

**T.C.
SAKARYA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**KARDİYOMETABOLİK MULTİMORBİDİTESİ
OLAN YAŞLI HASTALARDA BAKIM
GEREKSİNİMLERİNİ SINIFLANDIRMA VE
HEMŞİRELİK TANILARINI BELİRLEMeye
YÖNELİK BİR KARAR DESTEK SİSTEMİNİN
GELİŞTİRİLMESİ**

**DOKTORA TEZİ
Merve GÜLBAHAR EREN**

Enstitü Anabilim Dalı: Hemşirelik

Tez Danışmanı: Doç. Dr. Havva SERT

AĞUSTOS -2025

T.C.
SAKARYA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**KARDİYOMETABOLİK MULTİMORBİDİTESİ
OLAN YAŞLI HASTALARDA BAKIM
GEREKSİNİMLERİNİ SINIFLANDIRMA VE
HEMŞİRELİK TANILARINI BELİRLEMeye
YÖNELİK BİR KARAR DESTEK SİSTEMİNİN
GELİŞTİRİLMESİ**

DOKTORA TEZİ

Merve GÜLBAHAR EREN

Enstitü Anabilim Dalı: Hemşirelik

“Bu tez .../.../2025 tarihinde aşağıdaki jüri tarafından oy birliği ile kabul edilmiştir.”

JÜRİ ÜYESİ	KANAATİ	İMZA

BEYAN

Bu çalışma, birinci ve ikinci aşamaları için T.C. Sakarya Üniversitesi Tıp Fakültesi Girişimsel Olmayan Etik Kurulu'ndan 28/12/2023 tarihinde ve üçüncü aşaması için ise T.C. Sakarya Üniversitesi Tıp Fakültesi İlaç Dışı Klinik Uygulamalar Etik Kurulu'ndan 22/12/2023 tarihinde onay alınarak hazırlanmıştır.

Bu tezin kendi çalışmam olduğunu, planlamasından tezin yazımına kadar her aşamasında etik ilkelere bağlı kaldığımı, tez çalışmamda tüm bilgileri etik ve akademik kurallar içinde elde ettiğimi, çalışmam sonucundaki bilgiler dışındaki tüm bilgilerde yararlanılan kaynakları kaynaklar listesinde gösterdiğimi, tez çalışmamda patent ve telif haklarını ihlal etmediğimi beyan ederim.

...../...../.....

Merve GÜLBAHAR EREN

Araştırma, Sakarya Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 2024-26-61-161 nolu doktora tez proje numarası ile desteklenmiştir.

TEŞEKKÜR

Doktora eğitimim ve akademik gelişimim boyunca değerli bilgilerini benimle paylaşan, çalışmamın her aşamasında önemli katkılar sağlayarak yoluma ışık tutan saygıdeğer danışman hocam Doç. Dr. Havva SERT'e,

Tez izleme sürecinde yapıcı geri bildirimleri ve akademik katkılarıyla çalışmama yön veren saygıdeğer hocalarım Prof. Dr. Nursan ÇINAR ve Prof. Dr. Selçuk YAYLACI'ya; tez savunma jürimde yer alarak mesleki bilgi ve deneyimleriyle çalışmamı zenginleştiren kıymetli hocalarım Prof. Dr. Zehra GÖK METİN ve Prof. Dr. Feride TAŞKIN YILMAZ'a,

Çalışmamın yürütüldüğü birimlerde görev yapan değerli meslektaşlarıma, araştırmaya gönüllü olarak dahil olan ve araştırmanın gerçekleştirilmesinde önemli katkıları olan değerli hastalara,

Her koşulda yanımda olarak sevgileri ve destekleri ile güç veren kıymetli anneme ve babama,

Akademik yolculuğum boyunca sevgisi, sabrı, anlayışı ve desteği ile en büyük motivasyon kaynağım olan sevgili eşime,

Daha dünyaya gelmeden hayatımızı bahara döndüren, tekmeleri ile bana en anlamlı desteği sağlayan canım oğluma,

Sonsuz teşekkürlerimi sunarım.

Saygılarımla...

İÇİNDEKİLER

BEYAN.....	i
TEŞEKKÜR	ii
İÇİNDEKİLER	iii
KISALTMA VE SİMGELER.....	vii
ŞEKİLLER LİSTESİ.....	ix
TABLolar LİSTESİ.....	x
ÖZET.....	xii
SUMMARY	xiii
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER.....	5
2.1. YAŞLI BİREYLER VE MULTİMORBİDİTE	5
2.2. KARDİYOMETABOLİK MULTİMORBİDİTE	6
2.2.1. Kardiyometabolik Multimorbidite Tanımı	6
2.2.2. Kardiyometabolik Multimorbidite Epidemiyolojisi	6
2.2.3. Kardiyometabolik Multimorbidite Bileşenleri.....	8
2.2.4. Kardiyometabolik Multimorbiditeli Hastalarda Ortak Görülen Semptomlar	11
2.2.5. Kardiyometabolik Multimorbiditeli Hastalarda Yaşam Kalitesi	12
2.3. KARDİYOMETABOLİK MULTİMORBİDİTE VE KIRILGANLIK İLİŞKİSİ.....	14
2.4. KARDİYOMETABOLİK MULTİMORBİDİTELİ YAŞLI HASTALARDA HEMŞİRELİK BAKIM YÖNETİMİ	16
2.5. HASTA SINIFLANDIRMA SİSTEMLERİ.....	19
2.6. KLİNİK KARAR DESTEK SİSTEMLERİ.....	21
2.6.1. Makine Öğrenimi Tabanlı Klinik Karar Destek Sistemleri ...	23
2.7. ARAŞTIRMANIN HEMŞİRELİK AÇISINDAN ÖNEMİ	25
3. GEREÇ VE YÖNTEM.....	28

3.1. ARAŞTIRMANIN AMACI VE TİPİ	28
3.1.1. Araştırmanın Hipotezleri	28
3.2. ARAŞTIRMANIN ETİK YÖNÜ.....	29
3.3. BİRİNCİ AŞAMA: HEMŞİRE GÖRÜŞLERİNE İLİŞKİN NİTEL ÇALIŞMA	29
3.3.1. Araştırmanın Yapıldığı Yer ve Zaman	30
3.3.2. Araştırmanın Örneklemi	30
3.3.3. Araştırmanın Veri Toplama Süreci.....	31
3.3.4. Araştırmanın Etik Yönü.....	31
3.3.5. İstatiksel Analiz	32
3.4. İKİNCİ AŞAMA: KARDİYOMETABOLİK MULTİMORBİDİTELİ HASTALARDA SEMPTOM ŞİDDETİ ÖLÇEĞİNİN (KM-SŞÖ) GELİŞTİRİLMESİ, GEÇERLİK VE GÜVENİRLİK ÇALIŞMASI	33
3.4.1. Araştırmanın Yapıldığı Yer ve Zaman	33
3.4.2. Araştırmanın Örneklemi	33
3.4.3. Araştırmanın Veri Toplama Süreci.....	34
3.4.3.1. Hasta bilgi formu.....	34
3.4.3.2. Kardiyometabolik multimorbiditeli hastalarda semptom şiddeti ölçeği (KM-SŞÖ)	34
3.4.3.3. EQ-5D-3L Genel yaşam kalitesi ölçeği.....	34
3.4.4. Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeğinin Geliştirilme Aşamaları.....	35
3.4.4.1. Tasarım aşaması	35
3.4.4.2. Pilot uygulama aşaması	37
3.4.4.3. Uygulama aşaması.....	37
3.4.5. İstatiksel Analiz	37
3.5. ÜÇÜNCÜ AŞAMA: KLİNİK KARAR DESTEK SİSTEMİ GELİŞTİRİLMESİ.....	38
3.5.1. Araştırmanın Yapıldığı Yer ve Zaman	38
3.5.2. Araştırmanın Örneklemi	38
3.5.3. Araştırmanın Veri Toplama Süreci.....	40
3.5.3.1. Hasta bilgi formu.....	40

3.5.3.2. Edmonton kırılabilirlik ölçeği (EKÖ)	41
3.5.4. Araştırmanın istatistiksel analizi	42
3.5.4.1. Bakım gereksinimlerinin sınıflandırılması	42
3.5.4.2. Hemşirelik tanımlarının belirlenmesi	45
4. BULGULAR	48
4.1. BİRİNCİ AŞAMA: HEMŞİRE GÖRÜŞLERİNE İLİŞKİN NİTEL BULGULAR	48
4.2. İKİNCİ AŞAMA: KARDİYOMETABOLİK MULTİMORBİDİTELİ YAŞLI HASTALARDA SEMPTOM ŞİDDETİ ÖLÇEĞİNİN (KM-SŞÖ) GEÇERLİK VE GÜVENİRLİĞİNE İLİŞKİN BULGULAR	62
4.2.1. Katılımcıların Tanımlayıcı Özellikleri.....	62
4.2.2. Açıklayıcı Faktör Analizi	63
4.2.3. Doğrulamalı Faktör Analizi	66
4.2.4. Ölçüt Geçerliliği	67
4.2.5. Güvenirlik Analizi	68
4.2.6. Ayırt Edicilik	68
4.3. ÜÇÜNCÜ AŞAMA: KLİNİK KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİNE YÖNELİK BULGULAR	68
4.3.1. Bakım Gereksinimlerinin Sınıflandırılmasına Yönelik Bulgular	68
4.3.2. Hemşirelik Tanımlarının Belirlenmesine Yönelik Bulgular	72
4.3.2.1. Kalp debisinde azalma.....	73
4.3.2.2. Etkisiz periferik doku perfüzyonu	74
4.3.2.3. Aktivite intoleransı	75
4.3.2.4. Fiziksel mobilitede bozulma	77
4.3.2.5. Etkisiz sağlık öz yönetimi	78
4.3.2.6. Kırılabilir yaşlı sendromu	80
4.3.2.7. Kan basıncında değişkenlik riski.....	81
4.3.2.8. Kardiyovasküler fonksiyon bozulma riski	83
4.3.2.9. Elektrolit dengesizliği riski	84
4.3.2.10. Etkisiz renal perfüzyon riski.....	86
5. TARTIŞMA	88

5.1. BİRİNCİ AŞAMA: HEMŞİRE GÖRÜŞLERİNE İLİŞKİN NİTEL SONUÇLARIN TARTIŞILMASI	88
5.1.1. Bakım Sürecinde Yaşananlar	88
5.1.2. Bakım Gereksinimlerini Sınıflandırma ve Hemşirelik Tanılarını Önceliklendirme	90
5.1.3. Klinik Karar Destek Sistemi Geliştirilmesine Yönelik Görüşler	91
5.2. İKİNCİ AŞAMA: KARDİYOMETABOLİK MULTİMORBİDİTELİ YAŞLI HASTALARDA SEMPTOM ŞİDDETİ ÖLÇEĞİNİN (KM-SSÖ) GEÇERLİK VE GÜVENİRLİĞİNE İLİŞKİN SONUÇLARIN TARTIŞILMASI	95
5.2.1. Geçerlik Analizleri	96
5.2.2. Güvenirlik Analizleri	97
5.3. ÜÇÜNCÜ AŞAMA: KLİNİK KARAR DESTEK SİSTEMİ GELİŞTİRİLMESİNE İLİŞKİN SONUÇLARIN TARTIŞILMASI.....	99
6. SONUÇ VE ÖNERİLER.....	105
7. ARAŞTIRMANIN SINIRLILIKLARI	108
KAYNAKLAR	109
EKLER.....	130
ÖZGEÇMİŞ.....	159

KISALTMA VE SİMGELER

AFA	: Açımlayıcı Faktör Analizi
AMOS	: Analysis of Moment Structures
BKİ	: Beden Kitle İndeksi
DFA	: Doğrulayıcı Faktör Analizi
DKB	: Diyastolik Kan Basıncı
DM	: Diabetes Mellitus
DSÖ	: Dünya Sağlık Örgütü
EKÖ	: Edmonton Kırılganlık Ölçeği
HDL	:Yüksek Yoğunluklu Lipoprotein
HT	: Hipertansiyon
KAH	: Koroner Arter Hastalığı
KGİ	: Kapsam Geçerlik İndeksi
KKDS	: Klinik Karar Destek Sistemi
KKH	: Koroner Kalp Hastalıkları
KMO	: Kasiyer Meyer Olkin
KM-SŞÖ	: Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği
LDL	: Düşük Yoğunluklu Lipoprotein
MAXQDA	: Max Qualitative Data Analysis
Mİ	: Miyokard İnfarktusü
NICE	: Ulusal Sağlık ve Bakım Mükemmelliği Enstitüsü
SKB	: Sistolik Kan Basıncı
SpO₂	: Oksijen Satürasyonu

SPSS	: Statistical Package for the Social Science
SVM	: Destek Vektör Makineleri
TSH	: Tiroid Uyarıcı Hormon
TÜİK	: Türkiye İstatistik Kurumu
VAS	: Visual Analog Skala
XGBoost	: Extreme Gradient Boosting
YZ	: Yapay Zekâ



ŞEKİLLER LİSTESİ

Şekil 1: Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ)’nin Geliştirilmesi Aşamaları	35
Şekil 2: Kırılganlık düzeyinin EKÖ’ye göre skorlaması	42
Şekil 3: Scree Plot Grafiği	65
Şekil 4: DFA’ya İlişkin Diyagram.....	66
Şekil 5: SHAP Tabanlı Öznitelik Etki Analizi	71
Şekil 6: Özniteliklerin Karar Sürecine Katkı Düzeylerinin SHAP Özeti	72
Şekil 7: Kalp Debisinde Azalma Karar Ağacı Modeli	74
Şekil 8: Etkisiz Periferik Doku Perfüzyonu Karar Ağacı Modeli	75
Şekil 9: Aktivite İntoleransı Karar Ağacı Modeli.....	76
Şekil 10: Fiziksel Mobilitede Bozulma Karar Ağacı Modeli	78
Şekil 11: Etkisiz Sağlık Öz Yönetimi Karar Ağacı Modeli.....	79
Şekil 12: Kırılgan Yaşlı Sendromu Karar Ağacı Modeli	81
Şekil 13: Kan Basıncında Değişkenlik Riski Karar Ağacı Modeli.....	82
Şekil 14: Kardiyovasküler Fonksiyon Bozulma Riski Karar Ağacı Modeli	84
Şekil 15: Elektrolit Dengesizliği Riski Karar Ağacı Modeli	85
Şekil 16: Etkisiz Renal Perfüzyon Riski Karar Ağacı Modeli	87

TABLolar LİSTESİ

Tablo 1: KKDS Geliştirilmesi Aşaması İçin Örneklem Dahil Edilme ve Dışlanma Kriterleri.....	40
Tablo 2: Hemşire Katılımcıların Tanımlayıcı Özellikleri	49
Tablo 3: Temalar, Alt temalar ve Kodlar	50
Tablo 4: AFA için Katılımcıların Tanımlayıcı Özellikleri.....	62
Tablo 5: DFA için Katılımcıların Tanımlayıcı Özellikleri.....	63
Tablo 6: Faktör Yükleri ve Ortak Varyans Değerleri	65
Tablo 7: DFA İndeks Değerleri.....	66
Tablo 8: DFA Faktör Yükleri.....	67
Tablo 9: Bakım Gereksinim Düzeyinin Sınıflandırılmasında Kullanılan Makine Öğrenimi Modellerinin 40 Öznitelik İçin Performans Karşılaştırması	69
Tablo 10: Bakım Gereksinim Düzeyinin Sınıflandırılmasında Kullanılan Makine Öğrenimi Modellerinin 19 Öznitelik İçin Performans Karşılaştırması	70
Tablo 11: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Kalp Debisinde Azalma Tanısına İlişkin Öznitelikler.....	73
Tablo 12: Kalp Debisinde Azalma Hemşirelik Ait Model Performans Göstergeleri	74
Tablo 13: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Etkisiz Periferik Doku Perfüzyonu Tanısına İlişkin Öznitelikler	74
Tablo 14: Etkisiz Periferik Doku Perfüzyonu Tanısına Ait Model Performans Göstergeleri	75
Tablo 15: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Aktivite İntoleransı Tanısına İlişkin Öznitelikler	75
Tablo 16: Aktivite İntoleransı Tanısına Ait Model Performans Göstergeleri.....	77
Tablo 17: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Fiziksel Mobilitede Bozulma Tanısına İlişkin Öznitelikler.....	77

Tablo 18: Fiziksel Mobilitede Bozulma Tanısına Ait Model Performans	
Göstergeleri	78
Tablo 19: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test	
Edilen Etkisiz Sağlık Öz Yönetimi Tanısına İlişkin Öznitelikler	78
Tablo 20: Etkisiz Sağlık Öz Yönetimi Tanısına Ait Model Performans	
Göstergeleri	80
Tablo 21: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test	
Edilen Kırılgan Yaşlı Sendromu Tanısına İlişkin Öznitelikler	80
Tablo 22: Kırılgan Yaşlı Sendromu Tanısına Ait Model Performans Göstergeleri	
.....	81
Tablo 23: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test	
Edilen Kan Basıncında Değişkenlik Riski Tanısına İlişkin Öznitelikler	
.....	81
Tablo 24: Kan Basıncında Değişkenlik Riski Tanısına Ait Model Performans	
Göstergeleri	83
Tablo 25: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test	
Edilen Kardiyovasküler Fonksiyon Bozulma Riski Tanısına İlişkin	
Öznitelikler.....	83
Tablo 26: Kardiyovasküler Fonksiyon Bozulma Riski Tanısına Ait Model	
Performans Göstergeleri.....	84
Tablo 27: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test	
Edilen Elektrolit Dengesizliği Riski Tanısına İlişkin Öznitelikler	84
Tablo 28: Elektrolit Dengesizliği Riski Tanısına Ait Model Performans	
Göstergeleri	85
Tablo 29: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test	
Edilen Etkisiz Renal Perfüzyon Riski Tanısına İlişkin Öznitelikler...	86
Tablo 30: Etkisiz Renal Perfüzyon Riski Tanısına Ait Model Performans	
Göstergeleri	87

ÖZET

GİRİŞ VE AMAÇ: Üç aşamada gerçekleştirilen araştırmanın ilk aşamasında klinik karar destek sisteminin (KKDS) geliştirilmesine yönelik hemşire görüşlerinin belirlenmesi, ikinci aşamada Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ) geliştirilmesi ve son aşamada ise hastaların bakım gereksinimlerini sınıflandırma ve hemşirelik tanılarını belirlemeye yönelik makine öğrenimi tabanlı KKDS geliştirilmesi amaçlanmıştır.

GEREÇ VE YÖNTEM: Nitel aşamada kardiyometabolik multimorbiditeli yaşlı hastalara bakım veren 20 hemşire ile görüşmeler yapılmıştır. Veriler, MaxQDA yazılımı kullanılarak tematik analiz yöntemi ile değerlendirilmiştir. İkinci aşamada, en az iki kardiyometabolik hastalığı bulunan 65 yaş ve üzeri 388 hasta, son aşama ise 700 hasta ile yürütülmüştür. Farklı öznitelikleri içeren veri seti üzerinde kırılganlık derecesine göre bakım gereksinimi tahminine yönelik Random Forest, XGBoost ve SVM makine öğrenimi algoritmaları; 10 hemşirelik tanısına yönelik karar ağacı modelleri geliştirilerek değerlendirilmiştir.

BULGULAR: Bakım sürecindeki yaşananlar, bakım gereksinimlerini sınıflandırılma ve hemşirelik tanılarını önceliklendirilme, KKDS geliştirilmesine yönelik görüşler olmak üzere üç ana tema ortaya çıkmıştır. Geliştirilen ölçeğin Cronbach alfa katsayısının 0,978 olduğu bulunmuştur. En çok katkı sağlayan 19 öznitelik için ikili sınıflandırmada XGBoost modeli (%86) ve üçlü sınıflandırma SVM modeli (%76) en yüksek performansı göstermiştir. Öznitelikler doğrultusunda ele alınan tüm hemşirelik tanılarının %97 ile %100 arasında yüksek doğrulukla gerçekleştirdiği görülmüştür.

SONUÇ: Karmaşık bakım gereksinimi olan yaşlı bireylerde bakım planlaması yapılırken, çok boyutlu özniteliklere dayalı makine öğrenimi tabanlı KKDS'lerden yararlanılması, hemşirelerin klinik karar alma süreçlerini kolaylaştırabilir.

Anahtar Kelimeler: Hemşirelik bakımı, kardiyometabolik multimorbidite, yaşlı hastalar, klinik karar destek sistemi, makine öğrenmesi, yapay zekâ

SUMMARY

Developing a Decision Support System for Classifying Care Needs and Determining Nursing Diagnoses in Older Patients with Cardiometabolic Multimorbidity

INTRODUCTION AND AIM: The aim of the first phase of this three-stage study was to determine nurses' opinions on the development of a clinical decision support system (CDSS), the second phase aimed to develop the "Symptom Severity Scale in Cardiometabolic Multimorbid Patients (SSS-CM)," and the final phase aimed to develop a machine learning-based CDSS to classify patients' care needs and determine nursing diagnoses.

MATERIALS AND METHODS: In the first phase, semi-structured interviews were conducted with 20 nurses who cared for older adults with cardiometabolic multimorbidity. The data were analyzed through thematic analysis using an inductive approach via MaxQDA software. In the second phase, 388 patients aged 65 years and older with at least two cardiometabolic diseases were included. The final phase was conducted with 700 patients. Based on the dataset containing various features, Random Forest, XGBoost, and SVM machine learning algorithms were used to predict care needs based on frailty level. For each of the ten nursing diagnoses, separate decision tree models were trained and evaluated.

RESULTS: Three main themes were identified: experiences during the care process, classification of care needs and prioritization of nursing diagnoses, and views on the development of a decision support system. The Cronbach's alpha coefficient of the developed scale was found to be 0.978, and it showed good model fit overall. For binary classification with the top 19 features, the XGBoost model performed best (86%), while for three-class classification, the SVM model showed the highest accuracy (76%). The ten nursing diagnoses evaluated using the decision tree method were classified with high accuracy, ranging from 97% to 100%.

CONCLUSION: Utilizing machine learning-based CDSSs based on multidimensional features may facilitate nurses' clinical decision-making when planning care for older individuals with complex care needs.

Keywords: Nursing care, cardiometabolic multimorbidity, older adults, clinical decision support system, machine learning, artificial intelligence



1. GİRİŞ VE AMAÇ

İleri yaş, multimorbidite için temel bir risk faktörü olup multimorbidite prevalansı 65 yaş üstü bireylerin yarısından fazlasını etkiler duruma gelmiştir (Gao et al 2021). Bu yüksek prevalansta, hipertansiyon (HT), diyabetes mellitus (DM), koroner kalp hastalıkları (KKH), inme ve dislipidemi gibi kardiyometabolik hastalıklar başlıca rol oynamaktadır (Gao et al 2021). Kardiyometabolik multimorbidite, bozukluklardan en az ikisinin aynı bireyde birlikte bulunması olarak tanımlanmaktadır (Di Angelantonio et al 2015, Sakakibara, Obembe and Eng 2019). Yaşlanan toplum yapısı ile kardiyometabolik hastalıkların ortak risk faktörleri ve birbirini etkileyen patofizyolojik mekanizmaları, kardiyometabolik multimorbiditenin giderek artmasında belirleyici rol oynamaktadır (Di Angelantonio et al 2015).

Kardiyometabolik multimorbiditeye sahip yaşlı bireylerde kırılgnlık, semptom yükü ve yaşam kalitesi gibi faktörler, sağlık sonuçlarını önemli ölçüde etkilemektedir (Rivera-Almaraz et al 2018, Zhang, Meng, Qiu, Yang and Sun 2018). Kırılgnlık, yaşlı bireylerin stres faktörlerine karşı dirençlerinin azalması ile karakterize edilen bir durumdur ve bu bireylerde olumsuz sağlık sonuçlarıyla ilişkilidir. Ayrıca, semptom yükünün artması, yaşam kalitesinin düşmesine ve sağlık hizmeti kullanımının artmasına neden olmaktadır (Rivera-Almaraz et al 2018). Özellikle hastanede yatan yaşlı kardiyometabolik sorunları olan hastaların bakım yönetimi, sağlık profesyonelleri için önemli zorluklar içermektedir (Cesari, Pérez-Zepeda and Marzetti 2017, Vetrano et al 2019). Bu hastalar, genellikle birden fazla kronik hastalığa sahip olup, karmaşık tedavi ve bakım planlarına ihtiyaç duymaktadır. Ayrıca, bu bireylerde eşlik eden geriatrik sendromlar, polifarmasi, ilaç etkileşimleri, tedaviye uyum sorunları ve bilişsel gerileme gibi faktörler, bakım sürecini daha da karmaşık hale getirmektedir (Renne and Gobbens

2018; Zhang et al 2018). Bu nedenle, yaşı kardiyometabolik hastaların bakım yönetiminde, bireyselleştirilmiş ve bütüncül yaklaşımlar önem taşımaktadır. Ancak, mevcut sağlık sistemleri genellikle genç ve tekil sağlık sorunları olan hastaların gereksinimlerini karşılamaya odaklandığı için, yaşı bireylerin çok yönlü bakım gereksinimlerini karşılamada yetersiz kalabilmektedir (Liu, Atkins, Chomik and Judd 2023, Zisberg et al 2024). Bu durum, demografik geçişle birlikte parçalanmış bakım süreçlerine, ilaç hatalarına, çelişkili tedavi önerilerine ve hem hastalar hem de aileler için artan stres ve kafa karışıklığına yol açmaktadır (Beil et al 2021, Moghadam, Moghadam, Qazani, Pławiak and Alizadehsani 2024). Aynı zamanda sağlık sistemi maliyetlerini ve sağlık çalışanlarının fiziksel ve psikolojik yükünü de artırmaktadır (Beil et al 2021, Moghadam et al 2024).

Semptom yükü, kardiyometabolik multimorbiditeye sahip yaşı bireylerde sağlık sonuçlarının kritik bir belirleyicisi olarak öne çıkmaktadır (Otieno, Asiki, Wilunda, Wami and Agyemang 2023). Literatürde Edmonton Semptom Değerlendirme Ölçeği, Memorial Semptom Değerlendirme Ölçeği ve MD Anderson Semptom Envanteri gibi çeşitli semptom değerlendirme araçlarının yaygın olarak kullanıldığı görülmektedir (Cleeland et al 2000, Chang, Hwang, Thaler, Kasimis and Portenoy 2004). Ancak bu ölçekler, esas olarak onkoloji veya palyatif bakım popülasyonları için tasarlanmış olup, kardiyometabolik multimorbiditeye özgü semptom profillerini yeterince kapsamamaktadır. Bu araçlar genellikle ağrı, ağız kuruluğu ve düşük enerji gibi genel semptomlara odaklanmakta ve eş zamanlı kardiyovasküler, serebrovasküler ve metabolik hastalıkları olan yaşı bireylerin karmaşık ve benzersiz semptom yapılarını yansıtmakta yetersiz kalmaktadır. Öte yandan, kardiyometabolik multimorbidite kapsamındaki her hastalık için ayrı ayrı geliştirilen spesifik ölçekler mevcuttur. Örneğin, Tip 2 Diyabet Semptom Kontrol Listesi (Grootenhuys, Snoek, Heine and Bouter 1994), Kardiyak Semptom Anketi (Nieveen, Zimmerman, Barnason and Yates 2008), İskemik İnme Semptomları Anketi (Beal, Ogola and Allen 2019) ve Kardiyovasküler Semptomlar Ölçeği (Juárez-García, González-Muñoz and Aguirre-Moreno 2019) bu alanda sıkça kullanılan ölçütlerdir. Ancak, bu ölçeklerin ayrı ayrı uygulanması iş yükünün artmasına hem de zaman kaybına yol açmakta ve bütüncül bir değerlendirme sağlayamamaktadır. Türk toplumunda ise kardiyometabolik hastalıklara sahip yaşı

bireylerin yaygın semptomlarını değerlendirecek kapsamlı ve kültürel olarak uyarlanmış bir araç bulunmamaktadır. Literatürde mevcut ölçüm araçları, kardiyometabolik multimorbidite hastalarında semptom yükü ve sağlık sonuçlarını kapsamlı ve entegre bir şekilde değerlendirmede yetersiz kalmaktadır. Bu nedenle, bu çalışmanın amaçlarından biri sağlık profesyonellerinin kardiyometabolik multimorbiditesi olan yaşlı bireylerin semptomlarını kolayca ve bütüncül olarak değerlendirebilmelerini sağlayacak, kapsamlı bir ölçüm aracı olan Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeğinin (KM-SSÖ) geliştirilmesidir.

Kardiyometabolik hastalıkların eşzamanlı varlığı hemşirelerin klinik karar alma süreçlerini karmaşıklştırmakta ve bakım sürekliliğini içeren hasta merkezli bakım planlarının önceliklendirilmesini beraberinde getirmektedir (Sakakibara et al 2019, Moghadam et al 2024). Bu bağlamda, makine öğrenimi tabanlı klinik karar destek sistemlerinin (KKDS) geliştirilmesi ve uygulanması, bu karmaşık hasta grubuna yönelik bakımın optimize edilmesi açısından önem kazanmaktadır (Sakakibara et al 2019, Dixon et al 2024, Chaparala et al 2025). Makine öğrenimi tabanlı KKDS'leri, bakım süreçlerini kişiselleştirerek ve klinik karar verme süreçlerini destekleyerek, yaşlı bireylerin özgün bakım gereksinimlerine duyarlı çözümler sunabilmektedir (Kwon, Karim, Topaz and Currie 2019, Choudhury, Renjilian and Asan 2020, Rony, Kayesh, Bala, Akter and Parvin 2024). Son dönemde yapılan çalışmalar, makine öğrenimi tabanlı KKDS'lerin karmaşık hasta popülasyonlarında tedavi süreçlerini standartlaştırma, tanı doğruluğunu artırma ve hemşirelik bakımını iyileştirme potansiyeline sahip olduğunu vurgulamaktadır (Akbar, Lyell and Magrabi 2021, An et al 2021, Zolnoori et al 2021, Moghadam et al 2024). Ancak, literatürde, kardiyometabolik multimorbiditeye sahip yaşlı bireylerde bakım gereksinimlerinin sınıflandırılması ve hemşirelik tanılarının belirlenmesinde makine öğrenimi tabanlı KKDS'lerin geliştirilmesi veya kullanımına dair bir çalışmaya rastlanmamıştır.

Kardiyometabolik multimorbiditeye sahip yaşlı bireylerin hastanede yatan hasta popülasyonunda, bakım gereksinimlerini sınıflandırmak; yalnızca klinik verilerin değerlendirilmesini değil, aynı zamanda hasta merkezli, kırılganlığa duyarlı ve kişiselleştirilmiş bir yaklaşımın geliştirilmesini zorunlu kılmaktadır (Dunlay and

Chamberlain 2016, Holm, Berland and Severinsson 2016, Yarnall et al 2017, Bunn et al 2025). Bu hasta grubunda çoklu kronik hastalıklar, yaşlanmaya bağlı fizyolojik rezerv kaybı ve bilişsel gerileme gibi faktörler, kırılabilirlik sendromunun gelişimini hızlandırmakta ve bireyin bakım ihtiyaçlarını daha karmaşık hale getirmektedir (Holm et al 2016, Yarnall et al 2017). Aynı zamanda, çoklu kronik hastalıkların neden olduğu fizyolojik yük ve eşzamanlı semptomlar, hemşirelerin klinik karar alma süreçlerini karmaşıklştırmakta ve dinamik olarak değişen bakım ihtiyaçlarını karşılamada zorluk yaratmaktadır (Yarnall et al 2017). Bu nedenle, makine öğrenimi tabanlı KKDS'leri, hemşirelerin bu karmaşık hasta profilinde bakım ihtiyaçlarını bütüncül bir bakış açısıyla tanımlamasına yardımcı olarak bakımın kişiselleştirilmesine olanak tanımaktadır (An et al 2021, Zolnoori et al 2021, Moghadam et al 2024). Ayrıca, hastanede yatan kardiyometabolik hastaların dinamik bakım gereksinimlerinin tanımlanması ve sınıflandırılması, bakımın sürekliliğini sağlayarak komplikasyonların önlenmesine, iyileşme süresinin kısalmasına ve hasta güvenliğinin artırılmasına katkı sunmaktadır (An et al 2021, Zolnoori et al 2021, Moghadam et al 2024). Böylece, bakım gereksinimlerini sınıflandırmak ve KKDS yardımı ile bu süreci optimize etmek; hastanede yatan kardiyometabolik multimorbiditeli yaşlı bireylerde yaşam kalitesini yükseltmek, bakım kalitesini artırmak ve hasta merkezli yaklaşımı güçlendirmek için vazgeçilmez bir temel oluşturmaktadır. Yukarıda bilgiler ışığında, bu araştırmada kardiyometabolik multimorbiditesi olan yaşlı hastaların hastane ortamında bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını belirlemeye yönelik makine öğrenimi tabanlı KKDS geliştirilmesi amaçlanmıştır.

2. GENEL BİLGİLER

2.1. YAŞLI BİREYLER VE MULTİMORBİDİTE

Son yıllarda, beklenen yaşam süresinin uzaması ile nüfusun yaşlanması küresel sağlık sorunu olarak ortaya çıkmaktadır (Fortin, Stewart, Poitras, Almirall and Maddocks 2012). Nüfus yaşlandıkça kronik hastalıklar daha fazla ilgi görmekte ve multimorbidite kavramı gittikçe önem kazanmaktadır (Fortin et al 2012). Dünya Sağlık Örgütü (DSÖ) ve Ulusal Sağlık ve Bakım Mükemmelliği Enstitüsü (NICE) kılavuzları multimorbiditeyi tek bir bireyde iki veya daha fazla kronik hastalığın veya durumun birlikte ortaya çıkması olarak tanımlanmaktadır (Willadsen et al 2016, Aubert et al 2020, Eriksen et al 2022). Multimorbidite sıklığı yaşla birlikte artarak 65 yaş üstü bireylerin %60'ından fazlasını etkilemektedir (Nguyen et al 2019). 85 yaş ve üzeri hastalarda ise multimorbidite prevalansı %90'a ulaşmaktadır (Nguyen et al 2019).

