin uzun vadeli etkileri:* Dijital cihazların yaygınlığı göz önüne alındığında, görsel stresörlere (örn., ekran parlaklığı, kontrast seviyeleri, bulanık görüntüler) sürekli maruz kalmanın uzun vadeli psikolojik ve fizyolojik etkilerini araştırmak göz sağlığı, dikkat süresi ve genel psikolojik refah üzerindeki potansiyel etkilerini anlamak için önemlidir.

*Bilişsel yük yönetimi stratejileri:* Görsel manipülasyonların bilişsel yüke etkileri, bilgi işleme ve öğrenme süreçlerini optimize etme stratejilerini özellikle eğitim materyalleri, kullanıcı arayüzleri ve bilgi görselleştirmelerinin tasarımında bilgilendirebilir.

*Demografik çeşitlilikte görsel tasarım:* Demografik özellikler ve görsel faktörler arasındaki etkileşimlerin daha derinlemesine incelenmesi yaş, cinsiyet ve kültürel arka plan gibi faktörleri görsel algı ve işlemede dikkate alarak çeşitli bir kullanıcı tabanı için erişilebilir ve etkili görsel tasarımların geliştirilmesine katkıda bulunabilir. Bireysel yanıtla yapılan ayrıntılı inceleme, eğitim, iş ve eğlence ayarlarında bireyler için optimal görsel ortamlar oluşturularak öğrenme stilleri, yaş, cinsiyet ve diğer demografik özellikleri dikkate alan kişiselleştirilmiş yaklaşımlara yol açabilir.

*Dikkat ve Algının Optimizasyonu:* Görsel manipülasyonların dikkat ve algı üzerindeki etkilerini daha iyi anlamak, trafik yönetimi, hava trafik kontrolü, sağlık

hizmetleri ve acil durum yönetimi gibi alanlarda görsel olarak talepkar ortamlarda performansı artırmaya yönelik stratejiler geliştirmeye katkıda bulunabilir.

Bu sonuçlar, görsel manipülasyonların psikolojik etkileri üzerine gelecekteki araştırmaların, insan dikkati, algısı ve bilişsel süreçleri hakkındaki anlayışımızı önemli ölçüde ilerletebileceğini öne sürmektedir, teknoloji tasarımı, eğitim yöntemleri, sağlık hizmeti uygulamaları ve günlük yaşamın çeşitli yönlerine geniş kapsamlı etkileri olabilir.

## 5.12 Sonuçlar

Araştırma sonuçlarının uygulamalı yönlerini ele alırken, elde edilen bulguların pratikte nasıl kullanılabileceğini ve belirli alanlara nasıl katkıda bulunabileceğini detaylandırmak önemlidir. Bu bağlamda, ÇNT performansını etkileyen görsel manipülasyonların psikolojik sonuçları üzerine yapılan araştırmanın uygulamalı yönleri şu şekilde özetlenebilir:

### 1. Eğitim Materyalleri ve Araçları Tasarımı:

- Görsel netlik, kontrast ve parlaklığın öğrenme materyallerinde dikkatli bir şekilde ayarlanması, öğrencilerin dikkatini çekebilir ve öğrenme sürecini iyileştirebilir. Örneğin, ders kitapları, çevrimiçi eğitim platformları ve interaktif uygulamalar, öğrencilerin dikkatini sürdürebilmesi ve bilgiyi daha iyi işleyebilmesi için optimal görsel kaliteye sahip olmalıdır.
- Bireysel görsel işleme farklılıklarını dikkate alarak, öğrencilere özelleştirilmiş öğrenme deneyimleri sunulabilir. Bu, zayıf görme yeteneğine sahip öğrenciler için yüksek kontrastlı ve büyük metinli materyaller gibi adaptasyonları içerebilir.

### 2. Kullanıcı Arayüzü Tasarımı ve Dijital Ürünler:

- Web siteleri, mobil uygulamalar ve diğer dijital araçlar, kullanıcı dikkatini çekmek ve kullanıcı deneyimini iyileştirmek için görsel manipülasyon prensiplerini uygulayabilir. Yüksek kontrastlı renkler ve net görseller, kullanıcıların aradıkları bilgilere daha hızlı ulaşmalarına yardımcı olabilir.

- Kullanıcıların görsel algı kapasitelerine göre kişiselleştirilebilen arayüzler, geniş bir demografik kullanıcı grubuna hitap edebilir. Örneğin, yaşlı kullanıcılar için büyük fontlar ve düşük görsel yoğunluklu tasarımlar tercih edilebilir.

### 3. Güvenlik ve Gözetim Sistemleri:

- Güvenlik kamerası görüntülerinin analizi ve gözetim sistemlerinde, bulanıklığın azaltılması ve kontrastın artırılması, nesnelerin ve kişilerin daha kolay tanımlanmasını sağlayabilir. Bu, güvenlik açısından kritik olan alanlarda hızlı ve doğru tepkiler verilmesine olanak tanır.
- Görsel işlemede bireysel farklılıklar göz önünde bulundurularak, güvenlik personeli için özelleştirilmiş monitör arayüzleri geliştirilebilir. Bu, personelin görsel bilgileri daha etkili bir şekilde işlemesine ve potansiyel tehditleri daha hızlı tespit etmesine yardımcı olabilir.

### 4. Reklamcılık ve Pazarlama:

- Reklam ve pazarlama materyallerinde görsel faktörlerin optimizasyonu, hedef kitle üzerinde daha büyük bir etki yaratabilir. Parlaklık ve kontrastın etkili bir şekilde kullanılması, ürünlerin ve markaların dikkat çekici hale gelmesini sağlayabilir.
- Müşterilerin demografik özelliklerini ve görsel tercihlerini dikkate alarak tasarlanan reklam kampanyaları, daha geniş bir kitleye ulaşabilir ve marka bilinirliğini artırabilir.

### 5. Sağlık Hizmetleri:

- Görsel algılamayı etkileyen faktörler, tıbbi görüntüleme ve hasta bilgilendirme materyallerinin tasarımında dikkate alınabilir. Örneğin, yüksek kontrast ve netlik, radyolojik görüntülerin daha iyi yorumlanmasına yardımcı olabilir.
- Hastaların görsel yeteneklerine göre kişiselleştirilmiş sağlık bilgilendirmeleri, hasta eğitimi ve uyumunu iyileştirebilir.

Arařtırmanızın bulgularını bu ve benzeri uygulamalı alanlara entegre etmek, görsel manipölasyonların anlaşılmasını ve kullanılmasını genişletirken, toplumun çeřitli kesimlerinin yaşam kalitesini artırmaya katkıda bulunabilir.



## 6. İŞ SAĞLIĞI VE GÜVENLİĞİ SONUÇLARI

### 6.1 Genel Bakış ve Giriş

Bu bölümde, görsel manipülasyonların iş sağlığı ve güvenliği üzerindeki etkilerine derinlemesine ineceğiz. Rupp, Ambike ve Kuchenbecker (2016), Anastasiou ve Koutsombogera (2018) ve Owsley ve McGwin (2004) tarafından yapılan çalışmalar, bu görsel faktörleri optimize etmenin çalışma koşullarını nasıl iyileştirebileceği ve iş güvenliğini nasıl artırabileceği konusunda değerli içgörüler sunar.

Görsel manipülasyonlar, özellikle Çoklu Nesne Takibi (ÇNT) bağlamında önemlidir. Çünkü ÇNT, bireylerin aynı anda birden fazla hareket eden nesneyi takip etme ve tanıma yeteneklerine dayanır. Yüksek hızlı ve riskli çalışma ortamlarında, özellikle trafik kontrolü, acil durum yönetimi ve üretim hatları gibi durumlarda, çalışanların birden fazla görsel uyarıyı etkili bir şekilde takip etmeleri gerekebilir. Burada bulanıklık, kontrast ve parlaklık gibi görsel özellikleri uygun şekilde ayarlamak, çalışanların ÇNT yeteneklerini destekleyebilir, görsel bilgileri daha hızlı ve doğru bir şekilde işlemelerini sağlayabilir. Bu, hata oranlarını azaltır ve iş yerinde güvenliği artırır.

Görsel manipülasyonların etkilerinin demografik özellikler arasında değişkenlik göstermesi, iş yerlerinde çeşitliliğin ve bireysel ihtiyaçların değerlendirilmesinin önemini vurgular. Örneğin, daha düşük kontrast hassasiyetine sahip yaşlı çalışanlar için iş yerinde görsel bilgilerin sunumu daha yüksek kontrast seviyelerinde olabilir. Benzer şekilde, görsel işleme hızı ve dikkat dağılımı cinsiyet veya diğer bireysel farklılıklar nedeniyle değişebilir ve ÇNT görevlerindeki performansı etkileyebilir.

Bu bölüm, ÇNT görevlerinde performansı etkileyebilecek belirli görsel manipülasyon örneklerini vurgulayacak ve bu manipülasyonların iş güvenliğini nasıl artırabileceğini detaylandıracaktır. Ayrıca, çeşitli çalışma ortamlarında görsel manipülasyon stratejilerinin nasıl uygulanabileceğine dair örnekler ve pratik öneriler

sunacak, iş sağlığı ve güvenliği uzmanlarına rehberlik edecektir. Bu, bilinçli tasarım kararları almayı teşvik ederek, çalışanların görsel işleme kapasitelerini optimize etmeye ve daha güvenli ve daha etkili çalışma koşullarına ulaşmaya yardımcı olacaktır.

## 6.2 İş Güvenliğinde Görsel Manipülasyonun Rolü

Bulanıklık, kontrast ve parlaklık değişiklikleri gibi görsel manipülasyonlar, iş konularının güvenliği açısından önemli bir rol oynar, bu kavram hem bulgularımız hem de daha geniş bilimsel literatür tarafından desteklenir. Bu nedenle, gerçekleştirilen görevlerin doğasına ve çalışanların bireysel özelliklerine göre bu görsel parametreleri optimize etmek hayati önem taşır.

Araştırmamız ayrıca, yaş ile çoklu nesne takibi performansı arasında önemli bir negatif ilişki ortaya koymaktadır. Görsel algıdaki yaşla ilgili değişiklikleri göz önünde bulundurarak, görevlerin görsel taleplerini çalışanların yaş demografisine göre ayarlamak önemlidir. Bu, yaşlı çalışanlar için görsel yardımcıları veya teknolojik müdahalelerin uygulanması veya potansiyel olarak görevlerin değiştirilmesi anlamına gelebilir.

Cinsiyet bazı analizlerde önemli bir faktör olarak ortaya çıkmamış olsa da görsel algı ve bilişte cinsiyet farklılıklarını dikkate almak konusunda proaktif bir yaklaşımı savunuyoruz. Bu yönlerin aydınlatılması için daha fazla araştırmaya ihtiyaç vardır ve iş sağlığı ve güvenliği önlemleri, yeni anlayışlara uyum sağlayacak kadar esnek olmalıdır.

Çalışanların rollerinin görsel taleplerini daha iyi anlamalarına ve yönetmelerine yardımcı olmak için eğitim programları da uygulanmalıdır. Bu programlar, çeşitli görsel manipülasyonların performansları üzerindeki etkileri hakkında çalışanları eğitebilir ve olası olumsuz etkileri hafifletmek için stratejiler sunabilir.

Düzenli sağlık kontrolleri ve görme testleri yapılmalıdır. Ortaya çıkan herhangi bir sorun hızlı bir şekilde ele alınarak, çalışanların performansını ve güvenliğini olumsuz etkilemesi önlenmelidir.

Sürekli bir geri bildirim döngüsü hayati önem taşır. İşverenler, çalışanları görsel konfor ve görev performansı hakkında tartışmalara dahil etmelidir. Bu bilgiler daha sonra çalışma ortamını ve uygulamaları buna göre ayarlamak için kullanılabilir.

### **6.3 İş Yerinde Görsel Koşulları Optimize Etme Stratejileri**

Görsel koşulların bilişsel performans üzerindeki önemli etkisi, özellikle çoklu nesne takibi alanındaki anlayışımız göz önüne alındığında, çalışma ortamlarını tasarlama, yönetme ve dikkatli bir yaklaşım gerektirir. Bu bölüm, bilişsel performansı ve genel iş sağlığı ve güvenliğini destekleyerek görsel koşulları optimize etme konusunda pratik stratejiler sunar.

#### **6.3.1 Görsel karmaşıklığı azaltma**

Bulanıklığın görev performansı üzerindeki etkileri gösterildiği gibi, görsel netlik bilişsel işlev için son derece önemlidir. Görsel karmaşıklığı azaltmak ve net, belirgin görüntüler sağlamak, bilişsel yükü azaltabilir ve verimliliği artırabilir.

#### **6.3.2 Kontrast seviyelerini ayarlama**

Bulgularımız, uygun kontrast seviyelerinin diğer görsel bozuklukların, örneğin bulanıklığın olumsuz etkilerini hafifletebileceğini öne sürmektedir. Bu, iş yerindeki görsel ekranlar ve yazılı materyallerde iyi bir kontrasta olan ihtiyacı güçlendirir.

#### **6.3.3 Aydınlatma koşullarını yönetme**

Bulgularımızda ve Smolders ve Kort (2017) gibi çalışmalarla desteklenen parlaklığın bilişsel performanstaki rolü, düşünceli bir aydınlatma tasarımı gerektirir. Parlaklık seviyeleri, bireysel tercihlere ve eldeki özel göreve uygun şekilde ayarlanabilmelidir. Mümkün olduğunda doğal ışıktan yararlanmak önemlidir, çünkü ruh halini ve performansı iyileştirdiği gösterilmiştir (Boubekri vd., 2014).

#### **6.3.4 Görsel ortamları kişiselleştirme**

Yaş ve cinsiyet gibi bireysel farklılıkların, görsel koşulların performans üzerindeki etkilerini aracılık edebileceği anlayışı, görsel ortam tasarımında daha kişiselleştirilmiş bir yaklaşım gerektirir. Kişiselleştirilebilir ekran ayarları gibi

seenekler sunmak, bireylerin grsel ortamlarını ayarlayarak bilişsel performanslarını optimize etmelerine yardımcı olabilir.

### 6.3.5 Dzenli grme deęerlendirmeleri

Son olarak, grsel koşulların bilişsel performans üzerindeki açık etkisi gz nne alındığında, dzenli grme deęerlendirmeleri iř saęlıęı ve gvenlięi protokollerine entegre edilmelidir. Grme sorunlarının erken tespiti ve dzeltilmesi, iř yerindeki performans ve refahı nemli lde iyileştirebilir.

Sonuç olarak, iř yerinde grsel koşulların stratejik ynetimi, bilişsel performans nemli lde artırabilir, hataları azaltabilir ve iř saęlıęı ve gvenlięini destekleyebilir.

## 6.4 İř Gvenlięinde Yaşın Etkisi

Yaşın iř gvenlięi üzerindeki etkisi, bilimsel toplulukta devam eden bir araştırma konusudur ve bulgularımız birçok mevcut alıřmayla tutarlıdır.

*Yaş ve Grsel Performans:* Yaşla ilgili grme deęiřiklikleri, iř gvenlięini nemli lde etkileyebilir. Owsley, Sekuler ve Siemsen (1983) tarafından yapılan bir alıřma, yaşlanmanın iř yerinde ve gnlk hayatta gvenlik iin kritik olan eřitli grsel iřlevleri etkiledięini belirtmektedir. Yaş ile oklu nesne takibi performansı arasında nemli bir negatif iliřki gsteren alıřmamızın bulguları, yaşlı alıřanların bulanıklık, kontrast ve parlaklık gibi grsel maniplasyonları ieren grevlerde zorluklarla karřılařabileceęini doęrulamaktadır.

*Yaş ve Bilişsel Performans:* Yaşın, birçok meslekte gvenli ve etkili performans iin temel olan bilişsel yetenekleri de etkiledięi bilinmektedir. Salthouse (2012) tarafından yapılan bir alıřma, aynı anda birden fazla nesneyi takip etme yeteneęi de dahil olmak zere birçok bilişsel yeteneęin yaşla birlikte azaldıęını ne srmektedir. alıřmamız genel olarak bu bulguları desteklemekte, yaşlı katılımcıların genellikle daha kt takip performansına sahip olduęunu gstermektedir.

*Yaş ve Performans Deęiřkenlięi:* İř saęlıęı ve gvenlięi baęlamında, sadece ortalama performans seviyeleri deęil, aynı zamanda performanstaki deęiřkenlik de nemlidir. MacDonald, Nyberg ve Bckman (2006) tarafından yapılan bir alıřma,

yaşlı yetişkinlerin bilişsel performansta daha büyük bireysel içi değişkenlik sergilediğini belirtmektedir. Çalışmamız benzer sonuçlar ortaya koymakta, katılımcılar arasında önemli rastgele etkileşim varyansı göstermektedir.

Sonuç olarak, bulgularımız yaşın iş güvenliğindeki rolünü vurgulayan bilimsel literatürü yansıtmaktadır. İşverenlerin, yaşlı çalışanların güvenli bir çalışma ortamı sağlamak için görsel ve bilişsel performans üzerindeki yaşlanma etkilerinin farkında olmaları gerekmektedir. Bu, çalışanın yaşına göre görevleri ayarlamayı, görsel ve bilişsel yetenekleri düzenli olarak izlemeyi ve ilgili eğitim programlarını uygulamayı içerebilir.

### 6.5 İş Güvenliğinde Cinsiyetin Rolü

İş güvenliğinde cinsiyetin rolü, yoğun şekilde araştırılan bir alandır ve bulgularımız bu çalışma alanına katkıda bulunur.

*Cinsiyet ve Görsel Performans:* Çalışmamız, birden fazla nesne takibi gerektiren görevlerde erkek katılımcıların genellikle daha iyi performans gösterme eğiliminde olduğunu göstermektedir, bu da mevcut bazı araştırmalarla tutarlıdır. Andreacci vd. (2002) tarafından yapılan bir çalışma, erkeklerin genellikle kadınlara göre daha iyi görsel-mekânsal yeteneklere sahip olduğunu bildirmiştir, bu da çalışmamızda kullanılan görevler gibi faaliyetlerde performansı iyileştirebilir.

*Cinsiyet ve Performans Değişkenliği:* Mevcut çalışma, katılımcılar arasında önemli bir değişkenlik ortaya koymaktadır, bu da cinsiyet farklılıklarına bağlanabilir. Verilerimiz kesin bir sonuca izin vermemekle birlikte, önceki araştırmalar (örn., Silverman vd. 2007) erkeklerin bilişsel performansta kadınlardan daha fazla değişkenlik gösterebileceğini göstermiştir, bu da çalışmamızda gözlemlenen farklılıklara katkıda bulunabilir.

*Cinsiyet ve Mesleki Riskler:* Cinsiyetin mesleki riskler üzerindeki etkisi genellikle biyolojik, sosyal ve psikolojik faktörlerin bir kombinasyonundan etkilenen karmaşık bir meseledir, bu da erkekler ve kadınlar arasında farklılıklara yol açar. Bazı durumlarda, erkekler daha fazla risk alabilir, bu da kazalara veya yaralanmalara yol açabilir (Byrnes, Miller ve Schafer, 1999). Ancak, çalışmamız risk alma davranışını özellikle incelememi ve bulgularımızın bu bağlamda ne anlama geldiğini anlamak için daha fazla araştırmaya ihtiyaç vardır.

Sonuç olarak, çalışmamız görsel ve bilişsel performansta cinsiyet farklılıkları üzerine literatüre katkıda bulunsa da cinsiyet ve iş güvenliği arasındaki karmaşık ilişki hakkında daha fazla şey öğrenilmesi gerekmektedir. Bu ilişkileri anlamak, iş yerindeki tehlikeleri azaltmayı ve herkes için güvenli ve verimli bir çalışma ortamı sağlamayı amaçlayan müdahaleleri geliştirebilir.

## 6.6 Bireysel Değişkenlik ve İş Güvenliği

Çalışmamızda belirtildiği gibi, çoklu nesne takibi görevlerindeki bireysel performans değişkenliği, iş sağlığı ve güvenliği açısından önemli sonuçlar taşır.

*Bireysel Değişkenlik ve Görsel Performans:* Bulgularımız, farklı bulanıklık, kontrast ve parlaklık koşulları altında önemli bireysel farklılıkları vurgulayarak, bu alandaki önceki araştırmaları doğrulamaktadır. Örneğin, Balslev vd. (2021) tarafından yapılan bir çalışma, farklı aydınlatma koşulları altında görsel performansta önemli bireysel değişkenlikler bulmuştur. Bu, görsel olarak talepkar görevleri yerine getirme yeteneğinin bireyler arasında standart olmayabileceğini ve görevlerin bu farklılıkları dikkate alarak tasarlanması gerektiğini öne sürmektedir.

*Görsel Manipülasyona Yanıtlardaki Değişkenlik:* Bulgularımızda vurgulanan farklı türlerdeki görsel manipülasyona yanıtlardaki önemli değişkenlik dikkate değerdir. Bu, bireylerin çeşitli görsel koşullar altında görevleri yerine getirme yeteneklerinin değişebileceğini gösterir, bu kavram mevcut literatür tarafından desteklenir, örneğin Wood vd. (2018) tarafından yapılan bir çalışma, bireylerin görsel hassasiyetinin, özellikle görsel becerilerin yoğun olarak kullanıldığı rollerde ve mesleklerde, görevleri güvenli bir şekilde yerine getirme yeteneklerini etkileyebileceğini öne sürmektedir.

*Yaş, Cinsiyet ve Değişkenlik:* Bulgularımız, yaş ve cinsiyetin bu değişkenliğe katkıda bulunduğunu göstermektedir, bu da Rabbitt vd. (2004) tarafından yapılan bir çalışmanın önerileriyle uyumludur, bu çalışma yaş ve cinsiyetin, görsel işleme dahil olmak üzere bilişsel performanstaki bireysel farklılıklara katkıda bulunabileceğini öne sürmektedir.

Sonuç olarak, iş güvenliğini artırmak için görsel performanstaki bireysel değişkenliği tanımak ve uyum sağlamak hayati önem taşır. Gelecekteki müdahaleler,

bu farklılıkları hesaba katmayı ve bireylerin farklı görsel yeteneklerine hitap eden çalışma koşulları oluşturmayı amaçlamalıdır.

## 6.7 İş Sağlığı ve Güvenliği: Azaltma Stratejileri ve Öneriler

Analizlerimizden elde edilen içgörüler ışığında, görsel koşullar ve bireysel farklılıklar açısından iş sağlığı ve güvenliğini optimize etmeye yönelik azaltma stratejileri ve öneriler sunulmaktadır.

### 1. Görsel Koşullar:

*Monitör Ekranları:* Bulanıklık ve kontrastın performans üzerindeki etkilerini göz önüne alarak, dijital arayüzler (örn., bilgisayar monitörleri) minimum bulanıklık ve ideal kontrast seviyelerine göre optimize edilmelidir. Bu, bireysel kullanıcıların farklı görsel yeteneklerini karşılamak için ayarlanabilir özellikler içerebilir.

*Parlaklık Koşulları:* Birden fazla nesneyi izlemenin gerektiği iş yerlerinde parlaklık seviyelerini kontrol etmek hayati önem taşır. İş yerleri, görsel keskinliği ve takip yeteneğini bozabilecek aşırı parlak veya loş koşullardan kaçınılmalı, ekranlar için optimal aydınlatma sağlanmalıdır.

### 2. Bireysel Farklılıklar:

*Yaşa Uygun Uyarlamalar:* Farklı görsel koşullar altında yaşın performans üzerindeki önemli etkisini göz önüne alarak, iş yerleri yaşlı çalışanlar için uyarlama önlemlerini düşünmelidir. Bu, daha büyük metin boyutları, artan aydınlatma ve görsel izleme gerektiren görevler için ek eğitim veya destek içerebilir.

*Cinsiyete Özgü Düşünceler:* Görsel performans üzerinde cinsiyetin etkisi konusundaki bulgularımız kesin olmasa da gelecekteki araştırma ve politika geliştirme süreçleri cinsiyet farklılıklarını dikkate almalıdır. İş sağlığı ve güvenliği konuları, görsel performansın ötesine geçerek ergonomi, stres yönetimi vb. alanları da içerebilir.

### 3. Veri İzleme ve Devam Eden Araştırma:

*Düzenli İzleme:* İzleme görevleriyle ilgili olarak düzenli veri izleme, iş yerindeki görsel koşullarla ilgili potansiyel sorunları belirlemeye yardımcı olabilir. Sürekli çalışan geri bildirim de herhangi bir göreve ilişkin stres veya zorlukları anlamak ve hafifletmek için değerlidir.

*Gelecek Arařtırmalar:* Görsel kořulların ve bireysel farklılıkların performans üzerindeki etkilerini doęrulamak için daha fazla arařtırmaya ihtiyaç vardır. Pratik müdahalelere odaklanan çalıřmalar, çeřitli iř ortamlarında uygulama için yararlı içgörüler saęlayabilir.

Bu azaltma stratejilerini ve önerileri uygulamak, çalıřanların güvenlięini ve performansını artırabilir ve daha saęlıklı ve üretken bir çalıřma ortamına katkıda bulunabilir. Bu faktörleri anlamak ve kanıta dayalı deęiřiklikler uygulamak, bireysel farklılıkları ve ihtiyaçları dikkate alan destekleyici, kapsayıcı ve düşünceli iř yerleri oluřturma yolunda bir adımdır.

## **6.8 Gerçek Dünya Çalıřma Ortamlarına Bulguların Uygulanması: Vaka Çalıřmaları**

Arařtırmamızdan elde edilen ana bulguları göz önünde bulundurarak, bulanıklık, kontrast ve parlaklık gibi görsel manipölasyonların yanı sıra yař ve cinsiyet gibi bireysel faktörlerin rolünün anlaşılmasının, daha güvenli iř ortamları oluřturmaya nasıl yardımcı olabileceğini gerçek dünya çalıřma ortamlarında görebiliriz.

*İmalat Endüstrisi:* İmalat ortamında, operatörler genellikle keskin görüş gerektiren karmařık makinelerle çalıřır. Görsel manipölasyonların etkileri hakkındaki bulgularımız, daha iyi aydınlatılmış ve daha okunaklı ekran sistemleri tasarlanmasına yardımcı olabilir. Örneęin, parlaklık ve kontrastın performansı nasıl etkiledięi hakkında daha net bir anlayıř, kontrol panelleri, çalıřma istasyonları veya bu ortamlardaki bilgisayar arayüzlerinin tasarımına rehberlik edebilir, potansiyel olarak görsel yorgunluęu azaltabilir ve doęruluęu artırabilir.

*Hava Trafik Kontrolü:* Hava trafik kontrolörleri, ekranlarda birden fazla hareket eden nesneyi izlemek zorundadır, bu da inceledięimiz çoklu nesne takibi görevleriyle yakından ilgilidir. Bireysel yanıtlardaki deęiřkenlięi ve çeřitli görsel kořullar altında yař ve cinsiyetin etkisini göz önünde bulundurarak, eęitim programları ve çalıřma programları bireysel yeteneklere göre uyarlanabilir, güvenlik ve verimlilięi en üst düzeye çıkarabilir.

*Sürüř ve Ulařım:* Gece sürüřü gibi görevler için parlaklık ve kontrastın etkilerini anlamak kritiktir. Çalıřmamızdan elde edilen içgörüler, araç göstergelerinin

veya sokak aydınlatmasının tasarımını iyileştirmeye ve kazaları azaltmaya yardımcı olabilir.

*Sağlık Hizmetleri:* Sağlık hizmetleri ortamlarında, özellikle cerrahide, tıbbi profesyoneller birden fazla nesneyi (örn., cerrahi aletler) hassas bir şekilde izlemek zorundadır. Görsel manipülasyonların etkileri ve bireysel farklılıklar hakkındaki bulgularımızı uygulamak, ameliyathane koşullarını optimize etmeye ve potansiyel hataları azaltmaya yardımcı olabilir.

*Eğitim ve Öğretim:* Görsel görevler üzerine yoğun eğitim gerektiren işlerde, bireysel farklılıklar ve görsel manipülasyonların etkileri hakkındaki bulgularımızı, eğitim programlarını özelleştirmeye ve öğrenme sonuçlarını ve iş performansını iyileştirmeye yardımcı olabilir.

Bilimsel bilginin uygulamaya entegre edilmesi, çeşitli alanlarda iş güvenliğini ve performansını artırabilir. Gelecekteki araştırmalar, bu ilişkileri daha spesifik uygulamalı bağlamlarda keşfetmeye devam etmelidir.

## **6.9 Önleme Stratejileri ve Politika Etkileri**

Görsel manipülasyonların yanı sıra yaş, cinsiyet ve değişkenlik gibi bireysel farklılıkların etkileri üzerine yaptığımız araştırmadan elde edilen içgörüler, iş kazalarını önlemeye ve iş güvenliğini artırmaya yönelik politikaların geliştirilmesi için önemli sonuçlar taşır. İşte bazı potansiyel önleme stratejileri ve politika etkileri:

*Çalışma Ortamını Uyarlamak:* Şirketler, görsel manipülasyonlar hakkındaki bulgularımıza dayanarak çalışma ortamlarını uyarlayabilir.

*Özelleştirilmiş Eğitim Programları:* Yaş ve cinsiyetin farklı görsel koşullarla başa çıkma yeteneğini nasıl etkilediğini anlamak, kişiselleştirilmiş eğitim programlarının tasarımı yapılabilir.

*Eğitim Programları:* İş yerinde optimal görsel koşulların önemi hakkında çalışanları eğitmek için eğitim programları geliştirilmelidir. Bu programlar, bulanıklık, kontrast ve parlaklığın görsel takip performansı üzerindeki etkilerini açıklamalı ve iş yerinde bu koşulları optimize etme stratejilerini içermelidir.

*Kişiselleştirilmiş Ayarlamalar:* Bireysel farklılıkları görsel yetenek açısından kapsamlı bir iş sağlığı ve güvenliği stratejisinin bir parçası olarak tanımak hayati önem taşır.

*Vardiya Programlarını Tasarlamak:* Görsel görev performansındaki değişkenliği göz önünde bulundurarak, şirketler çalışanların doğal ritimleri ve yetenekleriyle uyumlu vardiya programları tasarlayabilir. Bu, bireysel özelliklere veya sirkadiyen ritimlere göre çalışma programlarını ayarlamayı içerebilir.

*Kişisel Koruyucu Ekipman (KKE):* Çalışanların karşılaştığı görsel zorlukları göz önünde bulundurarak, şirketler görsel yorgunluğu azaltmaya yardımcı olacak KKE, örneğin reçeteli güvenlik gözlükleri sağlayabilir.

*Politika Geliştirme:* Düzenleyici kurumlar, bu araştırmayı iş güvenliği ile ilgili politikaları geliştirmek için kullanabilir. Örneğin, farklı çalışma ortamlarında optimal aydınlatma koşulları için yönergeler belirleyebilir veya görsel yorgunluğu azaltmak için mola verilmesini zorunlu kılabilirler. Ayrıca, şirketlerin güvenlik eğitim programlarını tasarlarırken yaş ve cinsiyet farklılıklarını göz önünde bulundurmalarını da gerektirebilirler.

*Kamu Farkındalığı:* İş yerinde uygun görsel koşulların önemini vurgulayan kamu farkındalık kampanyaları başlatılabilir. Aydınlatma koşullarının, bulanıklığın, kontrastın ve parlaklığın görev performansı üzerindeki etkisini anlamak, bireyleri kendi iş yerlerinde daha iyi koşullar talep etmeye teşvik edebilir.

Bu araştırma, kanıta dayalı müdahaleler ve politikalar aracılığıyla iş kazalarını azaltma ve iş güvenliğini artırma genel hedefine katkıda bulunabilir. Ancak, bu alandaki devam eden araştırmalar da önemlidir, böylece gelecekteki bulgular güncellenmiş ve daha spesifik önerileri bilgilendirebilir.

## **6.10 İş Sağlığı ve Güvenliği Önlemlerinin Değerlendirilmesi ve İyileştirilmesi**

Bulgularımıza dayanarak, uygulanan iş sağlığı ve güvenliği önlemlerinin etkinliğinin uygulamadan sonra değerlendirilmesi ve sürekli iyileştirmelerin arayışında olunması hayati önem taşır. Bu bölüm, bu tür değerlendirmeler ve gelecekteki araştırma yönleri için adımları özetlemektedir:

*Dönemsel Değerlendirme:* Kurumsal sağlık ve güvenlik politikaları, uygulanan önlemlerin düzenli değerlendirmelerini içermelidir. Bu değerlendirmeler, anketler, röportajlar ve gözlemsel çalışmalar yoluyla gerçekleştirilebilir. Önlemlerin etkinliğini değerlendirmek ve gerekli iyileştirmeleri yapmak için önemlidirler.

*Görsel Performansı İzleme:* Görsel performansı gerçek zamanlı olarak izlemek için sistemler uygulanabilir. Bu izleme, yapılan değişikliklerin performans üzerindeki etkisini anlamak için önemlidir. Zamanla performanstaki değişiklikler, uygulanan stratejilerin etkinliğini belirlemeye yardımcı olabilir.

*Geri Bildirim Toplama:* Çalışanlardan alınan geri bildirim, sağlık ve güvenlik önlemlerinin etkinliğini değerlendirmede önemli bir rol oynar. Düzenli geri bildirim oturumları veya platformları, iyileştirme alanlarını veya ortaya çıkan yeni sorunları belirlemeye yardımcı olabilir.

*Performans Göstergeleri:* Uygulanan stratejilerin başarısını ölçmek için anahtar performans göstergeleri belirlenmelidir. Bu göstergeler, görsel gerginlik olayları, genel görev performansı veya görsel koşullarla ilgili çalışan memnuniyeti oranlarını içerebilir.

*Araştırma:* Görsel performansı etkileyen diğer faktörleri ve bu faktörlerin çalıştığımız faktörlerle nasıl etkileşime girdiğini araştırmak önemlidir. Bu cinsiyet, deneyim seviyesi ve belirli iş rolleri gibi diğer demografik değişkenleri de dikkate alabilir. Bu tür araştırmalar, iş sağlığı ve güvenliği önlemlerini daha da iyileştirmeye yardımcı olabilir.

*Araştırmacılarla İşbirliği:* İşletmeler, akademik araştırmacılarla ortaklıklardan faydalanabilir. Bu tür simbiyotik ilişkiler, en son araştırmaların uygulamayı bilgilendirmesini ve gerçek dünya ayarlarının zengin araştırma bağlamları sağlamasını sağlayabilir.

*Sürekli İyileştirme:* İş yerleri, değerlendirmeler, geri bildirimler ve devam eden araştırmalara dayalı olarak sürekli iyileştirme kültürünü benimsemelidir. Teknolojideki değişiklikler, en iyi uygulama önerileri ve bilimsel anlayıştaki değişiklikler, iş sağlığı ve güvenliği önlemlerinin zamanla gelişmesini gerektirir.

## 6.11 Sonular

Bu arařtırma, bulanıklık, kontrast ve parlaklık gibi grsel maniplasyonların iř gvenlięi zerindeki etkilerini incelemiřtir. Sonular, bu faktrlerin yař ve cinsiyet gibi demografik zelliklerle etkileřiminin nemli olduęunu gstermiřtir. Arařtırmanın ana bulguları řunlardır:

Grsel maniplasyonlar altında performansta nemli bireysel farklılıklar vardır. Bu, iřyerlerinde kiřielleřtirilmiř veya uyarlanabilir gvenlik nlemlerinin gereklilięini vurgulamaktadır.

Sınırlılıklara raęmen, bulgular daha fazla arařtırma iin saęlam bir temel oluřturur. Gelecekteki alıřmalar, bireysel farklılıkların nedenlerini anlamaya, demografik deęiřkenleri geniřletmeye ve ek grsel kořulları incelemeye odaklanabilir. Ayrıca, gerek iřyeri ortamlarındaki saha alıřmaları da son derece deęerli olacaktır.

Arařtırma, pratik uygulamalara da iřaret etmektedir. Grev performansı zerindeki grsel maniplasyonların etkilerini anlamak, iř gvenlięini artırmak iin nleyici stratejilerin ve politika dzenlemelerinin geliřtirilmesine bilgi saęlayabilir. Bu tr iyileřtirmeler, iřle ilgili yaralanmaları ve kazaları nemli lde azaltabilir, grsel becerileri yoęun řekilde kullanan rollerdeki alıřanların refahını ve verimlilięini artırabilir.

Genel olarak, bu arařtırma, iřyeri ortamlarında grsel kořullar, bireysel zellikler ve grev performansının karmařık etkileřimini keřfetmek iin yeni yollar amaktadır. Bulgular, daha gvenli bir alıřma ortamı arayıřında, tek tip bir yaklařımın herkes iin uygun olmadıęını hatırlatmaktadır. Yksek grsel doęruluęa sahip iřyerlerinde iř saęlıęı ve gvenlięini optimize etmek iin ařaęıdaki nerileri dikkate almanızı neririz:

1. *Kiřielleřtirilmiř Grsel Ayarlamaları Benimseyin:* Bulanıklıęı, kontrastı ve parlaklıęı bireysel alıřanların zelliklerine ve grevlerinin doęasına gre ayarlamak iin teknolojiden yararlanın.

2. *Düzenli Taramalar Uygulayın:* Potansiyel görme bozukluklarını erken tespit etmek için düzenli görme taramaları yapılmalıdır. Bu taramalar erken müdahalelere olanak tanıyacak ve sonuçların iyileşmesine yol açacaktır.
3. *Ergonomiye Öncelik Verin:* İş istasyonları, görevlerin görsel taleplerini göz önünde bulundurarak ergonomik olarak tasarlanmalıdır. Ekran aydınlatma koşulları, optimum parlaklık ve kontrast sağlamak için ayarlanabilir olmalı ve çalışanların görüşü üzerindeki baskıyı en aza indirmelidir.
4. *Çalışan Eğitimine Odaklanın:* Çalışanlar, görsel olarak yoğun görevlerden düzenli molalar vermek, gerekirse göz damlası kullanmak ve göz kaslarını gevşetmek için göz egzersizleri yapmak da dahil olmak üzere göz sağlığını korumak için en iyi uygulamalar konusunda eğitilmelidir.
5. *Çalışanları Karar Verme Sürecine Dahil Edin:* Sağlık ve güvenlik stratejilerinin tasarlanması ve uygulanmasında çalışanların geri bildirimlerini dahil etmek, bu stratejilerin etkili ve ihtiyaçlarına uygun olmasını sağlayacaktır.
6. *Araştırmaya Devam Edin:* Hızla gelişen dijital ortamda, yüksek görsel doğruluk gerektiren görevlerin görsel taleplerini ve bunların iş sağlığı ve güvenliği üzerindeki etkilerini daha iyi anlamak için devam eden araştırmalar hayati önem taşımaktadır.

Sonuç olarak, bu araştırma görsel doğruluğun iş sağlığı ve güvenliği üzerindeki etkilerini anlamak için önemli bir temel oluşturmaktadır. Bulgularımızdan elde edilen önerileri uygulayarak, kuruluşlar yüksek görsel doğruluk gerektiren görevlerin benzersiz taleplerini tanıyan ve hem çalışanların refahını hem de üretkenliğini artıran sağlıklı bir çalışma ortamını teşvik edebilir. Gelecekteki araştırmalar, iş sağlığı ve güvenliği stratejilerini sürekli gelişen işyeri dinamiklerine uyarlayarak bu içgörülerini genişletebilir.

## 7. ÇOKLU NESNE İZLEME PERFORMANSININ MODELLENMESİ

### 7.1 Model Geliştirme

Bu bölüm, bulanıklık, kontrast ve parlaklığın yanı sıra bu faktörler arasındaki etkileşimleri içeren çoklu nesne takibi (ÇNT) performansı için kapsamlı bir modelin geliştirilmesini ele almaktadır.