Multimorbiditesi olan yaşlıların sağlık hizmeti ihtiyaçları ve bu ihtiyaçların ne ölçüde karşılandığı, 21. yüzyılda dünya çapında sağlık sistemlerinin karşılaştığı zorluklar arasında yer almaktadır (Haines et al 2020, Beil et al 2021). İngiliz Geriatri Derneği, Birleşik Krallık Hastane Bölüm İstatistiklerine dayanarak, 65 yaş üstü bireylerin, hastaneye kabullerin %60'ını, yatakta geçirilen günlerin %65'ini, gecikmiş transferlerin %90'ını ve acil tekrar kabullerin ise %65'ini oluşturduğunu bildirmiştir. Özellikle sağlık hizmetlerinin büyük bir bölümü, genellikle yalnızca tek bir hastalığı olan genç veya orta yaş grubundaki bireylerin ihtiyaçlarını karşılamaya yönelik olarak yapılandırılmıştır (Haines et al 2020, Beil et al 2021). Ancak yaşlı bireylerde görülen çoklu hastalık durumları, bu yaklaşımların doğrudan uygulanmasını hem karmaşık hem de potansiyel olarak zararlı hâle

getirebilmektedir (Beil et al 2021). Multimorbid yaşı bireylerde bu durum; sağlık bakım hizmetlerinin yinelenmesi, koordinasyonsuz müdahaleler, çelişkili klinik öneriler ve tedavi süreçlerinde belirsizlik gibi çeşitli sorunlara yol açmakta; bunun sonucunda ilaç hataları, yetersiz tedavi, hasta ve aile açısından artan psikolojik yük ve sağlık sistemine yönelik ekonomik baskılar ortaya çıkmaktadır (Yarnall et al 2017, Beil et al 2021). Yapılan çalışmalar da hastaneye yatırılan yaşı hastaların fiziksel, zihinsel, psikolojik ve/veya sosyal gereksinimlerini karşılamada farklı sağlık uzmanlıklarından koordineli bakım almayı gerektirmesi nedeni ile zor bir süreç olduğunu raporlamıştır (Yarnall et al 2017, Beil et al 2021). Bu hastalara sıklıkla "karmaşık yaşı" veya "karmaşık ihtiyaçları olan yaşı hasta" adı verilmektedir. Bu durum, ileri yaşı eşzamanlı birden fazla tıbbi durumu olan bu hastaların ihtiyaç duyduğu bakımın karmaşıklığını yansıtmak amacıyla kullanılmaktadır (Haines et al 2020, Beil et al 2021). Tüm bu durumlar göz önüne alındığında, son yıllarda, multimorbiditesi olan yaşı hastaların bakım yönetiminin sağlık profesyonellerinin ve politika yapıcıların gündeminde üst sıralarda yer aldığı dikkat çekmektedir (Haines et al 2020, Beil et al 2021).

2.2. KARDİYOMETABOLİK MULTİMORBİDİTE

2.2.1. Kardiyometabolik Multimorbidite Tanımı

Hipertansiyon, DM, KKH ve inme gibi kardiyometabolik hastalıklar, yaşılanan toplumlarda artan sıklıkla görülmektedir (Zhou, Wang and Yi 2025). Yaşıla birlikte fizyolojik değişimlerin yanı sıra genetik yatkınlık, yaşam biçimi tercihleri ve çevresel faktörlerin etkileşimi, bu hastalıklara yakalanma olasılığını anlamlı şekilde artırmaktadır (Yang et al 2023, Zhou et al 2025). Bu kronik hastalıklar arasında KKH, HT, DM, inme ve dislipidemi gibi kardiyometabolik bozukluklardan iki veya daha fazlasının aynı bireyde bir arada bulunması kardiyometabolik multimorbidite olarak adlandırılmaktadır (Di Angelantonio et al 2015, Sakakibara et al 2019).

2.2.2. Kardiyometabolik Multimorbidite Epidemiyolojisi

Özellikle küresel düzeyde yaşılanan nüfusun etkisi ile kardiyometabolik multimorbidite prevalansı ciddi bir artış göstermektedir. Amerika Birleşik

Devletleri'nde 1999-2018 dönemine ait veriler doğrultusunda yapılan bir çalışmada, 2017-2018 arasında genel yetişkin popülasyonda kardiyometabolik multimorbidite prevalansının %14,4 olduğu saptanmıştır (Cheng, Ma, Ouyang, Zhang and Bai 2022, Ma et al 2023). Bu sıklık 60-79 yaş grubunda %34,8'e, 80 yaş ve üzeridekilerde %42,9'a yükselmektedir (Cheng et al 2022). Kardiyometabolik multimorbiditenin Kanada ve Güney Asya'daki popülasyonun yaklaşık %25'ini etkilediği rapor edilmiştir (Sakakibara et al 2019). Benzer şekilde, Çin'de yetişkin kadınlarda yapılan bir analizde, HT, DM, hiperlipidemi ve inme gibi durumları birlikte ele alan kardiyometabolik multimorbidite prevalansının %33,1 düzeyine ulaştığı; 45-54 yaş grubunda %28,5, 75 yaş ve üstünde %65,3 olduğu bildirilmiştir (Zhao et al 2023). Ayrıca, çalışmalar, kardiyometabolik durumların kombinasyonlarının ölüm riskini artırdığını, her ilave hastalığın ölüm riskini iki katına çıkardığını vurgulamıştır (Di Angelantonio et al 2015, Sakakibara et al 2019, Sewpaul, Mbewu, Fagbamigbe, Kandala and Reddy 2021). 2021 yılında yapılan bir çalışmada 60 yaş üstü bireylerde eşlik eden diyabet, miyokard infarktüsü (MI) ve inme öyküsü, sağlıklı bireylere kıyasla yaşam beklentisinin 15 yıl azalmasıyla ilişkilendirilmiştir (Sewpaul et al 2021).

Ülkemizde kardiyometabolik multimorbidite prevalansına yönelik veri bulunmamaktadır. Ancak, Türkiye'de 65 yaş ve üzeri bireylerde kronik hastalık yükü oldukça yüksektir. Türkiye Yaşlı Profili Araştırması 2023 yılı verilerine göre, HT, diyabet, kalp hastalığı, kanser, böbrek yetmezliği, inme, hepatit ve astım gibi en az bir kronik hastalığı bulunan yaşlı bireylerin oranı %78,7 olarak rapor edilmiştir. Güncel bir çalışmada ise ülkemizdeki 40 yaş üstü multimorbiditeli bireylerin prevalansı %27,8 olarak bildirilmiştir (Akturan, Karahan ve Akman 2021). Aynı çalışmada diğer bir önemli bulgu ise yaş arttıkça multimorbidite görülme sıklığının da (%55,9) artmasıdır (Akturan ve ark 2021). Bu bulgular, yaşlı nüfusun büyük çoğunluğunun birden fazla sağlık sorunu ile karşı karşıya olduğunu ortaya koymaktadır. Öte yandan, Türkiye İstatistik Kurumu (TÜİK) verilerindeki ölüm nedeni istatistikleri incelendiğinde, 2024 yılında ölen bireylerin %36,0'nın dolaşım sistemi hastalıkları nedeniyle yaşamını yitirdiği ve bu ölümlerin %42,9'unun iskemik kalp hastalıkları, %18,3'ünün serebro-vasküler hastalıklar ve %9,3'ünün hipertansif hastalıklar kaynaklı olduğu görülmektedir. Endokrin ve

metabolik hastalıklara bağılı ölüm oranının ise %4,8 olduđu raporlanmıřtır (TÜİK, 2024). Tüm bu veriler ölkemizde kardiyometabolik multimorbidite prevalansının yüksek olduđunu düşöndürmektedir.

2.2.3. Kardiyometabolik Multimorbidite Bileřenleri

Koroner kalp hastalıđı, inme, HT, DM ve dislipidemi gibi kardiyometabolik hastalıkların birbiriyle örtüşen risk faktörleri, ortak etiyolojileri ve çift yönlü etkileri, kardiyometabolik multimorbiditeyi giderek daha yaygın hale getirmektedir (Di Angelantonio et al 2015, Sakakibara et al 2019, Gao et al 2021).

- Kardiyovasküler hastalıklar, KKH, koroner arter hastalıđı (KAH) ve akut koroner sendromu gibi çeřitli durumları içermektedir (Komalasari and Yoche 2019, Sanchis-Gomar, Perez-Quilis, Leischik and Lucia 2016). KAH, koroner arterlerde ateroskleroz ile karakterize ve asemptomatik olabilirken, akut koroner sendrom genellikle kararsız angina gibi bir semptomla ortaya çıkmakta ve KAH'nın varlıđından bağımsız olarak sıklıkla MI ile iliřkili olmaktadır (Lippi, Sanchis-Gomar and Cervellin 2016, Sanchis-Gomar et al 2016). KKH ise KAH'nın bir sonucu olarak angina pectoris, Mİ ve sessiz miyokard iskemisini içermektedir. Klinik risk faktörleri olarak HT, DM ve dislipidemi, koroner kalp hastalıklarında aterosklerotik sürecin gelişiminin güçlü öngörücüleridir (Pollack et al 2020). Kardiyovasküler hastalıklar, fonksiyonel kapasiteyi sınırlandırarak yaşam kalitesini olumsuz etkilemekte ve dispne, yorgunluk, uyku bozuklukları, depresyon ve göğüs ağrısı gibi çeřitli semptomlarla iliřkilendirilmektedir (Lippi et al 2016, Sanchis-Gomar et al 2016, Komalasari and Yoche 2019). Bu semptomlar, bireyin günlük yaşam aktivitelerini sürdürebilme yetisini azaltarak, fiziksel ve psikolojik yük oluşturmakta ve hastalıđın birey ve toplum üzerindeki olumsuz etkilerini artırmaktadır (Komalasari and Yoche 2019).
- İnme, vasküler kökenli beyin hasarına bağılı olarak gelişen kompleks bir nörolojik sendromdur (Ovbiagele and Nguyen-Huynh 2011, Murphy and Werring 2020). Bu durum, serebral arterlerde oluşan tromboz veya emboli sonucunda beyin dokusuna kan akışının kesilmesiyle meydana gelen iskemik inme ya da bir arterin yırtılması ile intrakraniyal kanamanın olduđu hemorajik

inme şeklinde ortaya çıkabilir (Ovbiagele and Nguyen-Huynh 2011, Murphy and Werring 2020). Bu patolojik süreçler, oksijen yetersizliği nedeniyle nöronal hücre ölümüne yol açar. İnme, kalıcı motor fonksiyon kaybı, bilişsel bozukluklar ve psikiyatrik rahatsızlıklar, özellikle anksiyete ve depresyon, gibi ciddi uzun vadeli sonuçlar doğurmaktadır (Murphy and Werring 2020). İnme geçiren bireylerin fiziksel, bilişsel veya iletişimsel fonksiyon kaybına uğraması nedeni ile inmenin bireysel, ailesel ve sağlık sistemi üzerindeki ekonomik ve sosyal yükü oldukça büyüktür (Ovbiagele and Nguyen-Huynh 2011, Murphy and Werring 2020).

- HT, tekrarlayan arteriyel kan basıncı ölçümlerinde sistolik kan basıncının 140 mmHg veya üzerinde, diyastolik kan basıncının ise 90 mmHg veya üzerinde olması ile karakterize kronik bir durumdur (Hall et al 2012, Saxena, Ali and Saxena 2018). Esansiyel HT'nin gelişiminde rol oynayan periferik direnci etkileyen çeşitli mekanizmalar ele alınmaktadır. Özellikle, sempatik sinir sistemi aşırı aktivitesi, fazla sodyum alımı, endotel hücre disfonksiyonu ve nitrik oksit yolu, renin-anjiyotensin-aldosteron sistemi (RAAS), insülin direnci ve metabolik sendrom gibi durumlar HT gelişiminde rol oynar (Hall et al 2012, Saxena et al 2018). HT, kardiyovasküler ve serebrovasküler hastalıkların önde gelen nedenlerinden biridir (Sewpaul et al 2021). Gözlemsel çalışmalar, kardiyovasküler hastalıklarda mortalitenin sistolik kan basıncı 115 mmHg ve diyastolik kan basıncı ise 75 mmHg'nin üzerine çıktıkça kademeli ve doğrusal olarak arttığını göstermektedir (Lewington, Clarke, Qizilbash, Peto and Collins 2003, Lawes, Vander Hoorn and Rodgers 2008, Hall et al 2012). Kan basıncında her 20 mmHg sistolik veya 10 mmHg diyastolik artış için, 40 ila 89 yaş arasındaki tüm yaş gruplarında hem iskemik kalp hastalığından hem de inmeden kaynaklanan ölüm oranı iki katına çıkmaktadır (Lewington et al 2003, Hall et al 2012).
- DM, hiperglisemi ile karakterize karmaşık bir metabolik bozukluktur. Hiperglisemi, insülin salgılanmasında veya insülin etkisinde veya her ikisinde anormalliklerden kaynaklanır ve kronik bir şekilde karbonhidrat, yağ ve protein metabolizmasında işlev bozuklukları olarak ortaya çıkar (Rawshani et al 2017, Banday, Sameer and Nissar 2020). Çoğunlukla hipergliseminin ve bununla

ilişkili metabolik anomaliler mikro ve makro damar sisteminin normal yapısı ve işlevini bozar (Rawshani et al 2017). Organ hasarı, işlev bozukluğu ve nihayetinde organ yetmezliği mikrovasküler ve makrovasküler komplikasyonları karakterize eder (Rawshani et al 2017, Banday et al 2020). Serebrovasküler hastalık, HT ve KKH ile aterosklerotik hastalıklar diyabetin yaygın görülen ve diyabetle ilişkili morbidite ve mortalitenin başlıca nedenlerini oluşturan makrovasküler komplikasyonlarından (Rawshani et al 2017, Sakakibara et al 2019, Banday et al 2020, Galicia-Garcia et al 2020). Diyabetin başlı başına kardiyovasküler hastalık riskini yaklaşık iki kat artırdığı bilinmektedir (Sattar 2013). Aynı zamanda hiperglisemiye bağlı aşırı oksidatif stres, inflamasyon ve endotel disfonksiyonu aterosklerotik hastalıkların restenoz gelişimini hızlanmaktadır (Di Angelantonio et al 2015, Sakakibara et al 2019).

- Dislipidemi, kandaki lipit düzeylerinde anormallikler olması durumudur. Genellikle total kolesterol, düşük yoğunluklu lipoprotein (LDL) kolesterol ve trigliserit seviyelerinin yükselmesi; yüksek yoğunluklu lipoprotein (HDL) kolesterol seviyesinin ise azalması ile karakterizedir (Gau and Wright 2006, Jebari-Benslaiman et al 2022). Dislipidemi ateroskleroz patogeneziindeki temel faktörlerden biridir (Gau and Wright 2006, Jebari-Benslaiman et al 2022). Aterosklerozun temelinde, trigliseritler, fosfolipitler ve kolesterol içeren lipoproteinlerin metabolizmasında meydana gelen değişiklikler yer alır (Gau and Wright 2006, Jebari-Benslaiman et al 2022). Bu değişimler, makrofaj aktivasyonu, köpük hücre oluşumu, düz kas hücrelerinin proliferasyonu ve göçü, ekstraselüler matriks üretimi ve neovaskülarizasyon ile seyreden damar duvarındaki kronik inflamatuvar süreçleri tetikler (Gau and Wright 2006, Jebari-Benslaiman et al 2022). Bu süreç, KKH, inme, HT, DM ve metabolik sendrom gibi hastalıklara zemin hazırlar (Gau and Wright 2006, Wengrofsky, Lee and Makaryus 2019, Jebari-Benslaiman et al 2022).

Sonuç olarak, KKH, inme, HT, DM ve dislipidemi gibi kardiyometabolik hastalıklar multimorbiditenin ana bileşenlerindendir ve bir dizi birbiriyle ilişkili durumu kapsamaktadır (Di Angelantonio et al 2015, Sakakibara et al 2019, Gao et al 2021). Tüm bu hastalıkların bireysel düzeyde yarattığı sağlık sorunlarının yanı

sıra, birden fazla kardiyometabolik hastalığın bir arada bulunması, bireyler için daha karmaşık ve yönetilmesi zor bir sağlık tablosu ortaya çıkararak hastalık yükünü arttırmaktadır.

2.2.4. Kardiyometabolik Multimorbiditeli Hastalarda Ortak Görülen Semptomlar

Semptom, hasta bireyin biyopsikososyal işleyişini, duyumlarını veya algısını yansıtan öznel bir deneyim olarak tanımlanmaktadır (Garin et al 2014). Kardiyometabolik multimorbiditesi olan hastalar, yaşam kalitelerini önemli ölçüde etkileyen bir dizi semptom deneyimlemektedir (Garin et al 2014, Zheng et al 2023). Kardiyometabolik multimorbiditesi olan yaşlı bireylerde semptomlar, izole bir şekilde ortaya çıkabileceği gibi, sıklıkla diğer semptomlarla birlikte veya dinamik ve birbirine bağlı bir sürecin parçası olarak birbirinden önce gelişebilir (Zheng et al 2023, Willadsen et al 2021). Örneğin, dispne, yorgunluk, uyku bozuklukları ve ruh hali değişiklikleri, yaşlı kardiyometabolik bireylerde sıklıkla birlikte görülür ve sinerjik etkileşimleriyle hastalık yükünün bütüncül ve kümülatif algılanmasına katkıda bulunur (Willadsen et al 2021). Bu bağlamda, semptom yükü fazla ve yönetimi oldukça zor olan kardiyometabolik multimorbidite hastalarında semptomların şiddeti arttıkça, morbidite ve mortalite hızı da artmakta ve prognoz kötüleşmektedir (Zhang et al 2022, Jin, Liang, Hong, Liang and Luo 2023).

Kardiyometabolik multimorbiditesi olan hastalarda semptomların gelişimi, birden fazla faktörün etkisiyle gerçekleşmektedir (Rushton and Kadam 2014, Zheng et al 2023). Ortak risk faktörleri ve benzer patojenik mekanizmalar birbiriyle ilişkili olup bu süreci şekillendirmektedir (Rushton and Kadam 2014, Zheng et al 2023). Göğüs ağrısı, nefes darlığı, kalp çarpıntısı, yorgunluk, halsizlik, baş dönmesi, senkop, endişe, huzursuzluk hissi ve uyku sorunları kardiyovasküler hastalıkları olan hastalarda günlük aktivitelerini ve yaşam kalitelerini etkileyen yaygın görülen semptomlardır (Rushton and Kadam 2014, Violán et al 2016, Singh-Manoux et al 2018). Bu semptomların şiddeti, HT, DM ve inme gibi eşlik eden durumların varlığıyla artabilir ve ek olarak bilinç bulanıklığı, hafıza, hatırlama sorunları, bulanık/çift görme, denge ve koordinasyon problemleri, kol veya bacaklarda güç/his kaybı, ellerde veya ayaklarda uyuşma/karınalanma gibi semptomların

ortaya çıkmasına neden olabilir (Rushton and Kadam 2014, Violán et al 2016, Singh-Manoux et al 2018). Kardiyometabolik multimorbiditeli hastalıklarda ortak görülen bu semptomlar, hastaların fonksiyonel kapasitelerinde azalma, günlük yaşam aktivitelerini yerine getirmede zorlanma, bakım bağımlılığında artma, tekrarlı hastane yatışları ve tüm bu etkilerin sonucunda sağlıkla ilişkili yaşam kalitesinde azalmaya neden olmaktadır (Parker, Moran, Roberts, Calvert and McCahon 2014, Gu et al 2018). Tüm bu etkiler dikkate alındığında, kardiyometabolik multimorbidite hastalarına kapsamlı bakım hizmetinin verilmesinde, tekrarlı hastane yatışların azaltılmasında ve yaşam kalitelerinin artırılmasında kardiyometabolik hastalıklara özgü ve en sık görülen ortak semptomların varlığını, şiddetini ve her bir semptomun hastalar üzerindeki etkilerini bütüncül değerlendirmek önemli bir gereklilik halini almaktadır.

2.2.5. Kardiyometabolik Multimorbiditeli Hastalarda Yaşam Kalitesi

Kardiyovasküler hastalığa bağlı ölümlerin tüm dünyada ilk sırada yer alması ve nüfusun giderek yaşlanması, kardiyometabolik multimorbiditesi olan yaşlı hastalarda sağlık hizmetlerinin kullanım sıklığının ve tekrarlı hastaneye yatışlarının artması ile ilişkilidir (Di Angelantonio et al 2015; Sakakibara et al 2019). Kardiyovasküler hastalıklarla birlikte metabolik durumların kombinasyonu ise yaşlı bireylerde hastalık yükünü daha da arttırmakta ve fonksiyonel yetenekler ve yaşam kalitesi üzerinde olumsuz bir etkiye neden olmaktadır (Yarnall et al 2017). Yaşam kalitesi, yalnızca fiziksel sağlıkla sınırlı kalmayan; bireyin sosyal ilişkilerini, psikolojik iyilik halini, işlevsel kapasitesini ve genel yaşam doyumunu içeren çok boyutlu bir kavramdır ve bireyin sağlığını çeşitli düzeylerde yansıtan önemli sağlık sonuçlarından biridir (Garin et al 2014).

Önceki çalışmalar, eşzamanlı kronik rahatsızlıkların sayısının artmasının ayakta tedavi ziyaretlerinin sıklığında artma, hastanede kalış süresinde uzama ve sağlıkla ilişkili yaşam kalitesinde azalma ile ilişkili olduğunu ortaya koymuştur (Sum et al 2019, Lu et al 2024). Buna ek olarak, çoklu morbiditeye sahip yaşlı yetişkinlerde semptom yükü ile sağlıkla ilişkili yaşam kalitesi arasında güçlü bir negatif korelasyon bulunduğu bildirilmiştir (Lu et al 2024). Bangshaw ve ark. (2015) 12 aylık kohort çalışmalarında kırılğan hastaların daha yaşlı, daha fazla komorbiditeye

sahip olduğunu ve hastalık şiddetinin daha yüksek olduğunu bildirmiştir. Bu durumlar ise sağlıkla ilişkili yaşam kalitelerinde önemli bir düşüş ile sonuçlanmıştır (Bangshaw et al 2015). Klompstra, Ekdahl, Krevers, Milberg ve Eckerblad (2019) multimorbiditeli hastalarda iki yıllık takip periyodunda semptom yükündeki artışın, bir yıl boyunca sağlıkla ilişkili yaşam kalitesinde azalmayla sonuçlandığını raporlanmıştır (Klompstra et al 2019). Ayrıca, bu çalışmada, çoklu hastalığı olan yaşlı bireylerde yaşam kalitesinin belirlenmesinin, sağlık hizmeti planlamasına bilgi sağlamak, hasta ihtiyaçlarını karşılamak ve yaşlı bireylerde hastalık yükünü ve sağlık hizmetlerinin kullanımını azaltmak için önemli olduğu belirtilmiştir (Klompstra et al 2019).

Benzer şekilde, kardiyometabolik bileşenlerin, düşük yaşam kalitesi , yüksek morbidite ve mortalite oranı gibi olumsuz sonuçlarla güçlü bir şekilde ilişkili olduğu gösterilmiştir (Gao et al 2021). Otieno ve ark. (2023) çalışmasında, kardiyometabolik multimorbidite varlığının ayaktan hastane ziyareti sıklığını arttırdığını ve bu hasta grubunun multimorbiditesi olmayanlara kıyasla daha düşük yaşam kalitesine sahip olduğunu raporlamıştır. Bu bulgular, kardiyometabolik multimorbiditenin yaşlı bireylerde artan hastalık yüküyle birlikte yaşam kalitesini derinden etkileyen önemli bir unsur olduğunu açıkça ortaya koymaktadır. Kardiyometabolik hastalıkların neden olduğu fizyolojik bozulmalar, fonksiyonel kısıtlılıklar ve artan semptom yükü, bireyin günlük yaşam aktivitelerine katılımını, sosyal etkileşimini ve psikolojik dengesini zayıflatmaktadır (Gao et al 2021, Otieno et al 2023). Dolayısıyla, kardiyometabolik multimorbidite yalnızca fiziksel sağlık alanında değil, aynı zamanda yaşlı bireylerin yaşam kalitesinin sosyal, ruhsal ve psikolojik boyutlarında da ciddi olumsuzluklar yaratmaktadır. Bu durum, bakım süreçlerinde, artan hastalık yükünü ve bireyin çok boyutlu ihtiyaçlarını dikkate alan bütüncül ve kişiselleştirilmiş yaklaşımların önemini daha da belirgin hale getirmektedir.

2.3. KARDİYOMETABOLİK MULTİMORBİDİTE VE KIRILGANLIK İLİŞKİSİ

Yaşlı bireylerde kırılabilirlik, olumsuz sağlık sonuçlarına karşı artan bir hassasiyet ve azalan fizyolojik rezervler ile karakterize yaygın ve zayıflatıcı bir durumdur (Clegg, Young, Iliffe, Rikkert and Rockwood 2013, Yarnall et al 2017, Vetrano et al 2019). Kırılabilirliğe katkıda bulunan temel etmenler arasında yaşlanma, kronik hastalıklar, fiziksel hareketsizlik, yetersiz beslenme ve stres yer almaktadır (Yarnall et al 2017, Vetrano et al 2019). Bu faktörler, kırılabilirliğin işlevsel kayıplara, azalmış hareketliliğe ve bağımsızlık kaybına yol açarak kısır döngü şeklinde ilerlemesine katkıda bulunmaktadır (Vetrano et al 2019). Kırılabilirlik ilerledikçe, zihinsel sağlık, fiziksel kapasite ve sosyal etkileşimlerin bozulması nedeni ile yaşam kalitesi de önemli ölçüde azalmaktadır (Renne and Gobbens 2018, Rivera-Almaraz et al 2018, Zhang et al 2018). Ayrıca, kırılabilirlik hastaneye yatış sıklığı, morbidite ve mortalite risklerinin artışı ile de yakından ilişkilidir (Renne and Gobbens 2018, Rivera-Almaraz et al 2018)

Kırılabilirlik, biyolojik olarak yaşlı bireylerin durumunda hızlı değişiklikler yaşamaya yatkınlığını tanımlamaktadır (Clegg et al 2013, Vetrano et al 2019). Literatürde, kronik hastalıkların kırılabilirliğin gelişimine katkıda bulunduğu vurgulanmaktadır (Cesari et al 2017, Vetrano et al 2019). Kronik hastalıklar, doğrudan fizyolojik kayıplara neden olmanın yanı sıra, azalmış hareketlilik veya kas kitlesi kaybı gibi dolaylı yollarla da kırılabilirliğe zemin hazırlar (Rolfson, Majumdar, Tsuyuki, Tahir and Rockwood 2006, Aygör, Fadiloğlu, Şahin, Aykar ve Akçiçek 2018). Diğer taraftan kırılabilirlik, malnütrisyon ve azalmış fiziksel aktivite gibi mekanizmalar aracılığıyla kronik hastalık gelişiminde veya kronik hastalıkların ortaya çıkışında predispozan bir faktördür (Rolfson et al 2006, Aygör ve ark 2018).

Kırılabilirlik ve multimorbidite, yaşlanma sürecinin altında yatan mekanizmaları incelemek için umut verici klinik biyobelirteçler olarak kabul edilmekte ve aralarında çift yönlü nedensel bir ilişki olduğu varsayılmaktadır (Clegg et al 2013, Cesari et al 2017, Vetrano et al 2019). Kırılabilirlik, bireyleri birden fazla kronik hastalığın gelişimine yatkın hale getirebilir (Clegg et al 2013). Aynı zamanda,

kırılganlık birden fazla hastalığın bir arada bulunmasından da kaynaklanabilir (Cesari et al 2017, Vetrano et al 2019). 48 kesitsel çalışmanın sistematik incelemesi ve meta-analizinde, 10 kırılgan yetişkinden yedisinin hastaneye multimorbidite ile başvurduğunu ve multimorbiditesi olan yetişkinlerin neredeyse beşte birinin de kırılganlıkla başvurduğu bulunmuştur (Vetrano et al 2019). Ayrıca multimorbidite kırılgan olma olasılığını neredeyse iki kat artırmaktadır (Vetrano et al 2019).

İnme, diyabet ve kalp hastalıkları gibi kardiyometabolik hastalıklar da kritik fizyolojik süreçleri bozarak fiziksel işlevdeki düşüşe önemli ölçüde katkıda bulunmaktadır (Yudkovicz et al 2021, Molsted et al 2022, Zhou et al 2025). Bu hastalıklar, inflamasyon, oksidatif stres, damar hasarı, insülin direnci, sarkopeni ve nörodejenerasyon gibi mekanizmalar aracılığıyla fiziksel kapasiteyi zayıflatmakta ve kırılganlık riskini artırmaktadır (El Assar, Laosa and Mañas 2019, Stewart 2019). Kardiyometabolik hastalıkların sayısı arttıkça, fiziksel güç ve genel dirençte ilerleyici bir azalma yaşanmakta ve kırılganlık daha belirgin hale gelmektedir (Gao et al 2021). Ma ve ark. (2023) çalışmasında, kırılganlığı kardiyometabolik multimorbiditenin ilerleyişinde bağımsız bir risk faktörü olarak tanımlanmış olup tekli hastalık, multimorbidite ve nihayetinde mortaliteye kadar olan geçişleri kolaylaştırdığını bildirmiştir. Literatürde kardiyometabolik hastalıkların yaşlı nüfusta oldukça yaygın olduğu ve kırılganlıkla güçlü bir şekilde ilişkili olduğu da ortaya konmuştur (Jia et al 2022, Wang et al 2023, Zhou et al 2025). Zhou ve ark. (2025) yaşlı bireylerde kardiyometabolik durumların sayısı arttıkça kırılganlık indeksinde önemli bir artış olduğunu, daha fazla multimorbiditenin daha şiddetli kırılganlıkla önemli bir korelasyona sahip olduğunu ortaya koymuştur. Bu bulgular, kardiyometabolik multimorbiditenin yaşlı popülasyonlarda kırılganlık üzerindeki önemli etkisini vurgulamaya hizmet etmektedir (Zhou et al 2025). Aynı zamanda, kardiyometabolik durumların sayısı arttıkça, kırılganlığın şiddetinin artmasına karşılık gelen sağlık hizmeti taleplerinin ve sağlık harcamalarının da önemli ölçüde arttığı bildirilmiştir (Gao et al 2021, Zhou et al 2025).

Bu bağlamda, söz konusu hasta grubuna yönelik tedavi ve bakım süreçlerinin, kırılganlık durumunu da dikkate alarak yapılandırılması gerektiği vurgulanmaktadır (Cesari et al 2017, Vetrano et al 2019). Kırılganlık ve kardiyometabolik multimorbidite birlikteliği, yaşlı bireylerin bakım ihtiyaçlarını

daha karmaşık ve çok boyutlu hale getirmekte; bu da hemşirelik bakımının yalnızca fiziksel değil, holistik bir yaklaşımla planlanmasını gerektirmektedir. Bu nedenle, hastaların özgün bakım gereksinimlerini karşılayacak şekilde hemşirelik bakımının kişiselleştirilerek planlanması büyük önem arz etmektedir. Böyle bir yaklaşım, kırılgan ve multimorbid yaşlı bireylerin hemşirelik bakım kalitesini arttırarak sağlık hizmetlerinin etkinliğini de güçlendirecektir.

2.4. KARDİYOMETABOLİK MULTİMORBİDİTELİ YAŞLI HASTALARDA HEMŞİRELİK BAKIM YÖNETİMİ

Yaşlı bireylerde multimorbidite yönetimi ile ilişkili sağlık hizmetlerinin sunumu, bu popülasyonun karmaşık sağlık gereksinimleri nedeniyle günümüz sağlık bakım sistemlerinin karşı karşıya kaldığı en zorlu problemlerden biridir (Van der Aa, Van den Broeke, Stronks and Plochg 2017, Eriksen et al 2022). van Oostrom ve ark. (2016) çalışmasında tek kronik hastalığı olan kişilerle karşılaştırıldığında, multimorbiditeli hastaların fiziksel işlevsellik, fonksiyonel aktiviteler ve öz-bakım faaliyetlerinde azalma ve daha fazla ağrı ve bilişsel problemler yaşadığını bildirmiştir. Koller ve ark. (2014) çalışmasında tek kronik rahatsızlığı olanlarla karşılaştırıldığında, multimorbiditesi olan yaşlı yetişkinlerin bakıma bağımlı olma riskinin daha yüksek olduğunu raporlamıştır. Bu doğrultuda, multimorbidite kavramı sağlık hizmetlerinin sunumunda, karar verme ve yönetim süreçlerinde göz önünde bulundurulması gereken önemli bir konu haline gelmiştir (Koller et al 2014, Beil et al 2021).

Literatür incelendiğinde, multimorbiditeli yaşlı hastalar ve bireysel gereksinimleri için gerekli olan holistik ve entegre bir bakımı süreci sağlamaya yönelik çalışmaların hala yetersiz olduğu vurgulanmaktadır (Haines et al 2020, Beil et al 2021). Öte yandan, multimorbidite için hastalar üzerindeki bireysel yükü ve etkiyi tanımlayan ve dolayısıyla hastalar için uygulanabilir bilgiler sağlayacak evrensel bir kavram hâlâ mevcut değildir (Aubert et al 2020, Beil et al 2021). Yalnızca kronik durumların sayısının göz önünde bulundurulması, karmaşık bakım gereksinimleri olan multimorbiditeli hastalar için basit bir kavramsal çerçeve

sunmaktadır (Aubert et al 2020, Beil et al 2021). Ancak, yaşlı hastalarda kronik hastalık sayısı, prognoz veya gereken bakım düzeyi açısından yeterli bir parametre değildir (Beil et al 2021). Bu durum, sağlık profesyonellerinin multimorbiditesi olan hastaların bakım gereksinimlerini belirleme ve önceliklendirme konusunda fikir birliğine varmasını ve bakım sürecini yönetmeyi zorlaştırmaktadır.

Multimorbiditesi olan yetişkinler için bakım gereksinimlerinin ve hastalık yönetiminin desteklenmesinde hemşirelerin merkezi konumuna rağmen, hemşirelerin rollerini tanımlayan çalışma sayısı sınırlıdır (Kivelitz et al 2021). Multimorbiditeli hastaların bakımıyla ilgili hemşirelerin algı ve inançlarına ilişkin yapılan sistematik bir incelemede 11 nitel araştırmadan elde edilen veriler rapor edilmiştir (Whitehead et al 2021). Bu çalışmada, bu nüfusa hemşirelik bakımı sağlamanın zorluğu, hemşireler arasında holistik ve birey merkezli hemşirelik bakımı sunma ihtiyacına olan güçlü inanç, terapötik bir hemşire-hasta ilişkisi geliştirmenin önemi ve mesleklerarası bakım ekibinin bir parçası olarak hemşirelik bakımı sunmanın önemi şeklinde temalar ortaya çıkmıştır (Whitehead et al 2022). Çoklu sağlık problemlerini yönetmenin karmaşıklığı ve kronik bakımın baskın tek hastalık modeli, çalışmalarda hemşireler için zorluklar olarak tanımlanmıştır (Whitehead et al 2022). Clerencia-Sierra ve ark. (2015) da mevcut sağlık sistemlerinin multimorbiditesi olan yaşlı hastaların sağlık bakım ihtiyaçlarını uygun şekilde karşılamadığını belirtmiştir. Bu durumun yaşlı hastaların yetersiz klinik değerlendirmesi tanısal ve terapötik müdahalelerin tekrarlanmasına ve hastaların kendisi için öncelikli sağlık hizmetlerinden sapmalara neden olduğu raporlanmıştır (Clerencia-Sierra et al 2015). Multimorbiditeli hasta bakımında hemşirelik rollerine ve bakım yönetimine ilişkin kanıt eksikliği, geleceğe yönelik etkili ve kaliteli bakımı optimize etmeyi amaçlayan hemşire yöneticileri, klinik hemşireleri ve politika yapıcılar için önemli bir boşluk olarak dikkat çekmektedir (Whitehead et al 2022).