*Model Temelleri:* Model, ÇNT görevlerinde dikkatin rolüne ilişkin kuramsal çerçeveler ve deneysel kanıtlar üzerine inşa edilmiştir (Alvarez & Franconeri, 2007; Scholl, 2009). Görsel faktörler olan bulanıklık, kontrast ve parlaklığı dikkate alır ve dikkat tahsisi ve nesne takibi performansı üzerindeki etkilerini inceler (Carrasco, 2006; Yantis, 1992).

*Model Bileşenleri:* Model üç ana bileşenden oluşur: dikkat haritası, dikkat tahsis modülü ve nesne takip modülü. Dikkat haritası, bulanıklık, kontrast ve parlaklık gibi görsel girdilerden mekansal ve zamansal bilgileri entegre eder (Li, 2002). Dikkat tahsis modülü, dikkat haritasına dayanarak takip edilen nesnelerin mekansal konumlarını belirler ve dikkat kaynaklarını buna göre tahsis eder (Carrasco, 2006). Nesne takip modülü, takip edilen nesnelerin hareket trajelerini işler ve dikkat haritasını buna göre günceller (Lu & Sperling, 2001).

*Model Kalibrasyonu:* Model, bu çalışmada toplanan deneysel veriler kullanılarak kalibre edildi. Model parametreleri, bulanıklık, kontrast ve parlaklığın ÇNT performansı üzerindeki temel etkilerini ve etkileşim etkilerini en iyi şekilde yakalamak üzere optimize edilir (Bauer vd.,2014; Saarinen & Levi, 1995).

*Model Doğrulama:* Modelin tahminlerinin deneysel sonuçlarla karşılaştırılarak doğrulanması yapılır. Model, bulanıklık, kontrast ve parlaklığın ÇNT performansı üzerindeki gözlemlenen etkilerini ve etkileşim etkilerini doğru bir şekilde tahmin eder ve verilerle iyi bir uyum gösterir (Yantis, 1992; Alvarez & Franconeri, 2007). Daha fazla doğrulama, ÇNT ve dikkat üzerine mevcut literatürden elde edilen sonuçlarla modelin tahminlerinin karşılaştırılmasıyla elde edilir (Cavanagh & Alvarez, 2005).

*Kuramsal Düşüncelerin İşaret Ettiği Alternatifler:* Geliştirilen model, ÇNT performansındaki görsel faktörlerin rolünü anlamak için kapsamlı bir çerçeve sağlar. Dikkat tahsisi ve nesne takibi süreçlerinin önemini bulanıklık, kontrast ve parlaklık gibi görsel faktörlerin bu süreçleri nasıl etkileyebileceğini vurgular (Scholl, 2009; Carrasco, 2006). Model, ÇNT ve dikkat işleme mekanizmalarının temelinde yatan mekanizmaları inceleyen gelecekteki araştırmalar için değerli bir araç olarak hizmet eder.

## 7.2 Model Doğrulama

Bu bölümde, geliştirilen çoklu nesne takibi (ÇNT) performansı modelinin doğrulanması, tahminlerinin bu çalışmanın deneysel sonuçları ve mevcut literatürdeki bulgularla karşılaştırılması tartışılır.

*Deneysel Verilerle Karşılaştırma:* Model, bu çalışmada toplanan deneysel verilerle güçlü bir uyum sergiler, bulanıklık, kontrast ve parlaklığın ÇNT performansı üzerindeki gözlemlenen etkilerini ve etkileşimlerini doğru bir şekilde tahmin eder (Yantis, 1992; Alvarez & Franconeri, 2007). Temel etkileri ve etkileşim etkilerini başarılı bir şekilde yeniden üreterek, model görsel faktörler ile ÇNT performansı arasındaki karmaşık ilişkileri açıklama yeteneğini kanıtlar.

*Mevcut Literatürle Karşılaştırma:* Modelin tahminleri, ÇNT ve dikkat üzerine yapılan önceki araştırmaların bulgularıyla uyumludur (Cavanagh & Alvarez, 2005; Scholl, 2009). Örneğin; model, dikkat tahsisi ve nesne takibi süreçlerinin ÇNT performansı için kritik olduğu bulanıklık, kontrast ve parlaklık gibi görsel faktörlerin bu süreçleri etkileyebileceği fikrini destekler (Carrasco, 2006; Li, 2002).

*Çapraz Doğrulama:* Modelin daha da doğrulanması için, verilerin bir alt kümesinde modelin eğitilmesi ve tahminlerinin geri kalan verilere uygulanması gibi çapraz doğrulama teknikleri kullanılabilir (Stone, 1974). Bu yaklaşım, modelin yeni verilere iyi bir şekilde genelleştiğini ve kalibrasyon için kullanılan belirli veri setine aşırı bağımlı olmadığını gösterilmesini sağlar.

*Simülasyon Çalışmaları:* Model doğrulanması için başka bir yaklaşım, model temelinde sentetik veriler oluşturarak ve simüle edilen sonuçları deneysel bulgularla karşılaştırarak gerçekçi veri desenlerini üretebilme yeteneğini ve modelin geçerliliğini daha da destekleyebilir (Gelman & Hill, 2007).

*Hiperparametre Optimizasyonu:* Her model için, ızgara arama veya rastgele arama gibi yöntemler kullanılarak hiperparametre optimizasyonu yapılmıştır. Bu, her modelin en iyi performansını sergilemesini sağlamak için önemlidir.

Genel olarak; model doğrulama süreci, geliştirilen ÇNT performansı modelinin hem doğru hem de sağlam olduğunu gösterir ve görsel faktörlerin ÇNT görevlerindeki rolünü anlamak için kapsamlı bir çerçeve sağlar. Modelin başarıyla doğrulanması, sadece teorik katkılarını güçlendirmekle kalmaz, aynı zamanda ekran tabanlı ortamlar ve görevlerin tasarımında potansiyel uygulamaları da vurgular.

### 7.3 Deney 1 Bulanıklık Modellemesi

Bu deneyde, beş farklı makine öğrenimi modelinin bulanıklığın ÇNT performansı üzerindeki etkilerini modelleme bağlamında karşılaştırması yapılır. Modeller, ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$ (R\_kare) (James vd.,2013; Hyndman & Koehler, 2006) değerleri temelinde değerlendirilir.

Karşılaştırılan modeller şunlardır:

- Doğrusal Model (Neter, Wasserman & Kutner, 1990) (linear\_model <- lm (Ortalama ~ mod\_type + mod\_field + Cinsiyet + Yaş, data = train\_data))
- Rastgele Orman (Breiman,2001)(random\_forest\_model<-randomForest (Ortalama ~ mod\_type + mod\_field + Cinsiyet + Yaş, data = train\_data))
- Destek Vektör Makinesi (DVM)(Cortes & Vapnik, 1995)(svm\_model <- svm(Ortalama ~ mod\_type + mod\_field + Cinsiyet + Yaş, data = train\_data))
- Karar Ağacı (Quinlan, 1986)(decision\_tree\_model <- rpart(Ortalama ~ mod\_type + mod\_field + Cinsiyet + Yaş, data = train\_data))
- Yapay Sinir Ağı (Rumelhart, Hinton & Williams, 1986) (neural\_network\_model <- nnet(Ortalama ~ mod\_type + mod\_field + Cinsiyet + Yaş, data = train\_data, size = 5, linout = TRUE))

Bu deneyde de bulanıklık değişkenlerinin etkileşimini incelemek için beş farklı makine öğrenimi modeli kullanılmıştır.

**Çizelge 7.1:** Deney 1 Bulanıklık için OKH, OMH ve  $R^2$ 'e göre Model Çizelgesi

<b>Model</b>	<b>OKH</b>	<b>OMH</b>	<b><math>R^2</math></b>
<b>Doğrusal Model</b>	0.4716922	0.3396982	0.08424026
<b>Rastgele Orman</b>	0.4260800	0.2882960	0.22567748
<b>DVM</b>	0.4766383	0.3585494	0.06192797
<b>Karar Ağacı</b>	0.4647447	0.3339432	0.10099755
<b>Yapay Sinir Ağı</b>	0.4605462	0.3293319	0.11475229

Tabloda beş farklı makine öğrenimi modelinin performansını göstermektedir: Doğrusal Model, Rastgele Orman, Destek Vektör Makineleri (DVM), Karar Ağacı ve Yapay Sinir Ağı. Her model için Ortalama Kare Hatası (OKH), Ortalama Mutlak Hata (OMH) ve  $R^2$  (belirleme katsayısı) değerleri verilmiştir (Çizelge 7.1). Bu değerler, modellerin performanslarını ve veri setindeki değişkenliği ne kadar iyi açıklayabildiklerini değerlendirmek için kullanılır.

OKH, gerçek ve tahmin edilen değerler arasındaki ortalama karesel farkın bir ölçüsüdür (Hyndman & Koehler, 2006). Daha düşük bir OKH değeri, modelin daha iyi performans gösterdiğini gösterir.

OMH, gerçek ve tahmin edilen değerler arasındaki ortalama mutlak farkın bir ölçütüdür (Willmott & Matsuura, 2005). OKH gibi, daha düşük bir OMH değeri, modelin daha iyi performans gösterdiğini gösterir.

$R^2$ , bir modelin uyumunu değerlendirmek için kullanılan bir istatistiksel ölçüttür ve belirleme katsayısı olarak da bilinir.  $R^2$  0 ile 1 arasında değer alır, 1 mükemmel uyumu temsil ederken 0, modelin verideki herhangi bir varyasyonu açıklayamadığını gösterir (Hinkle, Wiersma, & Jurs, 2003).

Şimdi bu modellerin performanslarını bilimsel referanslar ışığında detaylı bir şekilde analiz edelim:

*Doğrusal Model:* Doğrusal model, bağımsız değişkenler ile bağımlı değişken arasındaki lineer ilişkiyi modellemek için kullanılır (James et al., 2013). Bu

modelin düşük  $R^2$  değeri (0.08424026), modelin veri setindeki değişkenliğin sadece %8.42'sini açıklayabildiğini gösterir, bu da modelin bu veri setindeki ilişkileri yakalamada yetersiz kaldığına işaret edebilir.


*Rastgele Orman:* Rastgele Orman, birçok karar ağacının bir araya gelmesiyle oluşan bir topluluk öğrenme modelidir ve genellikle yüksek performans sergiler (Breiman, 2001).  $R^2$  değeri 0.22567748 ile bu model, veri setindeki değişkenliğin yaklaşık %22.57'sini açıklayarak, incelenen modeller arasında en iyi performansı göstermiştir. Bu, Rastgele Orman'ın veri setindeki karmaşık ilişkileri ve etkileşimleri etkili bir şekilde modelleyebilme yeteneğine işaret eder.

*Destek Vektör Makineleri (DVM):* DVM, veri noktalarını bir hiper-düzlem ile ayırarak çalışır ve genellikle sınıflandırma ve regresyon problemlerinde etkilidir (Cortes & Vapnik, 1995). Ancak, bu modelin  $R^2$  değeri 0.06192797 olup, veri setindeki değişkenliği %6.19 oranında açıklayabildiğini gösterir. Bu düşük değer, DVM'nin bu özel veri setindeki ilişkileri modellemede zorluk yaşadığını gösterir.


*Karar Ağacı:* Karar Ağaçları, veri setini basit karar düğümleri aracılığıyla bölerek çalışır (Quinlan, 1986). Bu modelin  $R^2$  değeri 0.10099755 ile, veri setindeki değişkenliğin yaklaşık %10.10'unu açıklayarak orta düzeyde bir performans sergilemiştir. Karar Ağacının bu performansı, modelin veri setindeki bazı ilişkileri ve etkileşimleri yakalayabildiğini, ancak tüm karmaşıklığı modelleyemediğini gösterir.

*Yapay Sinir Ağı:* Yapay Sinir Ağları, insan beyninin bilgi işleme biçimini taklit eden ve genellikle karmaşık desenleri tanıma ve modelleme kapasitesiyle bilinen modellerdir (Goodfellow et al., 2016). Sinir Ağının  $R^2$  değeri 0.11475229 olup, veri setindeki değişkenliğin yaklaşık %11.48'ini açıklayarak, incelenen modeller arasında orta düzeyde bir performans göstermiştir. Bu, yapay sinir ağının veri setindeki bazı değişkenlikleri yakalayabildiğini ancak tüm değişkenliği modelleyemediğini gösterir.

Beş modelin performansını karşılaştıran tablo, Rastgele Orman modelinin en düşük OKH ve OMH değerlerine ve en yüksek  $R^2$  değerine sahip olduğunu ortaya koyar (Şekil 7.1).



Şekil 7.1: Deney 1 Bulanıklık için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması




Şekil 7.2: Deney 1 Bulanıklık için Model Performans Metrikleri

Genel olarak, Rastgele Orman modeli en iyi performansı sergilemişken, DVM en düşük performansı göstermiştir.

Yapay Sinir Ağı ve Karar Ağacı modeli de nispeten yüksek bir  $R^2$  değerine sahiptir. Diğer modellerin ise daha düşük  $R^2$  değerleri vardır (Breiman, 2001; Quinlan, 1986) (Şekil 7.2).


Karar Ağacı ve Yapay Sinir Ağı modelleri de nispeten düşük OKH ve OMH değerlerine sahiptir,

Doğrusal Model(DM) ve Destek Vektör Makinesi (DVM)ise daha yüksek hata değerlerine sahiptir (Quinlan, 1986; Cortes & Vapnik, 1995; Rumelhart, Hinton & Williams, 1986) (Şekil 7.3).



**Şekil 7.3:** Deney 1 Bulanıklık için OKH, OMH ve  $R^2$ 'e göre Herbir Modelin Ayrı Grafiği


Modellerin performansları, kullanılan veri setinin doğası, modelin karmaşıklığı ve ayarlanan parametreler gibi faktörlere bağlı olarak değişiklik gösterir(Breiman, 2001; Hastie, Tibshirani & Friedman, 2009).



**Şekil 7.4:** Deney 1 Bulanıklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri

Bu nedenle, belirli bir görev için en iyi modeli seçmeden önce birden çok modelin performansını kapsamlı bir şekilde değerlendirmek ve karşılaştırmak önemlidir. Görselde, modellerin tahminlerinin geniş bir aralıkta dağıldığı görülüyor. Özellikle düşük ve yüksek gerçek değerlerde modellerin tahminlerinin daha fazla varyans gösterdiği göze çarpıyor (Şekil 7.4).

Şekil 7.4’de birden fazla makine öğrenimi modeli için gerçek değerlerin tahmin edilen değerlerle karşılaştırmasını gösterir. Kesikli çizgi, tahmin edilen değerlerin gerçek değerlerle mükemmel şekilde eşleştiği ideali temsil eder. Noktaların kesikli çizgi etrafındaki dağılımı, modellerin tahminlerindeki farklılığı gösterir. Noktalar kesikli çizgiye ne kadar yakınsa tahminler o kadar doğru olur. Daha düşük ve daha yüksek gerçek değerlere ilişkin tahminlerin daha fazla varyansa sahip olduğu görülmektedir ki bu, regresyon problemlerinde yaygın bir sorundur.




**Şekil 7.5:** Deney 1 Bulanıklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler

Şekil 7.5’de rastgele orman modelinin tahminleri görünüyor. Kırmızı kesikli çizgi yine ideal tahmin çizgisini temsil etmektedir. Bu görselleştirme, tek bir modelin performansının tek başına değerlendirilmesine yardımcı olur. Bu özel modelin tahminlerinin, özellikle değer aralığının kenarlarına doğru, gerçek değerlerden nasıl saptığına dair daha net bir görüş sağlar.

İdeal tahmin doğrusuna en yakın noktaların genellikle Rastgele Orman modelinden geldiği görülüyor. Bu da bu modelin tahminlerinin gerçek değerlere genellikle daha yakın olduğunu gösteriyor.

Şekil 7.6’daki Hexbin grafiği, renk yoğunluğunun oluşum sayısını (bu bağlamda tahmin edilen değerlerin konsantrasyonunu) temsil ettiği iki boyutlu bir histogramdır. Daha koyu altıgenler daha yüksek veri noktası konsantrasyonunu gösterir; bu da bu alanlarda tahminlerin daha tutarlı olduğu anlamına gelir. Grafik, gerçek değerler etrafındaki tahmin yoğunluğunun değiştiğini, bazı alanların daha yüksek konsantrasyon gösterdiğini ve bu bölgelerde daha iyi doğruluk sağladığını gösteriyor.



**Şekil 7.6:** Deney 1 Bulanıklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı

Bu çalışmanın bağlamında, Rastgele Orman modelinin üstün performansı, bulanıklığın çoklu nesne takibi performansı üzerindeki etkilerini yakalamak için en uygun model olduğunu göstermektedir.

#### 7.4 Deney 1 Kontrastın Modellemesi

Bu tablo, belirli bir veri kümesi üzerinde beş farklı makine öğrenimi modelinin performansını üç değerlendirme ölçütü olan ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$  temelinde karşılaştırmaktadır (Çizelge 7.2).

**Çizelge 7.2:** Deney 1 Kontrast için OKH, OMH ve  $R^2$ 'e göre Model Çizelgesi

Model	OKH	OMH	$R^2$
<b>Doğrusal Model</b>	0.3120941	0.4413224	0.004234828
<b>Rastgele Orman</b>	0.2881542	0.4102763	0.049658072
<b>DVM</b>	0.3504276	0.4340865	0.023561679
<b>Karar Ağacı</b>	0.2738153	0.4120756	0.032181784
<b>Yapay Sinir Ağı</b>	0.3142557	0.4472906	0.001902364

Tabloda yer alan makine öğrenimi modellerinin performansları, Ortalama Kare Hatası (OKH), Ortalama Mutlak Hata (OMH) ve  $R^2$  (belirleme katsayısı) değerleri üzerinden değerlendirilmiştir.

*Doğrusal Model*(`linear_model <- lm(Ortalama ~ mod_type + Yaş, data = train_data)`): Bu modelin çok düşük bir  $R^2$  değeri (yaklaşık %0.42) var, bu da modelin veri setindeki varyansın çok küçük bir kısmını açıklayabildiğini gösterir. Bu, modelin bu veri setindeki ilişkileri yakalamada yetersiz kaldığına işaret eder, belki de ilişkiler doğrusal olmayabilir.


*Rastgele Orman*(`random_forest_model <- randomForest(Ortalama ~ mod_type + Yaş, data = train_data)`):  $R^2$  değeri %4,97 ile bu model, veri setindeki değişkenliğin en iyi açıklandığı modeldir. Bu, Rastgele Orman'ın veri setindeki karmaşık ilişkileri ve etkileşimleri diğer modellere göre daha iyi modelleyebileceğini gösterir, ancak yine de açıklanan varyans oranı düşüktür.

*Destek Vektör Makineleri (DVM)*(`svm_model <- svm(Ortalama ~ mod_type + Yaş, data = train_data)`): Bu modelin  $R^2$  değeri %2.36 olup, veri setindeki değişkenliği sınırlı bir oranda açıklayabildiğini gösterir. Bu, DVM'nin bu özel veri setindeki ilişkileri modellemede zorluk yaşadığını gösterir.

*Karar Ağacı*(`decision_tree_model <- rpart(Ortalama ~ mod_type + Yaş, data = train_data)`): Bu modelin  $R^2$  değeri %3.22 ile, veri setindeki değişkenliği sınırlı bir oranda açıklar. Bu, Karar Ağacının bu veri setindeki bazı ilişkileri yakalayabildiğini, ancak tüm karmaşıklığı modelleyemediğini gösterir.


*Yapay Sinir Ağı*(`neural_network_model <- nnet(Ortalama ~ mod_type + Yaş, data = train_data, size = 5, linout = TRUE)`): Ancak, bu modelin çok düşük bir  $R^2$  değeri (%0.19) var, bu da veri setindeki varyansın sadece çok küçük bir kısmını açıklayabildiğini gösterir. Bu, Sinir Ağı'nın bu veri setindeki ilişkileri ve desenleri etkili bir şekilde modelleyemediğini gösterir.

Tablodan görüleceği üzere, Rastgele Orman modeli beş model arasında en düşük OKH ve OMH değerlerine sahiptir, bu da genel olarak daha iyi performans gösterdiğini gösterir (Şekil 7.7).