Ulusal Sağlık ve Bakım Mükemmeliyeti Enstitüsü (NICE) kılavuzları, multimorbiditeyi yönetmede bireyselleştirilmiş bir değerlendirme ve gereksinimlere yönelik hastalık yönetim planının geliştirilmesini içeren bir bakım yaklaşımını savunmaktadır (Yarnall et al 2017). Bu yaklaşım ile multimorbid yaşlı hastaların bakım yaklaşımının bireysel ihtiyaçları, tedavi tercihleri, sağlık

öncelikleri ve yaşam kalitelerini dikkate almanın gerekliliği vurgulanmaktadır (Yarnall et al 2017, Aubert et al 2020, Eriksen et al 2022). NICE, bu alandaki araştırmalar için anahtar konulardan birini öncelikli bakımın organizasyonu ve bütüncül değerlendirme olarak önermiştir (Yarnall et al 2017). Multimorbiditesi olan hastalar için, özellikle de yaşlılarda, kritik bakımın uyarlanmasına ilişkin karar vermede yaşam kalitesi ve hastalık yükü, tedavi yükü gibi hasta merkezli sonuç ölçütlerinin dikkate alınması ve önceliklendirilmesi gerekmektedir (Kivelitz et al 2021). Kısa ve uzun vadeli hedefler, bireysel hasta gereksinimlerine göre belirlenmelidir (Kivelitz et al 2021). Bu doğrultuda, sağlık durumundaki akut veya subakut değişikliklerin hızlı tanı ve tedavisi, hemşirelik girişimlerinin önceliklendirmesiyle birlikte, daha fazla fonksiyonel bozulmayı ve hastaneye yatışı önleyebilir ve bakım alanların fonksiyonelliğini koruyarak uzun vadeli faydalar sağlayabilir.

Tüm bu bilgiler ışığında, hastanede tedavi gören kardiyometabolik multimorbiditeye sahip yaşlı bireylerin hemşirelik bakım süreci, yalnızca klinik semptomların yönetimini değil, aynı zamanda hastanın bütüncül ihtiyaçlarını karşılayan çok boyutlu ve kişiselleştirilmiş bakım yaklaşımlarını zorunlu kılmaktadır (Marques et al 2021, Saizen et al 2021, Whitehead et al 2022). Hemşirelerin kapsamlı geriatrik değerlendirme ile bu hastaların klinik durumlarını düzenli olarak değerlendirme ve özellikle artan semptom yükü ve kırılganlık durumunu yönetmek için sürekli gözlem ve müdahalede bulunma sorumlulukları bulunmaktadır (Ellis, Whitehead, Robinson, O'Neill and Langhorne 2011). Hastane ortamında sık karşılaşılan polifarmasi ve ilaç etkileşimleri gibi sorunlarda hemşireler aktif bir rol üstlenir, ilaçların güvenli bir şekilde uygulanmasını sağlar ve yan etkileri yakından takip eder (Maher, Hanlon and Hajjar 2014). Ayrıca, yaşlı hastaların tedavi süreçlerine uyumunu artırmak ve yaşam kalitesini yükseltmek amacıyla sürekli hasta eğitimi ve danışmanlık çalışmaları yürütür (Marques et al 2021). Etik ve hukuki sorumluluklar bağlamında ise, özellikle bilişsel gerileme ve kırılganlık durumlarında hastaların onam ve özerklik haklarını korur, yaşam sonu bakım gibi konularda profesyonel rehberlik sunar (Whitehead et al 2022). Hemşireler aynı zamanda multidisipliner ekiplerle yakın iş birliği yaparak, hastane ortamında farklı uzmanlık alanlarının katkılarını birleştirir ve entegre bakım

süreçlerinin sürekliliğini sağlar (Marques et al 2021, Saizen et al 2021). Tüm bu roller, hastanede tedavi gören yaşlı kardiyometabolik sorunları olan hastaların karmaşık bakım gereksinimlerini karşılamada hemşirenin kritik ve vazgeçilmez bir konumda olduğunu göstermektedir.

2.5. HASTA SINIFLANDIRMA SİSTEMLERİ

Hasta sınıflandırma sistemlerinin kullanımının temel amaçlarından biri, hemşirelerin dinamik ve değişken hasta bakım gereksinimlerine etkin bir şekilde yanıt verebilme kapasitesini arttırmaktır (Huckabay and Skonieczny 1981, Edwardson and Giovannetti 1994). Bununla birlikte, hasta sınıflandırma sistemleri, hemşirelik personel kaynaklarının belirlenmesi ve bu kaynakların etkin bir şekilde tahsis edilmesine yönelik bir araç olarak da işlev görmektedir (Edwardson and Giovannetti 1994, Flo, Landmark, Tønnessen and Fagerström 2019). Hasta sınıflandırma sistemleri genel olarak prototip değerlendirme sistemleri ve faktör değerlendirme sistemleri olarak iki temel kategoriye ayrılmaktadır (Flo et al 2019). Prototip değerlendirme sistemleri, belirli hasta sınıflarına özgü tipik hasta özelliklerini veya standart hemşirelik görevlerini tanımlayan sistemlerdir (Giovannetti and Johnson 1990, Brady et al 2007, Flo et al 2019). Hasta sınıflandırma sistemlerinin ilk geliştirildiği dönemde yaygın olarak kullanılan prototip değerlendirme sistemleri, günümüzde kısmen faktör değerlendirme sistemleri ile yer değiştirmiştir (Brady et al 2007, Flo et al 2019). Faktör değerlendirme sistemleri, hemşirelik bakım gereksinimlerini ve hasta özelliklerini belirleyen çeşitli kritik göstergelerin veya faktörlerin derecelendirilmesine dayanmaktadır (Brady et al 2007, Flo et al 2019).

Tam anlamıyla işlevsel bir hasta sınıflandırma sisteminin en az altı temel unsuru içermesi gerekmektedir: (1) Hastaların hemşirelik bakım gereksinimlerini bireysel tahmin edebilmek için kullanılan bir değerlendirme aracı, (2) Sağlanan bakım miktarının doğrulanmasına yönelik mekanizmalar, (3) Bakım sunum modellerinin sistematik olarak değerlendirilmesi, (4) Bakım gereksinimlerinin tekrar doğrulanması, (5) Hemşirelik bakım gereksinimlerinin personel kaynak tahsisiyle

ilişkilendirilmesi ve (6) Sistemin zaman içindeki güvenilirliğini izlemeye yönelik bir değerlendirme yöntemidir (DeGroot 1989, Flo et al 2019). Bu unsurların sistematik olarak uygulanması, hasta sınıflandırma sistemlerinin hemşirelik hizmetlerinin planlanması ve yönetimi açısından etkinliğini artırmakta, bakım kalitesinin sürdürülebilirliğini sağlamaktadır (Flo et al 2019). Flo ve ark. (2019) evde sağlık bakım hizmetlerinin sunumunda hemşirelik yoğunluğunu sınıflandırmak ve hemşirelik personeli kaynaklarını değerlendirmek için kullanılan hasta sınıflandırma sistemlerini bir kapsam inceleme çalışmasında ele almıştır. Aynı çalışmada, hastaların ihtiyaçlarının çeşitli hasta sınıflandırma sistemlerinde nasıl tanımlandığı, değerlendirildiği ve puanlandığı, arasında ne tür farklılıklar olduğu, hasta sınıflandırma sistemlerinin geçerliği ve güvenilirliği hakkında sınırlı bilgi sağlanmış olsa da yine de hastaların gereksinimlerini, iş yükünü ve personel dağılımını ölçme açısından faydalı oldukları raporlamıştır (Flo et al 2019).

Literatür incelendiğinde, hasta bağımlılığı sınıflandırması, hastalık şiddetini sınıflandırmaya yönelik sistemler, hemşirelik yoğunluğu ölçüm sistemleri gibi araçlar hastane ortamında özellikle yoğun bakım ünitelerinde kullanıldığı görülmektedir (Adomat and Hewison 2004). Bazı çalışmalarda hastaların hastalık şiddetini tahmin etmek için Akut Fizyoloji ve Kronik Sağlık Değerlendirme Skoru II (APACHE II) kullanılmış (Wright, Plenderleith and Ridley 2003, Martos-Benítez et al 2018) ve hasta sınıflandırma yönetimi uygulanmıştır. Bu sınıflandırma sistemleri hastaların bazı laboratuvar sonuçlarına, mekanik ventilasyon ve bilinç düzeyi gibi parametrelere dayalı olarak geliştirilmiştir. Ancak bu sınıflama sistemi sadece yoğun bakım hastaları için kullanılmaktadır. Multimorbid bireyler açısından sınıflandırma sistemleri incelendiğinde ise; Alonso-Morán, Nuño-Solinis, Onder ve Tonnara (2015) sistematik derleme çalışmalarında çoklu hastalığı olan yetişkin bireylerde olumsuz sağlık sonuçları riskini değerlendirmek için risk sınıflandırma araçlarını özetlemiştir. Bu çalışmada en yaygın çoklu hastalık ölçüsünün Charlson Komorbidite İndeksi olduğu bildirilmiştir. Bu indeksin birincil amacı, tek başına veya birlikte ölüm riskini değiştirebilecek kronik durumlar için prognostik bir araç oluşturmaktır. Charlson Komorbidite İndeksi prognostik tahmini sadece kronik hastalık sayısına göre yapmaktadır. Sistematik derlemede de belirtildiği gibi multimorbidite risk sınıflandırma araçlarının hastaneye kabulleri veya yeniden

hastane yatışları, sağlık hizmeti maliyetleri ve mortaliteyi tahmin etmek için kullanıldığı görülmektedir (Alonso-Morán et al 2015). Bu doğrultuda, literatürde özellikle hastanede tedavi gören kardiyometabolik multimorbiditesi olan yaşlı hastaların sınıflandırılmasına yönelik bir KKDS'nin olmadığı görülmüştür. Bu doğrultuda, bir karar destek sistemi ile benzer klinik gidişata sahip kardiyometabolik multimorbiditeli yaşlı hastalardan oluşan alt grupların belirlenerek bakım gereksinimlerinin sınıflandırılması ve bu bireylerin gereksinimlerine göre uyarlanmış kapsamlı bakımın sağlanması için hemşirelik tanımlarının belirlenmesi, verimli ve kaliteli bakım sağlamanın anahtarı olabilir.

2.6. KLİNİK KARAR DESTEK SİSTEMLERİ

Klinik Karar Destek Sistemleri, verilerin analiz edilmesi ve işlenmiş bilgilerin sunulması yoluyla karar verme süreçlerini optimize etmeyi hedefleyen bilgisayar tabanlı sistemlerdir (Berner and La Lande 2016, Sutton et al 2020). Bu sistemler, karar alma mekanizmasının yerine geçmez; aksine, karar vericilerin sezgisel ve deneyimsel yaklaşımlarını nicel verilerle destekleyerek yönetsel süreçlerde tamamlayıcı bir rol oynar (Berner and La Lande 2016, Sutton et al 2020). KKDS'leri ilk kez 1980'lerde sağlık hizmetlerinde güvenli ve etkili uygulamaları kolaylaştırmak amacıyla geliştirilmiş ve günümüzde geniş bir kullanım alanı bulan teknolojilerdir (Berner and La Lande 2016). Bu sistemlerin, sağlık hizmeti kalitesinin artırılması, hastalıkların erken teşhisi, insan hatalarının önlenmesi, maliyetlerin düşürülmesi ve hastalara en uygun tedavi seçeneklerinin sunulması gibi önemli katkıları bulunmaktadır (Berner and La Lande 2016, Sutton et al 2020).

Klinik bilgilerin artan hacmi, karmaşıklığı ve değişkenliği göz önüne alındığında, bu sistemler sağlık profesyonellerine hızlı, doğru ve etkili kararlar alma süreçlerinde önemli bir destek sunmaktadır (Padley et al 2020, Sutton et al 2020, Souza-Pereira, Ouhbi and Pombo 2021). Ayrıca, bu teknolojiler kanıta dayalı ve tutarlı klinik uygulamalara erişim sağlamada kritik bir araçtır (Padley et al 2020, Souza-Pereira et al 2021). KKDS'ler sağlık profesyonelleri tarafından çeşitli alanlarda uygulanmakta olup, iş süreçlerinin etkinliğini artırma, daha

kişiselleştirilmiş bakım sunma, bilgiye dayalı karar alma güvenliğini geliştirme, reçete yazma süreçlerini optimize etme ve gereksiz laboratuvar testleri ile görüntüleme tetkiklerini azaltma gibi katkılar sağlamaktadır (Greenes et al 2018, Muhiyaddin, Abd-Alrazaq, Househ, Alam and Shah 2020, Padley et al 2020). Multimorbid bireyler açısından KKDS'lerin kullanıldığı çalışmalar incelendiğinde ise Michel ve ark. (2008) kapsamlı ilgili bilgilerin (hasta bilgileri, hasta ilaçları, hasta laboratuvar sonuçları ve eşlik eden hastalıkları) bir özeti yoluyla pratisyen hekime rehberlik etmeyi amaçlayan ve kronik ağrı için en uygun opioid tedavisini öneren bir karar destek sistemi geliştirmiştir. Abidi, Cox, Shepherd ve Abidi (2012) doktorlara hastaların tanı ve tedavisinde yardımcı olan çoklu hastalığı olan bireyler için klinik yolları hizalayabilen bilgi merkezli bir sistem oluşturmuştur. de Wit ve ark. (2013) ilaç incelemesine odaklanan ve yaşlılar için daha güvenli bakımı desteklemeyi amaçlayan çalışmalarında elektronik reçeteleme sistemlerinden (hasta ilaçları, hastalıklar ve hasta laboratuvar sonuçlarını içeren) klinik verilerin özetlerini işleyebilen ve hemşireleri potansiyel olarak zararlı durumlar konusunda uyararak bir sistem oluşturmuşlardır. Martinez-Garcia ve ark. (2013) çoklu kronik hastalığı olan bireyler için sağlık profesyonellerine klinik uygulama kılavuzlarından ilgili bilgileri sağlayarak klinik rehberliği iyileştiren ve aynı zamanda sağlık profesyonelleri arasındaki iletişimi destekleyen bir sistem geliştirmişlerdir. Fraccaro, Casteleiro, Ainsworth ve Buchan (2015) sistematik derleme çalışmalarında multimorbiditede KKDS'lerinin kullanımı ve ne ölçüde benimsendiğini incelemiştir. Bu çalışmada, karar vericiler açısından bu sistemlerin en çok kullanıcıları pratisyen doktorlar olurken, bunu uzman doktorlar takip etmiş, hemşirelik profesyonelleri açısından ise multimorbid bireylerin bakımına yönelik bir KKDS'nin olmaması dikkat çekmiştir. Ayrıca, bu sistematik derlemede klinik kararları destekleme bilişiminde çoklu morbiditenin yeterince araştırılmadığı, çoklu hastalıkta hasta güvenliğini artırmak için hem koşulların hem de bakım süreçlerinin nasıl etkileşimde bulunduğu daha fazla kanıtı ihtiyaç olduğu ve kanıt tabanını oluşturmak için gereken verilerin birçok elektronik sağlık kayıt sisteminde mevcut olduğu ancak yeterince kullanılmadığı sonucuna varılmıştır (Fraccaro et al 2015).

2.6.1. Makine Öğrenimi Tabanlı Klinik Karar Destek Sistemleri

Klinik karar destek sistemleri, bilgi tabanlı ve bilgi tabanlı olmayan sistemler olmak üzere iki ana kategoriye ayrılmaktadır (Sutton et al 2020). Bilgi tabanlı sistemler, hasta verilerini mevcut kanıta dayalı bilgilerle eşleştirmek suretiyle önceden tanımlanmış kurallar çerçevesinde en uygun önerileri sunmaktadır (Berner and La Lande 2016). Bilgi tabanlı olmayan sistemler ise yapay zekâ (YZ) ve makine öğrenimi gibi veri odaklı yöntemler kullanarak tahminlerde bulunmakta ve karar alma süreçlerini desteklemektedir (Sutton et al 2020). YZ, insan benzeri düşünme, öğrenme ve problem çözme süreçlerini bilgisayar sistemleri aracılığıyla taklit etmeyi amaçlayan geniş kapsamlı bir teknolojik alandır (Majnarić, Babić, O’Sullivan and Holzinger 2021, Dixon et al 2024, Chaparala et al 2025). Sağlık hizmetlerinde YZ’nin giderek artan biçimde kullanılması, özellikle karmaşık ve çok boyutlu hasta verilerinin analiz edilmesi gereken durumlarda klinik karar alma süreçlerini kolaylaştırmakta ve sağlık hizmetlerinin daha etkili, hızlı ve bireyselleştirilmiş biçimde sunulmasına katkı sağlamaktadır (Majnarić et al 2021, Dixon et al 2024, Chaparala et al 2025). YZ’nin alt alanlarından biri olan makine öğrenimi, sistemlerin açık programlamaya gerek kalmadan verilerden örüntüler öğrenmesini ve bu öğrenimleri yeni durumlara uyarlayarak tahminlerde bulunmasını mümkün kılmaktadır (Majnarić et al 2021, Khalifa, Albadawy and Iqbal 2024). Gözetimli, gözetimsiz ve pekiştirmeli öğrenme gibi alt başlıklara ayrılan makine öğrenimi yöntemleri, özellikle sağlık verilerinin analizinde öne çıkmakta; hastalık risklerinin belirlenmesi, tıbbi tanılarının desteklenmesi, tedavi sonuçlarının tahmin edilmesi ve hasta sonuçlarının optimize edilmesi gibi birçok alanda uygulanmaktadır (Majnarić et al 2021, Khalifa et al 2024).

Makine öğrenimi tabanlı KKDS’ler elektronik sağlık kayıtları, laboratuvar sonuçları, yaşamsal bulgular ve hasta beyanı gibi çeşitli veri türlerini analiz ederek sağlık profesyonellerine anlamlı ve veri temelli geri bildirimler sunmayı amaçlamaktadır (Varghese, Kleine, Gessner, Sandmann and Dugas 2018, Choudhury et al 2020). Makine öğrenimi tabanlı KKDS’ler, klinik karar sürecini kolaylaştırmakta aynı zamanda belirsizliği azaltarak daha güvenilir ve kanıta dayalı kararların alınmasına yardımcı olmaktadır. Özellikle hemşireler, elektronik tıbbi kayıtların mevcudiyeti göz önüne alındığında, makine öğrenimi tabanlı KKDS’ler

ile hasta verilerini inceleyerek ve bilinmeyen bilgileri keşfederek hemşirelik planlarını kademeli olarak geliştirebilecek içgörüler elde etmek için hasta düzeyinde yeni veriler elde edilebilir ve analiz edilebilir (An et al 2021). Hossain, Sharma, Sultana, Tasnim ve Faizah (2020) tarafından belirtildiği üzere, YZ destekli KKDS'ler, özellikle karmaşık hasta bakımında hemşirelik uygulamalarını kolaylaştırmakta; görevlerin bir kısmını otomatikleştirerek hemşirelerin klinik karar alma sürecine daha fazla odaklanmasını sağlamaktadır. Bu teknolojilerin hasta başı karar desteği sunması, yanlış teşhis risklerini azaltmakta ve erken müdahale olanaklarını artırarak hasta bakım sonuçlarını olumlu yönde etkilemektedir (Singh and Nashwan 2025).

Makine öğrenimi tabanlı KKDS'lerin yaşlı ve multimorbid bireylerde kullanımı son yıllarda artış göstermektedir; ancak bu alandaki uygulamalar halen sınırlı ve çoğunlukla gelişim aşamasındadır. Yapılan çalışmalar, makine öğrenimi tabanlı modellerin yaşlı bireylerde komplikasyon riskini öngörme, hastane yeniden yatış olasılığı, mortalite riski ve ilaç yönetimi gibi durumlarda kullanıldığını ortaya koymaktadır (Varghese et al 2018, O'Connor 2022, Moghadam et al 2024, Singh and Nashwan 2025). Choudhury ve ark. (2020), özellikle YZ sistemlerinin kronik hastalıklar için geriatrik klinik bakımda mevcut kullanımını inceledikleri sistematik derlemede, dahil ettikleri hiçbir çalışmada kişiselleştirilmiş bakım sağlayabilen makine öğrenimi modellerinin geliştirilmemiş veya uygulanmamış olduğunu ve hasta sağlık durumundaki değişkenliklerin dikkate alınmadığını raporlamıştır. Ayrıca, makine öğrenimi kullanılan çalışmaların çoğunda tanıların ikili sınıflandırma düzeyine indirildiği ancak kronik hastalıkların bir arada bulunabileceği multimorbidite durumunun ya da hastalıkların farklı şiddet derecelerinde seyredebildiği gerçeğinin göz ardı edildiği bildirilmiştir (Choudhury et al 2020). Bu doğrultuda, makine öğreniminin geriatrik klinik bakımı iyileştirmeye yardımcı olup olamayacağını doğrulamak için sağlık hizmetleri uygulamalarına göre uyarlanmış daha fazla çalışmaya ve multimorbid yaşlı hastalarda standartlaştırılmış makine öğrenimi uygulamalarına ihtiyaç olduğu açıktır (Choudhury et al 2020). Damoiseaux-Volman ve ark. (2021) yaşlı hastanede yatan hastalarda KKDS müdahalelerinin etkilerini ele aldıkları sistematik derlemede, ilaç incelemesi, düşmeler, deliryum, taburcu olma veya sonrasında

bakım, işlevsel azalma ve basınç yaralanmalarına odaklanan 18 farklı KKDS müdahalesi tanımlamıştır. Bu KKDS müdahalelerinin %72'si hastane süreçleriyle ilgili olarak geriatrik bakımı etkili bir şekilde iyileştirmiştir. Ancak, geriatri alanındaki literatür, hasta özelliklerinin heterojenliği ve yaşlı bireylerin klinik araştırmalarda yetersiz temsil edilmesi nedeniyle sıklıkla daha düşük düzeyde kanıt içermektedir (Varghese et al 2018, Damoiseaux-Volman et al 2021). Bu durum, KKDS temelini oluşturan klinik bilginin de daha düşük düzeyde kanıta dayanmasına neden olmaktadır. Oysa, KKDS'nin etkinliğinde belirleyici olan en önemli unsurlardan biri klinik bilginin niteliğidir (Varghese et al 2018). Bahsedilen sistematik derlemede dahil edilen çalışmaların hiçbirinde tahmin modelleri veya makine öğrenimi temelli klinik bilgi tanımlanmamış ve veri odaklı bir KKDS kullanılmamıştır (Damoiseaux-Volman et al 2021). Bununla birlikte, mevcut sistemlerin çoğu hekim merkezli kararları hedeflemekte olup, hemşirelik bakımı bağlamında, özellikle hemşirelik tanımlarını desteklemeye yönelik örnekler oldukça sınırlıdır. Bu durum, hemşirelerin çok boyutlu klinik verilerle çalışırken karar verme süreçlerinde karşılaştıkları belirsizlikleri aşmalarına yardımcı olacak, açıklanabilir ve pratik araçlara duyulan ihtiyacı açıkça ortaya koymaktadır.

2.7. ARAŞTIRMANIN HEMŞİRELİK AÇISINDAN ÖNEMİ

Makine öğrenimi tabanlı KKDS'ler, multimorbid hastaların bakımında çoğunlukla tıbbi tanıların doğrulanması, komplikasyonların öngörülmesi veya risk sınıflamalarının yapılması amacıyla geliştirilmiş ve bu yönüyle genellikle hekimlere yönelik karar destek süreçlerinde yoğun biçimde incelenmiştir (Dixon et al 2024, Singh and Nashwan 2025). Ancak, hemşirelik bakım sürecinin ayrılmaz bir parçası olan hemşirelik tanımlarının sistematik biçimde desteklenmesi amacıyla YZ teknolojilerinin kullanımı oldukça sınırlıdır (Dixon et al 2024, Singh and Nashwan 2025).

Hemşirelik tanımları, bireylerin, ailelerin veya toplumların yaşadığı mevcut ya da potansiyel sağlık sorunlarına ya da yaşam süreçlerine ilişkin olarak hemşirelerin vardığı klinik yargılardır (de Carvalho et al 2018, Nishi, Kashiwagi, Yokota, Ishii

and Miyo 2025). Bakım planlarının oluşturulması, uygulanması ve değerlendirilmesinde hemşirelik tanıları temel alınmakta; böylece hasta güvenliği ve bakım kalitesinin artırılmasına yönelik daha hedefli planlamaların yapılması sağlanmaktadır (de Carvalho et al 2018, Nishi et al 2025). Hemşirelik tanıları; bireyi çok boyutlu olarak değerlendirmeyi gerektirir ve bu yönüyle makine öğreniminin çok değişkenli veri analiz gücünden yararlanılabilecek uygun bir uygulama alanı sunmaktadır (Nishi et al 2025). Hemşirelik sürecinin ilk ve en kritik adımı olan tanılama evresi, klinik gözlem, fizyolojik bulgular ve fonksiyonel değerlendirme gibi çoklu bilgi kaynaklarını birleştirmeyi gerektirmektedir. Özellikle hastanede yatan kardiyometabolik multimorbiditeye sahip yaşlı bireylerin karmaşık bakım gereksinimlerinin belirlenmesi ve sınıflandırılması, hemşirelerin klinik gözlemlerinin yanı sıra hasta merkezli, bütüncül ve kişiselleştirilmiş bir yaklaşımı da zorunlu kılmaktadır. Son yıllarda, hemşirelik kayıtlarıyla makine öğrenimi ve derin öğrenme uygulamalarını entegre etmeye yönelik çeşitli çalışmalar yapılmış olsa da doğrudan hemşirelik tanıların tahmini ya da seçimine odaklanan araştırmalar sınırlı sayıdadır. Daha önceki bazı girişimler, bilgisayar destekli sistemler aracılığıyla hemşirelik tanı sürecini iyileştirmeyi amaçlamışlardır ancak, bu sistemler genellikle kapsamlı bilgi tabanlarına ve yoğun insan emeğine ihtiyaç duymuş; ayrıca mevcut klinik verilerle çalışan uygulamalara yeterince yer verilmemiştir. Bu eksiklikler doğrultusunda, bu tez kapsamında geliştirilen makine öğrenimi tabanlı KKDS, geriatrik bakımda çok boyutlu klinik verileri kullanarak hemşirelik tanı sürecine sistematik, ölçeklenebilir ve açıklanabilir bir katkı sunmayı hedeflemektedir. Bu nedenle, geliştirilecek KKDS'nin kardiyometabolik multimorbiditeli yaşlı hastaların hemşirelik bakım gereksinimlerini ve tanılanabilir özelliklerini belirlemeye odaklanması hem literatürdeki boşluğu doldurmakta hem de hemşirelik pratiğinde bütüncül bakım kararlarını desteklemektedir.

Bu amaçla geliştirilen bir makine öğrenimi tabanlı KKDS doğrudan hastanelerin elektronik bilgi sistemine entegre edilebilir. Bu KKDS'yi kullanırken, hemşireler kardiyometabolik multimorbiditeli yaşlı hastaların karmaşık bakım gereksinimleri ile ilgili herhangi bir endişe duymadan, doğru hasta sınıflandırmasını kolaylıkla elde edebilir ve bakımını bu sınıflandırmaya göre planlayarak önceliklendirebilirler. Hemşirelik yöneticileri, bilimsel olarak test edilmiş bir klinik

KKDS kullanarak, hasta bakımını optimize etme konusunda hastaların ihtiyaçlarını belirleyip önceliklendirerek kliniklerdeki hemşire sayısını, özellikle de gece nöbetlerindeki hemşire sayılarını etkin bir şekilde belirleyerek hemşirelik kaynaklarını verimli bir şekilde yönetebilir. Bu durum, karmaşık bakım gereksinimi olan yaşlı ve multimorbid hastalara bakım sağlayan hemşirelerin fiziksel ve zihinsel yorgunluklarının azalması ve böylece hemşirelik bakım kalitesinin de artmasına yol açabilir. Ayrıca, KKDS'ler hemşirelerin hasta özelliklerine ve hasta durumundaki değişikliklere göre bireyselleştirilmiş bir hemşirelik bakım planı geliştirmelerine, temel göstergelerdeki değişiklikleri izlemelerine, eleştirel ve bağımsız düşünmelerini teşvik etmelerine ve sorunları zamanında çözmelerine yardımcı olabilir. Dolayısıyla, hastanede yatan kardiyometabolik multimorbiditeli yaşlı hastalarda, bakım gereksinimlerinin sistematik olarak belirlenmesi ve sınıflandırılması; yalnızca bireyselleştirilmiş bakım planlarının oluşturulmasına değil, aynı zamanda klinik karar alma süreçlerinin bilimsel temellere dayandırılmasına ve hasta merkezli bakımın etkin bir şekilde yürütülmesine olanak sağlayabilir. Bu süreç, yaşlı bireylerin yaşam kalitesini desteklerken, sağlık hizmetlerinin kalitesinin ve etkinliğinin de güçlenmesine katkı sunabilir.

3. GEREÇ VE YÖNTEM

3.1. ARAŞTIRMANIN AMACI VE TİPİ

Bu araştırmada kardiyometabolik multimorbiditeli yaşlı hastaların bakım gereksinimlerini sınıflandırmaya ve hemşirelik tanılarını belirlemeye yönelik makine öğrenimi tabanlı KKDS geliştirilmesi amaçlanmıştır. Üç aşamada gerçekleştirilen araştırmanın birinci aşamasında KKDS'ye yönelik ihtiyaç analizi için hemşireler ile nitel görüşmeler yapılmış, ikinci aşamada “KM-SŞÖ” geliştirilerek geçerlik güvenirliği gerçekleştirilmiş ve son aşamada ise makine öğrenimi tabanlı KKDS geliştirilmiştir.

3.1.1. Araştırmanın Hipotezleri

Birinci Hipotez

Hipotez (H1₀): Türk toplumunda geliştirilen Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ) geçerli ve güvenilir bir ölçek değildir.

Hipotez (H1₁): Türk toplumunda geliştirilen Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ) geçerli ve güvenilir bir ölçektir.

İkinci Hipotez

Hipotez (H2₀): Geliştirilen makine öğrenimi tabanlı KKDS kardiyometabolik multimorbiditesi olan yaşlı hastalarda bakım gereksinimlerini sınıflandırma ve hemşirelik tanılarını belirlemede geçerli ve güvenilir bir yöntem değildir.

Hipotez (H2₁): Geliştirilen makine öğrenimi tabanlı KKDS kardiyometabolik multimorbiditesi olan yaşlı hastalarda bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını belirlemede geçerli ve güvenilir bir yöntemdir.

3.2. ARAŞTIRMANIN ETİK YÖNÜ

Araştırmaya başlamadan önce nitel aşama (E-71522473-050.01.04-318591-385, 28.12.2023) ve ölçek geliştirme (E-71522473-050.01.04-318591-384, 28.12.2023) aşamaları için Sakarya Üniversitesi Tıp Fakültesi Girişimsel Olmayan Etik Kurulu'ndan onay alınmıştır (Ek 1), (Ek 2). KKDS geliştirilmesi aşamasının yürütülmesi için ise Sakarya Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu'ndan Etik Kurul Onayı (E-16214662-050.01.04-319658-190, 22.12.2023) alınmıştır (Ek 3). Etik kurul izinleri alındıktan sonra Sakarya Eğitim Araştırma Hastanesinde araştırmanın yürütülebilmesi için Başhekimlikten ve İl Sağlık Müdürlüğünden kurum izni alınmıştır (Ek 4). Kurum izni alındıktan sonra araştırma kapsamına dahil edilen tüm bireyler için gönüllülük ilkesi esas alınmıştır. Katılımcılara araştırmanın amacı, aşamaları, faydaları ve araştırma için toplanan bilgilerin gizliliği hakkında açıklama yapılarak tüm katılımcılardan yazılı ve sözlü onam alınmıştır.

3.3. BİRİNCİ AŞAMA: HEMŞİRE GÖRÜŞLERİNE İLİŞKİN NİTEL ÇALIŞMA

Bu araştırmanın ilk aşaması nitel araştırma olarak tasarlanmıştır. Bu aşamada, kardiyometabolik multimorbiditesi olan yaşlı hastalara bakım veren hemşirelerin, bu hastaların bakım ihtiyaçlarını sınıflandırmaya ve hemşirelik tanımlarını belirlemeye yönelik geliştirilmesi planlanan makine öğrenimi tabanlı KKDS'ye ilişkin düşünceleri, algıları ve ihtiyaçlarının belirlenmesi amaçlanmıştır. Ayrıca, kardiyometabolik multimorbiditesi olan yaşlı yetişkinlere bakım verirken hemşirelerin yaşadıkları deneyimlerin incelenmesi, klinik ortama entegre

edilebilecek bir KKDS'nin tasarımı için de başlangıç noktası oluşturabilir. Bu doğrultuda, bu aşamada nitel betimleyici araştırma deseni kullanılmıştır. Bu desen, kardiyometabolik multimorbiditesi olan yaşlı hastalara bakım veren hemşirelerin deneyimlerini ve bir KKDS'ye yönelik algılanan ihtiyaçlarını anlatı tarzındaki veriler aracılığıyla tematik olarak analiz etmeye olanak tanımıştır (Bradshaw, Atkinson and Doody 2017). Nitel betimleyici desen, belirli olgu ya da yaşantılardan ortaya çıkan ihtiyaçlarla ilgili durumu saptarken katılımcıların deneyimlerini açık ve erişilebilir bir biçimde ortaya koymaktadır (Bradshaw et al 2017).

3.3.1. Araştırmanın Yapıldığı Yer ve Zaman

Sakarya Eğitim Araştırma Hastanesi iç hastalıkları, kardiyoloji ve nöroloji servisleri ile dahiliye ve nöroloji-inme yoğun bakım ünitelerinde çalışan hemşireler ile Eylül-Ekim 2024 tarihleri arasında veriler toplanmıştır.

3.3.2. Araştırmanın Örneklemi

Araştırmanın bu aşamasında amaçlı örnekleme yöntemine bağlı olarak maksimum çeşitlilik örnekleme stratejisi kullanılmıştır. Amaçlı örnekleme, incelenen olgu hakkında özellikle bilgili veya deneyimli olan bireylerin ya da grupların seçilmesini içermektedir (Patton 2015). Bilgi ve deneyimin yanı sıra, katılımcıların gönüllü olmaları ve deneyimlerini iletmede açık, yansıtıcı bir tutum sergilemeleri de önemli seçim kriterleri arasındadır (Patton 2015, Palinkas et al 2015). Bu bağlamda, katılımcılar arasında klinik geçmiş, mesleki deneyim yılı ve bakım ortamı açısından çeşitliliği sağlamak amacıyla maksimum çeşitlilik örnekleme benimsenmiştir. Bu strateji, kardiyometabolik multimorbiditesi olan yaşlı yetişkinlerin yönetimine ilişkin klinik zorlukları ve sistem gereksinimlerini kapsayan çok yönlü bir anlayış geliştirmeyi ve bakım deneyimleri ile algılanan ihtiyaçların geniş bir yelpazesini yakalamayı hedeflemiştir (Palinkas et al 2015).

Araştırmanın örnekleme, dahil edilme kriterlerini karşılayan hemşirelerden oluşmuştur: (1) aktif olarak yaşlı kardiyometabolik multimorbid hastalara bakım vermek, (2) iletişim engelinin bulunmaması ve (3) çalışmaya katılmaya gönüllü olmaktır. Nitel araştırmalarda örneklem sayısının ideal sayıya ulaşması verilerin doyuma ulaşmasıyla oluşan tekrarlanma döngüsüne bağlıdır (Merriam 2018). Tekrarlanma döngüsünde, yinelemenin ilk gerçekleştiği anda veri toplamanın

durdurulması gerektiği belirtilmektedir (Onwuegbuzie and Collins 2007). Bu bağlamda, veri toplama süreci, nitel veri doygunluğuna ulaşılan kadar devam etmiştir ve bu doygunluk 20 katılımcıyla görüşmeler yapıldıktan sonra sağlanmıştır.

3.3.3. Araştırmanın Veri Toplama Süreci

Araştırmacılar tarafından literatür doğrultusunda hazırlanan yarı yapılandırılmış görüşme formu uzman görüşüne gönderilmiştir. Uzman görüş ekibi, iç hastalıkları hemşireliği alanında uzman bir Profesör Doktor ve iki Doçent Doktor ile nitel çalışmaları bulunan bir Profesör Doktor ve bir Doçent Doktordan oluşmaktadır. Uzman görüşü sonrasında gerekli revizyonlar yapılmış ve bir hemşire ile pilot çalışma yapılarak görüşme formu son haline getirilmiştir. Formda toplam beş açık uçlu soru bulunmaktadır. Form kardiyometabolik multimorbiditeli hastalara yönelik bakım süreçleri, bakım gereksinimlerinin nasıl önceliklendirdiği, bir karar destek sisteminin geliştirilmesinin gerekliliği ve bu sistemlerin hemşirelik tanımlarının belirlenmesindeki potansiyel katkılarına odaklanmıştır (Ek 5).

Görüşme başlamadan önce katılımcılara araştırma protokolü hakkında ön bilgi verilmiş ve gönüllü katılımcılar için uygun bir görüşme tarih ve saati belirlenmiştir. Belirlenen gün ve saatte, öncelikle katılımcılara literatür doğrultusunda hazırlanan "Kişisel Bilgi Formu"ndaki (yaş, cinsiyet, eğitim düzeyi, çalışılan klinik, çalışma yılı ve bir şifftte bakılan hasta sayısı) sorular yöneltilmiştir (Ek 5). Ardından, klinik karar destek sisteminin geliştirilmesiyle ilgili bakış açılarına yönelik derinlemesine bire-bir yüz-yüze nitel görüşmeler yapılmıştır. Görüşmeler 15-40 dakika arasında sürmüştür.

3.3.4. Araştırmanın Etik Yönü

Bu çalışmanın güvenilirliğini sağlamak için Lincoln ve Guba'nın (1991) güvenilirlik kriterlerinden, güvenilirlik, aktarılabilirlik, bağımlılık ve teyit edilebilirlik ilkelerinden yararlanılmıştır. Verilerin güvenilirliğini artırmak için katılımcılara görüşmeler sırasında isimleriyle hitap edilmemiştir. Bunun yerine, katılımcıların gizliliğini korumak amacıyla "P1, P2, ... P20" gibi kodlar kullanılmıştır. Görüşmeleri gerçekleştiren araştırmacı ile katılımcılar arasında herhangi bir tanışıklık yoktur. Araştırmacı, görüşmeler sırasında katılımcıları dikkatle ve önyargısız bir şekilde dinlemiş, yargılayıcı bir tutum sergilememiştir.

Katılımcıların yanıtları daha net ve ayrıntılı bilgi elde edebilmek amacıyla detaylı bir şekilde sorgulanmıştır. Tüm veriler, şifre korumalı bilgisayar dosyalarında saklanmıştır.

3.3.5. İstatiksel Analizi

Araştırmada nitel veriler Braun ve Clarke'ın (2006) tematik analiz yaklaşımı ile analiz edilmiştir. Veri analizi, ilk görüşmeden kısa bir süre sonra kaydedilen ses kayıtlarının Google docs aracılığıyla doğrudan bilgisayara yazılmasıyla başlamıştır. Kişisel tanımlayıcı veriler kaldırılarak ve sıralı tanımlama numaraları atanarak görüşmeler anonimleştirilmiştir. Transkribe edilen veri kümeleri, nitel veri organizasyonunu ve kodlamayı destekleyen bir yazılım olan Max Qualitative Data Analysis (MAXQDA) Analytics Pro2022'ye aktarılmıştır. Bir sonraki adımda, açık veri kodlaması, verileri satır satır dikkatlice okuyarak, her kelimeyi, ifadeyi veya paragrafı çalışmanın amacına uygun şekilde çıkarıp kodlayarak devam etmiştir. Kategorizasyon aşamasında, kodlar tutarlı bir şekilde karşılaştırılmış ve farklılıkları ve benzerlikleri de dahil olmak üzere bağılıklarına göre sıralanmıştır. Kodlar daha sonra alt kategorilere ayrılarak sıralanmış ve daha az sayıda, daha kapsamlı kategoriler halinde birleştirilmiştir. Birinci araştırmacı (MGE) kodlamayı ve ilk kategorizasyonu bağımsız olarak yapmış ve ikinci araştırmacı (HS) doğrulamayı ve değişiklik önerilerini yapmıştır. Bu yinelemeli süreç yeni kod veya kategori eklenemeyene kadar devam etmiştir. Metodolojik olarak verilerin analizinde tümevarımsal kodlama izlenmiştir. Tüm temalar ve alt temalar tanımlanmış, tartışılmış ve fikir birliğine varılarak son kodlama şeması yazarlar tarafından oluşturulmuştur. Temalar ve alt temalar araştırma dışından üç uzmana görüş için gönderilmiş ve revize edilerek son hali verilmiştir.

3.4. İKİNCİ AŞAMA: KARDİYOMETABOLİK MULTİMORBİDİTELİ HASTALARDA SEMPTOM ŞİDDETİ ÖLÇEĞİNİN (KM-SSÖ) GELİŞTİRİLMESİ, GEÇERLİK VE GÜVENİRLİK ÇALIŞMASI

Araştırmanın metodolojik tasarımıdaki ikinci aşamasında KKDS geliştirilmesinde bir öznitelik olarak kullanılan semptom şiddetini belirlemeye yönelik “KM-SSÖ” geliştirilmiş ve geçerlik ve güvenirlik çalışması yapılmıştır.

3.4.1. Araştırmanın Yapıldığı Yer ve Zaman

Araştırmanın bu aşaması Sakarya Eğitim Araştırma Hastanesi iç hastalıkları, kardiyoloji ve nöroloji-inme servislerinde yatan hastalar ile Ağustos-Kasım 2024 tarihleri arasında gerçekleştirilmiştir.

3.4.2. Araştırmanın Örneklemi

Çalışmanın yapıldığı kliniklerde kardiyometabolik multimorbidite tanısı ile takip edilen ve yatarak tedavi alan hastalar çalışmanın evrenini oluşturmuştur. Araştırmanın örneklemine (1) 65 yaş üzeri, (2) en az iki tane kardiyometabolik hastalık (KKH, HT, DM, inme ve dislipidemi) tanısı olan, (3) sözel iletişim kurulabilen, (4) çalışmaya katılmaya gönüllü bireyler dahil edilmiştir. Bu araştırmada amaçlı örnekleme yöntemi kullanılmıştır. Literatürde, ölçek geliştirme çalışmasında önerilen örneklem büyüklüğü, ölçeğin maddeleri, faktör sayısı ve yönteme bağlı olarak değişmektedir. Yaygın olarak önerilen bir yaklaşım, her bir madde için en az 5-10 katılımcının seçilmesidir (Thorndike 1995).

Açımlayıcı faktör analizi (AFA) için önerilen minimum örneklem büyüklüğü 100 katılımcı ve ideal olarak 150-400 katılımcı arasında değişmekte olup (Memon et al 2020) doğrulayıcı faktör analizi (DFA) için gereken örneklem büyüklüğünün 100-200 katılımcı olması gerektiği bildirilmektedir (Kyriazos and Poga-Kyriazou 2023). Bu bağlamda, bu çalışma 388 hasta ile yürütülmüştür. Veri toplama süreci tamamlandıktan sonra, toplam örneklem (N=388) faktör analizi için rastgele iki bağımsız alt örneğe ayrılmıştır. Bu rastgele dağıtım, analiz aşamasında SPSS'in rastgele sayı üretici işlevi kullanılarak gerçekleştirilmiştir. Alt örneklem 1 (n=200) AFA için ve Alt örneklem 2 (n=188) DFA için kullanılmıştır.

3.4.3. Araştırmanın Veri Toplama Süreci

Veriler “Hasta Bilgi Formu” ve “KM-SŞÖ” aracılığıyla toplanmıştır. Ölçeğin yapı geçerliliği AFA ve DFA ile değerlendirilmiş, ölçüt geçerliliği için “EQ-5D-3L Genel Yaşam Kalitesi Ölçeği” kullanılmıştır (Ek 6).

3.4.3.1. Hasta bilgi formu

Araştırmacılar tarafından geliştirilen hasta tanımlama formunda sosyo-demografik özellikler (yaş, cinsiyet, eğitim durumu, sigara ve alkol kullanımı) ile hastalıkların tanısına ilişkin bilgileri içeren (KKH, DM, HT, inme ve dislipidemi varlığı ve tanı süreleri, son bir yıl içinde hastaneye yatış) toplam 11 soru yer almıştır.

3.4.3.2. Kardiyometabolik multimorbiditeli hastalarda semptom şiddeti ölçeği (KM-SŞÖ)

Araştırmacılar tarafından geliştirilen ölçek, en az iki tane kardiyometabolik hastalığı olan yaşlı bireylerde ortak görülen semptomların şiddetini değerlendirmeyi amaçlayan tek boyutlu ve 25 maddeden oluşmaktadır. Ölçekte yer alan 25 maddenin her biri, 0 (Hiç) ile 4 (Çok şiddetli) arasında derecelendirilen 5’li Likert tipi bir ölçekle değerlendirilmektedir. Toplam puan, tüm madde puanlarının toplanmasıyla elde edilir ve 0 ile 100 arasında değişen bir toplam skora ulaşılır. Hiçbir madde ters kodlama gerektirmemektedir. Maksimum olası puan 100 olduğu için, ek bir puan dönüşümüne ihtiyaç duyulmamaktadır. Elde edilen toplam puanın yüksek olması, birden fazla kardiyometabolik hastalığı bulunan bireylerde semptom şiddetinin daha fazla olduğunu göstermektedir.

3.4.3.3. EQ-5D-3L Genel yaşam kalitesi ölçeği

Bu ölçek genel sağlık durumunu ve yaşam kalitesini değerlendirmek için kullanılmaktadır. EuroQol grubu tarafından 1987’de geliştirilmiş olup, Türkçe geçerlik ve güvenirlik çalışması Kahyaoğlu Süt ve Ünsar (2009) tarafından yapılmış ve Cronbach alfa katsayısı 0,860 olarak bulunmuştur. Ölçek EQ-5D-3L indeks ölçeği ve EQ-5D-3L Visual Analog Skalası (VAS) olmak üzere iki bileşenden oluşmaktadır. EQ-5D-3L indeks ölçeğinin, hareket, öz-bakım, günlük aktiviteler, ağrı/rahatsızlık ve endişe/depresyon olmak üzere beş boyutu bulunmaktadır (Rabin and Charro 2001). Yanıtlar "problem yok", "biraz problem

var" ve "majör problem var" şeklinde sınıflandırılmaktadır (Rabin and Charro 2001). Skor, -0,59 ile 1 arasında değişmekte olup, 0 ölümü, 1 kusursuz sağlığı, negatif değerler ise kötü sağlık durumlarını temsil etmektedir. EQ-5D VAS ise bireylerin öznel sağlık algısını niceliksel olarak belirlemek amacıyla mevcut sağlık durumlarını 0-100 arasında değerlendirdikleri görsel analog bir ölçektir (Rabin and Charro 2001, Kahyaoğlu Süt ve Ünsar 2009).

3.4.4. Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti

Ölçeğin Geliştirilme Aşamaları

Ölçeğin geliştirilmesi tasarım, pilot uygulama ve uygulama aşamaları olmak üzere üç adımda gerçekleştirilmiştir (Şekil 1). Geliştirilen ölçeklerin ölçülmek istenen özelliğe uygun olup olmadığını, ölçümün kurallara uygun olarak yapıp yapılmadığını ve ölçüm verilerinin ölçülmek istenen özelliği yansıtmayı yansıtmadığını belirlemek amacıyla geçerliliği ve güvenilirliği incelenmiştir.

Tasarım Aşaması	Pilot Uygulama Aşaması	Uygulama Aşaması
• Kapsamlı literatür taraması • Hasta ve servislerdeki hemşirelerle ön görüşme • Ölçeğin amacı doğrultusunda madde havuzunun oluşturulması • Taslak ölçeğin uzman görüşüne sunulması • Taslak ölçeğe uzman görüşüne göre son hal verilmesi	• 10 hasta ile pilot çalışma gerçekleştirilmesi • Ölçeğin anlaşılabilirliği, okunabilirliği ile ilişkili olumsuz geribildirim alınmamıştır. • Bu hastalar ana örnekleme dahil edilmemiştir.	• <u>Geçerlilik Kapsamında;</u> ➢ Açıklayıcı faktör analizi ➢ Doğrulamalı faktör analizi • <u>Güvenirlilik Kapsamında;</u> ➢ Cronbach's Alpha değeri ➢ Benzer test ilişkisi

Şekil 1: Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ)'nin Geliştirilmesi Aşamaları

3.4.4.1. Tasarım aşaması

Araştırmacılar tarafından ölçek geliştirmeye yönelik literatür taraması ve kardiyometabolik hastalara bakım veren hemşireler (5 hemşire) ve yatarak tedavi gören hastalar (5 hasta) ile ön görüşmeler yapılarak hazırlanan kardiyometabolik multimorbiditeli hastaların ortak semptomlarına yönelik madde havuzu oluşturulmuştur.

Ölçek geliştirme çalışmalarında örneklemeden veri toplanmadan önce taslak ölçeğin, yüzey ve kapsam geçerliğinin sağlanması gerekmektedir. Bu nedenle araştırılan konu hakkında deneyim sahibi olan uzman kişilerden görüş alınması önerilmektedir (Kishore, Jaswal, Kulkarni and De 2021). Taslak madde havuzu (25 madde) uzmanlara e-posta aracılığıyla gönderilmiştir. Araştırmada daha önce ölçek geliştirme çalışması yapmış ve kardiyometabolik hastalıklar ile ilgili çalışmaları olan, alanında uzman üç doktor ve 12 hemşire akademisyen olmak üzere toplam 15 uzmandan görüş alınmıştır (Ek 7). Ölçek maddelerinin içeriğinin oluşturulmasında yer alan uzmanların her bir maddeyi uygunluğu ve anlaşılabilirliği açısından değerlendirmesi istenmiştir. Davis tekniğine göre her bir ifadeyi 1-4 puan (1 puan: uygun değil, 2 puan: biraz uygun, 3 puan: uygun, 4 puan: tamamen uygun) arasında puanlamaları ve her bir maddeye ilişkin görüş ve önerilerini açıkça yazmaları istenmiştir. Uzman görüşlerinin değerlendirilmesinde kapsam geçerlilik indeksi (Content Validity Index-KGİ) kullanılmıştır. Bu indeksten her bir madde için uzmanların o maddeyi gerekli görüp görmediklerinin belirlenmesinde yararlanılmaktadır (Boateng, Neilands, Frongillo, Melgar-Quinonez and Young 2018, Kishore et al 2021).

Birinci etap uzman görüşü sonrası Davis yöntemine göre KGİ hesaplanmış ve yutma güçlüğü ve bulantı maddeleri $KGİ=0,73$ olduğundan çıkarılmıştır. Nicel değerlendirmenin ötesinde, uzman paneli her bir maddenin klinik önemini de göz önünde bulundurmuştur. Bulantı, yalnızca düşük KGİ puanı nedeniyle değil, aynı zamanda kardiyometabolik durumlarla güçlü bir ilişkisi bulunmayan, özgül olmayan bir semptom olarak değerlendirilmesi nedeniyle de dışlanmıştır. Yutma güçlüğü ise, bazı popülasyonlarda klinik olarak anlamlı olmakla birlikte, bir semptomdan ziyade inme sonrası gelişen bir sekel olarak sınıflandırılmış ve bu nedenle semptom şiddet ölçeğine dahil edilmesi uygun bulunmamıştır.

Uzmanlardan gelen yorumlar ışığında ölçek maddeleri revize edilmiş ve iki madde (Uykuya dalma/sürdürme güçlüğü ve Kaygı/endişe hissi) eklenmiştir. Eklenen soru olması nedeniyle 25 maddeden oluşan taslak ölçek yeniden uzman görüşüne gönderilmiş ve beş uzman tarafından değerlendirilmiştir. İkinci etap uzman değerlendirmesi sonrası KGİ yine Davis yöntemi kullanılarak hesaplanmış ve 0,80'in altında kalan madde olmadığından herhangi bir madde çıkarılmamıştır.

3.4.4.2. Pilot uygulama aşaması

İkinci uzman görüşü sonrası 25 maddeden oluşan taslak ölçek ile pilot uygulama yapılmıştır. Ölçek son şekli ile araştırmacı tarafından 10 hastaya uygulanmış ve hastaların ölçek maddelerini “düzgünlük, anlamlılık, okunurluk, terimlerin anlaşılabilirliği, anlamın açıklığı ve netliği yönünden değerlendirmeleri istenmiştir. Ölçeğin anlaşılabilirliği, okunabilirliği ile ilişkili olumsuz geribildirim alınmadığından ölçek maddelerinin net olduğu görülmüş ve bu nedenle herhangi bir değişiklik yapılmamıştır. Tüm maddelerin uygunluğu onaylandıktan sonra taslak ölçeğe son hali verilmiştir. Pilot çalışmadan elde edilen veriler ana örnekleme dahil edilmemiştir.

3.4.4.3. Uygulama aşaması

Araştırmacı tarafından bireylere çalışmanın amacı ve önemi hakkında bilgi verilmiş ve katılmayı kabul eden bireylere veri toplama araçları uygulanmıştır. Yatarak tedavi gören ve dahil edilme kriterlerine uyan hastalar çalışmaya dahil edilmiş ve hasta bilgi formu, KM-SŞÖ ve paralel ölçek geçerliğini değerlendirmek için EQ-5D-3L Genel Yaşam Kalitesi Ölçeği araştırmacı tarafından, yüz yüze görüşme tekniği ile uygulanmıştır. Ölçeğin son hali, 388 kardiyometabolik multimorbiditesi olan yaşlı hastaya uygulanarak geçerlik ve güvenilirlik çalışmaları yapılmıştır. Çalışma formlarının bireyler tarafından doldurulması yaklaşık 10-15 dakika sürmüştür.

3.4.5. İstatiksel Analizi

Araştırmada elde edilen veriler bilgisayar ortamında SPSS (IBM SPSS for Windows, versiyon 26) ve AMOS (Analysis of Moment Structures) istatistik programı aracılığıyla değerlendirilmiştir. Faktör analizlerinden önce normallik varsayımını değerlendirmek amacıyla çarpıklık (skewness) ve basıklık (kurtosis) değerleri hesaplanmıştır. Açımlayıcı faktör analizi örnekleminde (n=200) çarpıklık değerleri 0,05 ile 1,93 arasında, basıklık değerleri ise -0,67 ile 1,95 arasında değişmiştir. Benzer şekilde, DFA örnekleminde (n=188) çarpıklık değerleri 0.34 ile 1,80 arasında, basıklık değerleri ise -0,55 ile 1,71 arasında değiştiği bulunmuştur. Tüm değerler kabul edilebilir sınırlar olan ± 2 aralığında yer aldığından (George and

Mallery 2010) hem AFA hem de DFA için parametrik yöntemlerin uygulanabilirliği desteklenmiştir.

Ölçek yapı geçerliliğine ilişkin AFA ve DFA yapılmıştır. Ölçek güvenirliği Cronbach Alpha ve McDonald's Omega analizi ile yapılmıştır. Madde analizi ile birlikte iç tutarlılık test edilmiştir. Ölçek ayırt ediciliği alt ve üst %27'lik gruplar arasında bağımsız gruplar t-testi ile analiz edilmiştir. Ölçüt geçerliliğini belirlemek üzere korelasyon analizi yapılmıştır.

3.5. ÜÇÜNCÜ AŞAMA: KLİNİK KARAR DESTEK SİSTEMİ GELİŞTİRİLMESİ ÇALIŞMASI

Araştırmanın bu aşamasında kardiyometabolik multimorbiditesi olan yaşlı hastaların bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını önceliklendirmeye yönelik makine öğrenimi yardımı ile klinik karar destek sistemin geliştirilmesi çalışması yapılmıştır.

3.5.1. Araştırmanın Yapıldığı Yer ve Zaman

Araştırma, Sakarya Üniversitesi Eğitim ve Araştırma Hastanesi iç hastalıkları, kardiyoloji ve nöroloji-inme servislerinde yatarak tedavi gören en az iki tane kardiyometabolik hastalık tanısı (KKH, HT, DM, inme ve dislipidemi) olan yaşlı hastalar ile Aralık 2024-Mayıs 2025 tarihleri arasında gerçekleştirilmiştir.

3.5.2. Araştırmanın Örneklemi

Araştırmanın örneklemi araştırmaya katılmayı kabul eden ve araştırmaya dahil edilme kriterlerine uyan hastalar oluşturmuştur (Tablo 1). Kardiyometabolik multimorbiditesi olan yaşlı hastalarda bakım gereksinimini sınıflandırma ile ilişkili olabilecek değişkenler literatür doğrultusunda belirlenmiştir (Di Angelantonio et al 2015, Singh-Manoux et al 2018, Gao et al 2021, Ma et al 2023, Otieno et al 2023, Zhao et al 2023, Zhou et al 2025). Değişken seçiminin uygunluğunu sağlamak için, iç hastalıkları alanında bir profesör, hemşirelik alanında bir profesör ve bir doçent akademisyen tarafından değişkenler gözden geçirilerek doğrulanmıştır. Son olarak, yaş, cinsiyet, eğitim durumu, sigara içme, alkol kullanma, beden kitle indeksi

(BKİ), her bir kardiyometabolik hastalık varlığı ve tanı süresi (KKH, HT, DM, inme ve dislipidemi), kullanılan ilaç sayısı, düşme risk puanı, ağrı şiddeti, sistolik kan basıncı (SKB) ve diyastolik kan basıncı (DKB), kalp hızı, solunum sayısı, oksijen saturasyonu (SpO₂), hemoglobin, açlık kan glikozu, glikozile hemoglobin (HbA1c), sodyum, potasyum, kreatinin, ürik asit, kan üre nitrojen (BUN) düzeyleri, kolesterol, trigliserid, HDL, LDL ve Tiroid Uyarıcı Hormon (TSH) değerleri ile semptom şiddeti ölçek puanları, yaşam kalitesi ölçek puanları ve sağlık durumlarını değerlendirdikleri VAS skorları dahil olmak üzere 40 öngörücü değişken belirlenmiştir.

Bu araştırma kesitsel nitelikte olduğundan, modelin tahmin performansı için örneklem büyüklüğü değişken başına olay sayısı (events per variable-EPV) ≥ 10 ilkesine göre hesaplanmıştır (Ogundimu, Altman and Collins 2016, An et al 2021, Zhang et al 2025). Bu çalışmada 40 değişkenin yer aldığı modeli oluşturmak için en az 400 örneklem büyüklüğüne ihtiyaç duyulmuştur. Model geliştirme ve test etme aşamaları için veriyi %80 eğitim, %20 test şeklinde ayırmak yaygın bir uygulamadır (Ogundimu et al 2016, Zhang et al 2025). Bu doğrultuda, modellemede kullanılan örneklem büyüklüğü toplam örneklem sayısının %80'ini oluşturduğundan, toplam örneklem büyüklüğü en az 500 hasta olarak hesaplanmıştır. Modelin öngörü performansını artırmak için %20'lik hasta kayıp oranı öngörüldüğünde çalışmada yer alması gereken toplam örneklem büyüklüğü en az 625 katılımcı olarak hesaplanmıştır. Bu doğrultuda, araştırmanın bu aşaması toplam 700 hasta ile sonlandırılmıştır.

Tablo 1: KKDS Geliştirilmesi Aşaması İçin Örneklem Dahil Edilme ve Dışlanma Kriterleri

Kriter Türü	Kriterler
Dahil Edilme Kriterleri	Mini Mental Test puanı en az 24 olan
	Sözel iletişim güçlüğü olmayan
	Çalışmaya katılmayı kabul eden
	En az okuryazar olan
	≥65 yaşında olan
	En az iki kardiyometabolik hastalık tanısı olan (KKH, HT, DM, inme, dislipidemi)
	Hastalığı nedeniyle servise yatırışı yapılan
Dışlanma Kriterleri	Demans, Alzheimer, depresyon gibi nöropsikiyatrik tanısı olan
	İşitme veya görme engeli olan
	Çalışmaya katılmayı kabul etmeyen
	Malignitesi (kanser veya tümör varlığı) olan
	Gastrointestinal kanaması olan
	Kalp yetersizliği, böbrek yetersizliği, karaciğer yetersizliği gibi hayati organların işlev bozukluğu olan
	Sinir sistemi hastalıkları (multiple skleroz, Parkinson, epilepsi vb.) tanısı olan hastalar

3.5.3. Araştırmanın Veri Toplama Süreci

Bu araştırmada öngörücü değişkenler Hasta Bilgi Formu'nda yer almaktadır. Ayrıca, araştırmacılar tarafından geliştirilen ikinci aşamada sunulan KM-SŞÖ ve EQ-5D-3L Genel Yaşam Kalitesi Ölçeği puanları da öngörücü değişken olarak ele alındığından bu ölçekler hastalara uygulanmıştır. Ölçeklerin detayları “3.4.3.2. Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ)” ve “3.4.3.3. EQ-5D-3L Genel Yaşam Kalitesi Ölçeği” başlığında verilmiştir. Model tahmini için kontrol skalası olarak Edmonton Kırılganlık Ölçeği (EKÖ) kullanılmıştır (Ek 8).

3.5.3.1. Hasta bilgi formu

Bu form iki bölümden oluşmuştur. Birinci bölümde yaş, cinsiyet, eğitim durumu, sigara içme, alkol kullanma ve BKİ olmak üzere hastaların tanımlayıcı verileri, hastaların kardiyometabolik hastalıklarına ilişkin olarak her bir hastalık varlığı ve tanı süreleri, kullanılan ilaç sayısı ve İtaki Düşme Riski Ölçeği'ne göre düşme risk puanı soruları yer almıştır. İkinci bölümde ise, katılımcıların yaşamsal bulguları ve laboratuvar değerleri ele alınmıştır. Hastaların çalışmaya dahil edilip verilerin toplandığı gün, saat 10.00'daki yaşamsal bulgu takiplerinde kaydedilen SKB, DKB,

kalp hızı, solunum sayısı, SpO₂ ve VAS'a göre ağrı şiddeti sonuçları yer almıştır. Laboratuvar değerlerinden ise hemoglobin, açlık kan glikozu, HbA1c, sodyum, potasyum, kreatinin, ürik asit, BUN düzeyleri, kolesterol, trigliserid, HDL, LDL ve TSH değerleri hastaların çalışmaya dahil edilip verilerin toplandığı günden bir veya iki gün önceki en güncel sonuçları dikkate alınarak kaydedilmiştir.

3.5.3.2. Edmonton kırılgnlık ölçeđi (EKÖ)

Rolfson, Majumdar, Tsuyuki, Tahir ve Rockwood (2006) tarafından geliştirilen bu ölçek, yaşlı bireylerde kırılgnlık durumunu tanımlamak ve sınıflandırmak amacıyla tasarlanmıştır. Kapsamlı Geriatrik Deđerlendirme çerçevesinde ele alınan ve kırılgnlık açısından kritik kabul edilen dokuz farklı alanı kapsamaktadır. Bu alanlar; bilişsel işlevler, genel sağlık durumu, günlük yaşamda bağımsızlık düzeyi, sosyal destek ağı, ilaç kullanımı, beslenme durumu, psikolojik iyilik hali, kontinans ve fiziksel performans olarak sıralanmaktadır. Deđerlendirme sırasında genel sağlık durumu ile ilaç kullanımı her biri iki soruyla, diđer alanlar ise tek bir soruyla ölçülmektedir. Bilişsel kapasite ve fiziksel performans ise gözleme dayalı testlerle deđerlendirilmektedir. Bilişsel deđerlendirme için saat çizme testi, fiziksel performans için ise zamanlı kalk ve yürü testi kullanılmaktadır (Rolfson et al 2006, Fabrício-Wehbe et al 2009, Aygör, Fadilođlu, Şahin, Aykar ve Akçiçek 2018).

Ölçek deđerlendirilirken toplam 11 madde üzerinden bir puanlama yapılmaktadır. Bilişsel işlevler, genel sağlık durumu, günlük yaşamda bağımsızlık, sosyal destek düzeyi ve fiziksel performansla ilişkin sorular her biri 0 ile 2 arasında puanlanırken; ilaç kullanımı, beslenme durumu, psikolojik durum ve kontinans ile ilgili sorular 0 ile 1 arasında puan almaktadır. Bu şekilde, bireyin genel kırılgnlık düzeyi sayısal olarak ifade edilebilmektedir (Rolfson et al 2006, Fabrício-Wehbe et al 2009, Aygör ve ark 2018). Ölçekten elde edilen toplam en düşük puan 0 en yüksek puan 17'dir. Ölçekten alınan puan arttıkça kırılgnlığın şiddeti de artmaktadır. Alınan toplam puan ise kırılgnlık düzeyine göre beş sınıfta gruplandırılmaktadır (Şekil 2) (Rolfson et al 2006, Aygör ve ark 2018). Orijinal ölçeğin Cronbach Alpha katsayısı 0,62 bulunmuş ve ölçeğin geçerli ve güvenilir bir araç olduđu bildirilmiştir (Rolfson et al 2006). Ölçeğin Türkçe geçerlik ve güvenilirlik çalışmasında Cronbach alfa

değeri 0,75 olarak bildirilmiştir (Aygör ve ark 2018). Mevcut çalışmada ölçeğin Cronbach Alpha değeri 0,70 olarak bulunmuştur.



Şekil 2: Kırılglanlık düzeyinin EKÖ'ye göre skorlaması

3.5.4. İstatiksel Analizi

Veri analizi ve makine öğrenmesi modellerinin uygulanmasında Python programından yararlanılmıştır. Araştırmanın amacı doğrultusunda makine öğrenimi tabanlı KKDS geliştirilmesi iki aşamada gerçekleştirilmiştir.

3.5.4.1. Bakım gereksinimlerinin sınıflandırılması

İlk olarak, hastaların bakım gereksinimlerini sınıflandırmak için kırılglanlık düzeyi 700 hasta için belirlenmiş ve bu değerler veri kümesinde yer alan tüm örnekler için sınıf etiketi olarak kullanılmıştır. Hedef değişken kırılglanlık düzeyi, EKÖ puanlarına göre üçlü sınıflandırma için “hafif=1 (7-8 puan), orta=2 (9-10 puan) ve şiddetli=3 (11 puan ve üzeri)” şeklinde; ikili sınıflandırma için ise orta ve şiddetli kırılglanlık birleştirilerek “hafif=1 (7-8 puan) ve şiddetli=2 (9 puan ve üzeri)” şeklinde etiketlenmiştir. Bu etiketlere karşılık gelen bakım gereksinimlerinin sınıflandırılması ise “hafif kırılglan=düşük düzey bakım gereksinimi”, “orta kırılglan=orta düzey bakım gereksinimi” ve “şiddetli kırılglan=yüksek düzey bakım gereksinimi” olarak ele alınmıştır. Ardından, tüm hasta gruplarına ait farklı öznitelikleri (demografik bilgiler, yaşamsal bulgular, laboratuvar değerleri, semptom şiddeti ve yaşam kalitesi puanları) içeren veri seti üzerinde kırılglanlık derecesine göre bakım gereksinimi tahminine yönelik çeşitli makine öğrenimi algoritmaları eğitilmiş ve değerlendirilmiştir. Eğitim ve test verileri %80–%20

oranında, sınıf oranlarını koruyacak şekilde ayrılmıştır. Sınıflandırma probleminin çözümünde yaygın olarak tercih edilen üç temel algoritma olan Destek Vektör Makineleri (SVM), Random Forest (Rastgele Orman) ve Extreme Gradient Boosting (XGBoost) modeli kullanılarak gerçekleştirilmiştir. Veri kümeleri üzerindeki geliştirilen modellerin sınıflandırma performansı incelenirken, farklı performans metrikleri üzerinden değerlendirmeler yapılmaktadır. Bu araştırmada, sınıflandırma performanslarını belirlemek için kullanılan metrikler ise doğruluk, kesinlik, duyarlılık ve F1 skorudur.

Accuracy (Doğruluk): Doğru tahminlerin tüm tahminlere oranıdır.

Precision (Kesinlik): Bir sınıfa ait olduğu tahmin edilen örneklerin gerçekten o sınıfa ait olma oranıdır.

Recall (Duyarlılık): Gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir.

F1 Score: Precision ve Recall'un harmonik ortalamasıdır ve sınıflar arası dengeyi ölçmek için kullanılır.

Bu metrikler her sınıf için ayrı ayrı hesaplanmakta ve özellikle F1-score, sınıflar arası dengesizliklerin bulunduğu durumlarda daha sağlıklı bir değerlendirme aracı olarak öne çıkmaktadır. Macro average F1, her sınıfın eşit öneme sahip olduğu varsayımı ile ortalama başarıyı temsil etmektedir.

Ayrıca, model kararlarının şeffaflığını ve açıklanabilirliğini artırmak için (SHapley Additive exPlanations-SHAP) tabanlı öznitelik katkı analizleri yapılmıştır. Bu sayede, hangi özelliklerin model tahminlerine ne düzeyde katkı sağladığı ayrıntılı biçimde yorumlanmıştır. Bu araştırmada özellik sınıflandırmada yararlanılan üç farklı makine öğrenimi yöntemi aşağıda ayrıntılı olarak sunulmuştur.

Destek Vektör Makineleri (SVM)

Destek vektör makineleri, genel olarak ikili ve çoklu sınıf etiketine sahip veri kümelerini birbirinden ayırmak için kullanılan denetimli sınıflandırma algoritmalarından biridir (Sabry 2023, Varma 2025). SVM, verilerden çıkarılan özellikleri sanal bir koordinat düzlemine yerleştirerek veri setini iki sınıfa ayıran bir sınır bölgesi oluşturmaktadır (Sabry 2023). Veri setindeki örneklerin doğrusal

olarak ayrılabilirdi veri kümelerinde, doğrusal çekirdek fonksiyonu kullanılmaktadır. Buradaki temel amaç sonsuz sayıdaki karar doğrusundan en iyi olan doğruya karar verebilmektir (Varma 2025).

Random Forest Algoritması

Random forest, sınıflandırma ve regresyon gibi denetimli öğrenme problemleri için kullanılan bir topluluk (ensemble) öğrenme yöntemidir (Sabry, 2023, Sun et al 2024). Bu yöntem, özellikle çok sayıda özelliğe sahip büyük veri kümeleriyle çalışırken sağladığı yüksek doğruluk, güvenilirlik ve etkinlik nedeniyle öne çıkmaktadır (Sun et al 2024, Varma, 2025). Random forest algoritması, birçok karar ağacı (decision tree) oluşturarak çalışır; sınıflandırma problemlerinde en sık görülen sınıfı, regresyon problemlerinde ise ağaçların ortalama tahminini kullanarak sonuç üretir. Bu yaklaşım, modelin aşırı öğrenmesini (overfitting) önler ve genel tahmin performansını artırır (Shahzad et al 2022).