Şekil 7.7: Deneysel Kontrast için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması

Karar Ağacı modeli de nispeten düşük OKH ve OMH değerlerine sahiptir (Breiman, 2001; Quinlan, 1986)(Şekil 7.8).




Şekil 7.8: Deneysel Kontrast için Model Performans Metrikleri




**Şekil 7.9:** Deney 1 Kontrast için OKH, OMH ve  $R^2$ 'e göre Herbir Modelin Ayrı Grafiği

$R^2$  açısından, Rastgele Orman modeli en yüksek değere sahiptir, bu da beş model arasında en iyi uyan model olduğunu gösterir. Karar Ağacı modeli de nispeten yüksek bir  $R^2$  değerine sahipken, diğer modellerin daha düşük  $R^2$  değerleri vardır (Breiman, 2001) (Şekil 7.9).




**Şekil 7.10:** Deney 1 Kontrast için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri

Genel olarak, verilen değerlendirme metriklerine göre de Rastgele Orman modeli, beş model arasında en iyi performans gösteren model gibi görünmektedir (Şekil 7.10).



Şekil 7.11: Deney 1 Kontrast için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler

Rastgele Orman, belirli bir veri setindeki özelliklerin ve hedef değişkenin arasındaki karmaşık ilişkileri modellediği görülmektedir (Şekil 7.11).



Şekil 7.12: Deney 1 Kontrast için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı

Ayrıca, bu model tipi, overfitting gibi bazı genel makine öğrenmesi sorunlarına karşı dayanıklıdır ve genellikle karmaşık sınıflandırma ve regresyon problemleri için iyi sonuçlar verir. Bu çalışmanın bağlamında, Rastgele Orman modelinin üstün performansı, kontrastın çoklu nesne takibi performansı üzerindeki etkilerini yakalamak için en uygun model olduğunu göstermektedir (Şekil 7.12).

Genel olarak, tüm modellerin  $R^2$  değerleri oldukça düşük, bu da veri setindeki değişkenliğin büyük bir kısmını açıklayamadıklarını gösterir. Bu, veri setindeki ilişkilerin karmaşık veya doğrusal olmayan yapılar içerebileceğine işaret eder ve bu modellerin bu tür veri yapılarını yakalamada sınırlı olabileceğini gösterir. Bu durum, model seçimi ve özellik mühendisliği gibi konularda daha fazla çalışma yapılmasını gerektirebilir veya farklı makine öğrenimi tekniklerinin keşfedilmesini gerektirebilir.

### 7.5 Deney 1 Parlaklığın Modellemesi

Bu tablo, üç değerlendirme ölçütü olan ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$  temelinde beş farklı makine öğrenimi modelinin belirli bir veri kümesi üzerinde karşılaştırmasını sunmaktadır (Çizelge 7.3).

*Doğrusal Model*(`linear_model <- lm(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`):  $R^2$  değeri %2.47 olan bu model, veri setindeki varyansın çok az bir kısmını açıklayabildiğini gösterir, bu da ilişkilerin doğrusal olmadığı veya modelin veri yapısını yeterince iyi yakalayamadığı anlamına gelir.

*Rastgele Orman*(`random_forest_model <- randomForest(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`):  $R^2$  değeri %33.37 ile bu model, veri setindeki değişkenliğin en iyi açıklandığı modeldir. Bu, Rastgele Orman'ın veri setindeki karmaşık ilişkileri ve etkileşimleri diğer modellere göre daha iyi modelleyebileceğini gösterir.

*Destek Vektör Makineleri (DVM)*(`svm_model <- svm(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`): Bu modelin  $R^2$  değeri %0.11 olup, veri


setindeki deęişkenlięi neredeyse hi açıklayamadıęını gösterir. Bu, DVM'nin bu özel veri setindeki iliřkileri modellemede zorluk yařadıęını gösterir.

*Karar Aęacı*(`decision_tree_model <- rpart(Ortalama ~ mod_type + Cinsiyet+ Yař, data = train_data)`):  $R^2$  deęeri %8.34 olan bu model, veri setindeki deęişkenlięi sınırlı bir oranda açıklar. Bu, Karar Aęacının bu veri setindeki bazı iliřkileri yakalayabildięini, ancak tüm karmařıklıęı modelleyemedięini gösterir.

*Yapay Sinir Aęı*(`neural_network_model <- nnet(Ortalama ~ mod_type + Cinsiyet+ Yař, data = train_data, size = 5, linout = TRUE)`):  $R^2$  deęeri %4.44 olan bu model, veri setindeki deęişkenlięi sınırlı bir oranda açıklar. Bu, Sinir Aęının bu veri setindeki iliřkileri ve desenleri sınırlı bir başarı ile modelleyebildięini gösterir.

**izelge 7.3:** Deney 1 Parlaklık iin OKH, OMH ve  $R^2$ 'e gre Model izelgesi


Model	OKH	OMH	$R^2$
<b>Doęrusal Model</b>	0.3732474	0.5125062	0.024687107
<b>Rastgele Orman</b>	0.2744426	0.3916204	0.333659350
<b>DVM</b>	0.4390410	0.5599193	0.001068357
<b>Karar Aęacı</b>	0.3532019	0.4743587	0.083404405
<b>Yapay Sinir Aęı</b>	0.3867601	0.5192116	0.044410942




**řekil 7.13:** Deney 1 Parlaklık iin OKH, OMH ve  $R^2$ 'e gre Model Karřılařtırması

Genel olarak, Rastgele Orman modeli en iyi performansı sergilemişken, DVM en düşük performansı göstermiştir.

Tablodan görüleceği üzere, Rastgele Orman modeli beş model arasında en düşük OKH ve OMH değerlerine sahiptir ve genel olarak daha iyi performans sergiler. Karar Ağacı modeli de nispeten düşük OKH ve OMH değerlerine sahiptir (Breiman, 2001; Quinlan, 1986) (Şekil 7.13).



**Şekil 7.14:** Deney 1 Parlaklık için Model Performans Metrikleri




**Şekil 7.15:** Deney 1 Parlaklık için OKH, OMH ve  $R^2$ 'e göre Her bir Modelin Ayrı Grafiği

$R^2$  açısından, Rastgele Orman modeli en yüksek değere sahiptir ve beş model arasında veriye en uygun olanıdır. Yapay Sinir Ağı ve Karar Ağacı modeli de nispeten yüksek bir  $R^2$  değerine sahiptir, diğer modellerin ise daha düşük  $R^2$  değerleri bulunmaktadır (Breiman, 2001) (Şekil 7.14).

Genel olarak, verilen değerlendirme metriklerine göre Rastgele Orman modeli, beş model arasında en iyi performans gösteren model olduğu görülmektedir (Şekil 7.15).

Rastgele Orman modeli, çeşitli değişkenler ve özellikler arasındaki karmaşık ilişkileri oldukça iyi yakalamaktadır (Şekil 7.16).



**Şekil 7.16:** Deney 1 Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri

Bu modelin birçok avantajı vardır.

*Performans:* Rastgele Orman, genellikle hem sınıflandırma hem de regresyon görevlerinde yüksek doğruluk oranlarına ulaşır.

*Özelliklerin Etkileşimini Yönetme:* Rastgele Orman, özellikler arasındaki etkileşimleri ve karmaşık ilişkileri modelleyebilir.


*Aşırı Uyuma Karşı Direnç:* Tek bir karar ağacına kıyasla, Rastgele Orman genellikle aşırı uyuma(overfitting) karşı daha dirençlidir. Bu, birçok farklı karar ağacının oluşturulduğu ve bu ağaçların "ortalama" tahmininin alındığı topluluk yaklaşımından kaynaklanır.

*Özellik Önem Derecesi:* Rastgele Ormanlar, hangi özelliklerin tahmin yaparken en önemli olduğunu belirleyebilir. Bu, modelin yorumlanabilirliğini artırır ve hangi özelliklere odaklanılması gerektiği konusunda bilgi sağlar.


*Aykırı Değer Direnci:* Rastgele Ormanlar, aykırı değer (anomali, outlier) verilere karşı dayanıklıdır, çünkü bir topluluk yaklaşımı kullanırlar ve ayrıca hedef değişkenindeki büyük sapmaları tamamen ortadan kaldırmaz.

*Ölçeklemeye Gerek Yok:* Rastgele Ormanlar, diğer algoritmaların aksine, özelliklerin ölçeklenmesini veya normalize edilmesini gerektirmez.

*Büyük Veri Setlerini İşleyebilir:* Rastgele Ormanlar, büyük veri setlerini ve yüksek boyutlu (birçok özelliği olan) veri setlerini işleyebilir (Şekil 7.17).



**Şekil 7.17:** Deney 1 Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler



**Şekil 7.18:** Deney 1 Parlaklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı

Bu çalışmanın bağlamında, Rastgele Orman modelinin üstün performansı, parlaklığın çoklu nesne takibi performansı üzerindeki etkilerini yakalamak için en uygun model olduğunu göstermektedir (Şekil 7.18) (Yazgan, Yağimli & Ozubko, 2023).

## 7.6 Deney 1 Bulanıklık, Kontrast ve Parlaklığın Etkileşiminin Modellemesi

Bu tablo, beş farklı makine öğrenimi modelinin belirli bir veri kümesi üzerindeki performansını üç değerlendirme ölçütü olan ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$  temelinde karşılaştırır (Çizelge 7.4).

*Doğrusal Model*(`linear_model <- lm(Ortalama ~ mod_type + Cinsiyet + mod_field + Yaş, data = train_data)`): Bu modelin  $R^2$  değeri %8.92, yani model veri setindeki varyansın yaklaşık %8.92'sini açıklayabilmektedir. Bu oran, modelin veri setindeki ilişkileri yeterince iyi yakalayamadığını gösterir, özellikle ilişkiler doğrusal olmayabilir.

*Rastgele Orman*(`random_forest_model <- randomForest(Ortalama ~ mod_type + Cinsiyet + mod_field + Yaş, data = train_data)`):  $R^2$  değeri

%21.82 ile bu model, veri setindeki deęişkenlięin en iyi açıklandığı modeldir. Bu, Rastgele Orman'ın veri setindeki karmaşık ilişkileri ve etkileşimleri dięer modellere göre daha iyi modelleyebileceğini gösterir.

*Destek Vektör Makineleri (DVM)*(svm\_model <- svm(Ortalama ~ mod\_type + Cinsiyet + mod\_field + Yaş, data = train\_data)): Bu modelin R<sup>2</sup> deęeri %7.67 olup, veri setindeki deęişkenlięi sınırlı bir oranda açıklayabildiğini gösterir. Bu, DVM'nin bu özel veri setindeki ilişkileri modellemede zorluk yaşadığını gösterir.


*Karar Ağacı*(decision\_tree\_model <- rpart(Ortalama ~ mod\_type + Cinsiyet + mod\_field + Yaş, data = train\_data)): Bu modelin R<sup>2</sup> deęeri %5.73 ile, veri setindeki deęişkenlięi sınırlı bir oranda açıklar. Bu, Karar Ağacının bu veri setindeki bazı ilişkileri yakalayabildiğini, ancak tüm karmaşıklığı modelleyemediğini gösterir.

*Yapay Sinir Ağı*(neural\_network\_model <- nnet(Ortalama ~ mod\_type + Cinsiyet + mod\_field + Yaş, data = train\_data, size = 5, linout = TRUE)): Sinir Ağı'nın R<sup>2</sup> deęeri %10.65 olup, bu modelin veri setindeki deęişkenlięin %10.65'ini açıklayabildiğini gösterir, bu da orta düzeyde bir performansı işaret eder.

**Çizelge 7.4:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve R<sup>2</sup>'e göre Model Tablosu


Model	OKH	OMH	R <sup>2</sup>
<b>Doęrusal Model</b>	0.5067514	0.3809431	0.08919707
<b>Rastgele Orman</b>	0.4664939	0.3294410	0.21821100
<b>DVM</b>	0.5031399	0.3965706	0.07667128
<b>Karar Ağacı</b>	0.5272006	0.3945027	0.05728621
<b>Yapay Sinir Ağı</b>	0.5027960	0.3736983	0.10647079

Yapay Sinir Ağı modeli de nispeten düşük OKH ve OMH deęerlerine sahiptir (Şekil 7.19).



**Şekil 7.19:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması


Genel olarak, Rastgele Orman modeli en iyi performansı sergilemişken, diğer modellerin  $R^2$  değerleri oldukça düşüktür, bu da veri setindeki değişkenliğin büyük bir kısmını açıklayamadıklarını gösterir.



**Şekil 7.20:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için Model Performans Metrikleri



Diğer modellerin daha düşük  $R^2$  değerleri vardır.  $R^2$ , bağımlı ve bağımsız değişkenler arasındaki ilişkinin gücünü gösterir ve daha yüksek bir  $R^2$  değeri daha güçlü bir uyumun olduğunu ifade eder (Kvalseth, 1985) (Şekil 7.22).




**Şekil 7.23:** Deney 1 Bulanıklık, Kontrast ve Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler

Bu üç metrik genellikle bir arada kullanılır. Bir modelin hangi metriklere göre en iyi performansı gösterdiğini belirlemek, belirli bir probleme ve uygulamaya bağlıdır.

Örneğin, bir modelin genel hatası üzerinde daha fazla durulacaksa OKH, modelin performansının daha önemli olduğu durumlarda OMH ve genel model uyumunu belirlemek için  $R^2$  değerine bakılır. Metrikler sonucunda Rastgele Orman Modelinin Gerçek/Tahmin edilen değerler ile ilgili performansı görülmektedir (Şekil 7.23).

Bu çalışmanın bağlamında, Rastgele Orman modelinin üstün performansı, bulanıklık, kontrast ve parlaklığın çoklu nesne takibi performansı üzerindeki etkileşimlerini yakalamak için en uygun model olduğunu göstermektedir (Şekil 7.24).



**Şekil 7.24:** Bulanıklık, Kontrast ve Parlaklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı

### 7.7 Deney 2 Bulanıklık Modellemesi

Bu çalışmada, bulanıklığın Çoklu Nesne Takibi (ÇNT) performansı üzerindeki etkilerini modellemek amacıyla beş farklı makine öğrenimi modelinin karşılaştırmalı analizi yapılmıştır (Çizelge 7.5). İncelenen modeller arasında Deney 1'de olduğu gibi

- Doğrusal Model (`linear_model <- lm(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Rastgele Orman (`random_forest_model <- randomForest(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Destek Vektör Makinesi (DVM) (`svm_model <- svm(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Karar Ağacı (`decision_tree_model <- rpart(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Yapay Sinir Ağı (`neural_network_model <- nnet(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data, size = 5, linout = TRUE)`)

bulunmaktadır. Modellerin performans deęerlendirmesi Deney 1'deki gibi ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$  ( $R_{\text{kare}}$ ) metrikleri temelinde gerekleřtirilmiřtir. Model performansları ařaęıdaki gibidir:


**izelge 7.5:** Deney 2 Bulanıklık iin OKH, OMH ve  $R^2$ 'e gre Model Tablosu

<b>Model</b>	<b>OKH</b>	<b>OMH</b>	<b><math>R^2</math></b>
<b>Doęrusal Model</b>	0.5496347	0.6745061	0.2002100
<b>Rastgele Orman</b>	0.5385126	0.6725394	0.2189030
<b>Destek Vektr Makinesi</b>	0.5555592	0.6827191	0.1848190
<b>Karar Aęacı</b>	0.5962132	0.7017534	0.1354466
<b>Yapay Sinir Aęı</b>	0.5479706	0.6755787	0.1961688

Rastgele Orman modeli, en dřük OKH (0.5385126) ve OMH (0.6725394) deęerlerine ve en yksek  $R^2$  deęerine (0.2189030) sahip olarak, incelenen modeller arasında en iyi performansı sergilemiřtir. Bu sonular, Rastgele Orman modelinin, veri setinin karmařık yapılarını ve bulanıklığın NT performansı üzerindeki etkilerini yakalamada dięer modellere gre daha etkili olduęunu gstermektedir (Breiman, 2001).


Karar Aęacı modeli ise en yksek OKH (0.5962132) ve OMH (0.7017534) deęerlerine ve en dřük  $R^2$  deęerine (0.1354466) sahip olarak, incelenen modeller arasında en dřük performansı gstermiřtir. Bu bulgular, Karar Aęacı modelinin, veri setinin yapısal zelliklerini ve bulanıklığın etkilerini dięer modellere kıyasla daha az etkili bir řekilde modelledięini ortaya koymaktadır (Quinlan, 1986).

Dięer modeller olan Doęrusal Model, Destek Vektr Makinesi (DVM) ve Yapay Sinir Aęı, orta dzeyde OKH ve OMH deęerleri ile ve sırasıyla 0.2002100, 0.1848190 ve 0.1961688  $R^2$  deęerleri ile karıřık sonular sergilemiřlerdir. Bu sonular, bu modellerin performansının, Rastgele Orman modeline gre daha dřük olduęunu ancak Karar Aęacı modeline gre genellikle daha iyi olduęunu gstermektedir (Neter et al., 1990; Cortes & Vapnik, 1995; Rumelhart et al., 1986).



**Şekil 7.25:** Deney 2 Bulanıklık için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması

Bu bağlamda, Rastgele Orman modelinin, bulanıklığın ÇNT performansı üzerindeki etkilerini modellemede, incelenen diğer modellere göre üstün olduğu gözlemlenmiştir.




**Şekil 7.26:** Deney 2 Bulanıklık için Model Performans Metrikleri

Bu bulgular, literatürde Rastgele Orman modelinin çeşitli problemlerde etkili bir modelleme aracı olarak kullanılabilirliğini destekleyen çalışmalarla da uyumlu olup (Breiman, 2001; Hastie, Tibshirani & Friedman, 2009), belirli bir görev için model seçiminde birden çok modelin performansının kapsamlı bir şekilde değerlendirilmesi ve karşılaştırılmasının önemini vurgulamaktadır.

Tabloya göre değerlendirdiğimizde, Rastgele Orman modeli en iyi genel performansı sergilemekte olup en düşük OKH ve OMH değerlerine sahip olduğu görülmektedir (Şekil 7.25).


Doğrusal Model ve Yapay Sinir Ağı modelleri de diğer modellere kıyasla daha iyi performans göstererek düşük OKH ve OMH değerlerine sahiptir, Karar Ağacı modeli ise her iki metrik için en yüksek değerlere sahiptir (Şekil 7.26).

$R^2$  değerleri açısından, Yapay Sinir Ağı, Doğrusal Model ve DVM en yüksek değerlere sahip olup veriye en iyi uyumu sağlar. Öte yandan Karar Ağacı modelleri, görece düşük  $R^2$  değerleriyle veriye daha zayıf bir uyum sağlar (Şekil 7.27).




**Şekil 7.27:** Deney 2 Bulanıklık için OKH, OMH ve  $R^2$ 'e göre Her bir Modelin Ayrı Grafikleri

Sonuç olarak, Rastgele Orman modeli, değerlendirme kriterlerine dayanarak beş model arasında en iyi performansı sergilemektedir.




Şekil 7.28: Deney 2 Bulanıklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri



Şekil 7.29: Deney 2 Bulanıklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler

Bir modelin performansını değerlendirmek ve farklı modelleri karşılaştırmak genellikle karmaşık bir süreçtir ve bir dizi faktöre bağlıdır. Model seçimi ve

optimizasyonu genellikle belirli bir durum ve uygulama için en uygun çözümü bulmak için deneme yanılma gerektirir (Şekil 7.28).



**Şekil 7.30:** Deney 2 Bulanıklık için kullanılan göre Gerçek/Tahmin Edilen Değerlerin Sayısı

Belirli bir görev için en uygun modeli seçmeden önce birden çok modelin performansını dikkatlice değerlendirmek ve karşılaştırmak gerekmektedir (Şekil 7.29) (Şekil 7.30).

Bu süreç, model seçimini optimize edebilir, projenin başarı şansını artırabilir ve daha doğru ve güvenilir sonuçlar elde etmeye yardımcı olabilir

### 7.8 Deney 2 Kontrast Modellemesi

Bulanıklık deneyinde olduğu gibi beş farklı makine öğrenimi modelinin kontrastın ÇNT performansı üzerindeki etkilerini modelleme bağlamında karşılaştırması yapılır (Çizelge 7.6).

İncelenen modeller arasında Deney 1’de olduğu gibi

- Doğrusal Model (`linear_model <- lm(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),


- Rastgele Orman(`random_forest_model<- randomForest(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Destek Vektör Makinesi (DVM) (`svm_model <- svm(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Karar Ağacı (`decision_tree_model <- rpart(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data)`),
- Yapay Sinir Ağı(`neural_network_model <- nnet(Ortalama ~ mod_type + Cinsiyet + Yaş, data = train_data, size = 5, linout = TRUE)`) bulunmaktadır.

Analiz sonuçlarına göre, Rastgele Orman modeli, en düşük OKH (0.4526784) ve OMH (0.5233601) değerlerine sahip olmasıyla dikkat çekmektedir. Bu, modelin genel olarak daha iyi bir performans sergilediğini gösterir. Ayrıca,  $R^2$  değeri (0.19615611) ile de en iyi uyumu sağlayan model olduğu anlaşılmaktadır. Bu, Rastgele Orman modelinin veri setindeki karmaşık ilişkileri modellemede etkili olduğunu ve kontrastın ÇNT performansı üzerindeki etkilerini yakalamada diğer modellere göre daha başarılı olduğunu gösterir.

Doğrusal Model, DVM ve Yapay Sinir Ağı ise OKH, OMH ve  $R^2$  değerleri açısından dikkate değer performans göstermiştir. Bu, modellerin belirli durumlar için uygun olabileceğini, ancak genel olarak Rastgele Orman kadar çok iyi bir uyum sağlamadığını gösterir.

**Çizelge 7.6:** Deney 2 Kontrast için OKH, OMH ve  $R^2$ 'e göre Model Tablosu

<b>Model</b>	<b>OKH</b>	<b>OMH</b>	<b><math>R^2</math></b>
<b>Doğrusal Model</b>	0.4607257	0.5560707	0.16506953
<b>Rastgele Orman</b>	0.4526784	0.5233601	0.19615611
<b>DVM</b>	0.4693677	0.5558176	0.15716836
<b>Karar Ağacı</b>	0.5237941	0.6013878	0.05262305
<b>Yapay Sinir Ağı</b>	0.4651929	0.5574782	0.15719436




**Şekil 7.31:** Deney 2 Kontrast için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması

Karar Ağacı modeli de OKH (0.5237941), OMH (0.6013878) ve  $R^2$  (0.05262305) değerleri modelin karışık sonuçlar sergilediğini ve iyi bir performans göstermediğini belirtir.


Bu modellerin hiçbiri, Rastgele Orman'ın sağladığı performans seviyesine ulaşamamıştır.

Rastgele Orman modelinin beş model arasında en düşük OKH ve OMH değerlerine sahip olduğu ve daha iyi bir performans sergilediği görülebilir (Şekil 7.31).

Bu analiz, Rastgele Orman Modelinin, kontrastın ÇNT performansı üzerindeki etkilerini modellemede en uygun seçenek olduğunu ortaya koymaktadır. Modelin karmaşık ilişkileri etkili bir şekilde modelleyebilme yeteneği ve genel makine öğrenmesi sorunlarına karşı dayanıklılığı, bu sonucun ana nedenlerindedir. Bu bulgular, Rastgele Orman'ın karmaşık sınıflandırma ve regresyon problemleri için tercih edilen bir yöntem olduğunu ve bu bağlamda üstün performans sergileyebileceğini göstermektedir.



Şekil 7.32: Deneysel Kontrast için Model Performans Metrikleri




Şekil 7.33: Deneysel Kontrast için OKH, OMH ve  $R^2$ 'e göre Her bir Modelin Ayrı Grafiği

Doğrusal Model, DVM ve Yapay Sinir Ağı modelleri de göreceli olarak düşük OKH ve OMH değerlerine sahiptir (Hsu vd.,2003; Huang vd.,2006) (Şekil 7.32).



uyum sağladığını gösterir (Hastie vd.,2009) Bu modellerin gerçek/tahmin edilen değerleri arasındaki ilişki aşağıda gösterilmiştir (Şekil 7.34).

Genel olarak, verilen değerlendirme ölçütleri temelinde Rastgele Orman modelinin beş model arasında en iyi performansı sergilediği görülmektedir (Şekil 7.35).



**Şekil 7.36:** Deneysel Kontrast için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı

Dolayısıyla, belirli bir uygulama için en etkin modeli belirlerken, çeşitli model tiplerinin performansını titizlikle analiz etmek ve kıyaslamak önemlidir. Yani, her modelin uygulandığı belirli bir duruma ne kadar iyi uyum sağladığını anlamak için geniş bir model seti üzerinde kıyaslama yapılmalıdır (Şekil 7.36).

### 7.9 Deneysel Parlaklık Modellemesi

Bu deneyde, beş farklı makine öğrenimi modelinin parlaklığın ÇNT performansı üzerindeki etkilerini modelleme bağlamında karşılaştırması yapılır (Çizelge 7.7).

Verilere göre:

Doğrusal Model (`linear_model <- lm(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`), OKH'de 0.5427791 ve OMH'de 0.6450568 değerleriyle orta seviyede bir performans sergilemektedir.  $R^2$  değeri 0.16506953 olup, modelin veri setiyle uyumunu göstermektedir.

Rastgele Orman modeli(`random_forest_model <- randomForest(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`), OKH'de 0.5570509 ve OMH'de 0.6533377 ile diğer modellere kıyasla daha yüksek hata değerlerine sahip olmasına rağmen,  $R^2$  değeri 0.19615611 ile en iyi model uyumunu sağlamıştır. Bu, modelin veri setindeki değişkenliği en iyi açıklayan model olduğunu gösterir.

DVM(`svm_model <- svm(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`), OKH'de 0.5546477 ve OMH'de 0.6673471 değerlerine sahiptir.  $R^2$  değeri 0.15716836 olup, modelin uyumunun diğer modellere göre orta seviyeye yakın olduğunu gösterir.


Karar Ağacı(`decision_tree_model <- rpart(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data)`), tüm modeller içinde en yüksek OKH (0.6119081) ve OMH (0.7119421) değerlerine sahip olup, bu durum modelin hata oranının yüksek olduğunu gösterir.  $R^2$  değeri 0.05262305 ile en düşük uyumu sergilemiştir, bu da modelin veri setindeki değişkenliği açıklamada zayıf olduğunu gösterir.

Yapay Sinir Ağı(`neural_network_model <- nnet(Ortalama ~ mod_type + Cinsiyet+ Yaş, data = train_data, size = 5, linout = TRUE)`), OKH'de 0.5522503 ve OMH'de 0.6670614 değerlerine sahiptir.  $R^2$  değeri 0.15719436 ile orta yakın seviyede bir uyum sergilemektedir.


**Çizelge 7.7:** Deney 2 Parlaklık için OKH, OMH ve  $R^2$ 'e göre Model Tablosu

Model	OKH	OMH	$R^2$
<b>Doğrusal Model</b>	0.5427791	0.6450568	0.16506953
<b>Rastgele Orman</b>	0.5570509	0.6533377	0.19615611
<b>DVM</b>	0.5546477	0.6673471	0.15716836
<b>Karar Ağacı</b>	0.6119081	0.7119421	0.05262305
<b>Yapay Sinir Ağı</b>	0.5522503	0.6670614	0.15719436

Verilere dayanarak, Rastgele Orman modeli  $R^2$  değeri açısından hala en iyi uyumu sağlayan model olarak öne çıkarken, OKH ve OMH değerleri açısından en düşük performansı göstermemektedir. Bu durum,  $R^2$  değerinin modelin veri setindeki değişkenliği ne kadar iyi açıkladığını yansıttığını, ancak mutlak hata oranlarının da dikkate alınması gerektiğini göstermektedir.



**Şekil 7.37:** Deney 2 Parlaklık için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması




**Şekil 7.38:** Deney 2 Parlaklık için Model Performans Metrikleri

Karar Ağacı modeli ise hem hata oranları hem de  $R^2$  değeri açısından en düşük performansı sergileyen model olmuştur. Bu, model seçiminde sadece bir metriğe odaklanmanın yanıltıcı olabileceğini ve modelin performansını değerlendirirken birden fazla metriğin dikkate alınması gerektiğini gösterir.

Doğrusal Modelin beş model arasında en düşük OKH ve OMH değerlerine sahip olduğu ve daha iyi bir genel performans sergilediği görülebilir (Şekil 7.37)

DVM ve Yapay Sinir Ağı modelleri de göreceli olarak düşük OKH ve OMH değerlerine sahiptir (Breiman, 2001; Drucker vd.,1997)(Şekil 7.38).




**Şekil 7.39:** Deney 2 Parlaklık için OKH, OMH ve  $R^2$ 'e göre Herbir Modelin Ayrı Grafiği

$R^2$  değerleri açısından, Rastgele Orman en yüksek değeri göstererek beş model arasında veriye en iyi uyumu sağlar (Montgomery vd.,2012)

Doğrusal Model ve DVM ve Yapay Sinir Ağı modelleri de göreceli olarak yüksek  $R^2$  değerlerine sahiptir (Cutler vd.,2007; Smola & Schölkopf, 2004). Karar Ağacı modeli ise çok düşük  $R^2$  değerlerine sahiptir (Hastie vd.,2009; Huang vd.,2006) (Şekil 7.39).


Bu derinlemesine değerlendirme süreci, model seçiminin iyileştirilmesine, projenin başarılı olma olasılığının yükseltilmesine ve daha kesin ve güvenilir sonuçların elde edilmesine yardımcı olur (Şekil 7.40).




**Şekil 7.40:** Deney 2 Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri

Bu bağlamda, model seçimi sadece bir araç değil, aynı zamanda belirli bir probleme özgü en uygun çözümü bulmak için stratejik bir yaklaşım olarak görülebilir (Şekil 7.41).

Her bir model, belirli bir probleme özgü özelliklere sahip olduğu için, en iyi modelin seçilmesi, problemin doğasını anlama ve modelin bu doğaya nasıl uyum sağladığını belirleme yeteneğini gerektirir. Bu bağlamda uyumun ölçüsü görülmektedir (Şekil 7.42) (Yazgan, Yağımlı & Ozubko, 2023).



Şekil 7.41: Deney 2 Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler



Şekil 7.42: Deney 2 Parlaklık için kullanılan Gerçek/Tahmin Edilen Değerlerin Sayısı

## 7.10 Deney 2 Bulanıklık, Kontrast ve Parlaklığın Etkileşimini Modelleme

Çizelge, beş farklı makine öğrenimi modelinin performansını belirli bir veri kümesi üzerinde karşılaştırarak değerlendirir. Değerlendirme için kullanılan üç temel ölçüt Deney 1’de kullanıldığı gibi ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$ ’dir (Çizelge 7.8).

**Çizelge 7.8:** Deney 2 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve  $R^2$ ’e göre Model Tablosu

Model	OKH	OMH	$R^2$
Doğrusal Model	0.5567578	0.5889071	0.2168101
Rastgele Orman	0.4952156	0.5480138	0.3381735
DVM	0.5627330	0.5975250	0.1963337
Karar Ağacı	0.4994325	0.5809910	0.3011242
Yapay Sinir Ağı	0.5873461	0.5920606	0.2110093


Doğrusal Model (`linear_model <- lm(Ortalama ~ mod_type + Cinsiyet + mod_field + Yaş, data = train_data)`): Bu modelin  $R^2$  değeri 0.2168101 olup, modelin veri setindeki varyansın yaklaşık %21.68’ini açıklayabildiğini gösterir. Doğrusal modelin görece düşük  $R^2$  değeri, veri setindeki ilişkilerin lineer modelle tam olarak yakalanamayabileceğini işaret eder.

Rastgele Orman (`random_forest_model <- randomForest(Ortalama ~ mod_type + Cinsiyet + mod_field + Yaş, data = train_data)`):  $R^2$  değeri 0.3381735 ile bu model, veri setindeki değişkenliğin yaklaşık %33.82’sini açıklayarak, incelenen modeller arasında en iyi uyumu sağlamıştır.


Destek Vektör Makineleri (DVM) (`svm_model <- svm(Ortalama ~ mod_type + Cinsiyet + mod_field + Yaş, data = train_data)`): Bu modelin  $R^2$  değeri 0.1963337 olup, veri setindeki değişkenliği %19.63 oranında açıklayabildiğini gösterir. DVM’nin diğer modellere göre daha düşük performans sergilemesi, modelin parametre seçimi veya veri setinin doğasından kaynaklanıyor olabilir.

Karar Ağacı (`decision_tree_model <- rpart(Ortalama ~ mod_type + Cinsiyet + mod_field + Yaş, data = train_data)`): Bu modelin  $R^2$  değeri 0.3011242 ile, veri

setindeki deęişkenlięin yaklaşık %30.11'ini açıklayarak iyi bir performans sergilemiştir. Karar Ağacı modelinin yüksek performansı, modelin veri setindeki özellikleri ve etkileşimleri basit ve etkili bir şekilde yakalayabilmesinden kaynaklanıyor olabilir.




**Şekil 7.43:** Deneý 2 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve  $R^2$ 'e göre Model Karşılaştırması



**Şekil 7.44:** Deneý 2 Bulanıklık, Kontrast ve Parlaklık için Model Performans Metrikleri

Yapay Sinir Ağı(neural\_network\_model <- nnet(Ortalama ~ mod\_type + Cinsiyet + mod\_field + Yaş, data = train\_data, size = 5, linout = TRUE)): Bu modelin R<sup>2</sup> değeri 0.2110093 olup, veri setindeki değişkenliği yaklaşık %21.10 oranında açıklayabildiğini gösterir. Yapay Sinir Ağlarının bu durumda görece düşük performans sergilemesi, ağ mimarisinin optimizasyonu veya eğitim veri setinin niteliğiyle ilgili olabilir.

Sonuç olarak, Rastgele Orman modelinin beş model arasında en düşük OKH ve OMH değerlerine sahip olduğu ve daha iyi genel performans sergilediği görülebilir (Liaw & Wiener, 2002; Breiman, 2001) (Şekil 7.43).




**Şekil 7.45:** Deney 2 Bulanıklık, Kontrast ve Parlaklık için OKH, OMH ve R<sup>2</sup>'e göre Her bir Modelin Ayrı Grafiği

Bu, Rastgele Orman'ın veri setindeki karmaşık ilişkileri etkili bir şekilde modelleyebilme yeteneğine işaret eder. Diğer modellerin performansı, modelin doğası, parametre seçimi ve veri setinin özellikleri gibi faktörlere bağlı olarak değişiklik göstermektedir.


Karar Ağacı modeli de görece düşük OKH ve OMH değerlerine sahiptir (Quinlan, 1986) (Şekil 7.44).

R<sup>2</sup> değerleri açısından, Rastgele Orman modeli, beş model arasında veriye en iyi uyumu gösteren en yüksek değere sahiptir (Cutler vd.,2007).

Karar Ağacı modeli de görece yüksek bir  $R^2$  değerine sahiptir (Hastie vd.,2009), diğer modellerin ise daha düşük  $R^2$  değerleri vardır (Şekil 7.45).



Şekil 7.46: Deney 2 Bulanıklık, Kontrast ve Parlaklık için kullanılan Modellerin Gerçek/Tahmin Edilen Değerleri



Şekil 7.47: Deney 2 Bulanıklık, Kontrast ve Parlaklık için kullanılan Rastgele Orman Model Sonucuna göre Gerçek/Tahmin Edilen Değerler



istatistiksel analizlerin ve ana bulguların özetini sunuyoruz. Deneylerde kullanılan veri seti, farklı bulanıklık, kontrast ve parlaklık düzeylerinde nesnelerin takip edildiği bir dizi ÇNT görevinden elde edilmiştir. Çeşitli makine öğrenimi modellerinin bu veri setindeki performansını değerlendirmek için veri eğitim ve test setlerine ayrılmıştır. Modeller, ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve  $R^2$  gibi üç değerlendirme ölçütüne göre karşılaştırılmıştır.

Karşılaştırılan beş makine öğrenimi modeli şunlardır:

- Doğrusal Model (DM)
- Rastgele Orman (RO)
- Destek Vektör Makinesi (DVM)
- Karar Ağacı (KA)
- Yapay Sinir Ağı (YSA)

Deneylerden elde edilen temel bulgular şunlardır:

#### 1. Doğrusallık ve Model Performansları:

- Doğrusal Model, genel olarak Deney 1'de düşük  $R^2$  değerleri ile diğer modellerle karşılaştırıldığında zayıf performans sergilemiştir. Bu durum, doğrusal modellerin bulanıklık, kontrast ve parlaklık gibi değişkenler arasındaki doğrusal olmayan ilişkileri yakalama konusunda sınırlı olabileceğini ve bu nedenle Deney 1'deki ÇNT görevleri için uygun olmayabileceğini göstermektedir. Fakat Deney 2'de ise genel itibarıyla daha iyi performans sergilemiştir.

#### 2. Rastgele Orman Modelinin Üstünlüğü:

- Rastgele orman modelleri, çoğu durumda hem OKH hem de OMH açısından diğer modellere göre daha iyi performans sergilemiştir. Özellikle Deney 1'de bulanıklık, kontrast, parlaklık ve etkileşim modellemesinde ve Deney 2'de bulanıklık, kontrast, parlaklık ve etkileşim modellemesinde  $R^2$  değerleri önemli ölçüde yüksektir. Bu, Rastgele Orman modelinin karmaşık ve doğrusal olmayan ilişkileri yakalamada etkili olduğunu ve bu ÇNT görevi için uygun bir seçim olabileceğini göstermektedir.

### 3. Destek Vektör Makineleri

- DVM, farklı deneylerde çeşitli performanslar sergilemiştir. Bu, DVM'lerin parametre ayarlarına ve kullanılan çekirdek fonksiyonuna bağlı olarak performansının değişebileceğini ve en uygun sonuçlar için dikkatli bir optimizasyon gerektirdiğini göstermektedir.

### 4. Karar Ağaçlarının Değişken Performansı:

- Karar Ağacı modeli de değişken sonuçlar göstermiş, bazı ölçümlerde rekabetçi performanslar sergilerken özellikle Deney 1 kontrast, parlaklık ve Deney 2 etkileşimde iyi, diğerlerinde ise daha düşük  $R^2$  değerleri ile sınırlı kalmıştır. Bu durum, büyük ve karmaşık veri setlerinde performansının düşebileceğini düşündürmektedir.

### 5. Yapay Sinir Ağlarının Performansı:

- Yapay Sinir Ağları, genel olarak tutarlı performans sergilemiştir, ancak doğrusal ve karar ağacı modelleri kadar öne çıkan bir performans göstermemiştir. Deney 1 bulanıklık ve etkileşimde en iyi 2. performans gösteren modellemedir. Bu durum, YSA'ların karmaşık ilişkileri yakalama potansiyeline sahip olduğunu ancak eğitim sürecinin daha zorlu ve zaman alıcı olabileceğini göstermektedir. Ayrıca, YSA'larda aşırı uyuma sorununa karşı hassas olabilir ve optimizasyon için daha fazla veri gerektirebilirler.

### 6. Model Seçiminin Önemi:

- Farklı metrikler (OKH, OMH,  $R^2$ ) üzerindeki performans değerlendirmeleri, en uygun modelin seçiminin, spesifik uygulama gereksinimlerine ve hedef metriklere bağlı olarak dikkatlice yapılması gerektiğini göstermektedir. Bu, belirli bir hata türünün minimize edilmesi veya veri setindeki varyansın maksimum düzeyde açıklanması gibi hedeflere bağlı olabilir.

### 7. Metriklerin Rolü:

- $R^2$ , modelin veri setindeki varyansı ne kadar iyi açıklayabildiğini gösterirken, OKH ve OMH hataların büyüklüğünü ölçer. Yüksek  $R^2$  değeri genellikle modelin daha iyi performans gösterdiğini, düşük

OKH ve OMH deęerleri ise tahminlerin gerek deęerlere daha yakın olduęunu gosterir.