XGBoost Modeli

Bu model, makine öğrenmesinde yüksek doğruluk elde etmek için sıklıkla kullanılan, gradyan artırma ilkesine dayalı güçlü ve optimize edilmiş bir topluluk algoritmasıdır. Temel prensibi, modelin önceki tahmin hatalarını analiz ederek her yineleme adımında bu hataları azaltmaya yönelik yeni karar ağaçları oluşturmaktır. Böylece model, her adımda daha doğru tahminler yapacak şekilde kendini geliştirmeye devam etmektedir (Zhang and Haghani 2015, Li 2022). Model hem ikili hem de çok sınıflı sınıflandırma görevlerinde kullanılabilir olup farklı görev türlerini desteklemektedir (Zhang and Haghani 2015, Li 2022).

SHapley Additive exPlanations- SHAP Analizi

Makine öğrenmesi modellerinde kararların yalnızca doğruluk açısından değil, yorumlanabilirlik ve şeffaflık açısından da değerlendirilmesi giderek önem kazanmaktadır (Lundberg et al 2020, Li 2022). Bu bağlamda geliştirilen SHAP yöntemi, modelin her bir özelliğe atfettiği katkıyı sayısal olarak ortaya koymayı amaçlayan güçlü bir açıklanabilirlik aracıdır (Lundberg et al 2020, Li 2022). SHAP, modelden bağımsız olarak kullanılabilmesi ve tüm girdilerin etkisini bağlamsal olarak birlikte değerlendirilerek açıklama sunması açısından dikkat çekicidir. Bu yönüyle özellikle açıklanabilir YZ alanında yaygın olarak tercih edilmektedir

(Lundberg et al 2020, Li 2022). Ayrıca, ağaç tabanlı algoritmalar için optimize edilmiş sürümleri sayesinde Random Forest ve XGBoost gibi modellerle birlikte etkin biçimde kullanılabilir. Bu çalışmada SHAP analizi ile, geliştirilen makine öğrenmesi modellerinin karar mekanizmalarının iç işleyişi incelenmiş ve her bir özelliğin tahmine olan katkısı sayısallaştırılmıştır. Böylece modelin yalnızca güçlü bir tahminleyici değil, aynı zamanda kararları açıklanabilir ve denetlenebilir bir araç olarak da değerlendirilebilmesi sağlanmıştır.

3.5.4.2. Hemşirelik tanılarının belirlenmesi

Araştırmada belirlenen özniteliklere göre hemşirelik tanılarının belirlenmesinde geliştirilecek KKDS için öznitelik-hemşirelik tanısı eşleştirme tabloları uzman görüşüne gönderilmiştir (Ek 9). Uzman görüşü sonrası her bir tanı için öznitelik-hemşirelik tanısı eşleştirme tabloları revize edilerek 10 tane hemşirelik tanısı belirlenmiş ve analizde kullanılmak üzere son hal verilmiştir.

Modelin hem eğitim hem de test süreçlerinde kullanılacak yeterli sayıda örneğe ulaşmak için belirlenen hemşirelik tanılarına karşılık gelen klinik öznitelik eşiklerini taşıyan bireyleri temsil eden veri sayısının yeterli olması gerekmektedir. Veri setinde belirli bir sınıf yetersiz temsil edildiğinde, sınıflandırıcının performansı çeşitli şekillerde olumsuz etkilenebilir (Temraz and Keane 2022). Örneğin, azınlık sınıfını tahmin etme konusunda düşük doğruluk gösterebilir, yalnızca çoğunluk sınıfındaki başarıya dayalı olarak yapay biçimde yüksek genel doğruluk sergileyebilir veya karar ağaçlarında yetersiz kural türetimine yol açabilir (Temraz and Keane 2022). Bu araştırmanın başlangıç noktasını oluşturan ve bakım gereksinimlerini sınıflandırmadan kullanılan 700 hasta verisinden yalnızca bir kısmı, oluşturulan 10 hemşirelik tanısı karar tablosundaki öznitelik-eşik koşullarını eksiksiz biçimde karşılamıştır. Diğer bir ifade ile gerçek gözlemlerin büyük çoğunluğu, ilgili eşik değerlerini karşılayamadığından kural uyumlu gözlemlerin tüm sınıflarda yetersiz olması nedeniyle kural tabanlı bir modelin eğitimi için yeterli sayıda geçerli örnek bırakmamaktadır. Bu nedenle, makine öğrenmesi tabanlı hemşirelik tanısı öneri modellerinin eğitimi için yeterli sayıda, klinik olarak anlamlı örneğe ulaşmak amacıyla öznitelik-eşik kombinasyonlarına dayanan kural tabanlı sentetik veri üretimi gerçekleştirilmiştir. Bu yaklaşım, makine öğrenim

modellerinin öğrenmesi gereken karar kurallarına doğrudan hizmet ettiğinden algoritmik eğitim sürecinin tutarlılığını arttırma ve öznitelik-eşik matrislerinin tanımladığı alt uzaydan örnekler örnekleyerek her bir sentetik kaydın karar ağacı mantığına uygun olmasını sağlamıştır. Her bir hemşirelik tanısı için ayrı bir karar ağacı modeli eğitilmiş ve elde edilen ağaçlar görsel olarak incelenmiştir. Bu kapsamda, tanımlayıcı niteliklerin tamamını sağlayan örnekler "Evet" (pozitif sınıf) olarak, en az bir koşulu sağlamayan örnekler ise "Hayır" (negatif sınıf) olarak etiketlenmiştir. Her tanı için dengeli şekilde 400 pozitif ve 400 negatif örnek üretilmiş, eğitim ve test verisi olarak %75-%25 oranında ayrılmıştır.

Literatürde incelendiğinde de hasta bakımını desteklemek ve karar alma süreçlerini güçlendirmek amacıyla birden fazla veri türünün bütüncül biçimde analiz edilmesi, klinik kararların daha isabetli verilmesine olanak tanırken, veri eksiklikleri ve sınıf dengesizlikleri gibi sorunların bu süreci güçleştirebileceği bildirilmektedir (Chlap et al 2021, Shorten, Khoshgoftaar and Furht 2021). Kural tabanlı sentetik verilerin bu sorunları ortadan kaldırarak modelin aşırı özelleşmesini engelleyerek genellenebilirliği artırdığını ve özellikle sınırlı veride aşırı uyumu (overfitting) azaltmada etkili olduğu belirtilmektedir (Chlap et al 2021, Shorten et al 2021). Bu bağlamda, sentetik veri üretiminden özellikle nadir görülen durumlar veya düşük temsil edilen alt gruplar için yeterli sayıda örnek sağlama potansiyeli ile sağlık alanındaki çalışmalarda da yararlanıldığı görülmektedir (Zhang, Paz, Nebot, Mugica and Romero 2023, El Emam, Mosquera, Fang and El-Hussuna 2024, Pezoulas et al 2024).

Karar Ağaçları (Decision Trees)

Karar ağaçları yorumlanabilir yapıları ve değişkenler arası ayırım noktalarını açık şekilde görselleştirebilmeleri nedeniyle klinik uygulamalarda sıkça tercih edilen sınıflandırma algoritmalarından biridir (De Ville 2013, Loh 2014). Karar ağaçları, bir dizi “eğer-ise” (if-then) kuralı aracılığıyla, girdi değişkenlerini (öznitelikleri) belirli eşik değerler üzerinden dallara ayırarak sınıflandırma işlemini gerçekleştirir. Modelin her düğümünde bir öznitelik ve bu özniteliğe ait bir eşik değeri yer almakta; gözlemler bu eşik değere göre iki alt gruba ayrılarak yaprak düğümlerde sınıf etiketine ulaşmaktadır (De Ville 2013, Loh 2014). Düğümlerin saflığı,

genellikle Gini indeksi ile deęerlendirilmekte olup, Gini deęeri sıfıra yaklařıkça dūęümdeki örneklerin homojenlięi artmakta ve karar daha güvenilir hâle gelmektedir (Grąbczewski 2014). Bu yöntem hem sayısal hem de kategorik veriler içeren veri kümeleriyle çalışabilme olanaęı sunmakta ve saęlık alanında genellikle hasta bakımının yönetiminde kullanımı kolay olduęu için tercih edilmektedir (Grąbczewski 2014).



4. BULGULAR

Bu tez çalışması üç aşamada gerçekleştirildiğinden tartışma bölümü; kardiyometabolik multimorbidesi olan yaşlı hastalarda bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını belirlemede KDSS'nin geliştirilmesine yönelik hemşire görüşlerini içeren nitel çalışma bulguları, KM-SŞÖ'nin geliştirilmesi ve geçerlik güvenirliği bulguları ve KKDS geliştirilmesine yönelik verilerden elde edilen bulgular olmak üzere üç bölümde sunulmuştur.

4.1. BİRİNCİ AŞAMA: HEMŞİRE GÖRÜŞLERİNE İLİŞKİN NİTEL BULGULAR

Nitel araştırmaya katılan hemşirelerin çoğunluğunu kadınlar (n=17) oluşturmuştur. Yaşları 24 ile 37 arasında değişen hemşirelerin çalışma süreleri 1-18 yıl arasında değişmektedir. Eğitim düzeyleri önlisans, lisans, yüksek lisans ve doktora seviyelerinde çeşitlilik göstermiştir. Ortalama olarak, yoğun bakım birimlerinde çalışan hemşireler 2-3 hasta; dahiliye servislerinde çalışan hemşireler ise 12-14 hasta bakmaktadır (Tablo 2).

Tablo 2: Hemşire Katılımcıların Tanımlayıcı Özellikleri

ID	Cinsiyet ve Yaş	Eğitim Durumu	Çalışma Süresi	Çalışılan Birim	Ortalama Bakılan Hasta Sayısı	Görüşme Süresi (dk:sn)
1	Kadın, 28 yaş	Yüksek lisans	6 yıl	Dahiliye Yoğun Bakım (İnme)	3	19:20
2	Kadın, 27 yaş	Önlisans	9 yıl	Genel Dahiliye Yoğun Bakım	3	15:01
3	Kadın, 27 yaş	Lisans	3 yıl	Dahiliye Yoğun Bakım (Nöroloji)	2	25:18
4	Erkek, 28 yaş	Yüksek lisans	5 yıl	Dahiliye Yoğun Bakım (Nöroloji)	2	18:57
5	Kadın, 28 yaş	Lisans	5 yıl	Genel Dahiliye Yoğun Bakım	3	34:54
6	Erkek, 26 yaş	Lisans	5 yıl	Dahiliye Yoğun Bakım (İnme)	3	19:52
7	Kadın, 29 yaş	Lisans	5 yıl	Nöroloji Yoğun Bakım	2	23:58
8	Erkek, 24 yaş	Lisans	1 yıl	Dahiliye Servisi (Nöroloji-İnme)	12	12:55
9	Kadın, 29 yaş	Yüksek lisans	7 yıl	Dahiliye Servisi (Kardiyoloji)	14	17:06
10	Kadın, 25 yaş	Lisans	3 yıl	Dahiliye Servisi (Kardiyoloji)	14	17:56
11	Kadın, 37 yaş	Lisans	18 yıl	Dahiliye Servisi (Nöroloji-İnme)	12	12:05
12	Kadın, 32 yaş	Lisans	9 yıl	Genel Dahiliye Servis	12	17:08
13	Kadın, 30 yaş	Yüksek lisans	6 yıl	Genel Dahiliye Servis	12	18:26
14	Kadın, 29 yaş	Yüksek lisans	5 yıl	Dahiliye Servisi (Kardiyoloji)	14	35:01
15	Kadın, 29 yaş	Lisans	6 yıl	Genel Dahiliye Servisi	12	13:76
16	Kadın, 35 yaş	Yüksek lisans	10 yıl	Genel Dahiliye Yoğun Bakım	3	18:56
17	Kadın, 34 yaş	Önlisans	11 yıl	Dahiliye Servisi (Kardiyoloji)	14	14:28
18	Kadın, 29 yaş	Lisans	6 yıl	Genel Dahiliye Servisi	12	13:76
19	Kadın, 30 yaş	Lisans	5 yıl	Dahiliye Servisi (Nöroloji-İnme)	12	13:12
20	Kadın, 34 yaş	Doktora	10 yıl	Dahiliye Servisi (Kardiyoloji)	14	20:11

Bu araştırmada hemşirelerin kardiyometabolik çoklu hastalığı olan yaşlı bireylerin bakım süreçlerine ilişkin deneyimleri ve makine öğrenimi dayalı KKDS geliştirilmesine ilişkin görüşlerine dayalı üç ana tema belirlenmiştir. Tema ve alt temaların özeti Tablo 3'te sunulmuştur.

Tablo 3: Temalar, Alt temalar ve Kodlar

Temalar	Alt Temalar	Kodlar
Bakım Sürecinde Yaşananlar	İletişim Sorunları ➤ Psikolojik iletişim engelleri ➤ Yetersiz hasta-hemşire ilişkisi	• Ölüm korkusu • Kaygı • Ajitasyon • Anksiyete • Kronik ağrı • Bilişsel bozukluklar • Bilişsel gerileme • İletişim güçlüğü • İletişim engeli • Etkisiz iletişim
	İş Yüğü ➤ Zaman kısıtlılığı ➤ Tükenmişlik hissi	• Yeterli zaman ayıramama • Fazla hasta sayısı • Çok fazla sayıda hasta ile ilgilenme • Zaman eksikliği • Çok fazla iş yükü • Fiziksel yük • Zihinsel yük • Yorgunluk • Umutsuzluk
Bakım Gereksinimlerini Sınıflandırma ve Hemşirelik Tanılarını Önceliklendirme	Bakım Gereksinimlerinin Sınıflandırılması ➤ Bakımın karmaşıklığı ➤ Kişiselleştirilmiş bakım eksikliği	• Bakımda eksiklik hissi • Bütüncül yaklaşım eksikliği • Çoklu hastalıklarla mücadele • Karar süreçlerinin belirsizliği • Karmaşık bakım gereksinimi • Kişiselleştirilmiş bakım planları eksikliği • Tedavi sürecinin zorluğu
	Hemşirelik Tanılarının Önceliklendirilmesi ➤ Yaşamsal fonksiyonlara öncelik verme ➤ Standart tanıların kullanımı	• Acil durum önceliği • Kritik müdahale gereksinimi • Hızlı müdahale • Zaman yetersizliği • Öncelik belirleme zorluğu • Çok fazla sayıda hasta ile ilgilenme • Standartlaşmış hemşirelik tanıların kullanımı • Rutinleşmiş hemşirelik tanıları koyma • Klinik duruma göre tanı koyamama • Sistematik tanı koyma zorlukları
Klinik Karar Destek Sisteminin Geliştirilmesine Yönelik Görüşler	Klinik Karar Destek Sistemine Yönelik Olumlu Görüşler ➤ Risk yönetimi ➤ Bakım kalitesini artırma ➤ İş yükünü hafifletme	• Hata riskinin azaltılması • Gözden kaçan durumları önleme • Komplikasyon riskini azaltma • Yatış süresini kısaltma • Bütüncül bakım • Sistematik yaklaşım • Klinik karar vermeyi kolaylaştırma • Bireyselleştirilmiş bakım sunma • Bakım süreçlerini hızlandırma • Zaman yönetimi • Verimlilik artışı • Azalmış iş yükü • Yorgunluğu azaltma
	Klinik Karar Destek Sistemine Yönelik Endişeler ➤ Uygulanabilirlik sorunları ➤ Güvenilirlik sorunları	• Teknolojiye uyumsuzluk • Entegrasyon zorlukları • Teknolojik altyapı yetersizlikleri • Sistemin karmaşıklığı

		• Uygulama sürecinin zorluğu • Zaman yetersizliği • Zaman alıcı olması • Olası teknik zorluklar • Hatalı uyarılar • Yanlış öneri verme • Sisteme güvensizlik • Tekrar kontrol etme gerekliliği
--	--	---

Tema 1: Bakım Sürecinde Yaşananlar

Bu tema, kardiyometabolik multimorbiditesi olan yaşlı bireylere bakım verme sürecinde hemşirelerin yaşadıkları zorlukları ve bu zorlukları yönetme sürecinde karar destek ihtiyacını ortaya koymaktadır. Katılımcı ifadeleri; kırılganlık, bilişsel gerileme ve yaşla birlikte artan eşzamanlı sağlık sorunlarının bakım sürecini zorlaştırdığını ve hemşirelerin iletişim engelleri ile zaman yönetimi gibi karmaşık süreçlerle başa çıkmak zorunda kaldıklarını göstermektedir. Bu çok katmanlı bakım süreçleri, karar verme süreçlerini güçleştirmekte ve hemşirelerin bireyselleştirilmiş bakım uygulamalarını sistematik olarak yürütememelerine neden olmaktadır. Katılımcıların ifadeleri, kardiyometabolik multimorbiditesi olan yaşlı hastalarla bakım sürecindeki yaşananlar ana teması altında, iletişim sorunları ve iş yükü alt temalarının ortaya çıktığını göstermektedir.

Alt Tema 1.2: İletişim Sorunları

İletişim, yalnızca bilgi aktarımı için değil, aynı zamanda tedaviye katılımı sağlamak, psikolojik destek sağlamak ve güven ilişkisi kurmak için de yaşlı hastaların bakımında önemli bir unsur olarak ortaya çıkmıştır. Ancak katılımcılar, yaşlı hastalarla iletişim sürecinin bilişsel ve psikolojik engeller nedeniyle yetersiz olduğunu bildirmiştir.

Psikolojik İletişim Engelleri: Katılımcılar, yaşlı hastalar ile iletişimde başa çıkılması en güç unsurlardan birinin bilişsel ve duygusal durumlar olduğunu ifade etmişlerdir. Ajitasyon, ağrıya aşırı tepki, bilinç düzeyinde dalgalanmalar, ölüm korkusu ve özellikle demans, etkili iletişimi engelleyen başlıca etmenler arasında yer almaktadır. Demans gibi, yaşlı bireylerde gerçeklik algısının bozulduğu durumlarda hemşirenin açıklama çabaları yetersiz kalmakta ve bu durum mesleki yeterlilikle ilgili kaygılara yol açmaktadır.

“Yaşlı hastalarla iletişim kurmak zor. Daha fazla ajite oluyor ve ağrılara aşırı tepki veriyorlar. Bu beni zorluyor. İletişim zor oluyor yaşlı hasta da sıvı yüklemesi oluyor işte diyor bana bir serum bile takmadı diyor anlamıyor ajite oluyor” (P3)

"Yaşlı hastada Alzheimer olduğu zaman genç hastaya göre iletişim zorlaşıyor. Bilinç değişiklikleri oluyor veya hastanede yatmak onlar için ölümü çağrıştırdığı için kaygılı oluyorlar, bizi anlamıyorlar." (P18)

Yetersiz Hasta-Hemşire İlişkisi: İletişim yalnızca bir araç değil, aynı zamanda bakımın da bir bileşenidir. İletişim sekteye uğradığında, yalnızca bilgi akışı değil, hemşire-hasta ilişkisi de zarar görmektedir. Katılımcılar, bilişsel gerileme, ölüm kaygısı ve depresif semptomlar nedeniyle hastaların tedavi sürecine aktif katılım sağlayamadıklarını bildirmişlerdir. Bu durum, bakım sürecine katılımın kısıtlanmasına, hemşire-hasta ilişkisinin zayıflamasına ve bakım sonuçlarının olumsuz etkilenmesine yol açmaktadır.

"Yaşlı hastalarla iletişim çok zor... ölüm korkusunu hissediyorum, bu da bize yansıyor, bu süreci yönetmek zor. Sonra mesela hasta tedavi sürecinde ne yapması gerektiğini anlamakta güçlük çekiyor ve bu durumun tedavi sürecini aksattığını düşünüyorum." (P7)

“Yaşlı hastalar genellikle hem fiziksel hem de bilişsel yeteneklerinde kayıplar yaşarlar. Örneğin, demans gibi bilişsel bozukluklar, tedavi süreçlerini anlamalarını ve uygulamalarını zorlaştırıyor. Bir vakada, diyabeti olan ve aynı zamanda demans tanısı konmuş bir hastanın kan şekerini düzenli olarak kontrol etmesi gerektiğinde, bu işin karmaşıklığını anlamadığı ve kontrolleri unuttuğu için ciddi komplikasyonlar yaşanmıştı. Bu bizim ilişkimizi zorlaştırdığı için tedavi ve bakım sürecinin başarısını doğrudan etkileyebiliyor.” (P20)

Alt Tema 1.3: İş Yüğü

Bu alt tema altındaki katılımcı anlatıları, hemşirelik bakımının yalnızca görev odaklı olmadığını, aynı zamanda zaman, duygu ve dikkat gerektiren çok boyutlu bir süreç olduğunu göstermektedir. Katılımcılar, bu hasta grubuyla çalışırken

zaman baskısı, yoğun müdahale ihtiyacı ve artan sorumluluklar nedeniyle artmış bir iş yükü hissettiklerini belirtmişlerdir.

Zaman Kısıtlılığı: Katılımcılar, daha genç hastalarla karşılaştırıldığında, birden fazla tanıya sahip yaşlı yetişkinlerin bakım süreçlerinin daha fazla zaman ve dikkat gerektirdiğini vurgulamışlardır. Bu hastaların, özellikle de komplikasyon riski taşıyanların başucunda kalma ihtiyacı, zaman yönetimini zorlaştırmakta ve diğer hastaların bakımını aksatabilmektedir. Buna göre, zaman kısıtlamaları hemşirenin klinik etkinliğini ve psikolojik dayanıklılığını tehdit eden bir faktör olarak ortaya çıkmıştır.

“Yaşlı bir hasta geldiğinde bu süreç uzuyor... iş yükü çok fazla ve zaman yönetimi zor. Mesela genç bir hasta 10 dakikada tedavi ve bakım sürecini bitirebilirken yaşlı komplike hastada yarım saat çıkamıyorsun, mesela bugün bir hastanın neredeyse 40 dakika başından ayrılamadım.” (P4)

“Bizim hastaların bakım verme sürecimizi ve şeklimizi hastanın yaşı arttıkça... zorlaşıyor... Daha çok bakım ihtiyacı ve daha çok tanı koymam demek o hastaya daha çok zaman ayırmam demek... iş yüküm artıyor ama zamanım yetmediği için baskı hissediyorum.” (P15)

Tükenmişlik Hissi: Katılımcılar yoğun iş yükü, hızlı karar alma zorunluluğu ve bakımın neredeyse bitmeyen doğası nedeniyle psikolojik yorgunluk bildirmişlerdir. Bu yorgunluk, sadece görev sayısı ile değil, aynı zamanda bu görevlerin sonuç üretip üretmemesiyle de ilgilidir. Bu durum hemşirelerin mesleki memnuniyetinin ve motivasyonlarının azalmasına neden olmaktadır.

“Son ana kadar her türlü tedavi yapılıyor ama umutsuzluk oluyor. Bizim işimiz çok zorlaşıyor çünkü çoklu hastalığı olanlarda her şeyi yakından takip etmek zorundayız, bu iş yükü olarak bize çok geri dönüş sağlıyor. Bir süre sonra çok kısıtlı zamanda çok iş yapmak gerekiyor özellikle psikolojik ve duygusal baskı hissediyorum.” (P5)

“Bu hastalar daha özel grup oluyor bunun yanında hemşirelerin bu hastaların daha fazla zaman ayırması sebebiyle zaten hasta başı yani daha fazla çalışmak ve emek vermek zorundayız daha fazla. Belki üzerimize düşen görev daha fazla olduğu için daha fazla emek sarf edebiliyoruz. Bu hastalara

bakmak, biz hemşirelerde tükenmişlik ve zorlanmaya neden oluyor. Çünkü çok fazla emek vermek zorundayız.” (P12)

Tema 2: Bakım Gereksinimlerini Sınıflandırma ve Hemşirelik Tanılarını Önceliklendirme

Bu tema, kardiyometabolik multimorbiditesi olan yaşlı bireylerin bakım sürecinde hemşirelerin karşılaştığı klinik karmaşıklık ve tanı sürecine ilişkin belirsizlikleri ele almaktadır. Katılımcı ifadeleri, hemşirelerin bakım ihtiyaçlarını sistematik olarak sınıflandıramadığını ve hastaların önceliklendirilmesinde zorluk yaşadığını ortaya koymuştur. Katılımcıların bu ana temaya ilişkin ifadeleri doğrultusunda bakım gereksinimlerinin sınıflandırılması ve hemşirelik tanılarının önceliklendirilmesi şeklinde iki alt tema belirlenmiştir.

Alt Tema 2.1: Bakım Gereksinimlerinin Sınıflandırılması

Bu alt tema, kardiyometabolik multimorbiditeli yaşlı hastalarda hemşirelerin karmaşık bakım ihtiyaçlarını belirlemede yaşadıkları zorlukları ve kişiselleştirilmiş bakım planlamasındaki eksiklikleri bir şekilde ortaya koymuştur. Bu hastaların bakımı, yalnızca hemşirenin klinik gözlemlerine dayalı kararlarla yönetilemeyecek kadar karmaşık bir süreci yansıtmaktadır. Bu doğrultuda, hemşirenin klinik gözlemlerini destekleyerek bakımın bireyselleştirilmesini ve sistematik biçimde sunulmasını sağlayacak KKDS'lere duyulan ihtiyaç açıkça ortaya çıkmıştır.

Bakımın Karmaşıklığı: Hemşireler, bu hastalarla ilgilenirken farklı sağlık sorunlarına dikkat etmek zorunda olduklarını, her bir hastanın bakım gereksinimlerinin birbirinden çok farklı olduğunu ve sürekli olarak birden fazla görevi yönetmeleri gerektiğini vurgulamıştır.

"Bizim hastaların bakım verme sürecimizi ve şeklimizi hastanın yaşı arttıkça kronik hastalık sayısı arttıkça bizim bakım verme sürecimizi zorlaştırıyor. Hastalar daha bir fazla bakıma muhtaç oluyor... çok fazla yakın takip gerektiriyor. Hipertansiyonu varsa çok dikkat gerektiriyor, bir yandan şeker takibi ee tabi yaşamsal bulguları da sık takip gerekiyor, immobilize yaşlı hastalarda bunu yönetmek daha da zor." (P15)

“Bir hastaya bakmak, yaşı olduğunda zorken birçok hastalığı beraberinde de getirdiği için daha da zor oluyor. Tansiyon parametresini değerlendirirken kan şekerini de ölçmeniz gerekiyor. Bir taraftan bunları sağlarken. Aritmisini takip etmeniz gerekiyor. Böbrekleri çalışıyor mu? Birçok parametreye bakmanız gerekiyor. Aynı zamanda bu hastaların basınç yaralanması olmaması açısından mobilize etmeniz gerekiyor. Eklem açıklığını sağlamanız gerekiyor. Aslında baktığınız zaman ayrı ayrı yapılacak ama bütün yapılması gereken çok fazla iş var. O anlamda hepsini ayrı ayrı belirleyebilmek bu hastada karmaşıklıyor ve zor olabiliyor.” (P16)

Kişiselleştirilmiş Bakım Eksikliği: Katılımcılar, her hastanın bakımının farklı olduğunu, bireysel olarak ele alınması ve öncelikli ihtiyaçlarının belirlenmesinin tedavi süreçlerinin daha verimli hale geleceğini ifade etmiştir. Ancak, zaman yetersizliği ve iş yükü fazlalığı nedeniyle hastaların ihtiyaçlarının kişisel olarak değerlendirilemediği ve bakımın etkinliğinin azaldığı ortaya çıkmıştır.

Zaman yetersizliğinden dolayı hastalara kişiselleştirilmiş bakım yapamıyoruz. Her hastanın farklı ihtiyaçları oluyor aslında özellikle yaşlıda daha kompleks oluyor. Yapılsa daha etkili bir bakım sağlayabiliriz ama maalesef hastanın gereksinimlerine göre bakım planı yapamıyoruz. (P6)

"Yoğun hasta yükü nedeniyle yaşı hastalarımızın bakım gereksinimlerini gerçek anlamda planlama fırsatı bulamıyoruz. Zaman kısıtlılığı nedeniyle bakım planları genellikle otomatik yapılıyor. Aslında biliyorum her hasta farklı ihtiyaca önceliğe sahip ama maalesef bunu klinikte yapamıyoruz. " (P7)

"Her hasta için farklı ihtiyaçlar var ama özellikle yaşlı hastada öncelikleri belirleyip buna göre bir bakım planı oluşturmak gerekiyor. Fakat bunu yapacak zamanımız yok, iş yükümüz çok. Çoğu zaman hastaya bireysel bakım planı yapamıyoruz." (P13)

Alt Tema 2.2: Hemşirelik Tanılarının Önceliklendirilmesi

Bu alt tema, hemşirelerin hayati fonksiyonları korumaya yönelik klinik önceliklendirme uygulamalarını ve hasta odaklı tanımlar oluşturma sürecinde karşılaştıkları sistematik zorlukları kapsamaktadır. Katılımcılar, genellikle acil durumlara yanıt vermeye odaklandıklarını ve hemşirelik tanımlarını bireysel ihtiyaçlardan ziyade tekrarlayan, standart tanımlar üzerinden şekillendirdiklerini ifade etmişlerdir. Bu nedenle, hemşirelik bakımının bilimsel temellere dayandırılması ve kişiselleştirilmiş sağlık hizmeti sunulması açısından veriye dayalı, hasta odaklı ve dinamik olarak güncellenebilen KKDS'lerin geliştirilmesi gerektiği öne çıkmaktadır.

Yaşamsal Fonksiyonlara Öncelik Verme: Katılımcılar, önceliklendirme yaparken hastanın yaşam fonksiyonlarını korumaya yönelik girişimlere ağırlık verdiklerini belirtmiştir. Hemşireler, yaşamı tehdit eden durumların öncelikle ele alınması gerektiğini ifade etmiştir.

“Öncelikle tabii ki fizyolojik olarak ve yaşam kalitesi olarak hastayı geliştirebilecek veya hastanın yaşam kalitesine ve fizyolojisine olumlu yönde katkı sağlayabilecek tanımları önceliklendiriyorum. Kalp hastası olan bireyin bir dolaşım problemi varsa bu dolaşım sorununa yönelik bir tanı vermeye çalışıyorum çünkü bunlar yaşam fonksiyonları olduğu için benim için öncelik tanımlar olabiliyor. İşte koroner arter hastası diyorum ki dolaşım bozuk olabilir ama mesela diyabette var o zaman ekstra takip dikkat gerekiyor. Tabiki bu gözle bakıyorum ama iş yoğunluğumuzdan her zaman hastanın ihtiyacına özgü tanımları koyamıyorum.” (P13)

“Hemşirelik tanımlarını belirlerken hastanın genel durumunu, acil gereksinimlerini ve uzun vadeli hedefleri göz önünde bulundururum. Önceliklendirme yaparken genellikle hastanın yaşamını tehdit eden bir durum varsa, bu durumu yönetmek öncelikli tabiki.” (P16)

Standart Tanımların Kullanımı: Özellikle birden fazla hastaya yetişmek zorunda kaldıkları için her hastaya gereken özeni gösteremedikleri ve standart tanımların kullanılması, hastaların bireysel ihtiyaçlarını karşılamada yetersiz kalmaktadır. Katılımcılar, hastanın klinik durumu ve ihtiyaçlarına göre tanı koymada

hemşirelerin yetersiz kaldığını ve çoğunlukla düşme riski, enfeksiyon riski gibi standart tanıları kullandıklarını ifade etmiştir.

"Yaşlı ve çoklu kronik hastalığı olanların hemşirelik tanılarını sistemden alıyoruz ama bu hastalar için daha çok tanı girmek gerekiyor.... Biz genellikle sistem üzerinden standart tanıları uyguluyoruz. İşte düşme riski ve enfeksiyon riski her hasta için giriyoruz. Ancak yaşlı hastalarda fizyolojik ve psikolojik açıdan daha derinlemesine değerlendirme yapmak gerekir ama yaşlı genç diye ayırmıyorum maalesef etkili bir bakım planlama ve o girişimleri uygulama yapamıyoruz." (P8)

"Bu serviste bize bir ya da üç tane tanı koymamız söyleniyor. Bizim tanılarımız genelde belli başlıdır, bilgi eksikliği ya da enfeksiyon riski gibi hep aynı tanıları tekrar ediyor. Ancak bunları hastaya özgü düşünerek değil, daha çok otomatik bir şekilde yazıyoruz. Vakit bulabilirsek seçiyoruz, ama çoğu zaman hızlı olması için hastaya en yakın olabilecek olanı seçip etiyojolojiyi çok da incelemeden geçiyoruz. Bu nedenle hemşirelik tanısı koyma ve bakım planlama süreci çok da etkili olmuyor maalesef. Ben üç yıldır bu işi yapıyorum, sadece birkaç uzun yatışlı hasta için boş vaktim olduğunda, örneğin gece nöbetinde, hastaya özgü tanı koyabildim. Ama genelde çok hasta olduğu için hastaların gereksinimlerine göre tanıları koymayı önemseyemiyoruz maalesef." (P10)

"Genelde enfeksiyon riski, düşme riski gibi sabit tanıları kullanıyoruz. Ancak hastaya özgü tanıları oluşturmak zor, çünkü zaman yok. Tanıları ezbere girmek zorunda kalıyoruz, çünkü hızlı olmak gerekiyor Çok yoğunuz çünkü o bakım planlarındaki girişimleri de yapmak mümkün olmuyor. Her gün sistemden hastanın tanısına ek durumlarına bakmadan her hasta için otomatik az önce dediğim tanıları alıyoruz. Yani yapmış olmak için yapıyoruz bir yerde." (P14)

Tema 3: Klinik Karar Destek Sisteminin Geliştirilmesine Yönelik Görüşler

Bu tema, hemşirelerin kardiyometabolik multimorbiditesi olan yaşlı hastaların karmaşık bakım süreçlerinde karar verme desteğine ilişkin bakış açılarını ve bu sistemlerin klinik uygulamaya entegrasyonuna dair beklentilerini ortaya

koymaktadır. Katılımcı ifadeleri doğrultusunda, KKDS geliştirmeye ilişkin görüşler ana teması altında olumlu görüşler ve sistemle ilgili endişeler olmak üzere iki alt tema belirlenmiştir.

Alt Tema 3.1: Klinik Karar Destek Sistemine Yönelik Olumlu Görüşler

Bu alt tema ile karar destek sistemlerinin yalnızca yazılım olarak değil, aynı zamanda hemşirenin iş yükünü hafifletmek, klinik karar sürecini yönlendirmek ve kişiselleştirilmiş bakım sağlamak ve böylece bakım kalitesini arttırmak için araçlar olarak da kabul edildiği ortaya çıkmıştır.

Risk Yönetimi: Katılımcılar tarafından bu karar destek sistemlerinin en büyük faydalarından biri, gözden kaçabilecek durumların tespit edilmesi ve bu sayede yanlış tanı sayılarının düşürülmesi olarak ifade edilmiştir. Karar destek sistemlerinin, hemşirelerin dikkatinden kaçabilecek belirtileri tespit ederek bakımın kalitesini artıracak ve hasta güvenliğini destekleyeceğini belirtmişlerdir.