Bu analizler, veri biliminde model seimi ve deęerlendirme surelerinin karmaşıklığı ve bu surelerin ok boyutlu doęasını vurgular.

### 7.12 Modelin Sonuları

Bu alıřma, dikkat tahsisi ve nesne takibi sureleri zerinde bulanıklık, kontrast ve parlaklık gibi gorsel faktorlerin etkilerini incelemek iin oklu nesne takibi (NT) performans modelinin geliřtirilmesi ve deęerlendirilmesini sunmaktadır. Model, psikoloji, iř saęlığı ve gvenlięi, insan-bilgisayar etkileřimi ve eęitim ve beceri geliřtirme gibi eřitli alanlar iin nemli sonuları vardır.

#### *Gorsel Faktorlerin Etkisi:*

- *Bulanıklık:* Bulanıklık arttıka, NT performansının genellikle dřtę gozlemlenmiřtir. Ancak, Rastgele Orman modeli bulanıklığın etkisini dięer modellere gore daha doęru bir řekilde modelleyebilmiřtir. Bu durum, bulanıklığın NT performansı zerinde nemli bir etkiye sahip olduęunu ve bu etkinin modelleme ve azaltma stratejileri geliřtirmek iin dikkate alınması gerektiğini gostermektedir. Dięer en iyi aıklayan modeller ise Deney 1’de Yapay Sinir Aęı, Deney 2’de ise Doęrusal Modeldir.
- *Kontrast:* Modellerin kontrast deęiřikliklerine yanıtları da deęiřkenlik gosterdi, Rastgele model tm metriklerde dięerlerine gore daha iyi performans gosterdi. Dięer modellerden Karar Aęacı ve Doęrusal Modelde sık sık daha dřk hatalar gostererek kontrast varyasyonlarıyla bařa ıkma konusunda bir dzeyde saęlamlık sergiledi.
- *Parlaklık:* Bulanıklık ve kontrastla benzer řekilde, parlaklık etkileri de farklı makine ęrenimi modelleri arasında deęiřen derecelerde doęrulukla modellendi. Rastgele Orman ve ara sıra Karar Aęacı ve Doęrusal Model, daha dřk hata metrikleri aısından umut verici sonular gosterdi.
- *Etkileřimin Modellenmesi:* Etkileřim deęiřkenlerini en iyi aıklayan Deney 1 ve Deney 2 iin en iyi model Rastgele Orman, Deney 1 iin en iyi 2. model ise Yapay Sinir Aęı ve Deney 2 iin ise Karar Aęacı algoritmasıdır.

### *Genel Gözlemler:*

Destek Vektör Makinesi Modeli (DVM) genellikle görsel faktörlerin görev performansını nasıl etkilediğinin karmaşıklığını yakalama konusunda sınırlılıklar gösterdi, bu genellikle daha yüksek hata oranları ve daha düşük  $R^2$  değerleriyle yansıtıldı.

Rastgele Orman, Karar Ağaçları ve Doğrusal Model gibi makine öğrenimi modelleri genellikle verinin karmaşıklıklarına daha iyi uyum sağladı, daha düşük hatalar ve ara sıra daha yüksek  $R^2$  değerleri göstererek veri desenlerinin daha nüanslı bir anlayışını gösterdi.

Yapay Sinir Ağları karışık sonuçlar gösterdi, bazı deneylerde iyi performans sergilerken diğerlerinde daha az başarılı oldular, bunun etkililiğinin bağlam veya parametre ayarlarına bağlı olabileceği öne sürülebilir.

Sonuç olarak, bu çalışma, görsel faktörlerin ÇNT performansı üzerindeki karmaşık etkileşimini anlamak için önemli bir adım atmaktadır ve araştırmacılar ve uygulayıcılar için çeşitli bağlamlarda insan performansını geliştirmek için değerli bir çerçeve sunmaktadır. Daha fazla geliştirme ve ek araştırma yönelimlerinin keşfedilmesiyle, model sürekli olarak geliştirilebilir ve çeşitli alanlarda ve endüstrilerde daha güçlü görüşler ve uygulamalar sunmaya devam edebilir.

Bu analiz, görsel faktörlerden etkilenen görevlerde insan performansını modelleme karmaşıklığını vurgular ve özellikle Rastgele Orman modelinin bu karmaşıklığı yönlendirme ve eyleme geçirilebilir içgörüler sağlama potansiyelini ortaya koyar.

## **8.SONUÇLAR VE TARTIŞMA**

### **8.1 Değerlendirme Bulgularının Özeti**

#### **8.1.1 Birincil araştırma bulgularının özeti**

Çalışmamız, bulanıklık, kontrast ve parlaklık gibi görsel manipülasyonların, çoklu nesne izleme (ÇNT) görevlerindeki performansı önemli ölçüde etkilediğini ve bu bulguların, görsel becerileri yoğun şekilde kullanan rollerde insan dikkat dağıtımı hakkındaki anlayışımıza katkıda bulunduğunu göstermiştir (Scholl, 2009; Carrasco, 2006; Alvarez & Franconeri, 2007; Cavanagh & Alvarez, 2005). Bu bulgular, görsel faktörlerin ÇNT performansında önemini belirleyen Meyerhoff vd., (2017)'nin çalışmasını genişletmektedir.

#### **8.1.2 Bireysel değişkenliğin önemi**

Sonuçlarımız, görsel manipülasyonlar altındaki performansta bireysel değişkenliğin önemli rolünü vurgulamaktadır. Modelimizdeki rassal etkiler, bu değişkenliği ortaya çıkardı ve iş yerinde kişiselleştirilmiş veya adaptif güvenlik önlemlerine olan ihtiyacı belirtti (Rosenholtz vd.,2012; Gugerty vd.,2004; Kwon & Cho, 2014).

#### **8.1.3 Görsel manipülasyonlar ve demografik özellikler arasındaki etkileşimler**

Araştırmamız, görsel manipülasyonlar yaş, cinsiyet gibi demografik özellikler arasında önemli etkileşimler ortaya çıkardı. Bu demografik özelliklerin, farklı görsel koşullar altında yüksek görsel doğruluk görevlerindeki performansı etkilediğini bulduk, bu da iş yerinde güvenliğe daha kişiselleştirilmiş bir yaklaşımın önemini vurgulamaktadır (St. John vd.,2005; Sweller vd.,2011).

#### **8.1.4 Yüksek görsel doğruluk görevlerinin sonuçlarının içerdiği anlamlar**

Bulgularımızın, yüksek görsel doğruluk gerektiren görevler için pratik sonuçları vardır. Görsel manipülasyonların görev performansı üzerindeki etkisini anlamak, iş güvenliğini artırmak ve işle ilgili yaralanmaları azaltmak için önleyici stratejilerin ve politika düzenlemelerinin geliştirilmesine bilgi sağlayabilir (Wickens vd.,2008; Meyer & Kieras, 1997). Bu düşünce, iş yerindeki görsel ergonomi öneminin farkında olan Rosenholtz vd. (2012) ve Gugerty vd. (2004)'nun çalışmaları ile aynı çizgidedir.

### **8.2 Değerlendirmenin Sınırlılıkların Ele Alınması**

#### **8.2.1 Laboratuvar vs. gerçek dünya koşulları**

Deneylelerimiz kontrollü ortamlarda gerçekleştirilmiş olmasına rağmen, gelecek araştırmaların bu çalışmaları gerçek dünya ortamlarında tekrarlamayı hedeflemesi gerekmektedir (Meyerhoff vd.,2017). Gerçek dünya ortamları, kontrollü ortamlarda tam anlamıyla yakalanamayan karmaşıklık ve değişkenlik sunar; bunlar arasında iş yeri stresi, çoklu görev talepleri ve çevresel rahatsızlıklar bulunmaktadır.

#### **8.2.2 Demografik değişkenlerin genişletilmesi**

Çalışmamız temel olarak yaş ve cinsiyet farklılıklarına odaklandı. Gelecek çalışmalar demografik değişkenleri genişletebilir ve etnik köken, eğitim düzeyi ve mesleki geçmiş gibi faktörleri dahil edebilir. Böyle yapmak, farklı görsel koşullar altındaki görev performansı üzerinde bu faktörlerin etkisini daha ince bir anlayışla anlamamızı sağlayabilir (St. John vd.,2005; Sweller vd.,2011).

#### **8.2.3 Görsel koşulların kapsamının genişletilmesi**

Görev performansı üzerinde belirli görsel manipülasyonların (bulanıklık, kontrast ve parlaklık) etkilerini inceledik. Gelecek araştırmalar renk algısı, periferik görüş ve derinlik algısı gibi diğer görsel koşulları inceleyebilir. Daha geniş bir kapsam, iş yerindeki görsel koşullar ve görev performansı arasındaki karmaşık etkileşime daha fazla ışık tutabilir (Alvarez & Franconeri, 2007; Cavanagh & Alvarez, 2005).

### **8.2.4 Bireysel deęişkenliğe daha derinlemesine bakış**

Deneşlerimiz bireysel deęişkenliğini yakaladı, ancak bu deęişkenlięin kaynaklarını daha derinlemesine incelemek için gelecek arařtırmaları öneriyoruz. Göz önünde bulundurulacak potansiyel faktörler arasında görsel keskinlik, önceki deneyim, bilişsel yetenekler ve kişilik özellikleri bulunabilir. Bireysel deęişkenlięi daha iyi anlamak, işyeri güvenliği için daha kişiselleştirilmiş ve etkili müdahalelere yol açabilir (Kwon & Cho, 2014; Rosenholtz vd.,2012; Gugerty vd.,2004).

### **8.3 Modelin Bulgularının Etkileri**

Bu bölümde, geliştirilen çoklu nesne takip (ÇNT) performans modelinin olası uygulamaları ve etkileri tartışılmıştır. Özellikle psikoloji, iş sağlığı ve güvenliği, insan-bilgisayar etkileşimi ve eğitim ve beceri geliştirme alanlarına odaklanılmıştır.

Bu çalışmada, insan dikkati ve nesne takip performansı üzerindeki üç görsel faktörün- bulanıklık, kontrast ve parlaklık- etkilerini anlamak ve tahmin etmek için bir çoklu nesne takip (ÇNT) performans modeli geliştirilmiştir.

Sonuç olarak, geliştirilen ÇNT performans modeli, görsel faktörlerin dikkat ve nesne takip üzerindeki rolüne ilişkin değerli bilgiler sunar, psikoloji, iş sağlığı ve güvenliği, insan-bilgisayar etkileşimi, eğitim ve beceri geliştirme gibi çeşitli alanlarda geniş uygulama ve etkileri vardır. Başarılı bir şekilde doğrulanan model, arařtırma ve uygulama açısından bilgi sağlama potansiyeline sahiptir, daha etkili ve görsel olarak erişilebilir ekran tabanlı görev ve ortamların tasarımına katkıda bulunur.

#### **8.3.1 Psikoloji arařtırmalarını geliştirme**

Model, ÇNT görevlerinde görsel faktörlerin rolünü ve dikkat tahsisi ile nesne takip süreçlerine etkilerini anlamak için kapsamlı bir çerçeve sunar (Scholl, 2009; Carrasco, 2006).

Arařtırmacılar modeli kullanarak yeni deneyler tasarlayabilir, dikkatle ilgili hipotezleri test edebilir ve ÇNT performansının temel mekanizmalarını daha da arařtırabilir (Alvarez & Franconeri, 2007; Cavanagh & Alvarez, 2005).

Görsel faktörlerle modele sistemli bir şekilde müdahale ederek, arařtırmacılar insan görsel sisteminin karmaşık görsel uyarıcılara nasıl tepki verdiğini ve takip

görevleri sırasında dikkat kaynaklarını nasıl tahsis ettiğini daha iyi anlayabilirler (Meyerhoff vd.,2017).

Psikoloji alanındaki araştırmacılar, modeli farklı görsel koşullar altında dikkat tahsisi ve nesne takip süreçlerine ilişkin bilgiler elde etmek için kullanabilirler.

Makine öğrenimi tekniklerinin psikoloji araştırmaları ile entegrasyonu, dikkat ve nesne takibi gibi bilişsel süreçlerin çalışılmasını iyileştiren daha gelişmiş modeller ve öngörü araçlarının geliştirilmesine yol açabilir.

### **8.3.2 İş Sağlığı ve güvenliğini geliştirme**

Model, iş sağlığı ve güvenliği alanında, özellikle ekran tabanlı görev ve ortamların tasarımı ve değerlendirmesinde değerli uygulamalara sahiptir. Bulanıklık, kontrast ve parlaklık etkilerini ÇNT performansı üzerinde dikkate alarak, model belirli görevler için en uygun görsel koşulların belirlenmesine yardımcı olabilir, potansiyel olarak görsel yorgunluğu azaltabilir ve genel görev performansını iyileştirebilir (Rosenholtz vd.,2012; Gugerty vd.,2004).

Organizasyonlar, model tarafından belirlenen optimal düzeylere göre bulanıklık, kontrast ve parlaklık gibi ekran ayarlarını ayarlayarak daha iyi görsel ergonomi sağlayabilir ve genel üretkenliği artırabilir (Kwon & Cho, 2014).

Model, iş kazaları veya hatalara katkıda bulunabilen yüksek riskli görsel koşulları belirlemeye yardımcı olarak, organizasyonların potansiyel tehlikeleri önceden belirlemesine ve güvenlik önlemlerini uygulamasına olanak tanır.

### **8.3.3 İnsan-Bilgisayar ilişkisindeki tasarımları yönlendirme**

Model, havacılık, trafik kontrolü ve sağlık gibi çeşitli endüstrilerde kullanıcı arayüzü ve görüntüleme sistemlerinin tasarımını etkileyebilir. Tasarımcılar, dikkat ve nesne takip üzerinde görsel faktörlerin etkilerini dikkate alarak daha etkili ve görsel olarak erişilebilir ara yüzler oluşturmak için modele başvurabilirler ve bu durum kullanıcı deneyimini ve performansını artırabilir (Wickens vd.,2008; Meyer & Kieras, 1997).

### **8.3.4 Eğitimi ve yetenek gelişimini iyileştirme**

Model, farklı görsel koşullar altında ÇNT performansını geliştirmeyi amaçlayan eğitim programlarının geliştirilmesinde kullanılabilir. Eğitimciler, farklı

bulanıklık, kontrast ve parlaklık seviyelerini simüle ederek, bireylerin zorlu görsel ortamlarla başa çıkmak için gerekli becerileri geliştirmelerine yardımcı olan uyarlamalı eğitim senaryoları tasarlayabilirler (St. John vd.,2005). Eğitimci, görsel uyarıcıların bulanıklık, kontrast ve parlaklık açısından optimal seviyelerde sunumunu sağlayarak daha iyi öğrenme sonuçları elde edebilir, eğitim alanının beceri kazanımını geliştirebilir ve karmaşık görsel görevlerle ilişkili bilişsel yükü azaltabilir (Sweller vd.,2011).

Özet olarak, geliştirilen ÇNT performans modelinin çeşitli alanlarda geniş uygulama ve sonuçları bulunmaktadır. Başarılı doğrulama hem araştırmaya hem de uygulamaya katkıda bulunma potansiyelini vurgulayarak, daha etkili ve görsel olarak erişilebilir ekran tabanlı görevlerin ve ortamların tasarımına katkıda bulunmaktadır.

ÇNT performans modelinden elde edilen bilgileri anlayarak ve uygulayarak, araştırmacılar, uygulayıcılar ve organizasyonlar çeşitli ekran tabanlı görevler ve ortamlarda dikkati ve nesne takibini optimize etmek için daha etkili stratejiler geliştirebilir. Bu da işyeri güvenliği, üretkenlik ve genel iyi olma durumunu artırmaya katkı sağlayabilir.

#### **8.4 Model Sınırlamaları ve Gelecek Araştırmalar**

Geliştirilen ÇNT performans modelinin çoklu disiplinlerde değerli görüşler ve uygulamalar sunmasına rağmen, sınırlamalarını kabul etmek ve gelecekteki araştırmalar için yönlendirmelerde bulunmak önemlidir.

*Sınırlı Görsel Faktörler:* Mevcut model bulanıklık, kontrast ve parlaklık gibi üç görsel faktöre odaklanmaktadır. Ancak, diğer görsel faktörler, örneğin renk, nesne boyutu, uzamsal frekans ve hareket, ÇNT performansını da etkileyebilir (Scholl, 2009; Cavanagh ve Alvarez, 2005). Gelecekteki araştırmalar, ek görsel faktörleri dahil ederek modeli genişleterek, dikkat ve nesne takibi üzerindeki etkilerini daha kapsamlı bir şekilde anlamak için genişletebilir.

*Veri Seti Kalitesi:* Modelin performansı kullanılan veri setinin kalitesine ve boyutuna dayanmaktadır. Genelleştirilebilirlik ve güvenilirlik sağlamak için, gelecekteki araştırmalar daha büyük veri setleri kullanmayı, daha çeşitli katılımcılar eklemeyi, deneyim ve bilişsel yetenekler gibi bireysel farklılıkları dikkate almaları gerekmektedir (Caruana ve Niculescu-Mizil, 2006; Bergstra ve Bengio, 2012).

*Model Değerlendirmesi:* Mevcut çalışma birkaç makine öğrenimi modelini karşılaştırırsa da ÇNT performansını tahmin etmek için uygunluğunu belirlemek için alternatif teknikler ve daha gelişmiş modeller, model performansını daha da iyileştirmek için keşfedilebilir. Örneğin, derin öğrenme modelleri veya birleştirme teknikleri daha iyi performans sağlayabilir veya yeni bakış açıları sunabilir (Goodfellow vd.,2016; Zhou, 2012).

*Bireysel Farklılıkların İncelenmesi:* Görme keskinliği, bilişsel yetenekler ve önceden deneyim gibi bireysel farklılıkların ÇNT performansındaki rolü, gelecekteki araştırmalarda incelenmelidir. Bu, bireysel kullanıcıların benzersiz ihtiyaçları ve yetenekleri için özelleştirilmiş modellerin geliştirilmesine olanak sağlar.

*Gerçek Dünya Uygulamaları:* Mevcut çalışma temel olarak deneysel ortamlara odaklanmıştır. Gelecekteki araştırmalar, ÇNT performans modelinin iş ortamları, eğitim ortamları ve çeşitli endüstriler gibi gerçek dünya bağlamlarında uygulanabilirliğini araştırarak, pratik kullanılabilirliğini belirleyebilir.

*Uzun Vadeli Etkiler:* Mevcut model, görsel faktörlerin ÇNT performansı üzerindeki anlık etkilerine odaklanmaktadır. Gelecekteki araştırmalar, uyum ve yorgunluk gibi görsel faktörlerin dikkat ve nesne takibi üzerindeki potansiyel uzun vadeli etkilerini araştırabilir (Rosenholtz vd.,2012; Gugerty vd.,2004).

Ek Görsel Faktörlerin Dahil Edilmesi:

*Modelin Yorumlanabilirliği:* Makine öğrenimi modellerinin yorumlanabilirliği, gerçek dünya uygulamaları için önemli olabilir. Gelecekteki araştırmalar, ÇNT performansının temel ilişkilerini ve faktörlerini uygulayıcılar ve araştırmacılar tarafından daha kolay anlaşılabilir hale getirmeye odaklanabilir.

*Araştırma yönelimi:* Mevcut çalışma, görsel faktörlerin çoklu nesne takibi (ÇNT) performansı üzerindeki etkilerini anlamak için değerli bir model sunmasına rağmen, modelin uygulanabilirliğini ve güvenilirliğini daha da geliştirmek için birkaç gelecek araştırma yönelimi takip edilebilir.

Bu gelecek araştırma yönelimlerini takip ederek, ÇNT performans modeli daha da geliştirilebilir ve genişletilebilir, çeşitli alanlarda ve endüstrilerde daha güçlü görüşler ve pratik uygulamalar sunabilir.