“Hani gözden kaçırdıklarımız oluyor en azından inmeye yönelik şeyler yazılar çıksa mesela oradan seçeyim ben hani o güzel olabilir. İnme ile ilgili ne bileyim kendi branşımızı seçtiğimizde karşımıza çıkan şeyler olsa hata riskimiz azalır. Ben 10 saat aklıma bile gelmiyor bazı şeyleri unutuyorum. Böyle aşağı kadar inemiyorsun şu anki sistemde hani gözden kaçırdıkların oluyor en azından mesela oradan seçeyim ben ya da bana uyarı. Mesela aynı zamanda hani bir tane hastalığı yok komplike bu hastalar mesela doktorda görse bu sistemden hasta uyarılarını işte riskleri bizim işimiz kolaylaşır, on kere laf anlatmak zorunda kalmam, böylece yaptıklarımız daha görünür kılınabilir.” (P6)

“Gözden kaçabilecek şeylere dikkat çekerdi bize uyarı vererek nelere dikkat etmemiz gerektiğini söylemesi mesela hastaları daha iyi analiz etmemizi sağlardı. Bazı şeylerin gözden kaçma düzeyi azalırdı, hemşirenin hasta farkındalığını arttırırdı ve böyle hata yapma riskimiz azalırdı. Bence taburculuk oranını iyileşme oranını katkı sağlarken mortalite oranı düşüreceğini daha çabuk taburcu olacağına o oranlarını etkileyeceğini olumlu yönde diye inanıyorum.” (P9)

Bakım kalitesini arttırma: Katılımcılar, karar destek sistemlerinin hastaların karmaşık sağlık durumlarını yönetmede önemli bir fayda sağlayabileceğini, klinik kararlarda belirsizliği azaltabileceğini ve bu sistemlerin bakımın kalitesini iyileştirebileceğini belirtmiştir.

"Karar destek sistemleri hastanın bireysel ihtiyaçlarına göre kişiselleştirilmiş bakım planları oluşturmada büyük bir yardımcı olabilir. Eğer böyle bir sistem olursa bizim işimizi kolaylaştırır. Yani zaman ve takip açısından etkili olabilir. Daha az yoruluruz bence. Tabi hasta açısından da olumlu katkıları olur daha efektif bir bakım veririz, bakımımız kolaylaşır kalitesi artar." (P7)

"Böyle bir karar destek sistemi geliştirildiğinde, hastaların önceliklendirilmesi ve bakım süreçlerinin düzenlenmesi çok daha kolay olurdu. Karar verme süreçlerimiz kolaylaşır, hasta bakımını kolaylaştırır ve bakım kalitesini arttırır. Hastalara daha iyi bakım verebilmemiz olanak sağlardı." (P9)

«Kesinlikle böyle bir karar destek sistemi geliştirilmesini yaşlı kardiyometabolik hastalığı olan bireylerin tedavi ve bakımını olumlu yönde etkileyeceğini düşünüyorum. Hemşirelik bakımlarının hemşirelik tanımlarının önceliklendirilmesi hastaya öncelikle hangi bakımı verebileceğimiz veya hastaya bütüncül yaklaşırken öncelikle hangi yönünün ele alınması gerektiği gibi durumları kolaylaştırabileceğini düşünüyorum bununla beraber hastanın daha kaliteli bakım alması ve daha doğru tedavi alması gibi olumlu katkıları olabilir." (P13)

İş Yükünü Azaltma: Katılımcılar, KKDS'nin bakım süreçlerini kolaylaştırarak iş yüklerini hafifleteceğini ifade etmiştir. Hemşireler, teknolojinin etkili kullanımı ile iş yüklerinin azalması sonucu verimliliklerinin artacağı ve daha fazla hastaya daha iyi zaman ayırabileceklerini dile getirmiştir.

"Bir karar destek sistemi bakım süreçlerini kolaylaştırarak iş yükümüzü hafifletebilir. Daha fazla hastaya daha iyi zaman ayırabiliriz iş yükümüz az olduğunda, bence eğer bu sağlanabilirse verimliliğimiz de artar." (P3)

"Mesela o şifte yüksek riskli hastalara belki daha fazla zaman ayırıp hani o günlük planlamamı öyle yapıp bir nevi iş yükümü azaltabilir. Belli yani

mükemmel bir fikir olurdu yani bu benim elim kolum ayağım gibi olurdu yani beni destekler bu bilgisayar üzerinden. Mesela hastaları tek tek ayrı incelemek için vakit harcamamış olacağım. Çünkü bu karar destek sistemi benim yerime incelemiş analiz etmiş olacak zaten, bu benim işimi kolaylaştırır hem fiziksel hem de psikolojik yükümü hafifletir.” (P10)

Alt Tema 3.2: Klinik Karar Destek Sistemine Yönelik Endişeler

Bu tema, hemşirelerin klinik ortamlarda KKDS’lerin geliştirilmesi ve hasta bakım süreçlerinde kullanılmasına ilişkin uygulanabilirlik ve güvenilirlik sorunları olmak üzere temel endişelerini ortaya çıkarmıştır. Katılımcılar, KKDS’lerin yalnızca teknik olarak doğru değil, aynı zamanda pratik, kolay kullanılabilir ve güvenilir olması gerektiğini; ayrıca hemşirenin mesleki yargısını dikkate alması gerektiğini vurgulamışlardır.

Uygulanabilirlik Sorunları: Katılımcılar, KDSS’lerin karmaşıklığı ve mevcut klinik ortamlara entegrasyonundaki zorlukları dile getirmiştir. Hemşireler, mevcut iş akışları zaten yoğun olduğunda manuel veri girişi gerektiren sistemlerin zaman alıcı olabileceğinden ve uygulama başarısızlığına meyilli olabileceğinden endişe duymaktadır. Ayrıca, sistemin hemşirelerin pratikteki işlerini nasıl etkileyeceği konusu ise belirsizdir.

“Açıkçası bilgisayar başında oturmayı bile bizim için ayrı bir zaman kaybı olarak görüyorum yani keşke hiçbir şey bilgisayardan yapmazsak hani dediğiniz mantıklı yapay zekayı bizim kullanabilmemiz için hastanın sisteminde kâğıt işi yerine bir tablet olacak bizim kendi tabletimiz herkesin bireysel olması gerekiyor bence. Tamam ben işimi yapıyorum ama olsun Hani atlama olabilir gözden kaçan şeyler olabilir böyle bir sistem bu durumları engelleyebilir bizi destekleyerek hata riskini azaltabilir. Ama hem gözlem hem tablet olursa yani hem de iş yükümüz iki katı olur. O yüzden bence zaman alıcı bir şey olmamalı bu. Uyumlu olmaması veya entegrasyon süreçlerinin karmaşıklığı, sistemin tam anlamıyla kullanılmasını engelleyebilir.” (P5)

“Teorikte bence böyle bir sistem güzel olur ama pratikte bence çoğu şey uygulanamıyor. Yani hemşirenin bakım planını kâğıda dökmesi bile zorken sisteme bakmak, veri girmek zor olabilir bilemiyorum. Yani doktor istemine

göre yapılabilir, uyarı verebilir işte insülini var doktor girmiş buna göre yönlendirme verebilir veya öneri verebilir hastanın durumunda bir değişiklik olursa işte kan şekerinde, tansiyonda, böylece bizde erken fark edebiliriz hastanın durumundaki değişikliği veya gözden kaçmamış olur atlanmamış olur hasta bakımında tedavisinde önemli noktalar. Yani böyle bir sistem gerekli teorikte ama kliniğe uygulamada entegrasyonda nasıl olur bilemiyorum.” (P7)

Güvenilirlik Sorunları: Katılımcılar, bu karar destek sisteminin nasıl çalıştığını ve hangi verilere dayandığını anlamadığında, sistemin önerilerine güvenme konusunda tereddüt yaşayabileceklerini ve yine kendilerinin kontrol etmesinin gerekliliğini belirtmiştir.

“Ben o sistemin sapmalara yol açacağını da bize bir şeye katması için bizim o sisteme katmamız gereken veya girmemiz gereken şeyler olduğunu düşünüyorum açıkçası. Ben o verileri doğru girmedim veya işlem vardı bu sefer sistem verileri hatalı olduğunda, önerilen kararlar da yanlış olabilir. Örneğin, eksik veya yanlış veri girişleri, hastalar için zararlı sonuçlara yol açabilecek yanlış kararlar vermemize neden olabilir.” (P2)

“Ekstra bir bilgisayar sisteminin hastayla arama girmesini istemem açıkçası. Bana uyarı verebilir. Ama hence bu tarz sistemler karışıklığa sebep olabilir bunlarla başa çıkabileceğimizi düşünmüyorum. Biz mesela kan basıncı yükseldiğinde bir sürü faktöre bakıyoruz bu sistem bunu algılayamaz bazen yanlış ölçtüğünde manşon farklı oluyor bir şey etkiliyor sistem bunu algılayamaz. Bana özellikle yaşlı kronik hastada detaylı veri sunacak bir şey olacağını sanmıyorum. Ama dediğim gibi gözlem de önemli, bir sorunun devamını sorgulamak önemli. Böyle bir sistemin ekstra detaya gireceğini düşünemiyorum. Sistem bize belirli kalıplar halinde sunacak öneride verse tanı da söylese, bu da hata riskine yol açabilir.” (P8)

4.2. İKİNCİ AŞAMA: KARDİYOMETABOLİK MULTİMORBİDİTELİ YAŞLI HASTALARDA SEMPTOM ŞİDDETİ ÖLÇEĞİNİN (KM-SSÖ) GEÇERLİK VE GÜVENİRLİĞİNE İLİŞKİN BULGULAR

4.2.1. Katılımcıların Tanımlayıcı Özellikleri

Çalışmaya katılan 200 katılımcının %52'si kadın, %50'sinin ortaöğretim mezunu olduğu görülmektedir. Ortalama yaş 67,41 (SD=5,78) olarak tespit edilmiştir. Kronik hastalıklar açısından, katılımcıların %83'ünde HT, %57,5'inde DM, %57'sinde KKH, %30,5'inde dislipidemi ve %13'ünde inme olduğu görülmüştür. KKH tanı yılı ortalaması 5,87 yıl, HT tanı yılı ortalaması 9,81 yıl, DM tanı yılı ortalaması 10 yıl, inme tanı yılı ortalaması 3,31 yıl ve dislipidemi tanı yılı ortalaması 6,87 yıl olarak hesaplanmıştır. Katılımcıların %48,5'i son bir yıl içinde hastaneye yatmadığını, %43'ü 1-2 kez yattığını bildirmiştir (Tablo 4).

Tablo 4: AFA için Katılımcıların Tanımlayıcı Özellikleri

Değişken	N		n	%
Cinsiyet	200	Kadın	104	52,0
		Erkek	96	48,0
Eğitim Durumu	200	Okur-yazar	62	31,0
		Ortaöğretim	100	50,0
		Lise	31	15,5
		Lisans	7	3,5
Sigara İçme Durumu	200	İçiyor	35	17,5
		Hiç İçmemiş	76	38,0
		Bırakmış	89	44,5
Alkol Kullanma Durumu	200	İçiyor	3	1,5
		Hiç İçmemiş	125	62,5
		Bırakmış	72	36,0
KKH	200	Evet	114	57,0
		Hayır	86	43,0
HT	200	Evet	166	83,0
		Hayır	34	17,0
DM	200	Evet	115	57,5
		Hayır	85	42,5
İnme	200	Evet	26	13,0
		Hayır	174	87,0
Dislipidemi	200	Evet	61	30,5
		Hayır	139	69,5
Bir Yıl İçinde Hastaneye Yatma	200	Hiç	97	48,5
		1-2 kez	86	43,0
		2'den fazla	17	8,5
		X±SS	Min	Maks
Yaş (Yıl)	200	67,41±5,78	65	88
KKH Tanı Yılı	114	5,87±4,40	1	20
HT Tanı Yılı	166	9,81±4,94	1	30
DM Tanı Yılı	115	10,00±4,73	1	30
İnme Tanı Yılı	26	3,31±4,12	1	20
Dislipidemi Tanı Yılı	61	6,87±3,50	2	15

X: Ortalama, SS: Standart sapma, Min: Minimum, Maks: Maksimum

Çalışmaya katılan 188 bireyin %50,5'inin erkek ve büyük çoğunluğunun (%43,1) ortaöğretim mezunu olduğu bulunmuştur. Katılımcıların %80,9'unda HT, %58,0'inde DM, %52,7'sinde KKH, %17,6'sında inme ve %30,3'ünde dislipidemi varlığı saptanmıştır. KKH tanı yılının ortalama 6,83 yıl, DM tanı yılının ise 10,65 yıl olarak raporlanması, hastalık geçmişlerinin genelde uzun bir süreyi kapsadığını göstermektedir. Katılımcıların bir yıl içinde hastaneye yatma oranları incelendiğinde, %47,9'unun hastaneye yatmadığı, %45,2'sinin 1-2 kez yattığı belirlenmiştir. Yaş ortalaması 69,19 (SD=5,99)'dur (Tablo 5).

Tablo 5: DFA için Katılımcıların Tanımlayıcı Özellikleri

Değişken	N		n	%
Cinsiyet	188	Kadın	93	49,5
		Erkek	95	50,5
Eğitim Durumu	188	Okur-yazar	68	36,2
		Ortaöğretim	81	43,1
		Lise	31	16,5
		Lisans	8	4,3
Sigara İçme Durumu	188	İçiyor	37	19,7
		Hiç içmemiş	80	42,6
		Bırakmış	71	37,8
Alkol Kullanma Durumu	188	İçiyor	6	3,2
		Hiç içmemiş	117	62,2
		Bırakmış	65	34,6
KKH	188	Evet	99	52,7
		Hayır	89	47,3
HT	188	Evet	152	80,9
		Hayır	36	19,1
DM	188	Evet	109	58,0
		Hayır	79	42,0
İnme	188	Evet	33	17,6
		Hayır	115	82,4
Dislipidemi	188	Evet	57	30,3
		Hayır	131	69,7
Bir Yıl İçinde Hastaneye Yatma	188	Hiç	90	47,9
		1-2 kez	85	45,2
		2'den fazla	13	6,9
	188	X±SS	Min	Maks
Yaş (Yıl)	188	69,19±5,99	65	90
KKH Tanı Yılı	99	6,83±5,08	1	23
HT Tanı Yılı	152	9,66±6,59	1	40
DM Tanı Yılı	109	10,65±5,75	2	30
İnme Tanı Yılı	33	4,12±4,28	1	20
Dislipidemi Tanı Yılı	57	6,79±3,10	1	15

X: Ortalama, SS: Standart sapma, Min: Minimum, Maks: Maksimum


4.2.2. Açıklayıcı Faktör Analizi

Açıklayıcı faktör analizi, ölçeğin tek faktörlü bir yapıya sahip olduğunu ve ölçek maddelerinin bu faktörle yüksek ilişki gösterdiğini ortaya koymuştur. Kaiser-Meyer-Olkin (KMO) testi, örneklem yeterliliğini değerlendirmek için yapılmış ve KMO değeri 0,965 olarak bulunmuştur. Ayrıca Bartlett Küresellik Testi ($\chi^2 = 5065,520$, $df = 300$, $p < 0,001$), değişkenler arasında yeterli düzeyde korelasyon bulunduğunu ifade etmektedir.

Faktör analizi, Temel Bileşenler Analizi (Principal Component Analysis) yöntemiyle gerçekleştirilmiş, faktör yapısını daha yalın ve yorumlanabilir hâle getirmek amacıyla Varimax rotasyon yöntemi kullanılmıştır. Rotasyon işlemi sonucunda ölçeğe ait tüm maddelerin anlamlı düzeyde tek bir faktör altında toplandığı görülmüştür. Ölçekte yer alan 25 maddenin faktör yükleri 0,658 ile 0,898 arasında değişmiş olup, çalışmada kabul edilebilir eşik değer olarak 0,60 ve üzeri yükler esas alınmıştır. Elde edilen değerler, tüm maddelerin bu eşik değerin üzerinde olduğunu ve ilgili faktöre güçlü biçimde yüklendiğini göstermektedir. Faktör analizi sonucunda, ölçeğin birinci faktörüne ait özdeğer (eigenvalue) 16,438 olarak bulunmuş, bu faktör toplam varyansın %65,753'ünü açıklamıştır. Bu oran, yaygın olarak kabul gören %40'lık alt sınırın oldukça üzerindedir ve ölçeğin yapı geçerliğini güçlü biçimde desteklemektedir. Ayrıca, yalnızca bir faktörün özdeğerinin 1'in üzerinde olması, ölçeğin tek faktörlü bir yapıya sahip olduğunu göstergesidir. Ortak varyans değerleri 0,433 ile 0,806 arasında değişmekte olup, bu değerler maddelerin ilgili faktör tarafından yeterli düzeyde açıklandığını göstermektedir (Tablo 6). Bu bulguları daha net bir şekilde görselleştirmek ve faktör analizi sonuçlarını değerlendirmek amacıyla aşağıda Scree Plot grafiği sunulmuştur (Şekil 3).


Tablo 6: Faktör Yükleri ve Ortak Varyans Değerleri

Madde	Faktör Yüğü	Ortak Varyans (Extraction)
Semptom_1	0,756	0,571
Semptom_2	0,747	0,558
Semptom_3	0,812	0,660
Semptom_4	0,795	0,632
Semptom_5	0,832	0,693
Semptom_6	0,851	0,723
Semptom_7	0,865	0,748
Semptom_8	0,807	0,651
Semptom_9	0,861	0,741
Semptom_10	0,824	0,680
Semptom_11	0,853	0,727
Semptom_12	0,866	0,749
Semptom_13	0,898	0,806
Semptom_14	0,789	0,623
Semptom_15	0,879	0,773
Semptom_16	0,658	0,433
Semptom_17	0,819	0,671
Semptom_18	0,838	0,702
Semptom_19	0,837	0,700
Semptom_20	0,739	0,547
Semptom_21	0,845	0,714
Semptom_22	0,760	0,577
Semptom_23	0,748	0,560
Semptom_24	0,823	0,677
Semptom_25	0,725	0,526

Scree Plot**Şekil 3:** Scree Plot Grafiğı

4.2.3. Doğrulayıcı Faktör Analizi

Doğrulayıcı faktör analizi sonucunda elde edilen modelin, veri ile uyumunu görselleştirmek ve faktör yapısının ilişkilerini daha net bir şekilde ortaya koymak için Şekil 4'te DFA'ya ilişkin diyagram sunulmuştur.



Şekil 4: DFA'ya İlişkin Diyagram

Doğrulayıcı faktör analizinde modelin uyum iyiliği, çeşitli uyum indeksleri kullanılarak değerlendirilmiştir. Analiz sonucunda elde edilen uyum iyiliği değerleri ve kabul edilen sınır değerler Tablo 7'de sunulmuştur.

Tablo 7: DFA İndeks Değerleri

Uyum İndeksleri	Uyum Değerleri	Sınır Değerler
χ^2	476,428	
df	274	
χ^2/df (CMIN/DF)	1,739	$0 \leq \chi^2/df \leq 5$
CFI	0,938	$0,80 \leq CFI \leq 1,00$
GFI	0,802	$0,80 \leq GFI \leq 0,95$
NFI	0,865	$0,90 \leq NFI \leq 0,95$
IFI	0,938	$0,80 \leq IFI \leq 1,00$
TLI	0,932	$0,80 \leq TLI \leq 1,00$
RMSEA	0,063	$0,05 \leq RMSEA \leq 0,08$
RMR	0,013	$0,05 \leq RMR \leq 0,08$

Doğrulayıcı faktör analizi uyum indeksleri, modelin veri ile uyumunun kabul edilebilir düzeyde olduğunu göstermektedir. χ^2/df oranı 1,739 olarak hesaplanmış

ve kabul edilebilir sınırın ($0 \leq \chi^2/df \leq 5$) içinde kalmıştır. CFI (0,938), IFI (0,938), ve TLI (0,932) değerleri oldukça yüksek olup, modelin iyi uyum sağladığını göstermektedir. GFI (0,802) ve NFI (0,865) değerleri ise kabul edilebilir alt sınırlara yakın bulunmuştur. RMSEA (0,063) ve RMR (0,013) değerleri, modelin veri ile uyumunun tatmin edici düzeyde olduğunu desteklemektedir.

Tablo 8'de sunulan sonuçlar, tüm maddelerin tek faktör yapısına anlamlı bir şekilde yüklendiğini göstermektedir. Maddelerin standart faktör yükleri (Std. β), 0,653 ile 0,797 arasında değişmekte olup, kabul edilebilir düzeylerde bulunmaktadır. Ayrıca, t değerlerinin tamamı 9,582 ile 12,256 arasında değişmekte ve $p < 0,001$ düzeyinde anlamlıdır.

Tablo 8: DFA Faktör Yükleri

Maddeler ve Faktörler			β	Std. β	S.Hata	t	p
S25	<---	F1	,784	1,000			
S24	<---	F1	,781	1,083	,091	11,943	$p < 0,001$
S23	<---	F1	,768	,990	,085	11,684	$p < 0,001$
S22	<---	F1	,711	,823	,078	10,616	$p < 0,001$
S21	<---	F1	,737	,852	,077	11,090	$p < 0,001$
S20	<---	F1	,759	,947	,082	11,517	$p < 0,001$
S19	<---	F1	,703	,823	,079	10,471	$p < 0,001$
S18	<---	F1	,772	,916	,078	11,763	$p < 0,001$
S17	<---	F1	,739	1,002	,090	11,138	$p < 0,001$
S16	<---	F1	,741	,808	,072	11,172	$p < 0,001$
S15	<---	F1	,653	,726	,076	9,582	$p < 0,001$
S14	<---	F1	,797	,961	,078	12,256	$p < 0,001$
S13	<---	F1	,777	,969	,082	11,851	$p < 0,001$
S12	<---	F1	,694	,777	,075	10,302	$p < 0,001$
S11	<---	F1	,717	,763	,071	10,731	$p < 0,001$
S10	<---	F1	,723	,852	,079	10,842	$p < 0,001$
S9	<---	F1	,650	,777	,081	9,534	$p < 0,001$
S8	<---	F1	,776	,979	,083	11,842	$p < 0,001$
S7	<---	F1	,678	,745	,075	10,002	$p < 0,001$
S6	<---	F1	,715	,870	,081	10,693	$p < 0,001$
S5	<---	F1	,755	,973	,085	11,439	$p < 0,001$
S4	<---	F1	,757	,913	,080	11,472	$p < 0,001$
S3	<---	F1	,694	,807	,078	10,300	$p < 0,001$
S2	<---	F1	,737	,925	,083	11,101	$p < 0,001$
S1	<---	F1	,772	,989	,084	11,772	$p < 0,001$

4.2.4. Ölçüt Geçerliliği

Korelasyon analizi sonuçlarına göre KM-SSÖ'nin toplam puanı ile EQ-5D-3L VAS sağlık durumu arasında negatif yönde anlamlı bir ilişki bulunmuştur ($r = -0,430$; $p < 0,001$). Benzer şekilde, ölçek toplam puanı ile EQ-5D-3L Genel Yaşam Kalitesi arasında yüksek düzeyde negatif bir ilişki tespit edilmiştir ($r = -0,790$; $p < 0,001$).

4.2.5. Güvenirlik Analizi

Güvenirlik analizi kapsamında, ölçeğin iç tutarlılığını değerlendiren Cronbach Alfa katsayısı 0,977, McDonald's Omega katsayısı ise 0,978 olarak bulunmuştur. Madde toplam korelasyonları 0,636 ile 0,887 arasında değişmektedir.

4.2.6. Ayırt Edicilik

Ölçeğin ayırt ediciliğini belirlemek üzere, alt %27'lik ve üst %27'lik gruplar arasında t-testi analizi gerçekleştirilmiştir. Bu analiz, ölçeğin farklı semptom şiddeti düzeylerine sahip bireyleri başarıyla ayırt edip edemediğini değerlendirmek amacıyla yapılmıştır. Analiz sonuçlarına göre, alt gruptaki semptom toplam puanı ortalaması 7,50 (SD = 6,21) iken, üst gruptaki ortalama 36,61 (SD = 9,11) olarak hesaplanmıştır. Gruplar arasında istatistiksel olarak anlamlı bir fark bulunmuştur ($t = -19,406$; $p < 0,001$). Cohen's d değeri -3,735 olarak tespit edilmiş ve bu durum, etkinin oldukça büyük olduğunu göstermiştir. Ayrıca, ortalama farkın güven aralığı (-32,09 ile -26,14), iki grup arasındaki farklılığın istikrarlı bir şekilde ortaya konduğunu desteklemektedir.

4.3. ÜÇÜNCÜ AŞAMA: KLİNİK KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİNE YÖNELİK BULGULAR

4.3.1. Bakım Gereksinimlerinin Sınıflandırılmasına Yönelik Bulgular

Bu çalışmada, hastaların bakım gereksinim düzeylerini sınıflandırmaya yönelik olarak geliştirilen makine öğrenimi tabanlı KKDS, hem ikili (düşük ve yüksek bakım gereksinim düzeyi) hem de üçlü (düşük–orta–yüksek bakım gereksinim düzeyi) sınıflandırma görevleri çerçevesinde farklı modeller ile test edilmiştir.

40 öznitelik kullanılarak yapılan iki sınıflı sınıflandırma görevinde, Random Forest modeli test setinde %89 doğruluk elde etmiştir. XGBoost modeli ise test setinde

%87 ile daha dengeli bir performans sergilemiştir. Ayrıca XGBoost’un kör veri setinde F1-skorda %85’i aşması, modelin genelleme kapasitesinin yüksek olduğunu göstermektedir. Random Forest modeli test setinde daha yüksek doğruluk sağlasa da XGBoost modeli kör veride daha istikrarlı sonuçlar üretmiştir. Bu sonuçlar, yüksek boyutlu öznitelik uzayında gradyan artırılmalı yöntemlerin sınıf ayrımında daha dengeli kararlar verebildiğini ve overfitting’e karşı daha dayanıklı olduğunu ortaya koymaktadır (Tablo 9).

40 öznitelikle gerçekleştirilen üç sınıflı sınıflandırma görevinde ise Random Forest (%76) ve XGBoost (%75) modelleri benzer doğruluk oranlarına ulaşmıştır. Ancak kör veri setinde Random Forest’in F1 skoru %54’e düşerken, XGBoost %65 ile daha dengeli bir performans sergilemiştir. Bu durum, XGBoost’un yüksek boyutlu verilerde daha kararlı genelleme yeteneğine sahip olduğunu göstermektedir (Tablo 9). Genel olarak, öznitelik sayısındaki artış tüm modeller için başarıyı artırmamış; aksine, bazı sınıflarda aşırı öğrenme ve karışıklık riskini artırmıştır.

Tablo 9: Bakım Gereksinim Düzeyinin Sınıflandırılmasında Kullanılan Makine Öğrenimi Modellerinin 40 Öznitelik İçin Performans Karşılaştırması

Özellik Sayısı	Görev Türü	Model	Test Doğruluk
40	2-sınıf (düşük-yüksek)	RandomForest	%89
40	2-sınıf (düşük-yüksek)	SVM	%78
40	2-sınıf (düşük-yüksek)	XGBoost	%87
40	3-sınıf (düşük-orta-yüksek)	RandomForest	%76
40	3-sınıf (düşük-orta-yüksek)	SVM	%70
40	3-sınıf (düşük-orta-yüksek)	XGBoost	%75


En anlamlı 19 öznitelik kullanılarak gerçekleştirilen ikili sınıflandırma görevinde, XGBoost modeli doğruluk açısından (%86) en yüksek başarıyı göstermiştir. SVM modeli de %82 doğruluk ile güçlü bir performans sergilemiş, özellikle “DÜŞÜK” sınıfında yüksek hassasiyet sağlamıştır. XGBoost ise “YÜKSEK” sınıfındaki duyarlılığı (%78–%81 arası F1) artırarak sınıflar arasında daha dengeli bir genel performans ortaya koymuştur (Tablo 10).

19 öznitelik kullanılarak gerçekleştirilen üç sınıflı sınıflandırma görevinde, SVM modeli %76 test doğruluğu ile en yüksek başarıyı gösterirken Random Forest model %72, XGBoost modeli ise %70 doğruluk sağlamıştır. Bu durum, SVM'nin sınıflar arasındaki ayrımı maksimize eden yapısı sayesinde, sınıf dengesizliklerinin görece az olduğu durumlarda istikrarlı bir performans sergilediğini göstermektedir. Öte yandan, XGBoost, özellikle kör set üzerinde daha dengeli duyarlık ve F1 skorları sunarak genelleme kapasitesini korumuştur. Buna karşılık, Random Forest modeli normal test setinde daha stabil sonuçlar üretmiş ancak bazı sınıflarda belirgin karışıklıklar yaşamıştır. Elde edilen sonuç, SVM'nin 19 öznitelik özelinde bakım gereksinimlerini düşük, orta, yüksek olarak üçlü sınıflamada diğer modellere kıyasla daha iyi genelleme yapabildiğini göstermektedir (Tablo 10).

Tablo 10: Bakım Gereksinim Düzeyinin Sınıflandırılmasında Kullanılan Makine Öğrenimi Modellerinin 19 Öznitelik İçin Performans Karşılaştırması

Özellik Sayısı	Görev Türü	Model	Test Doğruluk
19	2-sınıf (düşük-yüksek)	RandomForest	%82
19	2-sınıf (düşük-yüksek)	SVM	%82
19	2-sınıf (düşük-yüksek)	XGBoost	%86
19	3-sınıf (düşük-orta-yüksek)	RandomForest	%72
19	3-sınıf (düşük-orta-yüksek)	SVM	%76
19	3-sınıf (düşük-orta-yüksek)	XGBoost	%70


Eğitilen modellerin her birinin özniteliklere verdiği karar katkısı SHAP tabanlı öznitelik etki analizi ile değerlendirilmiştir. Her model için SHAP özet grafikleri çizilmiş ve özellik önem dereceleri görselleştirilmiştir (Şekil 5). Veri setinin sınıflandırma başarısını en üst düzeye çıkarmak amacıyla en çok etkileyen 19 özellik seçilmiştir. Bu doğrultuda, Random Forest ve XGBoost modellerinde "yaşam kalitesi total puan" ve "semptom şiddeti total puan" gibi değişkenlerin yüksek katkı sağladığı gözlemlenmiştir. Öte yandan, SVM modelinin sınırlı doğruluk başarısı SHAP etkilerini sınırlı düzeyde yansıtmaya neden olmuştur.



Şekil 5: SHAP Tabanlı Öznitelik Etki Analizi

Bar grafiği ise her bir özelliğin ortalama mutlak SHAP değeri üzerinden hesaplanan göreceli önemini göstermektedir (Şekil 6). Y-ekseni, model tahminlerine katkı büyüklüğünü; X-ekseni ise söz konusu özellikleri ifade etmektedir. Daha yüksek bir çubuk, ilgili özelliğin model kararlarında daha güçlü bir belirleyici olduğunu;

dolayısıyla model performansının artmasında ve farklı kırılganlık derecelerinin ayırt edilmesinde daha fazla rol oynadığını işaret etmektedir. Bu görselleştirme, özellikle ilk beş sıradaki özelliklerin modelin öngörü gücüne en yüksek düzeyde katkı sağladığını ortaya koymakta ve hem öznitelik seçimi hem de model yorumlanabilirliği açısından yol gösterici niteliktedir. SHAP analizi sonucunda en yüksek etki değerine sahip öznitelikler seçilerek yeni bir veri alt kümesi oluşturulmuş ve sınıflandırma modelleri yalnızca bu özniteliklerle yeniden eğitilmiştir. Bu yaklaşımın temel amacı, model karmaşıklığını azaltırken tahmin başarısını korumak ya da artırmaktır. Özellikle Random Forest ve XGBoost modelleri, bu alt küme üzerinde eğitim aldıklarında benzer doğruluk oranlarını sürdürmeyi başarmış, bazı sınıflarda F1 skorlarını artırmıştır. Sonuç hastaların bakım gereksinimlerini sınıflandırmada en çok katkı sağlayan 19 öznitelik sırası ile yaşam kalitesi, semptom şiddeti, kalp hızı, kolesterol değeri, yaş, trigliserid değeri, BUN, düşme riski puanı, ağrı şiddeti, sağlık durumunu değerlendiren VAS skoru, sistolik kan basıncı, sodyum değeri, solunum sayısı, sigara içme durumu, TSH değeri, ilaç sayısı, SpO₂ değeri, ürik asit ve HbA1c değeri olarak bulunmuştur.



Şekil 6: Özniteliklerin Karar Sürecine Katkı Düzeylerinin SHAP Özeti

4.3.2. Hemşirelik Tanılarının Belirlenmesine Yönelik Bulgular

Bakım gereksinimlerinin sınıflandırılmasında katkısı en fazla olan 19 özniteliğe göre uzman görüşü sonrası toplam 10 tane hemşirelik tanısı ele alınmıştır. Bu


öznitelik-hemşirelik tanı eşleştirmelerine dair model çıktılarının değerlendirilmesinde karar ağacı analizleri sırası ile aşağıda sunulmuştur.

4.3.2.1. Kalp debisinde azalma

Tablo 11: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Kalp Debisinde Azalma Tanısına İlişkin Öznitelikler

Öznitelik	Tanımlayıcı özellikler/ilişkili faktörler
KAH+HT varlığı	Evet
SKB	< 100 mmHg
Kalp Hızı	> 100 bpm
Solunum Sayısı	> 20/dk
BUN	> 20 mg/dL
KM-SŞÖ puanı	> 25 puan

Karar ağacı modeli bu özniteliklerin çoğunu ilk seviyelerde kullanmış olup özellikle KAH ve HT varlığı, SKB ve BUN düzeyi kararın şekillenmesinde belirleyici olmuştur (Şekil 7). Bazı düğümlerde eşik değerlerinin klinik tabloda belirtilen değerlerden farklı olması dikkat çekmektedir. Örneğin, klinik eşik "SKB < 100 mmHg" olarak verilirken, modelde bölme noktası "SKB ≤ 100" şeklinde ifade edilmiştir. Benzer şekilde "BUN > 20 mg/dL" koşulu, modelde "BUN ≥ 19" olarak bölünmüştür. Bu farklar, veri üretimi sırasında sürekli değerlerin kullanılması ve karar ağacının bölme kararı alırken dağılımları optimize edecek biçimde küçük sapmalar yapmasıyla açıklanabilir. Ancak bu sapmalar yön değiştirmedeği sürece (örneğin ">" yerine "<" gibi zıt yönlü bir karar alınmadığı sürece) klinik anlam kaybı yaratmamaktadır. Öte yandan, solunum sayısı ve semptom şiddeti puanı ise modelde yer almamıştır. Bu durum, söz konusu özniteliklerin pozitif ve negatif sınıfları ayırt etme gücünün, diğer özellikler kadar yüksek olmamasından kaynaklanmakta olup, modelin fazladan ayırım yapmasına gerek kalmadan sınıflandırmayı yüksek doğrulukla gerçekleştirebildiğini göstermektedir. Modelin genel doğruluk oranı "Kalp Debisinde Azalma" hemşirelik tanısını belirlemede %99 olup oldukça yüksek performans göstermiştir (Tablo 11).