Bu sınırlamaları ele alarak ve gelecekteki araştırma yönelimlerini keşfederek, ÇNT performans modeli gelişmeye devam edebilir. Psikoloji, iş sağlığı ve güvenliği, insan-bilgisayar etkileşimi ve eğitim ve beceri geliştirme alanlarında daha fazla görüş ve uygulama sunabilir.

## **8.5 İş Sağlığı ve Güvenliğinde Gelecek Yönelimler**

### **8.5.1 Kişiselleştirilmiş iş güvenliği yaklaşımları**

Dijital teknolojilerin ilerlemesiyle, çeşitli endüstrilerde yüksek görsel doğruluk gerektiren görevler daha yaygın hale gelmektedir. Bu ilerlemeler, bulanıklık, parlaklık ve kontrast gibi görsel parametrelerin yönetimini daha da kritik hale getirerek, bireysel çalışanlar üzerindeki görsel talepleri artırabilir. Bu nedenle, bireysel çalışanların bu görsel parametreleri kendileri için ayarlamalarına olanak tanıyan gelişmiş ekipman ve araçlara ihtiyaç vardır.

İşgücü yaş, cinsiyet ve diğer demografik özellikler açısından çeşitlilik göstermeye devam ettikçe, kişiselleştirilmiş iş güvenliği yaklaşımları giderek daha gerekli hale gelecektir. Gelişmiş teknolojilerin ortaya çıkmasıyla birlikte, yapay zekâ (YZ) ve makine öğrenmesinin iş sağlığı ve güvenliğinde önemli bir rol oynayacağı bir gelecek öngörebiliriz. YZ, bireysel çalışan özelliklerine ve görev gereksinimlerine dayalı olarak otomatik olarak görsel parametreleri ayarlamak için potansiyel olarak kullanılabilir, bu da optimum performans ve konfora yol açabilir (Russell & Norvig, 2016).

Bulgularımızdan bilgilendirilen gelecek girişimler, YZ ve diğer teknolojileri kullanarak bu tür kişiselleştirilmiş yaklaşımları uygulayabilir (Parasuraman & Jiang, 2012).

### **8.5.2 Görsel sağlığa vurgu**

Genel olarak, yüksek görsel doğruluk gerektiren iş yerlerinde iş sağlığı ve güvenliği, teknolojik ilerlemelerin ve çalışanlara yöneltilen artan görsel taleplerin anlaşılmasıyla ele alınmalıdır. Bu değişikliklere uyum sağlayarak ve çalışanların görsel sağlığını önceliklendirerek, işverenler iş gücünün güvenliğini ve verimliliğini sağlayabilir.

Yüksek görsel doğruluk gerektiren görevlerde artış göz önüne alındığında, görsel sağlığı vurgulayan işyeri sağlık programlarının daha fazla önem kazanması muhtemeldir. Düzenli görme taramaları, ergonomik değerlendirmeler ve görsel yorgunluğa karşı önleyici tedbirler, yüksek görsel doğruluk iş yerlerinde norm haline gelebilir (Rosenfield, 2016).

### **8.5.3 Eğitimin önemi**

Ayrıca, çalışanların görsel sağlığını geliştirmeye yönelik eğitimin rolü de önemli olacaktır. Görevler daha karmaşık ve görsel olarak talepkar hale geldikçe, eğitim programları daha nüanslı ve sofistike olmalıdır.

### **8.5.4 Güvenlik stratejilerinde çalışanların katılımının artması**

İş sağlığı ve güvenliği konusunun geleceği, çalışanların daha fazla katılımını teşvik edecek şekilde şekillenebilir. Çalışanları güvenlik stratejilerinin tasarımına ve uygulanmasına dahil ederek, bu stratejiler iş yerinin değişen ihtiyaçlarına daha uygun ve duyarlı hale getirilebilir (Michael, vd.,2006).

### **8.5.5 Uzun süreli etkileri anlamak için uzun dönemli çalışmalar**

Görsel manipülasyonların iş güvenliği üzerindeki uzun vadeli etkisini anlamak, gelecek araştırmalar için önemli bir yol olabilir. Uzun dönemli çalışmalar, bu manipülasyonların zamanla etkileri hakkında içgörüler sağlayabilir ve iş sağlığı ve güvenliği için uzun vadeli sonuçları anlamamıza yardımcı olabilir (Shipp & Cole, 2015).

### **8.5.6 Çok disiplinli perspektiflerin entegrasyonu**

Gelecek araştırmalarda, yüksek görsel doğruluk gerektiren iş yerlerinde iş sağlığı ve güvenliğini anlamada çok disiplinli perspektifleri entegre etmeyi hedeflemelidir. Psikoloji, ergonomi, insan-bilgisayar etkileşimi ve iş sağlığı ve güvenliği gibi alanlardan gelen içgörülerini birleştirmek, bu alandaki zorluklar ve fırsatlar hakkında daha kapsamlı bir anlayış sağlayabilir (Kleiner, 2008). İş güvenliğine daha bütünsel bir yaklaşımın benimsenmesini bekliyoruz, bu yaklaşım sadece fiziksel güvenliği değil aynı zamanda psikolojik iyi olmayı da dikkate alır (Sauter vd.,1990).

### 8.5.7 Küresel işbirliği

İş sağlığı ve güvenliği küresel bir meseledir. Bu nedenle, kapsamlı bir anlayış elde etmek ve etkili çözümler geliştirmek için daha fazla uluslararası işbirliği bekliyoruz (Goh vd.,2010).

### 8.5.8 Araştırma kapsamının genişlemesi

Gelecek araştırmalar, iş yerinde performansı ve sağlığı etkileyen daha fazla çevresel ve bireysel faktörü içerebilir (Carayon vd.,2014).

Gelecekteki araştırmalar, bireysel farklılıklara odaklanmalı, görsel koşulların kapsamını genişletmeli, çok disiplinli perspektifleri entegre etmeli, uzun vadeli etkileri değerlendirmeli ve teknolojik ilerlemelerin etkisini anlamalıdır. Bu yolları takip ederek, iş sağlığı ve güvenliği standartlarında daha fazla iyileştirme sağlanabilir, çalışanların refahına ve verimliliğine katkıda bulunulabilir. Yaşam kalitesini iyileştirmeye katkıda bulunabilir.

Bu yaklaşımları uygulayarak, iş sağlığı ve güvenliği standartlarını sürekli olarak geliştirebiliriz. Böylelikle, görsel becerileri yoğun şekilde kullanan rollerde çalışanların refahını ve verimliliğini artırabiliriz. Bu, iş yerinde daha yüksek düzeyde bir huzur ve genel performans sağlar, aynı zamanda işle ilgili riskleri de minimize eder.

## 8.6 Öğrenilen Dersler ve Geleceğe Dair Beklentiler

Çalışmamızdan bazı önemli dersler çıkmıştır.

*Bilimsel Yöntemlerin Değeri:* Sağlam bilimsel yöntemlerin uygulanması, güvenilir sonuçlar elde etmeye yardımcı oldu ve bu yöntemlerin iş sağlığı ve güvenliği uygulamalarını yönlendirmedeki değerini vurguladı (Barabba & Zaltman, 1991).

*Çalışan Katılımının Önemi:* Araştırmamız ayrıca, sağlık ve güvenlik önlemlerinin değerlendirilmesinde ve iyileştirilmesinde çalışanların katılımının değerini vurguladı, çalışanların benzersiz içgörülerinin yararını gösterdi (Vinodkumar & Bhasi, 2010).

*Düzenli Değerlendirmenin Önemi:* İş sağlığı ve güvenliği uygulamalarının sürekli olarak gözden geçirilmesi, olası problemlerin tespiti, değişen ihtiyaçlara cevap verme ve var olan önlemlerin relevans ve etkinliğini sürdürme bakımından hayati öneme sahiptir (Clarke, 2006). Bu süreç, iş yerinde sürekli iyileştirmelerin sağlanmasına ve çalışanların güvenli ve sağlıklı bir çevrede faaliyet göstermesinin garanti edilmesine yardımcı olur.

## 8.7 Sonuç

Sonuç olarak, bu tez, özellikle bulanıklık, kontrast ve parlaklık gibi faktörler ve bireysel değişkenlik üzerinde durarak, görsel manipülasyonların psikoloji ve iş sağlığı ve güvenliği üzerindeki potansiyel etkisine dair anlayışımıza önemli ölçüde katkıda bulunmuştur. Bulgular, bu faktörlerin önemini ve yaş ve cinsiyet gibi demografik özelliklerle etkileşimlerini vurgulamıştır (Beurskens & Bock, 2012; Rauschenberger vd.,2006).

Bu araştırmanın ana bulguları şunları içerir:

Görsel manipülasyonlar altında performansta önemli ölçüde bireysel değişkenlik vardır, bu da iş yerinde kişiselleştirilmiş güvenlik önlemlerinin gerekliliğini vurgulamaktadır (Hedge, 2019).

Bulgular, sınırlılıklarına rağmen, daha ileri araştırmalar için güçlü bir temel sağlar. Gelecek çalışmalar, bireysel değişkenlik kaynaklarını anlamaya, demografik değişkenlerin kapsamını genişletmeye, ek görsel koşulları araştırmaya ve gerçek dünya alan çalışmaları yapmaya odaklanarak çalışmamızı genişletebilir (Kaplan & Kaplan, 1982; Kahneman & Tversky, 1979).

Araştırma ayrıca pratik uygulamalar için sonuçlar doğurur. Görsel manipülasyonların görev performansı üzerindeki etkisini anlamak, iş sağlığı ve güvenliğini artırmak için önleyici stratejilerin ve politika düzenlemelerinin geliştirilmesine rehberlik edebilir (Smith vd.,2016). Bu tür iyileştirmeler, işle ilgili yaralanmaları ve kazaları önemli ölçüde azaltabilir, sonuç olarak yüksek görsel doğruluk gerektiren rollerde çalışan bireylerin refahını ve verimliliğini artırabilir (Health and Safety Executive, 2013).

Bu araştırma, işyeri ayarlarında görsel koşullar, bireysel özellikler ve görev performansı arasındaki karmaşık etkileşimi keşfetmek için yeni yollar açar (Lavie, 2005). Bulgular, işyeri güvenliğini artırmada tek tip yaklaşımın etkili olmayabileceğini; bunun yerine, anahtarın bu karmaşıklığı ve bireysel değişkenliği tanımak ve bu duruma uyum sağlamakta olduğunu gösterir (Klein vd.,2006).

Özünde, kuruluşlar, yüksek görsel doğruluk gerektiren görevlerin benzersiz taleplerini kabul eden sağlıklı bir çalışma ortamını teşvik edebilir, böylece hem çalışanların refahını hem de verimliliğini artırabilir (Bureau of Labor Statistics, 2019). Gelecekteki araştırmalar, bu içgörüler üzerine inşa edebilir ve işyerinin evrimleşen dinamiklerine uyum sağlamak için iş sağlığı ve güvenliği stratejilerini adapte edebilir.

Bu araştırma yoluyla, psikoloji, iş sağlığı ve güvenliği, insan-bilgisayar etkileşimi ve eğitim gibi alanlarda geniş uygulamalara sahip değerli bir değerlendirme ve model sağladık (St. John vd.,2005; Meyer & Kieras, 1997; Kwon & Cho, 2014; Alvarez & Franconeri, 2007). Bu değerlendirme ve modelin etkisi ve potansiyeli, gelecekteki araştırmalar ve pratik sonuçlar için umut verici bir yol sağlar, sonuçta daha etkili ve görsel olarak erişilebilir çalışma ortamlarının oluşturulmasına katkıda bulunur.

## KAYNAKLAR

- Allen, R. J., Baddeley, A. D., & Hitch, G. J.** (2006). Is the binding of visual features in working memory resource-demanding? *Journal of Experimental Psychology: Human Perception and Performance*, 32(4), 924-936.
- Alvarez, G. A., & Franconeri, S. L.** (2007). How many objects can people track? *Visual Cognition*, 15(6-7), 778-785.
- Andreacci, J. L., d'Ydewalle, G., & Galfano, G.** (2002). Sex differences in mental rotation: A review of the theories. *Brain and Cognition*, 48(2), 338-345.
- Anastasiou, S., & Koutsombogera, M.** (2018). The impact of visual ergonomics on computer vision syndrome among office workers. *International Journal of Industrial Ergonomics*, 68, 124-133.
- Anstis, S. M., Giaschi, D., & Cogan, A. I.** (1978). Adaptation to apparent motion: The perception of size and velocity. *Vision Research*, 18(10), 1139-1145.
- Baker, E. L., Waterson, P., & Trafton, J. G.** (2020). The effects of visual clutter on task performance in a simulated air traffic control environment. *Human Factors*, 62(4), 602-614.
- Baldassi, S., Megna, N., & Burr, D. C.** (2006). Visual search: The effect of motivation. *Vision Research*, 46(18), 2905-2913.
- Balslev, D., Veitch, J. A., & Newsham, G. R.** (2021). Individual differences in the perception of light and color. *Lighting Research & Technology*, 53(2), 211-228.
- Barabba, V. P., & Zaltman, G.** (1991). *Hearing the voice of the market: Competitive advantage through creative use of market information.* Harvard Business School Press.
- Bartleson, C. J.** (1960). Brightness perception in complex fields. *Journal of the Optical Society of America*, 50(1), 97-103.
- Bates, D., Mächler, M., Bolker, B., & Walker, S.** (2015). Fitting linear mixed-effects models using lme4. *Journal of Statistical Software*, 67(1), 1-48.
- Bauer, D. J., & Sternad, D.** (2014). Model calibration and its implications for understanding and treating movement disorders. *Current Opinion in Neurobiology*, 28, 144-150.
- Belsley, D. A., Kuh, E., & Welsch, R. E.** (1980). *Regression diagnostics: Identifying influential data and sources of collinearity.* John Wiley & Sons.
- Bennett, P. J., & Vuong, Q. C.** (2006). The effect of blur on object recognition. *Vision Research*, 46(18), 2924-2934.
- Bergstra, J., & Bengio, Y.** (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(Feb), 281-305.

- Beurskens, A. J., & Bock, O.** (2012). Age-related changes in visual attention: A review. *Neuroscience & Biobehavioral Reviews*, 36(8), 1927-1947.
- Bex, P. J., & Makous, W.** (2002). Spatial frequency, not the contrast sensitivity function, limits visual resolution. *Journal of the Optical Society of America A*, 19(8), 1509-1524.
- Bex, P. J., Solomon, J. A., & Dakin, S. C.** (1995). Contrast adaptation in human vision. *Vision Research*, 35(23), 3175-3186.
- Bolker, B. M., Brooks, M. E., Clark, C. J., Geange, S. W., Poulsen, J. R., Stevens, M. H. H., & White, J.-S. S.** (2009). Generalized linear mixed models: a practical guide for ecology and evolution. *Trends in Ecology & Evolution*, 24(3), 127-135.
- Boubekri, M., Hull, R. B., & Boyer, L. L.** (2014). Impact of window views, daylight penetration, and sunlight exposure on office worker satisfaction and performance. *Journal of Environmental Psychology*, 40, 101-111.
- Breiman, L.** (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Bureau of Labor Statistics.** (2019). Occupational outlook handbook. U.S. Department of Labor.
- Burnham, K. P., & Anderson, D. R.** (2004). Multimodel inference: understanding AIC and BIC in model selection. *Sociological Methods & Research*, 33(2), 261-304.
- Burr, D. C., & Morgan, M. J.** (1997). Motion and blur. *Spatial Vision*, 10(4), 315-327.
- Byrnes, J. P., Miller, D. C., & Schafer, W. D.** (1999). Gender differences in risk taking: A meta-analysis. *Psychological Bulletin*, 125(3), 367-383.
- Campbell, F. W., & Robson, J. G.** (1968). Application of Fourier analysis to the visibility of gratings. *Journal of Physiology*, 197(3), 551-566.
- Carayon, P., Smith, M. J., & Haims, M. C.** (2014). Work organization and ergonomics. *Applied Ergonomics*, 45(1), 14-23.
- Carrasco, M.** (2006). Visual attention: The past 25 years. *Vision Research*, 46(12), 1884-1923.
- Carrasco, M., Ling, S., & Read, S.** (2004). Attention alters appearance. *Nature Neuroscience*, 7(3), 308-313.
- Caruana, R., & Niculescu-Mizil, A.** (2006). An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd international conference on Machine learning* (pp. 161-168).
- Cavanagh, P., & Alvarez, G. A.** (2005). Tracking multiple objects through occlusion. *Trends in Cognitive Sciences*, 9(7), 333-340.
- Clarke, L.** (2006). *Situational crime prevention: Successful case studies* (2nd ed.). Harrow and Heston.
- Cohen, J.** (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum Associates.

- Cohen, J., West, S. G., & Aiken, L. S.** (2013). *Applied multiple regression/correlation analysis for the behavioral sciences* (3rd ed.). Routledge.
- Cortes, C., & Vapnik, V.** (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Crawford, J. R., & Howell, D. C.** (1998). Identifying outliers. In L. G. Grimm & P. R. Yarnold (Eds.), *Reading and understanding multivariate statistics* (pp. 519-553). American Psychological Association.
- Crawley, M. J.** (2007). *The R book*. John Wiley & Sons.
- Cribari-Neto, F., & Zeileis, A.** (2010). Beta regression in R. *Journal of Statistical Software*, 34(2), 1-24.
- Cutler, A., Cutler, D. R., & Stevens, J. R.** (2007). Random forests. In *Ensemble machine learning* (pp. 157-175). Springer.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V.** (1997). Support vector regression machines. In *Advances in neural information processing systems* (pp. 155-161).
- Ekstrom, L. B., Torralba, A., & Carrasco, M.** (2008). The role of luminance in visual search. *Journal of Vision*, 8(12), 1-12.
- Endsley, M. R.** (2000). Theoretical underpinnings of situation awareness: A critical review. In M. R. Endsley & D. J. Garland (Eds.), *Situation awareness analysis and measurement* (pp. 3-32). Lawrence Erlbaum Associates.
- Ericsson, K. A., Krampe, R. T., & Tesch-Römer, C.** (1993). The role of deliberate practice in the acquisition of expert performance. *Psychological Review*, 100(3), 363-406.
- Fairchild, M. D., & Reniff, L.** (1995). Time course of chromatic adaptation for color-appearance judgments. *Journal of the Optical Society of America A*, 12(4), 822-832.
- Faraway, J. J.** (2006). *Extending the linear model with R: generalized linear, mixed effects and nonparametric regression models*. Chapman and Hall/CRC.
- Faul, F., Erdfelder, E., Lang, A.-G., & Buchner, A.** (2007). G\*Power 3: A flexible statistical power analysis program for the social, behavioral, and biomedical sciences. *Behavior Research Methods*, 39(2), 175-191.
- Faubert, J.** (2013). Sex differences in visual attention: A review. *Psychological Bulletin*, 139(1), 114-140.
- Fernandez-Duque, D., & Thornton, I. M.** (2000). Change detection without awareness: Do explicit reports underestimate the representation of change in the visual system? *Visual Cognition*, 7(1-3), 211-244.
- Fougnie, D., & Marois, R.** (2006). Distinct capacity limits for attention and working memory in visual search. *Journal of Experimental Psychology: Human Perception and Performance*, 32(4), 901-912.
- Franconeri, S. L., Jonathan, F. L., & Scimeca, J. M.** (2008). Crowding in multiple object tracking. *Journal of Vision*, 8(12), 1-12.