Şekil 7: Kalp Debisinde Azalma Karar Ağacı Modeli

Tablo 12: Kalp Debisinde Azalma Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.99	0.99	100
1	0.99	1.00	1.00	100
Genel Doğruluk (Accuracy)			0.99	200
Macro Ort.	1.00	0.99	0.99	200
Ağırlıklı Ort.	1.00	0.99	0.99	200


4.3.2.2. Etkisiz periferik doku perfüzyonu

Tablo 13: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Etkisiz Periferik Doku Perfüzyonu Tanısına İlişkin Öznitelikler

Öznitelik	Tanımlayıcı özellikler/ilişkili faktörler
DM+ HT varlığı	Evet
Sigara Kullanımı	Evet/İçiyor
SpO ₂	< %92
SKB	< 100 mmHg
Kalp Hızı	< 60 bpm

İlgili tanıya ilişkin ağaç yapısı incelendiğinde kök düğümün “kalp hızı ≤ 60 ” koşulunu içerdiği görülmektedir; dolayısıyla kalp hızı kriteri tanıyı ayırmada en yüksek bilgi kazanımını sağlamıştır (Şekil 8). Ardışık düğümler sırası ile SKB, DM ve HT varlığı ve sigara içme durumuna göre ilerlemekte; böylece bu koşullar art arda test edilerek yaprağa ulaşılmaktadır. Dikkat çekici biçimde “SpO₂ <%92” özelliği ağaçta yer almamıştır. Bunun nedeni, ilk dört değişken kombinasyonunun pozitif ve negatif sınıfları tamamen saf kümelerle ayırması, dolayısıyla ek bölmenin Gini saflık ölçütünü iyileştirmemesidir. Bu durum, SpO₂ değişkeninin klinik

açından önemsiz olduğu anlamına değil, mevcut veri dağılımında ayırım gücünün diğer dört değişkene kıyasla marjinal kaldığına işaret etmektedir. Karar ağacı modeli performans açısından değerlendirildiğinde, “Etkisiz Periferik Doku Perfüzyonu” hemşirelik tanısının dört ana öz niteliğini kullanarak %100 doğrulukta sınıflandırma yaptığı görülmüştür (Tablo 13).



Şekil 8: Etkisiz Periferik Doku Perfüzyonu Karar Ağacı Modeli

Tablo 14: Etkisiz Periferik Doku Perfüzyonu Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	1.00	1.00	100
1	1.00	1.00	1.00	100
Genel Doğruluk (Accuracy)			1.00	200
Macro Ort.	1.00	1.00	1.00	200
Ağırlıklı Ort.	1.00	1.00	1.00	200


4.3.2.3. Aktivite intoleransı

Tablo 15: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Aktivite İntoleransı Tanısına İlişkin Öz nitelikler

Öznitelik	Tanımlayıcı özellikler/ilişkili faktörler
KAH varlığı	Evet
Solunum Sayısı	> 20/dk
SpO ₂	< %92
Düşme Riski Puanı	≥ 10 puan
İlaç Sayısı	≥ 5
KM-SŞÖ puanı	> 25 puan

Model çıktılarının değerlendirilmesinde, ilgili tanıya ilişkin karar ağacı incelendiğinde, modelin sınıflandırma yaparken belirli klinik nitelikleri öne

çıkardığı görülmektedir (Şekil 9). Karar ağacı modelinde ilk bölme noktası, KAH varlığına ilişkin olup, bu değişken modelin başlangıç ayrımı için belirleyici olmuştur. KAH'nın yokluğu (≤ 0) durumunda model örnekleri doğrudan negatif sınıfa (No) atamakta, bu da özelliğin yüksek ayrıştırma gücüne sahip olduğunu göstermektedir. Karar ağacının devamında, KAH pozitif bireylerde solunum sayısı 20'nin üzerinde olması, semptom şiddeti puanı ve SpO₂ eşik değerleri bir sonraki belirleyici faktör olarak model tarafından kullanılmıştır. KM-SSÖ puanının karar ağacındaki eşik değeri 24 olarak tanımlanmış olup, bu küçük fark, karar ağacı algoritmasının bölme işlemlerini ayırım gücüne göre gerçekleştirmesiyle ilişkilidir. Modelin karar ağacında düşme riski puanı ve ilaç sayısı gibi diğer özniteliklerin yer almamış olması, bu değişkenlerin modelin sınıflandırma başarısına anlamlı katkı sağlamadığı ya da diğer değişkenler tarafından temsil edilebilir nitelikte olduğunu düşündürmektedir. Bu durum, karar ağaçlarının yalnızca sınıflar arası en fazla bilgi kazancı sağlayan öznitelikleri tercih etme özelliğiyle uyumludur. Modelin genel doğruluk oranı “Aktivite İntoleransı” hemşirelik tanısını belirlemede %99 olup oldukça yüksek performans göstermiştir (Tablo 15).



Şekil 9: Aktivite İntoleransı Karar Ağacı Modeli

Tablo 16: Aktivite İntoleransı Tanısına Ait Model Performans Göstergeleri


Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.98	0.99	100
1	0.98	1.00	0.99	100
Genel Doğruluk (Accuracy)			0.99	200
Macro Ort.	0.99	0.99	0.99	200
Ağırlıklı Ort.	0.99	0.99	0.99	200

4.3.2.4. Fiziksel mobilitede bozulma

Tablo 17: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Fiziksel Mobilitede Bozulma Tanısına İlişkin Öznitelikler

Öznitelik	Tanımlayıcı özellikler/ilişkili faktörler
İnme varlığı	Evet
EKÖ	≥ 9 puan
Düşme Riski Puanı	≥ 10 puan
Ağrı şiddeti	≥ 4 olması

Bu hemşirelik tanısı için karar ağacı modeline bakıldığında, ilk bölme değişkeni olarak “inme varlığı” kullanılmıştır (Şekil 10). Bu değişkenin ≤ 0 olarak kodlanması, kategorik bir değişkeni olduğunu ve "Hayır" durumunu ifade ettiğini göstermektedir. İlk düğümde yer alan bölme sayesinde, inme geçirmemiş bireylerin tamamının tanıyı almadığı (class = No) görülmektedir. Bu durum, inme varlığının fiziksel mobilite bozulmasının belirleyicisi olduğunu açık biçimde göstermektedir. İnme varlığı gözlenen bireylerde ise, karar ağacı ilerleyen düğümlerde "düşme riski puanı", "EKÖ puanı" ve "ağrı şiddeti" değişkenlerini sırasıyla kullanarak daha hassas bir ayırım gerçekleştirmiştir. Ancak, EKÖ için ≥ 9 olarak belirtilen tanılayıcı kriter, modelde 8 olarak ayırım yaparak aynı doğrultuda ancak teknik bir dönüşümle eşik değer belirlemiştir. Modelin genel performansı, tüm metriklerde %100 doğruluğa yakın sonuçlar vermiştir (Tablo 17). Karar ağacının her düğümünde gini katsayısının 0 olması, modelin her aşamada tam saflıkta ayırım yaptığını göstermektedir. Ayrıca modelde kullanılmayan değişkenlerin bulunmaması, tanımlayıcı faktörlerin tamamının sınıflandırmada etkili rol oynadığını ortaya koymaktadır.



Şekil 10: Fiziksel Mobilitede Bozulma Karar Ağacı Modeli

Tablo 18: Fiziksel Mobilitede Bozulma Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	1.00	1.00	100
1	1.00	1.00	1.00	100
Genel Doğruluk (Accuracy)			1.00	200
Macro Ort.	1.00	1.00	1.00	200
Ağırlıklı Ort.	1.00	1.00	1.00	200


4.3.2.5. Etkisiz sağlık öz yönetimi

Tablo 19: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Etkisiz Sağlık Öz Yönetimi Tanısına İlişkin Öznitelikler

Öznitelik	Tanımlayıcı özellikler/ilişkili faktörler
Sigara Kullanımı	Evet/İçiyor
Sistolik Kan Basıncı	> 140 mmHg
İlaç Sayısı	≥ 5
Total Kolesterol	> 200 mg/dL
Trigliserid	> 150 mg/dL
HbA1c	> %8,0
KM-SŞÖ puanı	> 25 puan
EQ-5D-3L ölçek puanı	< 0,60
EQ-5D-3L VAS skoru	≤ 40 puan altı

İlgili hemşirelik tanısına ilişkin karar ağacı incelendiğinde, modelin en üst düzeydeki ayrımı, “sigara kullanımı” değişkenine göre gerçekleştirdiği bulunmuştur (Şekil 11). Bu ayrım, ilgili değişkenin sınıflar arası ayrımı sağlamada yüksek ayırt ediciliğe sahip olduğunu göstermektedir. Sigara kullanmayan bireyler doğrudan "Hayır" sınıfına yönlendirilirken sigara kullanan bireyler için model,

semptom şiddeti ölçek puanına göre ikinci düzeyde bir ayırım yapmaktadır. Modelin semptom şiddeti eşik değeri 25 puan altı veya üstü ile karar vermesi, veri setinde bu eşikten sonra sınıflar arasında anlamlı bir fark oluştuğunu ve bu sayede doğruluğun optimize edildiğini göstermektedir. Karar ağacında bir sonraki belirleyici değişken EQ-5D-3L indeks puanıdır. Modelde bu değişkenin $\leq 1,0$ eşik değeri ile sınıflandırma yaptığı görülmektedir. Tanımlayıcı tabloda bu eşik $<0,60$ olarak belirtilmiş olsa da modelin daha üst bir değeri kullanması, veri üretiminde bu sınırdaki homojenliğin daha üst düzeyde sağlandığını düşündürmektedir. Ardından gelen değişken SKB olup, karar ağacında SKB eşik değeri 134 mmHg ile ayırım yapılmaktadır. Bu değer, klinik eşik olan >140 mmHg ile doğrudan örtüşmese de, karar ağacının optimal ayırımı sağlamak adına bu şekilde bir sınır belirlemiş olması, modelin sınıf ayırımını maksimize etmeye çalıştığını göstermektedir. Gözlenen bu küçük sapmalar, modelin klinik anlamı bozmadan en iyi ayırımı sağlayan eşikleri belirleme eğilimindedir. Modelin karar ağacında diğer özniteliklerin yer almamış olması, bu değişkenlerin modelin sınıflandırma başarısına anlamlı katkı sağlamadığı ya da diğer değişkenler tarafından temsil edilebilir nitelikte olduğunu ortaya koymuştur. Modelin doğruluk oranı “Etkisiz Sağlık Öz Yönetimi” hemşirelik tanısını belirlemede %97 olarak bulunmuştur (Tablo 19).



Şekil 11: Etkisiz Sağlık Öz Yönetimi Karar Ağacı Modeli

Tablo 20: Etkisiz Sağlık Öz Yönetimi Tanısına Ait Model Performans Göstergeleri


Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.95	0.97	100
1	0.95	1.00	0.98	100
Genel Doğruluk (Accuracy)			0.97	200
Macro Ort.	0.98	0.97	0.97	200
Ağırlıklı Ort.	0.98	0.97	0.97	200

4.3.2.6. Kırılğan yaşlı sendromu

Tablo 21: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Kırılğan Yaşlı Sendromu Tanısına İlişkin Öznitelikler

Öznitelik	Tanımlayıcı özellikler/ilişkili faktörler
Yaş	> 70
EKÖ puanı	≥ 9 puan
Düşme risk puanı	≥ 10 puan
KM-SŞÖ puanı	> 25 puan
EQ-5D-3L ölçek puanı	< 0,60
EQ-5D-3L VAS skoru	≤ 40 puan altı

İlgili tanının karar ağacı modelinde sınıflandırma, ilk olarak “semptom şiddeti” değişkenine göre gerçekleştirilmiştir (Şekil 12). Bu değişken 25 puan ve altı olduğunda tüm bireyler 'Hayır' sınıfına ait olarak sınıflandırılmıştır. Bu durum, semptom şiddetinin düşük olduğu bireylerde sendromun görülme olasılığının minimal olduğunu göstermektedir. Semptom skoru eşik değerin üzerinde olduğunda, karar ağacı ikinci seviyede “EQ-5D-3L VAS skoru” değişkenine göre bir ayırım yapmaktadır. Bu noktada ≤ 41 olan bireyler “Evet” sınıfına yönlendirilmiş, bu eşik değerin üzerinde kalan bireyler ise yeniden negatif sınıfa atanmıştır. Bu sonuç, yaşam kalitesi algısı düşen bireylerde kırılğanlık semptomlarının daha belirgin olduğunu desteklemektedir. Modelin derin katmanlarında ise düşme riski ve EKÖ puanları kritik ayırım ölçütü olarak öne çıkmaktadır. Özellikle EKÖ puanı 9 üstünde olan bireylerin tamamının “Evet” sınıfına atanması, bu ölçeğin tanının belirlenmesinde yüksek ayırt ediciliğe sahip olduğunu göstermektedir. Modelin doğruluk performansı “Kırılğan Yaşlı Sendromu” hemşirelik tanısını belirlemede %98 olarak hesaplanmıştır (Tablo 21).



Şekil 12: Kırılğan Yaşlı Sendromu Karar Ağacı Modeli

Tablo 22: Kırılğan Yaşlı Sendromu Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.96	0.98	100
1	0.96	1.00	0.98	100
Genel Doğruluk (Accuracy)			0.98	200
Macro Ort.	0.98	0.98	0.98	200
Ağırlıklı Ort.	0.98	0.98	0.98	200


4.3.2.7. Kan basıncında değişkenlik riski

Tablo 23: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Kan Basıncında Değişkenlik Riski Tanısına İlişkin Öznitelikler

Öznitelik	Risk Faktörleri
HT varlığı	Evet
İlaç sayısı	≥ 5
SKB	> 140 mmHg veya < 100 mmHg
TSH	$> 4,5$ mU/L veya $< 0,4$ mU/L
Sodyum (Na ⁺)	< 135 mEq/L veya > 145 mEq/L

İlgili hemşirelik tanısı ile ilişkili modelin kök düğümünde HT varlığı yer almakta olup, bu değişken risk sınıflandırmasında belirleyici bir ön koşul olarak değerlendirilmiştir (Şekil 13). HT bulunmayan bireylerin tamamı risk taşımayan grup olarak sınıflandırılmıştır ki bu durum, HT'nin tanının temel belirleyicisi olduğunu göstermektedir. HT varlığı saptanan bireylerde ise ikinci ayırım noktası olarak ilaç sayısı değerlendirilmiştir. İlaç sayısının beş veya daha fazla olması,

modelde yüksek riskin belirleyicisi olarak öne çıkmakta, bu eşik değerin altında kalan bireyler ise çoğunlukla düşük risk grubuna dahil edilmektedir. Modelde üçüncü seviyede TSH düzeyi dikkate alınmaktadır. Karar ağacında TSH için 4,0 mU/L eşiği altında ve üstünde kalanlara göre sınıf atamaları yapılmıştır. Öte yandan, modelin karar ağacında SKB ve sodyum gibi temel özniteliklerin modelin sınıflandırma başarısına anlamlı katkı sağlamadığı görülmüştür. SKB değişkeninin modelde yer almaması, değişkenler arası korelasyon etkisinin bir sonucu da olabilir. Örneğin, HT varlığı zaten yüksek SKB ile ilişkili olduğundan, model HT değişkenini kullanarak SKB bilgisini dolaylı olarak içermiş olabilir. Bu iki öznitelik yer almamasına rağmen, modelin performans ölçütleri incelendiğinde, doğruluk oranının %99, pozitif sınıf için hassasiyetin 1,00 ve özgüllüğün 0,99 olması dikkat çekicidir (Tablo 23). Bu sonuçlar, modelin hem yüksek riskli bireyleri doğru sınıflandırmada hem de düşük riskli bireylerde yanlış pozitiflik üretmemede son derece başarılı olduğunu ortaya koymaktadır. Modelin sunduğu bu yapı, özellikle HT hastası bireylerde çoklu ilaç kullanımı ve tiroit fonksiyonlarının dikkatle izlenmesi gerektiğine dair önemli bir klinik farkındalık sağlamaktadır.



Şekil 13: Kan Basıncında Değişkenlik Riski Karar Ağacı Modeli

Tablo 24: Kan Basıncında Değişkenlik Riski Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.99	0.99	100
1	0.99	1.00	1.00	100
Genel Doğruluk (Accuracy)			0.99	200
Macro Ort.	1.00	0.99	0.99	200
Ağırlıklı Ort.	1.00	0.99	0.99	200


4.3.2.8. Kardiyovasküler fonksiyon bozulma riski

Tablo 25: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Kardiyovasküler Fonksiyon Bozulma Riski Tanısına İlişkin Öznitelikler

Öznitelik	Risk Faktörleri
DM+HT+KAH varlığı	Evet
Sigara Kullanımı	Evet/İçiyor
Total Kolesterol	> 200 mg/dL
Trigliserid	> 150 mg/dL
HbA1c	> %8.0
TSH	> 4,5 mU/L veya < 0,4 mU/L
Ürik asit	> 7,0 mg/dL

İlgili tanıya yönelik oluşturulan karar ağacı modelinin kök düğümünde yer alan değişken, bireyde DM, HT ve KAH'nın bulunup bulunmadığını gösteren birleşik tanı değişkenidir (Şekil 14). Eğer bu üç kronik hastalığa sahip olunmadığı durumda, model doğrudan "kardiyovasküler bozulma yok" (No) sınıfına yönelmektedir. Ancak bireyde en az iki kronik hastalık varlığı söz konusuysa, model ikinci düzeyde sigara kullanımı değişkenine başvurmaktadır. Sigara içmeyen bireyler, "bozulma yok" olarak sınıflandırılmış; sigara kullanımı mevcut ise model bireyin doğrudan "kardiyovasküler fonksiyon bozulma riski var" (Yes) sınıfına dahil edildiği bir terminal düğümle sonuçlanmaktadır. Modelin karar ağacında diğer özniteliklerin yer almamış olması, bu değişkenlerin modelin sınıflandırma başarısına anlamlı katkı sağlamadığı ya da diğer değişkenler tarafından temsil edilebilir nitelikte olduğunu düşündürmektedir. Özellikle kronik hastalıklar ve sigara kullanımı gibi güçlü belirleyicilerle yapılandırılan bu basit ama etkili karar ağacı, yorumlanabilirliği yüksek ve klinik karar destek süreçlerinde kullanılabilir bir model yapısı ortaya koymaktadır. Modelin genel doğruluk oranı "Kardiyovasküler

Fonksiyon Bozulma Riski” hemşirelik tanısını belirlemede %100 olup yüksek performans göstermiştir (Tablo 25).



Şekil 14: Kardiyovasküler Fonksiyon Bozulma Riski Karar Ağacı Modeli

Tablo 26: Kardiyovasküler Fonksiyon Bozulma Riski Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	1.00	1.00	100
1	1.00	1.00	1.00	100
Genel Doğruluk (Accuracy)			1.00	200
Macro Ort.	1.00	1.00	1.00	200
Ağırlıklı Ort.	1.00	1.00	1.00	200


4.3.2.9. Elektrolit dengesizliği riski

Tablo 27: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Elektrolit Dengesizliği Riski Tanısına İlişkin Öznitelikler

Öznitelik	Risk Faktörleri
Yaş	≥ 75
Sodyum (Na ⁺)	< 135 mEq/L veya > 145 mEq/L
İlaç Sayısı	≥ 5
SKB	> 140 mmHg veya < 100 mmHg
Kalp Hızı	> 100 bpm

İlgili tanıya ilişkin geliştirilen karar ağacı modelinin kök düğümünde yer alan yaş değişkeni, karar ağacının ilk ve en ayırt edici sınıflayıcısı olarak öne çıkmakta ve 75 yaş ve üzerindeki bireyler, elektrolit dengesizliği açısından daha yüksek risk grubuna dahil edilmektedir (Şekil 15). Karar ağacının ikinci seviyesinde ilaç sayısı öne çıkmakta ve beş ve üzeri ilaç kullanan bireylerin, polifarmasiye bağlı olarak elektrolit bozukluklarına daha yatkın olduğu görülmektedir. Üçüncü seviyede ise

kalp hızı değişkeni devreye girmekte ve 100 bpm üzerindeki değerler, özellikle sıvı-elektrolit dengesizliğine bağlı olarak gelişebilecek taşikardi gibi semptomlara işaret etmektedir. Modelde kalp hızı için belirlenen eşik değeri 73 bpm gibi görünmekle birlikte, bu sınır veri dağılımına bağlı olarak değişebilmekte ve örneklem bazında adaptif olarak belirlenmiş olabileceği değerlendirilmektedir. Bu noktada modelin, klinik eşik değerler ile istatistiksel optimum sınırları dengeli bir biçimde kullandığı gözlemlenmektedir. Öte yandan, modelin karar ağacında sodyum gibi temel elektrolitin modelin sınıflandırma başarısına anlamlı katkı sağlamamış olması ise dikkat çekicidir. Sonuç olarak, geliştirilen karar ağacı modeli, yaş, ilaç kullanımı ve kalp hızı gibi klinik olarak anlamlı değişkenleri temel alarak, “Elektrolit Dengesizliği Riski” hemşirelik tanısını %98 doğrulukla öngörebilmektedir (Tablo 27).



Şekil 15: Elektrolit Dengesizliği Riski Karar Ağacı Modeli

Tablo 28: Elektrolit Dengesizliği Riski Tanısına Ait Model Performans Göstergeleri


Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.97	0.98	100
1	0.97	1.00	0.99	100
Genel Doğruluk (Accuracy)			0.98	200
Macro Ort.	0.99	0.98	0.98	200
Ağırlıklı Ort.	0.99	0.98	0.98	200

4.3.2.10. Etkisiz renal perfüzyon riski

Tablo 29: Uzman Görüşüne Dayalı Belirlenen ve Karar Ağacı Modelinde Test Edilen Etkisiz Renal Perfüzyon Riski Tanısına İlişkin Öznitelikler

Öznitelik	Risk Faktörleri
DM+HT varlığı	Evet
Yaş	≥ 75
İlaç Sayısı	≥ 5
HbA1c	$> \%8,0$
SKB	< 100 mmHg
BUN	> 20 mg/dL

Modelin kök düğümünde yer alan "DM ve HT" birleşik değişkenin bir arada bulunmaması ($DM+HT \leq 0$) halinde bireylerin büyük çoğunluğunun renal perfüzyon riski taşımadığı ve bu grubun tamamen "No" sınıfına ait olduğu gözlemlenmiştir. Buna karşılık her iki kronik hastalığa da sahip bireylerde ise değerlendirme daha ileri düzey değişkenlerle detaylandırılmıştır (Şekil 16). İkinci seviyede yer alan değişken "SKB" olup, 100 mmHg eşiği belirleyici bir rol oynamaktadır. Hipotansif bireylerin büyük çoğunluğu riskli sınıfa aitken, normotansif ya da hipertansif bireylerde riskin değerlendirilmesi daha karmaşık hale gelmiştir. Bu grupta model sırasıyla HbA1c ve BUN düzeylerini dikkate alarak ayırım yapmaktadır. HbA1c düzeyinin $\%8,0$ 'in altında olması durumunda dahi model bazı istisnai örnekleri "No" sınıfına atarken, eşik üzerindeki bireylerde BUN düzeyinin 15 mg/dL'nin üstünde olması halinde tekil bir örnek dışında tüm bireylerin riskli sınıfa ait olduğu gözlemlenmiştir. Modelin karar ağacında yaş ve ilaç sayısının yer almamış olması, bu değişkenlerin modelin sınıflandırma başarısına anlamlı katkı sağlamadığı ya da diğer değişkenler tarafından temsil edilebilir nitelikte olduğunu ortaya koymuştur. Elde edilen istatistiksel ölçütler doğrultusunda modelin "Etkisiz Renal Perfüzyon Riski" hemşirelik tanısını belirlemede doğruluk oranı $\%99$ olarak hesaplanmıştır (Tablo 29).



Şekil 16: Etkisiz Renal Perfüzyon Riski Karar Ağacı Modeli

Tablo 30: Etkisiz Renal Perfüzyon Riski Tanısına Ait Model Performans Göstergeleri

Sınıf	Doğruluk (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
0	1.00	0.99	0.99	100
1	0.99	1.00	1.00	100
Genel Doğruluk (Accuracy)			0.99	200
Macro Ort.	1.00	0.99	0.99	200
Ağırlıklı Ort.	1.00	0.99	0.99	200

5. TARTIŞMA

Bu tez çalışması üç aşamada gerçekleştirildiğinden tartışma bölümü; kardiyometabolik multimorbidesi olan yaşlı hastalarda bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını belirlemede KDSS'nin geliştirilmesine yönelik hemşire görüşlerini içeren nitel aşama, KM-SŞÖ'nin geliştirilmesi ve geçerlik güvenirliği ve KKDS geliştirilmesine yönelik verilerden elde edilen bulguların tartışılması şeklinde üç bölümde sunulmuştur.

5.1. BİRİNCİ AŞAMA: HEMŞİRE GÖRÜŞLERİNE İLİŞKİN NİTEL SONUÇLARIN TARTIŞILMASI

Bu çalışmada, bakım sürecinde yaşananlar, bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını önceliklendirme ve KKDS geliştirilmesine yönelik görüşler olmak üzere üç ana tema ortaya çıkmıştır. Bu çalışmanın bulguları, hemşirelerin kardiyometabolik multimorbiditesi olan yaşlı hastaların hemşirelik bakımına KKDS'lerin entegrasyonuna ilişkin bakış açılarını, algılarını ve ihtiyaçlarını kapsamlı bir şekilde ortaya koymuştur.

5.1.1. Bakım Sürecinde Yaşananlar

Bu nitel araştırmada, kardiyometabolik multimorbiditesi olan yaşlı hastalara bakım veren hemşireler, bakım sürecinde iletişim ve iş yüküyle ilgili zorluklar yaşadıklarını bildirmiştir. Hemşirelerin bakım sürecinde yaşadıklarının ortaya konması, makine öğrenimi tabanlı KKDS'nin geliştirilmesinin fizibilitesini değerlendirmek için mevcut ihtiyaçların keşfedilmesi açısından kilit öneme sahiptir. Bu doğrultuda, hemşire ifadeleri yaşlı hastalarda psikolojik engeller ve

bilişsel gerileme nedeniyle bakım sürecinde iletişim zorluklarının yaşandığını ortaya koymuştur. Benzer şekilde, Rezaei-Shahsavarloo, Atashzadeh-Shoorideh, Ebadi ve Gobbens (2021), yaşlı bireylerin depresyon gibi psikolojik sorunlar veya deliryum gibi bilişsel bozukluklardan sıklıkla etkilendiğini ve bu kırılgan hastaların ihtiyaçlarını doğru ifade etmekte zorlandıklarını, dolayısıyla iletişimin güçleştiğini vurgulamaktadır. Whitehead ve ark. (2022) tarafından yapılan bir sistematik derleme ise, çoklu kronik hastalığı olan yetişkinlere bakımda hemşirelerin algılarını ve inançlarını inceleyen 11 nitel çalışmanın bulgularını analiz etmiştir. Bu derlemenin önemli sonuçlarından biri, etkili bakım için terapötik bir hemşire-hasta ilişkisinin kurulmasının kritik olduğudur (Whitehead et al 2022). Bu bağlamda, yaşlı hastalarda bilişsel gerileme ve psikolojik engeller, hemşire-hasta iletişimde önemli zorluklara yol açmakta ve bakım sürecinin verimliliğini olumsuz etkilemektedir. Bu tür zorlukların üstesinden gelmek ve terapötik hemşire-hasta ilişkisinin gelişimini kolaylaştırmak için, makine öğrenimi tabanlı bir KKDS daha etkili bir bakım süreci sunabilir.

Bu tema altında, çoklu kronik hastalığı olan kırılgan yaşlı hastaların fiziksel ve psikososyal zorluklarının, zaman kısıtlılığı ve bakım karmaşıklığıyla birleşerek hemşirelerde artan iş yüküne ve tükenmişlik hissine katkıda bulunduğu ortaya çıkmıştır. Benzer şekilde, Podgorica, Pjetri, Müller ve Perkhofer (2024), hemşirelerin yaşlı yetişkinlere bakım sağlarken karşılaştıkları zorlukları yansıtan önemli bir alt tema olarak “yetersiz zaman”ı tanımlamış ve bazı hemşirelerin optimal bakım sağlayamadıkları için suçluluk hissettiklerini bildirmiştir. Diğer çalışmalar da hemşirelerin yaşlı bakım evlerinde sıklıkla duygusal stres ve tükenmişlik yaşadığını, hastalarla bağ kurmaktan kaynaklanan duygusal tatminle fiziksel ve psikolojik yorgunluk arasındaki gerilimi vurgulamaktadır (Rachel and Francesco 2018, Heydari, Sharifi ve Moghaddam 2019, Foà et al 2020). Bu bağlamda, çoklu kronik hastalığı olan yaşlı hastaların bakım ihtiyaçlarını sınıflandırabilen bir makine öğrenimi tabanlı KKDS, hemşirelerin zaman yönetimine dayalı olarak bakım süreçlerini daha etkin planlamalarına yardımcı olabilir ve böylece iş yükünü azaltarak duygusal stresi hafifletebilir.

5.1.2. Bakım Gereksinimlerini Sınıflandırma ve Hemşirelik Tanılarını Önceliklendirme

Bu ana tema altında çalışmaya katılan hemşireler, yaşlı multimorbiditesi olan hastalarda bakımın karmaşıklığı nedeniyle bakım gereksinimlerinin sınıflandırılmasının zor olduğunu vurgulamışlardır. Ayrıca, hemşirelerin bakım gereksinimlerini sınıflandıramadıkları için bütüncül olarak hastayı değerlendiremedikleri ve kişiselleştirilmiş bakım planlayamadıkları öne çıkan bulgulardır. Literatür incelendiğinde, birden fazla kronik hastalığın yönetimi için gereken klinik karar verme sürecinin karmaşıklığı ve bu sürecin yönetiminin hemşireler için zaman alıcı olduğu belirtilmektedir (Younas and Inayat 2023). Ayrıca, çoklu hastalığı olan hastaların karmaşık sağlık bakım ihtiyaçları, hemşirelerin tek bir hastalık yaklaşımının ötesine geçerek daha bütünlük bir bakım sunabilmesinin önemli olduğu vurgulanmaktadır (Younas and Inayat 2023). Yoğun bakım ünitesinde yaşlı yetişkin hastalara bakım sağlamanın zorlukları ve engellerinin incelendiği nitel bir araştırmada, yaşlı hastaların aynı anda birden fazla hastalıktan muzdarip olmasının hemşirelik bakımını karmaşık ve zaman alıcı hale getirdiği raporlanmıştır (Heydari et al 2019). Benzer şekilde, Webster ve ark. (2019) çalışmalarında hemşirelerin kompleks bakım ihtiyacı olan hastalara kaliteli bakım sunmak için sıklıkla öğrenilmiş becerilerinin ve yeterliliklerinin ötesine geçmek zorunda olduklarını belirtmiştir. Aynı çalışma, çoklu hastalığı ve karmaşık sağlık ihtiyaçları olan hastaların acısını hafifletmenin, hemşireler için genel hasta popülasyonuna kıyasla daha zorlayıcı olabileceğine dair kanıtlar sunmaktadır (Webster et al 2019). Wu ve ark. (2023) Çin'de multimorbiditesi olan yaşlı yetişkinler için entegre bakımın kolaylaştırıcıları ve engellerine yönelik hemşire görüşlerinin ele alındığı nitel çalışmada, bireyselleştirilmiş bir bakım planı kullanılarak hastanın değişen sağlık sorunlarına, ihtiyaçlarına, önceliklerine ve hedeflerine odaklanmanın, çoklu hastalığı olan yaşlı yetişkinlere bütüncül ve kişiselleştirilmiş bir bakım sağlamada önemli bir kolaylaştırıcı olduğu belirtilmiştir. Avustralyalı hemşirelerin multimorbidite ile yaşayan yetişkinlere yönelik bakım sağlama deneyimlerinin incelendiği nitel çalışmada, hemşireler, multimorbidite alanını karmaşık olarak tanımlamıştır (Whitehead et al 2023). Aynı çalışmada, kişi

merkezli deęerlendirmenin önemini belirtilmiş olup bakım planlarının kişi merkezli bir yaklaşıma sahip olması gerektięi ifade edilmiştir (Whitehead et al 2023).

Öte yandan, hemşirelik tanılarının önceliklendirilmesi alt teması altında hemşireler hastaların yaşamsal fonksiyonlara öncelik vererek kritik ve acil durum müdahale gereksinimine göre hastaları ele aldıklarını ifade etmiştir. Çoęu hemşire tarafından belirtilen önemli noktalardan biri ise hastanın gereksinimlerine ve klinik durumuna özgü olamayan standartlaşmış tanıların kullanımıdır. Düşme riski, enfeksiyon riski gibi hemşirelik tanıları hasta servise yattığında rutin olarak elektronik sistemden alınmakta ve her hasta için en sık kullanılan tanıları oluşturmaktadır. Bu durum hemşirelerin iş yükü, zaman yetersizlięi, çok sayıda hastaya bakım verme nedenleri ile kişiselleştirilmiş bakım sağlayamamaları ve elektronik sistemden otomatik tanıları koyma eğiliminde olmaları ile ilişkilendirilebilir. Benzer şekilde bir çalışmada çeşitli engellerden muzdarip yaşlı hastaların karmaşık ihtiyaçlarının yeterince karşılanamadığı ve yaşlı hastalara sağlanan bakımın çoęunun rutin ve palyatif olduęu belirtilmiştir (Docherty, Anderson, Walsh and Lone 2016). Heydari ve ark. (2019) yoğun bakım ünitesinde yaşlı yetişkin hastalara bakım sağlamanın zorlukları ve engelleri açısından hemşirelerin deneyimlerini inceledikleri nitel çalışmasında, hemşireler hemşirelik bakımının genellikle rutin tabanlı müdahaleleri içerdığını ve yaşlı hastaların bakımı için özel bir sistemlerinin olmadığını raporlamıştır. Bu bağlamda, bakım gereksinimlerini sınıflandırmaya yönelik geliştirilecek bir KKDS, hastaların çoklu karmaşık sağlık durumlarını izleme ve tedavi planlarını optimize etmede klinik rehberlik sağlayabilir. Ayrıca, karmaşık bakım süreçlerini basitleştirerek hemşirelerin kişiselleştirilmiş ve bütüncül bir bakım sağlamasını kolaylaştırabilir.

5.1.3. Klinik Karar Destek Sistemi Geliştirilmesine Yönelik Görüşler

Hemşireler, KKDS geliştirilmesine yönelik görüşler ana teması altında yaşlı hastalarda risk yönetimini kolaylaştırma, bakım kalitesini artırma ve iş yükünü hafifletme konusunda olumlu görüşler bildirmiştir. Öte yandan, YZ tabanlı bir karar destek sisteminin uygulanabilirlik ve güvenilirlik açısından klinięe entegrasyonunda endişeleri olduğunu dile getirmişlerdir. Çalışma bulgularımıza benzer şekilde, Rony ve ark. (2024) hemşirelik profesyonellerinin YZ'nin sağlık hizmetlerinin

geleceğini şekillendirmedeki rolüne ilişkin algılarını inceledikleri nitel çalışmada YZ'ye yönelik “faydalar ve endişeler” temasını ortaya koymuştur. Aynı çalışmada, hemşireler, YZ'nin erken teşhis, hayat kurtarma ve rutin görevleri kolaylaştırma konusundaki potansiyelini öngörmüş ancak ayrıntıların göz ardı edilmesi ve bütüncül bakımın korunması konusunda endişelerini dile getirmiştir (Rony et al 2024).