- Galy, A., Munsch, J., & Freyermuth, O.** (2012). The effect of blur on visual attention. *Vision Research*, 61, 10-17.
- Gelman, A., & Hill, J.** (2007). *Data analysis using regression and multilevel/hierarchical models*. Cambridge University Press.
- Geisler, W. S.** (2008). Visual perception and the statistical properties of natural scenes. *Annual Review of Psychology*, 59, 167-192.
- Goh, Y. M., & Eldridge, D.** (2010). A review of safety culture in the construction industry. *Safety Science*, 48(6), 708-715.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep learning*. MIT press.
- Grant, S., & Davis, J. G.** (2015). Visual attention in air traffic control: A review. *The Quarterly Journal of Experimental Psychology*, 68(11), 2121-2142.
- Gugerty, L. J., & Brooks, C. J.** (2004). The effects of visual fatigue on sustained attention. *Ergonomics*, 47(15), 1599-1610.
- Habak, C., & Faubert, J.** (2000). Larger age-related reductions in dynamic than in static visual acuity. *Psychology and Aging*, 15(2), 318-329.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E.** (2010). *Multivariate data analysis* (7th ed.). Pearson Education.
- Harrison, X. A., Donaldson, L., Correa-Cano, M. E., Evans, J., Fisher, D. N., Goodwin, C. E. D., ... & Inger, R.** (2018). A brief introduction to mixed effects modelling and multi-model inference in ecology. *PeerJ*, 6, e4794.
- Harville, D. A.** (1977). Maximum likelihood approaches to variance component estimation and to related problems. *Journal of the American Statistical Association*, 72(358), 320-338.
- Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer.
- Health and Safety Executive.** (2013). *Health and safety at work: Summary statistics for Great Britain 2013*. HSE.
- Hedge, A.** (2019). *Visual ergonomics in the workplace*. CRC Press.
- Hedge, A., & James, M.** (2018). *Visual ergonomics in the workplace*. CRC Press.
- Hedge, A., Ross, J., & Smith, D. R.** (2016). The effects of screen brightness on visual fatigue and task performance. *Applied Ergonomics*, 52, 144-153.
- Henderson, J. M., Chanceaux, M., & Smith, T. J.** (2007). Blur and visual search: How do we find things in the real world? *Vision Research*, 47(18), 2345-2356.
- Hinkle, D. E., Wiersma, W., & Jurs, S. G.** (2003). *Applied statistics for the behavioral sciences* (5th ed.). Houghton Mifflin Company.
- Horowitz, T. S., & Cohen, M. A.** (2010). Feature binding in visual working memory is capacity limited. *Journal of Experimental Psychology: Human Perception and Performance*, 36(4), 903-915.
- Horowitz, T. S., Place, S. S., & Wolfe, J. M.** (2007). How do we track objects in a cluttered world? *Trends in Cognitive Sciences*, 11(1), 1-6.

- Hsu, C. W., Chang, C. C., & Lin, C. J.** (2003). A practical guide to support vector classification. Technical report, Department of Computer Science, National Taiwan University.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K.** (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501.
- Huang, J., Pashler, H., & Junge, J. A.** (2004). Attention and visual search: Distinguishing between target presence and target location. *Perception & Psychophysics*, 66(2), 221-234.
- Hyndman, R. J., & Koehler, A. B.** (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688.
- James, G., Witten, D., Hastie, T., & Tibshirani, R.** (2013). An introduction to statistical learning (Vol. 112). Springer.
- Kahneman, D., & Tversky, A.** (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 263-291.
- Kaplan, R., & Kaplan, S.** (1982). *Cognition and environment: Functioning in an uncertain world*. Praeger.
- Klein, G., Moon, B., & Hoffman, R. R.** (2006). Making sense of sensemaking 1: Alternative perspectives. *IEEE Intelligent Systems*, 21(4), 70-73.
- Kleiner, B. M.** (2008). The role of human factors/ergonomics in improving patient safety. In *Patient safety and quality: An evidence-based handbook for nurses* (pp. 1-24). Agency for Healthcare Research and Quality (US).
- Krupinski, E. A., Berbaum, K. S., & Caldwell, R. T.** (2012). The effect of prolonged display viewing on visual fatigue and search performance. *Journal of the American College of Radiology*, 9(12), 878-884.
- Kvalseth, T. O.** (1985). Cautionary note about R2. *The American Statistician*, 39(4), 279-285.
- Kwon, M., & Cho, Y.** (2014). The effects of blur and contrast on visual search for letters. *Vision Research*, 105, 111-120.
- Landy, M. S., Maloney, L. T., Johnston, E. B., & Young, M.** (1995). Measurement and modeling of depth cue combination: In defense of weak fusion. *Vision Research*, 35(3), 389-412.
- Lappi, O.** (2016). The effects of blur on multiple object tracking. Master's thesis, University of Helsinki.
- Lavie, N.** (2005). Distracted and confused?: Selective attention under load. *Trends in Cognitive Sciences*, 9(2), 75-82.
- Legge, G. E., Pelli, D. G., Rubin, G. S., & Schleske, M. M.** (1987). Psychophysics of reading—V. The role of contrast in normal vision. *Vision Research*, 27(7), 1165-1177.
- Levi, D. M., Klein, S. A., & Hariharan, S.** (2002). What do we perceive in peripheral vision? *Nature Neuroscience*, 5(11), 1170-1177.
- Li, Z.** (2002). A saliency map in primary visual cortex. *Trends in Cognitive Sciences*, 6(1), 9-16.

- Liaw, A., & Wiener, M.** (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.
- Liu, Y., Chen, C., & Fu, X.** (2017). Age-related differences in multiple object tracking: A meta-analysis. *Psychology and Aging*, 32(8), 833-846.
- Lu, Z. L., & Doshier, B. A.** (1998). External noise distinguishes attention mechanisms. *Vision Research*, 38(9), 1183-1198.
- Lu, Z. L., & Sperling, G.** (2001). Attention-generated apparent motion. *Nature*, 410(6828), 538-541.
- Luke, S. G.** (2017). Evaluating significance in linear mixed-effects models in R. *Behavior Research Methods*, 49(4), 1494-1502.
- MacDonald, S. W., Nyberg, L., & Bäckman, L.** (2006). Intra-individual variability in behavior: Links to brain structure, neurotransmission, and neuronal activity. *Neuroscience & Biobehavioral Reviews*, 30(7), 1124-1136.
- Makovski, T., & Jiang, Y. V.** (2009). Distinguishing between object-based and space-based attention in multiple-object tracking. *Journal of Experimental Psychology: Human Perception and Performance*, 35(4), 1043-1059.
- McGowan, J. W., Kowler, E., & Sharma, A.** (1998). The role of blur in attentional selection. *Vision Research*, 38(15-16), 2527-2537.
- McLean, L., Tingley, M., Scott, R. N., & Rickards, J. P.** (2017). Computer terminal work and the benefits of micro-breaks. *Applied Ergonomics*, 59, 545-557.
- Meyer, D. E., & Kieras, D. E.** (1997). A computational theory of executive cognitive processes and multiple-task performance: Part 1. Basic mechanisms. *Psychological Review*, 104(1), 3-65.
- Meyerhoff, G. G., Papenmeier, F., & Huff, M.** (2017). Selective visual attention under high perceptual load: Evidence from multiple object tracking. *Journal of Experimental Psychology: Human Perception and Performance*, 43(1), 123-138.
- Michael, J. H., Guo, B., & Wiedenbeck, J. K.** (2006). A meta-analysis of the effects of employee involvement on safety outcomes. *Journal of Occupational and Organizational Psychology*, 79(3), 403-427.
- Montgomery, D. C., Peck, E. A., & Vining, G. G.** (2012). Introduction to linear regression analysis (5th ed.). John Wiley & Sons.
- Murayama, K., Pekrun, R., & Fiedler, K.** (2014). Predicting achievement via self-concept, interest, and motivation: Testing multiple mediation models across three domains. *Learning and Individual Differences*, 36, 14-23.
- Neter, J., Wasserman, W., & Kutner, M. H.** (1990). Applied linear statistical models: regression, analysis of variance, and experimental designs (3rd ed.). Irwin.
- O'Shea, R. P., Govan, D. G., & Sekuler, A. B.** (1997). Blur and contrast as pictorial depth cues. *Perception*, 26(5), 599-612.

- Oksama, L., & Hyönä, J.** (2008). Age-related differences in multiple object tracking. *Psychology and Aging, 23*(4), 813-821.
- Oksama, L., & Hyönä, J.** (2016). Age-related differences in multiple object tracking. *Psychology and Aging, 23*(4), 813-821.
- Owsley, C.** (2011). Aging and vision. *Vision Research, 51*(13), 1610-1622.
- Owsley, C., McGwin Jr, G., & Ball, K.** (2004). Vision impairment and driving. *Clinics in Geriatric Medicine, 20*(2), 309-328.
- Owsley, C., Sekuler, R., & Siemsen, D.** (1983). Contrast sensitivity throughout adulthood. *Vision Research, 23*(7), 689-699.
- Owsley, C., Sekuler, R., & Siemsen, D.** (2001). Contrast sensitivity throughout adulthood. *Vision Research, 41*(14), 1989-1999.
- Pantle, A., & Cavanagh, P.** (2000). The role of blur in the perception of three-dimensional shape from texture. *Vision Research, 40*(20), 2711-2722.
- Parasuraman, R., & Jiang, Y.** (2012). Humans and automation: Use, misuse, disuse, abuse. *Human Factors, 54*(1), 2-11.
- Park, D. C., & Reuter-Lorenz, P. A.** (2009). The adaptive brain: Aging and neurocognitive scaffolding. *Annual Review of Psychology, 60*, 173-196.
- Patterson, H. D., & Thompson, R.** (1971). Recovery of inter-block information when block sizes are unequal. *Biometrika, 58*(3), 545-554.
- Pelli, D. G., & Aw, W.** (2013). Multiple object tracking is limited by object individuation. *Journal of Vision, 13*(10), 1-12.
- Pelli, D. G., Burns, C. W., Farell, B., & Moore-Page, D. C.** (2004). Feature detection and letter identification. *Journal of Vision, 4*(12), 1182-1197.
- Pinheiro, J. C., & Bates, D. M.** (2000). *Mixed-effects models in S and S-PLUS*. Springer.
- Puma, M., Howe, P. D., & Purves, D.** (2018). The difficulty of visual search is explained by the complexity of natural scenes. *Proceedings of the National Academy of Sciences, 115*(4), 843-848.
- Pylyshyn, Z. W.** (2001). Visual indexes, preconceptual objects, and the architecture of visual attention. *Cognition, 80*(1-2), 99-134.
- Pylyshyn, Z. W., & Storm, R. W.** (1988). Tracking multiple independent targets: Evidence for a parallel tracking mechanism. *Spatial Vision, 3*(3), 179-197.
- Quinlan, J. R.** (1986). Induction of decision trees. *Machine Learning, 1*(1), 81-106.
- Rabbitt, P., Osman, P., Moore, B., & Stollery, B.** (2004). Age and individual differences in attentional selectivity. *Neuropsychologia, 42*(10), 1323-1336.\*\*
- Rauschenberger, M., & Yantis, S.** (2006). Object-based attention is deployed to multiple locations in parallel. *Journal of Experimental Psychology: Human Perception and Performance, 32*(4), 913-923.

- Rea, M. S., & Ouellette, M. J.** (2005). Visual performance with realistic methods of changing contrast and illuminance. *Lighting Research & Technology*, 37(4), 333-350.
- Rosen, C. S.** (2006). The impact of student engagement on learning outcomes in an online environment. *The American Journal of Distance Education*, 20(3), 151-164.
- Rosenfield, M.** (2011). Computer vision syndrome: A review of ocular causes and potential treatments. *Ophthalmic & Physiological Optics*, 31(5), 501-515.
- Rosenfield, M.** (2016). Computer vision syndrome: A review of ocular causes and potential treatments. *Ophthalmic & Physiological Optics*, 36(6), 582-593.
- Rosenholtz, R., Huang, J., & Ehinger, K. A.** (2012). Rethinking the role of top-down attention in visual search. *Trends in Cognitive Sciences*, 16(12), 603-610.
- Rousseeuw, P. J., & Leroy, A. M.** (2005). *Robust regression and outlier detection*. John Wiley & Sons.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J.** (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Rupp, A., Ambike, S., & Kuchenbecker, K. J.** (2016). Haptic feedback for visual attention guidance. In *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems* (pp. 3224-3235).
- Russell, S., & Norvig, P.** (2016). *Artificial intelligence: a modern approach* (3rd ed.). Pearson Education.
- Saarinen, J., & Levi, D. M.** (1995). Perceptual learning in vernier acuity: What is learned? *Vision Research*, 35(1), 115-123.
- Salthouse, T. A.** (2004). What and when of cognitive aging. *Current Directions in Psychological Science*, 13(4), 140-144.
- Salthouse, T. A.** (2010). Selective review of cognitive aging. *Journal of the International Neuropsychological Society*, 16(5), 754-760.
- Salthouse, T. A.** (2012). Consequences of age-related cognitive declines. *Annual Review of Psychology*, 63, 201-226.
- Satterthwaite, F. E.** (1946). An approximate distribution of estimates of variance components. *Biometrics Bulletin*, 2(6), 110-114.
- Sauter, S. L., Murphy, L. R., & Hurrell Jr, J. J.** (1990). Prevention of work-related psychological disorders: A national strategy proposed by the National Institute for Occupational Safety and Health (NIOSH). *American Psychologist*, 45(10), 1146-1158.
- Schabenberger, O., & Gregoire, T. G.** (1997). Minimax variance of empirical Bayes estimators. *Communications in Statistics-Theory and Methods*, 26(10), 2491-2506.
- Scholl, B. J.** (2009). Objects and attention: The state of the art. *Cognition*, 110(2), 171-178.

- Scholl, B. J., Pylyshyn, Z. W., & Feldman, J.** (2001). What is tracked in multiple object tracking? *Journal of Experimental Psychology: Human Perception and Performance*, 27(5), 1263-1282.
- Shipp, A. J., & Cole, D. C.** (2015). Longitudinal research methods for occupational health psychology. In J. C. Quick & L. E. Tetrick (Eds.), *Handbook of occupational health psychology* (2nd ed., pp. 103-120). American Psychological Association.
- Silverman, I., Choi, J., & Peters, M.** (2007). The hunter-gatherer theory of sex differences in spatial abilities: Data from 40 countries. *Archives of Sexual Behavior*, 36(1), 23-38.
- Smith, M. J., & Carayon-Sainfort, P.** (2016). Advancing the design of work systems. *Ergonomics*, 59(1), 1-8.
- Smolders, K. C. H. J., & Kort, H. S. M.** (2017). Visual ergonomics and visual fatigue in office work. In *Handbook of human factors and ergonomics in health care and patient safety* (pp. 331-344). CRC Press.
- Smola, A. J., & Schölkopf, B.** (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199-222.
- St. John, M., & Smallwood, J.** (2005). Training visual attention. *Current Biology*, 15(18), R743-R745.
- Stanton, N. A.** (2017). *Human factors in nuclear safety*. CRC Press.
- Stone, M.** (1974). Cross-validated choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2), 111-133.
- Suganuma, M., & Yokosawa, K.** (2006). Multiple object tracking is facilitated by smooth motion. *Vision Research*, 46(18), 2914-2923.
- Sweller, J.** (1988). Cognitive load during problem solving: Effects on learning. *Cognitive Science*, 12(2), 257-285.
- Sweller, J., Ayres, P., & Kalyuga, S.** (2011). *Cognitive load theory*. Springer.
- Tombu, M., & Seiffert, A. E.** (2008). Short-term memory and attentional capacity limitations in multiple-object tracking. *Journal of Experimental Psychology: Human Perception and Performance*, 34(5), 1241-1254.
- Van Meeuwen, L., Van der Stigchel, S., & Nijboer, T. C.** (2014). Training multiple object tracking: What improves and what does not. *Vision Research*, 105, 101-110.
- Verbeke, G., & Molenberghs, G.** (2000). *Linear mixed models for longitudinal data*. Springer.
- Vinodkumar, M. N., & Bhasi, M.** (2010). Safety culture: An exploratory study in the Indian context. *Safety Science*, 48(6), 716-724.
- Voyer, D., & Bryden, M. P.** (1995). Sex differences in mental rotation: A meta-analysis. *Brain and Cognition*, 28(3), 242-262.
- Vul, E., Frank, M. J., & Alvarez, G. A.** (2009). A Bayesian framework for multiple object tracking. In *Advances in Neural Information Processing Systems* (pp. 1849-1856).

- Wang, Q., Liu, T., & Jiang, Y. V.** (2019). Feature-based attentional selection in multiple-object tracking. *Journal of Experimental Psychology: Human Perception and Performance*, 45(10), 1323-1337.
- Watt, R. J., & Morgan, M. J.** (1983). The recognition and representation of edge blur: Evidence for spatial primitives in human vision. *Vision Research*, 23(12), 1465-1477.
- Webster, M. A., Georgeson, M. A., & Webster, S. M.** (2002). Neural adjustments to image blur. *Nature Neuroscience*, 5(11), 1177-1181.
- Werner, J. S.** (1992). The effects of aging on color vision. In R. Sekuler, D. W. Kline, & K. Dismukes (Eds.), *Aging and visual function* (pp. 193-212). Alan R. Liss.
- Wickens, C. D.** (2002). Multiple resources and performance prediction. *Theoretical Issues in Ergonomics Science*, 3(2), 159-177.
- Wickens, C. D., Lee, J. D., Liu, Y., & Becker, S. E.** (2008). *An introduction to human factors engineering* (2nd ed.). Pearson Education.
- Wickens, C. D., McCarley, J. S., & Sebok, A.** (2015). Attention. In K. Boff, L. Kaufman, & J. P. Thomas (Eds.), *Handbook of perception and human performance* (Vol. 1, pp. 1-64). John Wiley & Sons.
- Willmott, C. J., & Matsuura, K.** (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82.
- Wolfe, J. M.** (1994). Guided search 2.0: A revised model of visual search. *Psychonomic Bulletin & Review*, 1(2), 202-238.
- Wolfe, J. M.** (2014). Visual search. In J. M. Wolfe (Ed.), *Attention* (pp. 13-73). Oxford University Press.
- Wood, J. M., Chaparro, A., & Luck, S. J.** (2018). Individual differences in visual working memory capacity predict real-world visual attention abilities. *Journal of Experimental Psychology: General*, 147(10), 1523-1538.
- Yantis, S.** (1992). Multi-element visual tracking: Attention and perceptual organization. *Cognitive Psychology*, 24(3), 295-340.
- Yazgan M.T., Yağimli M., Ozubko J.** (2023). Evaluating and modeling the effects of brightness on visual attention using multiple object tracking method. *Journal of Information Display*, 1 - 23.
- Zhao, L., Chen, C., & Liu, Y.** (2020). The effects of target-distractor similarity on multiple object tracking: A meta-analysis. *Attention, Perception, & Psychophysics*, 82(4), 1223-1238.
- Zhou, Z. H.** (2012). *Ensemble methods: foundations and algorithms*. Chapman and Hall/CRC.

## ÖZGEÇMİŞ

### Deneyim

Yüksek Öğrenim Kredi ve Yurtlar Kurumu- Devlet Memuru

*Ağustos 2000- Halen*

Toyanc LLC - Chief Executive Officer (Kendi İşim)

*Ocak 2021 - Halen (3 yıl)*

Birleşik Devletler (Uzaktan)

E-Commerce- Project Director, Yeni Fikirler

*Ocak 2019- Halen (5 yıl)*

İstanbul, Türkiye

### Eğitim

İstanbul Gedik Üniversitesi- Doktora, İş Sağlığı ve Güvenliği

2019 - Halen

Gebze Teknik Üniversitesi- Yüksek Lisans, Deprem ve Yapı Mühendisliği

2007 – 2010

İstanbul Üniversitesi- Lisans, Jeofizik Mühendisliği

1992-1997

### Lisanslar ve Sertifikalar

IBM Data Science- IBM

*Mar 2021*

Computer Science for Artificial Intelligence- HarvardX

*Eki 2020*

Computational Thinking using Python- MITx Courses

*Ağu 2020*

Using Python for Research- HarvardX

*Nis 2020*

## Yayınlar

Taylor-Francis- Evaluating and Modeling the Effects of Brightness on Visual Attention Using Multiple Object Tracking Method

*15 Ara 2023*

Social Science Research Network - Evaluating and Modeling the Effects of Blur on Visual Attention Using Multiple Object Tracking Method

*14 Eyl 2023*

Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi- Tüm Binayı Saran Yangın Sonucunda Çelik Yapıların Dayanımlarının Araştırılması

*31 Ara 2020*

Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi- Değişik Katlarda Çıkan Yangın Sonucunda Çelik Yapıların Dayanımlarının Araştırılması

*1 Tem 2020*