Makine öğrenimine dayalı KKDS'leri, kritik tıbbi göstergelerin erken tespiti, hata riskini azaltma, hızlı müdahaleleri geliştirme ve komplikasyonları önleme potansiyeli sunmaktadır (Jordan, Hauser, Cota, Li and Wolf 2023). Rony ve ark. (2024) YZ sistemlerinin, büyük miktarda hasta verisini hızla işlemede kolaylık sunduğu ve doğru klinik karar desteği sağlayarak hata riskinin azaltacağını ve hasta sonuçlarını iyileştireceğini belirtmiştir. Bu yararlarına ek olarak, bu araştırmaya katılan hemşirelerin de belirttiği üzere YZ'nin hemşireliğe entegre edilmesini sağlayan temel motivasyonlardan biri, hasta bakımının kalitesini artırma potansiyelidir. Araştırmamızda, hemşireler KKDS'nin klinik karar vermeyi kolaylaştıracağı, bireyselleştirilmiş ve bütüncül yaklaşım sunarak bakım kalitesini arttıracığını ifade ettiler. Chen ve Decary (2020) YZ algoritmalarının hasta kayıtlarını tarayarak kişiselleştirilmiş tedavi planlarını önerebileceğini bildirmiştir. Liaw ve ark. (2023) YZ'nin analitik becerisinin bireysel hasta ihtiyaçlarına titizlikle uyarlanmış bireyselleştirilmiş tedavi planlarının oluşturulmasına olanak sağlayarak hasta bakımında yeni bir çağın kapısını açtığına dikkat çekmiştir. Benzer şekilde, Kwon ve ark. (2019) hemşirelerin makine öğrenimini benzersiz hemşirelik bilgisiyle birleştirerek, hasta bakımını kişiselleştirebileceği ve bakım kalitesini iyileştirebileceğini raporlamıştır. Ayrıca, bu araştırmaya katılan hemşireler, YZ tabanlı bir KKDS'nin bakım süreçlerini hızlandırma ve daha etkin bir zaman yönetimi sağlayarak iş yüklerini hafifletmesini potansiyel faydalardan biri olarak dile getirmiştir. YZ'nin erken tanı ve müdahaleyi kolaylaştırma kapasitesine yönelik artan ilgi, hemşireleri rutin görevlerden kurtarma potansiyeli ile birleşerek, YZ'nin klinik karar alma süreçlerini geliştirme, iş akışı verimliliğini optimize etme ve iş yükünü azaltmadaki rolünü vurgulayan önceki nitel araştırmaların bulgularını desteklemektedir (Clavelle, Sweeney, Swartwout, Lefton and Guney 2019, Laukka, Hammarén and Kanste 2022, Rony et al 2024). Bu bağlamda, makine öğrenimi

tabanlı KKDS'leri, özellikle yaşı bakımının yönetiminde hemşireleri rutin görevlerden kurtarması, profesyonel mesleki becerilerini ve enerjilerini karmaşık hasta ihtiyaçlarına yönlendirebilecekleri ve daha derin bağlantılar kurabilecekleri bir gelecek öngörmektedir. Bu vizyon, hemşirelerin klinik prosedürlerin ötesine uzanan bütüncül ve sistematik bakım sağlama sorumlulukları ile uyumludur (Chen and Decary 2020).

Öte yandan, KKDS'lerin uygulanabilirliğinin veya entegrasyon süreçlerinin karmaşıklığı, sistemin sağlık ortamında tam anlamıyla etkili bir şekilde kullanılmasını engelleyebilir. Ayrıca, bazı sistemler, kullanıcıların çok fazla veri girmesini gerektirdiğinde ya da sistemin yanıt süreleri yavaş olduğunda, bakım süreçlerini yavaşlatabilir ve sağlık çalışanlarının daha fazla zaman harcamasına neden olabilir. Eksik veya yanlış veri girişleri ise hastalar için zararlı sonuçlara yol açabilecek yanlış kararlar önerilmesine neden olabilir. Bu araştırmada, hemşireler tarafından bildirilen KKDS'lere yönelik olumlu görüşlerin yanında, bu sistemlerin klinik ortamda uygulanabilirliği ve hasta bakım süreçlerinde güvenilirliği açısından endişelerinin olduğu ortaya konmuştur. Bu bulgularımız, hemşirelerin YZ tabanlı KKDS'leri uygulamaya yönelik dikkatli olmaları gerektiğine dair bir yaklaşıma vurgu yapması, YZ entegrasyonu bağlamında veri güvenliği, hatalı uyarılar ve öneriler ilgili endişelerin ele alınmasının zorunluluğunu vurgulayan diğer çalışmaların sonuçları ile örtüşmektedir (Hassan, Slight and Slight 2022, Rony et al 2024). Araştırmamızda uygulanabilirlik açısından hemşireler en çok teknolojiye uyumsuzluk, sistem karmaşıklığı ve teknolojik altyapı yetersizlikleri nedeniyle entegrasyon zorlukları konusunda endişelerini belirtmişlerdir. Benzer şekilde, hemşirelerde gerçekleştirilen bir nitel çalışmanın temalarından birini oluşturan “YZ uygulama engelleri” arasında klinik ortama başarılı bir entegrasyon için sınırlı kaynaklar ve teknolojiye direnç yer almıştır (Rony et al 2024). Kwon ve ark. (2019) makine öğrenimi klinik karar vermeyi desteklemek için giderek daha fazla uygulansa da bunun ne olduğu ve hemşirelerin pratikte nasıl benimsemeleri gerektiği konusunda önemli bir anlayış boşluğu olduğunu bildirmiştir.

Öte yandan, KKDS'lerin güvenilirliği konusunda deneyimli bir gözlemci hemşire tarafından algılanabilen ayrıntıların gözden kaçırma ve yanlış uyarılar verme olasılığı yüzünden tekrar kontrol etme gerekliliği dikkate değer bir endişe olarak

karşımıza çıkmaktadır. Weber (2007) bilgisayar tabanlı karar destek sistemleriyle birlikte kritik bakım hemşire uygulayıcıları ve klinik hemşire uzmanları olarak çalışan hemşirelerin deneyimlerini inceledikleri çalışmasında, katılımcıların sistemden türetilen verilere ilişkin göreceli güven duyduklarını raporlamıştır. Bu endişeler, teknoloji gelişmeye devam ederken bile hemşireliğin merkezinde yer alan kişilerarası boyutunu sürdürme önemini ve benzersiz insan bağlantısının korunması konusundaki endişeleri vurgulayan mevcut literatürle örtüşmektedir (Shorey et al 2020, Rony et al 2024). Benzer şekilde, bir çalışmada hemşirelerin makine öğrenimi algoritmalarının her hastanın kişiselleştirilmiş bakımına ilişkin benzersiz bilgileriyle şekillendirilmesini sağlamada önemli bir rol oynadığı vurgulanmıştır (Kwon et al 2019). Bu bağlamda, YZ tabanlı bir KKDS'nin başarılı entegrasyonu için uygulama zorluklarının aşılması ve hemşirelerin uyum sağlama ve yenilikçilik kültürünü teşvik ederek sorunsuz bir şekilde çoklu kronik hastalığı olan yaşlı bireylerin bakım sürecine dahil etmelerini sağlayacak proaktif yaklaşım geliştirmeleri önemlidir.

Sonuç olarak, araştırmanın bu nitel aşaması, kardiyometabolik multimorbiditesi olan yaşlı hastalara bakım verirken hemşirelerin iletişim engelleri ve iş yükü gibi önemli zorluklarla karşılaştığını ve bu karmaşık bakım ihtiyaçlarının bütüncül bir yaklaşımla ele alınması gerektiğini ortaya koymuştur. Çalışmanın bir diğer önemli bulgusu ise hemşirelerin sıklıkla standart tanımlara dayalı bakım uygulamaları yürüttüklerini ve bu nedenle hasta odaklı ihtiyaçları tam olarak karşılayamayan rutin bakım süreçlerinin ortaya çıktığını göstermiştir. Bu bulgular, kardiyometabolik multimorbiditesi olan yaşlı bireylerin karmaşık bakım ihtiyaçlarını sınıflandırabilen ve daha ayrıntılı hemşirelik tanımlarına katkı sağlayabilen bir makine öğrenimi tabanlı KKDS'nin geliştirilmesi gerekliliğini vurgulamaktadır. Çalışmada yer alan hemşireler, böyle bir KKDS'nin risk yönetimini iyileştirme, bakım kalitesini artırma ve iş yükünü hafifletme potansiyelini olumlu bir şekilde değerlendirmiş; ancak, sistemin entegrasyonu ve klinik ortamlardaki uygulanabilirliği konusundaki kaygılarını da dile getirmişlerdir. Bu nedenle, kardiyometabolik multimorbiditesi olan yaşlı hastaların bakımına özgü zorlukları ve hemşirelerin uygulama konusundaki endişelerini dikkate alan, ihtiyaç doğrultusunda geliştirilmiş bir makine öğrenimi tabanlı KKDS; bakım

ihtiyalarının sınıflandırılmasını ve hemşirelik tanılarının belirlenmesini destekleyerek hemşirelik bakımının kalitesini artırabilir ve hasta sonuçlarını iyileştirebilir.

5.2. İKİNCİ AŞAMA: KARDİYOMETABOLİK MULTİMORBİDİTELİ YAŞLI HASTALARDA SEMPTOM ŞİDDETİ ÖLÇEĞİNİN (KM-SSÖ) GEÇERLİK VE GÜVENİRLİĞİNE İLİŞKİN SONUÇLARIN TARTIŞILMASI

Bu ölçek, kardiyometabolik multimorbiditesi olan ve yatarak tedavi gören yaşlı hastalarda ortak görülen ve yaşam kalitesini etkileyen semptomların şiddetini belirlemek amacıyla geliştirilmiştir. Bu çalışma, tek faktörlü yapıdan oluşan KM-SSÖ'nin kapsam, yapı geçerliği ve güvenirlik açısından kriterleri karşıladığını ve ölçeğin kardiyometabolik multimorbidite tanısı olan hastalarda kolayca kullanılabileceğini göstermiştir.

Ölçeğin yapı geçerliğini değerlendirmek amacıyla Kaiser-Meyer-Olkin (KMO) katsayısı ile Bartlett Küresellik Testi kullanılmıştır (Green and Yang 2015, Shrestha 2021). Literatürde, KMO katsayısının 0,60'ın üzerinde ve 1'e yakın olması, verilerin faktör analizine uygunluğunu göstermektedir. KMO değeri 0,50'nin üzerinde olduğunda analiz yapılabilmesi kabul edilirken, 0,70–0,80 arası değerler orta düzeyde; 0,80–0,90 arası değerler iyi düzeyde; 0,90 üzerindeki değerler ise mükemmel düzeyde örneklem yeterliliğine işaret etmektedir (Green and Yang 2015, Shrestha 2021). Bartlett testinin anlamlı çıkması, maddeler arasındaki korelasyonların faktör analizi için uygun yapıda olduğunu gösterir. Bu araştırmada da yapı geçerliğinin belirlenmesinde aynı istatistiksel testler kullanılmış; KMO katsayısı 0,965 olarak saptanmış ve Bartlett testi anlamlı bulunmuştur. Bu sonuçlar, çalışmada yer alan örneklemin faktör analizine uygun olduğunu ve ölçek üzerinde geçerlik analizlerinin güvenle gerçekleştirilebileceğini göstermektedir.

5.2.1. Geçerlik Analizleri

Açımlayıcı faktör analizi sonuçları değerlendirilirken ölçeğin tek faktörlü ya da çok faktörlü yapıda olması durumunun özellikle dikkate alınması gerektiğinin altı çizilmektedir (Schreiber 2021). Literatürde tek faktörlü ölçeklerde toplam varyansın en az %30'nun açıklanması gerektiği ve %40 ila %60 arasında ideal olduğu bildirilmektedir (Schreiber 2021, Shrestha 2021). Araştırmamızda yapılan AFA sonucuna göre, KM-SŞÖ'nin tek faktörlü yapısı olduğu ortaya çıkmış ve ölçekteki faktörlerin toplam varyansın %65,753'ünü açıkladığı görülmüştür. Bu bulgu, ölçeğin maddelerinin birbirleri ile yeterli düzeyde ilişkili olduğunu göstermiştir (Boateng et al 2018). Ayrıca, Scree Plot grafiği, faktör analizi sonuçlarına ilişkin özdeğerlerin (eigenvalue) bileşenlere göre dağılımını göstermektedir (Reijer, Otter and Jacobs 2024). Grafikte birinci bileşenin özdeğeri diğerlerinden belirgin şekilde yüksek bir değere sahiptir ve ardından gelen bileşenlerde hızlı bir düşüş gözlemlenmektedir. Bu durum, ölçeğin tek faktörlü bir yapıya sahip olduğunu desteklemiştir. Özellikle, grafikteki "eğim kırılması" (elbow point) birinci bileşenin ardından gerçekleşmekte ve sonraki bileşenlerin özdeğerleri hızla azalarak sabit bir çizgiye yaklaşmaktadır (Reijer et al 2024). Bu analizde özdeğeri 1'in üzerinde olan yalnızca bir bileşen bulunmaktadır. Dolayısıyla, Scree Plot grafiği de, ölçeğin birinci faktörle açıklanmasının uygun olduğunu ve ek faktörlerin önemli bir varyans açıklamayacağını açıkça ortaya koymuştur.

Araştırmada geçerlik analizleri kapsamında uygulanan DFA, ölçeğin faktör analizi uyum indeksleri, modelin veri ile uyumunun kabul edilebilir düzeyde olduğunu göstermektedir. Uyumluluk indeksleri açısından literatürde, RMSEA değerinin 0,08'dan küçük olması ve χ^2/sd 'nin ise 3,0'den küçük olması iyi uyumu göstermektedir (Sathyanarayana and Mohanasundaram, 2024). Bulgularımızdaki uyumluluk indeksleri ele alındığında ($X^2/df=1,739$ ve $RMSEA=0,063$) ölçeğin modelin veri ile uyumunun tatmin edici düzeyde olduğunu desteklemektedir. Ayrıca DFA sonucunda da tüm maddelerin tek faktör yapısına anlamlı bir şekilde yüklendiğini göstermektedir. Maddelerin standart faktör yükleri (Std. β), 0,653 ile 0,797 arasında değişmekte olup, kabul edilebilir düzeylerde olduğu bulunmuştur (Boateng et al 2018, Sathyanarayana and Mohanasundaram, 2024). Bu durum,

DFA'ne göre de tüm maddelerin ölçeğin tek faktörlü yapısını desteklediğini güçlü bir şekilde göstermiştir.

Geçerlilik analizlerinde, ölçüt geçerliliği kapsamında test edilen ölçek ile geçerliliği ve güvenilirliği kanıtlanmış bir paralel form ile arasında ilişki aranır (DeVellis and Thorpe 2021). Bu çalışmada, korelasyon analizi sonuçları, KM-SŞÖ'nin ölçüt geçerliliğinin yüksek olduğunu göstermiştir. Ölçek toplam puanı ile EQ-5D-3L Genel Yaşam Kalitesi ve VAS sağlık durumu puanları ve arasında negatif yönde anlamlı bir ilişki bulunmuştur. Bu güçlü negatif korelasyon, semptom şiddetinin artmasının bireylerin genel yaşam kalitesi üzerinde belirgin bir olumsuz etki yarattığı ve sağlık durumu algısının kötüleştiğini ifade etmektedir. Elde edilen bu bulgular, KM-SŞÖ'nin diğer ölçütlerle anlamlı ve beklenen yönde ilişkiler kurarak geçerli bir ölçüm aracı olduğunu desteklemiştir.

5.2.2. Güvenirlilik Analizleri

Çalışmada ölçeğin güvenirliliği, Cronbach alfa katsayısı ile değerlendirilmiş ve elde edilen alfa değeri 0,977 olarak bulunmuştur. Literatürde, Cronbach alfa katsayısının 0 ile 1 arasında değiştiği ve bu katsayının 0,60 ile 0,80 arasında olması durumunda ölçeğin oldukça güvenilir; 0,80'in üzerinde olması durumunda ise yüksek güvenirliliğe sahip olduğu kabul edilmektedir (DeVellis and Thorpe 2021, Kennedy 2022). Bu bağlamda, araştırmamızda hesaplanan alfa katsayısı, ölçüm aracının iç tutarlılığının oldukça yüksek olduğunu ve literatürde belirtilen güvenirlilik kriterlerini karşıladığını göstermektedir.

Madde-toplam puan analizi, bir ölçekte yer alan maddelerin puanları ile o ölçeğin toplam puanı arasındaki ilişkileri belirlemek amacıyla yapılmaktadır. Bir maddenin hedeflenen niteliği ölçmedeki yeterliliği, korelasyon katsayısının değerine bağlıdır; yüksek korelasyon katsayıları daha yüksek yeterliliğe işaret eder. Bir madde-toplam puan korelasyon katsayısı 0,30'dan küçükse, madde ile ilgili önemli bir sorun olduğu düşünülür ve bu madde ölçekten çıkarılabilir. Madde-toplam puan korelasyon katsayılarının 0.30'dan büyük olması güvenirlilik açısından olumlu olarak yorumlanmaktadır (Boateng et al 2018, DeVellis and Thorpe, 2021). Bu çalışmada, madde toplam korelasyonları 0.636 ile 0.887 arasında değişmekte olup, bu durum

tüm maddelerin ölçek yapısına uygun olduğunu ve ölçülen kavramı tutarlı bir şekilde temsil ettiğini ortaya koymuştur.

Son olarak, ölçeğin ayırt ediciliğini belirlemek üzere, alt %27'lik ve üst %27'lik gruplar arasında t-testi analizi gerçekleştirilmiştir. Bu analiz, ölçeğin farklı semptom şiddeti düzeylerine sahip bireyleri başarıyla ayırt edip edemediğini değerlendirmek amacıyla yapılmıştır (DeVellis and Thorpe 2021, Hasançebi, Terzi ve Küçük 2020). Analiz sonuçlarına göre, alt gruptaki semptom toplam puanı ortalaması ile üst gruptaki ortalaması arasında istatistiksel olarak anlamlı bir fark bulunmuştur. Elde edilen bu bulgular, ölçeğin farklı semptom şiddeti düzeyine sahip bireyleri başarıyla ayırt edebildiğini ve ölçeğin güçlü bir ayırt edicilik özelliğine sahip olduğunu göstermektedir. Özellikle, ölçek maddelerinin belirli bir özelliği ölçme konusundaki başarısı, ölçme aracının geçerliliği ve güvenilirliği açısından önemli bir kanıt sunmaktadır.

Sonuç olarak, KM-SŞÖ hastanede yatan kardiyometabolik multimorbiditeli yaşlı bireylerde semptom şiddetini değerlendirmek üzere geliştirilmiş, geçerliliği ve güvenilirliği kanıtlanmış bir ölçme aracıdır. Buna göre, “Türk toplumunda geliştirilen Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği (KM-SŞÖ) geçerli ve güvenilir bir ölçektir.” hipotezi (Hipotez 1) kabul edilmiştir. Bu ölçeğin geliştirilmesi, söz konusu hasta grubunda görülen yüksek semptom yükü ve bakım süreçlerinin çok boyutlu yapısı göz önünde bulundurulduğunda, klinik uygulamalar açısından anlamlı bir katkı sunmaktadır. Semptom yükünün sistematik ve standardize biçimde izlenmesi, bireyselleştirilmiş ve hasta merkezli bakımın etkinliğini artırma potansiyeline sahiptir. KM-SŞÖ'nin 0-100 puan aralığındaki değerlendirme sistemi, hemşirelerin ve diğer sağlık profesyonellerinin yüksek şiddetteki semptomları hızlı biçimde tespit etmesine, müdahale önceliklerini belirlemesine ve klinik yanıtı izleyerek tedavi süreçlerini optimize etmesine olanak sağlayabilir. Gerek ayaktan gerekse yatan hasta izleminde uygulanabilir olan ölçek, elektronik sağlık kayıtlarına entegre edilerek karar destek sistemlerini, risk sınıflamasını ve kişiselleştirilmiş bakım planlarını güçlendirebilir.

5.3. ÜÇÜNCÜ AŞAMA: KLİNİK KARAR DESTEK SİSTEMİ GELİŞTİRİLMESİNE İLİŞKİN SONUÇLARIN TARTIŞILMASI

Son yıllarda hastanelerde yatarak tedavi gören yaşlı hasta sayısında belirgin bir artış gözlemlenmiş olup, bu artışın önümüzdeki yıllarda da devam etmesi beklenmektedir (Damoiseaux-Volman et al 2021). Hastaneye yatış süreci, çoklu kronik hastalığa sahip yaşlı bireylerin yaşam kalitesi üzerinde önemli bir etkiye sahiptir (Clerencia-Sierra et al 2015). Ayrıca, hastanede yatan yaşlı bireylerde kırılabilirlik başta olmak üzere çeşitli geriatrik sendromlar yaygın şekilde görülmekte; bu durum işlevsel gerileme ve mortalite riskini artırmaktadır (Clerencia-Sierra et al 2015, Damoiseaux-Volman et al 2021). Multimorbiditeye sahip yaşlı bireylerin karmaşık bakım gereksinimleri, hemşirelerin aktif ve sürekli hasta merkezli bir bakım sürecine katılımını ve hasta ile etkili iletişim kurmayı zorunlu kılmakta; bu da hastane bakımının yönetimini daha karmaşık hale getirmektedir (Kivelitz et al 2021). Bu doğrultuda, araştırmanın bu aşamasında hastanede yatan kardiyometabolik multimorbiditeli yaşlı hastaların bakım gereksinimlerini sınıflandırma ve hemşirelik tanımlarını belirlemede hemşirelere karmaşık bakım sürecinde destek sağlamak amacıyla makine öğrenimi tabanlı bir KKDS geliştirilmesi amaçlanmıştır.

İlk olarak, bu çalışmada, bakım gereksinim düzeylerinin sınıflandırılmasına yönelik geliştirilen makine öğrenimi modellerinin performansları karşılaştırıldığında, model başarısının hem kullanılan öznitelik sayısından hem de sınıf sayısından önemli ölçüde etkilendiği görülmüştür. İkili sınıflandırma yapılan durumlarda (düşük ve yüksek düzey bakım gereksinimi), 40 öznitelik için Random Forest modeli (%89), 19 öznitelik için XGBoost modeli (%86) en yüksek performansı göstermiştir. Bu sonuç, iki kategoriye ayrılmış verilerin daha net desenler içermesi sayesinde modellerin sınıflar arası ayrımı daha etkin biçimde yapabildiğini düşündürmektedir. Üç sınıflı sınıflandırmalarda (düşük, orta, yüksek düzey bakım gereksinimi), model performanslarının azaldığı gözlemlenmiştir. Random Forest modeli 40 öznitelik ile üç sınıf için %76 doğruluk sağlarken, öznitelik sayısının 19'a düşürülmesi durumunda doğruluk oranı SVM modeli ile

%76 doğruluk sağlamıştır. Bu doğrultuda, KKDS'nin daha az sayıda öznitelik ile hastanede yatan kardiyometabolik multimorbiditeli hastaların hemşirelik bakım gereksinimlerinin düşük, orta, yüksek şeklinde %76 doğruluk ile sınıflandırılabilceğı söylenebilir. SHAP öznitelik etki analizine göre, sınıflandırmaya en çok katkı sağlayan 19 öznitelik sırası ile yaşam kalitesi, semptom şiddeti, kalp hızı, kolesterol değeri, yaş, trigliserid değeri, BUN, düşme riski puanı, ağrı şiddeti, sağlık durumunu değerlendiren VAS skoru, sistolik kan basıncı, sodyum değeri, solunum sayısı, sigara içme durumu, TSH değeri, ilaç sayısı, SpO₂ değeri, ürik asit ve HbA1c değeri olarak bulunmuştur. Bu doğrultuda, geliştirilen KKDS yalnızca çok boyutlu verileri analiz etmekle kalmamış, aynı zamanda bu analizlerin klinik olarak anlamlı biçimde yorumlanabilmesini sağlamak amacıyla SHAP yöntemiyle açıklanabilirlik analizlerine de yer verilmiştir. Bu durum hem sistemin klinik kabul edilebilirliğini güçlendirmekte hem de veri temelli hemşirelik uygulamalarının sahaya entegrasyonunu kolaylaştırmaktadır.

İkinci olarak, yukarıda belirtilen öznitelikler doğrultusunda ele alınan 10 hemşirelik tanısı karar ağacı yöntemi ile analiz edilmiş ve tüm hemşirelik tanılarının %97 ile %100 arasında yüksek doğrulukla gerçekleştirdiğı görülmüştür. Sonuç olarak, karar ağaçları aracılığıyla geliştirilen hemşirelik tanı modelleri, hem klinik eşiklerin veri üzerinde nasıl ayırım sağladığını görselleştirmekte hem de sentetik veri üretimi sayesinde sınırlamaları aşarak kapsamlı modellemelere olanak tanımıştır. Özellikle modelin her tanı için klinik anlamlı öznitelikleri öncelikli olarak kullanması, geliştirilen sistemin sağlık profesyonellerince anlaşılabilir ve değerlendirilebilir bir yapı sunduğunu göstermektedir. Bu doğrultuda, “Geliştirilen makine öğrenimi tabanlı KKDS kardiyometabolik multimorbiditesi olan yaşlı hastalarda bakım gereksinimlerini sınıflandırma ve hemşirelik tanılarını belirlemede geçerli ve güvenilir bir yöntemdir” hipotezi (Hipotez 2) kabul edilmiştir.

Literatür incelendiğinde, kardiyometabolik multimorbiditeli yaşlı hastalarda bakım gereksinimlerini sınıflandıran veya hemşirelik tanılarını belirlemeye yardımcı olmak amacıyla geliştirilen bir KKDS'yi içeren herhangi başka bir çalışmaya da rastlanılamamıştır. Bu nedenle, geriatrik popülasyona yönelik geliştirilen makine öğrenimi tabanlı uygulamalar ve diğer hasta gruplarında sınıflandırma ve

hemşirelik tanımlarını belirlemeye yönelik geliştirilen KKDS'leri inceleyen çalışmaların sonuçları tartışılmıştır.

Son yıllarda yaşlı bireylerde makine öğrenimi tabanlı KKDS'lerin kullanımı giderek artmaktadır. Bu sistemlerin büyük bölümü hastaneye yatış ve acil servis başvuru tahmini, düşme riski, ilaç uyumsuzluğu, yaşam kalitesi gibi sadece tek klinik çıktıya odaklanmakta ve genellikle sınırlı veri türü ile çalışmaktadır (Ahmadi and Nopour 2022, Heo et al 2023, Seger et al 2024). Ayrıca, bu sistemlerin hemşirelik bakım yönetimini doğrudan destekleyecek şekilde yapılandırılmamış olması dikkat çekmektedir. Öte yandan, makine öğrenimi modellerinin yalnızca tahmin gücüyle değil, aynı zamanda yorumlanabilirlik yetenekleriyle de klinik karar verme süreçlerine entegre edilmesi, hemşirelik uygulamalarında önemli fırsatlar sunmaktadır (Shu et al 2024). Kronik ağrısı olan yaşlı bireylerde kırılabilirlik risk faktörlerini belirlemeye yönelik yapılan bir çalışmada, dokuz farklı makine öğrenimi modeli geliştirilmiş ve bunların çıktıları SHAP yöntemiyle analiz edilmiştir (Zhang et al 2025). Random Forest modeli, %82,2 doğruluk ile en iyi performansı gösterirken; modelde yer alan en belirleyici değişkenlerin ağrı düzeyi, depresyon düzeyi ve günlük yaşam aktiviteleri olduğu belirlenmiştir (Zhang et al 2025). SHAP temelli görselleştirme teknikleri, hemşirelerin bu değişkenlerin bireysel düzeyde kırılabilirlik riskine nasıl katkıda bulunduğunu daha ayrıntılı biçimde değerlendirmelerine olanak tanımış ve bu yönüyle kişiselleştirilmiş hemşirelik yönetimini desteklemiştir. Bu yaklaşım, klasik istatistiksel modellerin ötesinde, birey merkezli değerlendirme ve müdahale stratejilerinin geliştirilmesine yardımcı olarak, hemşirelerin klinik kararlarını daha sağlam veri temelli ve proaktif biçimde yapılandırabilmelerine olanak sağlamaktadır (Shu et al 2024). Bu metodolojik yapı, araştırmamızda da geliştirilen makine öğrenimi tabanlı KKDS'nin hemşirelik tanılması ve bakım planlamasında bireyselleştirilmiş, açıklanabilir ve dinamik bir araç olarak kullanılabileceğini destekleyen güncel bir örnek teşkil etmektedir.

Makine öğrenimi tabanlı geliştirilen sınıflandırma sistemlerini ele alan çalışmalar incelendiğinde ise Zador, Landry, Cusimano ve Geifman (2019) kritik hastalarda çoklu hastalık durumları, organ fonksiyon bozukluğu ve sepsis arasındaki ilişki özelliklerini araştırmak için, 36,390 hastayı altı alt gruba sınıflandırmak için

denetimsiz bir makine öğrenme yöntemi kullanmıştır. Hastalar 'kardiyopulmoner', 'hepatik/bağımlılık', 'genç', 'komplike diyabet hastaları', 'komplike olmayan diyabet hastaları' ve 'kardiyak' alt gruplar şeklinde sınıflandırılmıştır. Bu çalışma, çoklu hastalık alt popülasyonlarının tanımlanmasının ileriye dönük klinik tahminler ve deneysel tasarımlar için yararlı olduğunu ve ayrıca tıp ve sağlık alanındaki hastalık yönetimi modellerinin daha fazla araştırılması ve güncellenmesi için geniş kapsamlı bir öneme sahip olduğunu göstermiştir (Zador et al 2019, An et al 2021). An ve ark. (2021) tarafından gerçekleştirilen çalışma, yoğun bakım ünitesinde yatan yetişkin hastalar için makine öğrenimi tabanlı bir hasta sınıflama sistemi geliştirilmesini amaçlamıştır. Kesitsel tasarıma sahip bu çalışmada, 300 kritik hastaya ait 16 değişkene ait klinik veriler kullanılarak, hastalık şiddeti ve buna bağlı hemşirelik yoğunluğu ihtiyaçlarına göre hasta grupları tanımlanmıştır. İlk aşamada kümeleme analizleriyle homojen alt gruplar oluşturulmuş, ardından bu kümelere dayalı olarak Kısmi En Küçük Kareler (PLS) regresyonu ile sınıflama modeli geliştirilmiştir. Geliştirilen model, hastaları A, B ve C sınıfı olmak üzere bakım ihtiyacı düzeylerinde sınıflandırarak hemşirelerin iş yükünü yönetme, önceliklendirme yapma ve kaynak tahsisini planlama süreçlerine katkı sunmuştur (An et al 2021). Ancak söz konusu çalışmanın, sınıflama modelini yalnızca 16 klinik değişken üzerinden oluşturmuş olması ve sadece mekanik ventilasyon durumu, Glasgow Koma Skalası skoru, laktat, sodyum, potasyum, kreatinin ve üre azotu düzeyleri ve ortalama arteriyel kan basıncı gibi parametreleri içermesi modelin kapsamı ve genellenebilirliği açısından bir sınırlılık olarak değerlendirilebilir. Bu yönüyle, hemşirelik bakımı gibi çok boyutlu bir süreci anlamlandırmakta yetersiz kalabileceği düşünülmüştür. Öte yandan bu çalışmada, kardiyometabolik multimorbiditeli yaşlı bireylerin karmaşık bakım gereksinimlerini bütüncül biçimde ele alabilmek amacıyla daha geniş bir değişken seti kullanılmış; sosyodemografik, klinik, fizyolojik, laboratuvar parametreleri ile semptom şiddeti ve yaşam kalitesi gibi bileşenleri kapsayan çok boyutlu veriler modele entegre edilmiştir. Ayrıca, geliştirilen sistemin temel amacı yalnızca bakım yükünü sınıflamak değil, aynı zamanda hemşirelik tanımlarını destekleyerek bireyselleştirilmiş bakım planlarının oluşturulmasına yardımcı olmak olduğu için,

kapsam ve uygulama derinliđi aısından zgn olduđu ve literatre nemli katkı sađladıđı dřnlmektedir.

Literatr incelendiđinde, makine đrenimi modellerini kullanarak hemřirelik bakım planlarını ynetme konusunda ise sınırlı sayıda alıřmaya rastlanılmıřtır. Macieira, Yao ve Keenan (2021), elektronik sađlık kayıtlarından elde edilen ve palyatif bakımda kullanılan karmařık standartlařmıř hemřirelik bakım planı verilerinin (tanılar, mdahaleler, sonular) makine đrenimi ile anlamlı deđiřkenlere dnřtrmek iin yeni bir metodoloji tanımlamıřtır. Florida'daki drt hastanenin elektronik sađlık kayıtlarından elde edilen yařlı hastalara ait standart hemřirelik bakım planları alınarak, ncelikle sekiz kategorili palyatif bakım erevesine gre manuel sınıflandırma yapılmıřtır. Ardından bu etiketli veri ile Random Forest algoritmaları eđitilmiř ve iki uzmandan gelen %78'lik bařlangı uzlařma oranına dayanarak oluřturulan dođrulama sreci sonucunda sınıflandırma dođruluđu %77-%89 arasında bařarı ile sađlanmıřtır (Macieira et al 2021). Bu yntem, manuel hemřirelik tanısı etiketleme srecini otomasyonla yer deđiřtirerek byk veri analizi maliyetini ve zamanını azaltmıř, hemřirelik bakımının zn yansıtan deđiřkenlerin arařtırmalarda kullanılabilir hale gelmesini mmkn kılmıřtır. Bu alıřma, hemřirelik bakım planlarının ieriđini nicel arařtırma deđiřkenlerine dnřtrerek makine đrenimi tabanlı analizler iin uygun hale getirmek aısından nemli bir rnektir (Macieira et al 2021). Macri ve ark. (2025) yrttđ alıřmada, kronik ađrı tanısının hemřirelik srecinde daha tutarlı biimde belirlenmesine katkı sađlamak amacıyla makine đrenimi algoritmalarının performansını karřılařtırılmıřtır. alıřma, İtalyan hemřirelik bakım notlarından elde edilen metin verileri zerinden kronik ađrıyı dođru bir řekilde tanımlamak ve sınıflandırmak iin XGBoost, Gradient Boosting ve BERT modelleriyle yrtlmř; sınıflandırma dođruluđu Cohen's kappa katsayısıyla deđerlendirilmiřtir. En yksek performansın XGBoost modeliyle elde edildiđi raporlanmıřtır. Bu dođrultuda, makine đrenimi algoritmalarının hemřirelik notlarını otomatik tarayarak kronik ađrıya iliřkin gerek zamanlı uyarılar retmesi; bylece dokmantasyon ykn azaltması, tanı tutarlılıđını artırması ve kiřiselleřtirilmiř ađrı ynetimine katkı sađlaması aısından nemi vurgulanmıřtır (Macri et al 2025). Ancak, alıřma, hemřirelik tanılarının makine đrenimi ile desteklenebileceđini ortaya koymakla birlikte, yalnızca metin

temelli verilerden elde edilen tek bir hemşirelik tanısına odaklanmış ve çok boyutlu klinik veri kullanımını dışarıda bırakmıştır. Benzer şekilde, Nishi ve ark. (2025) tarafından yürütülen çalışmada, hemşirelik ilerleme notlarına dayalı olarak hemşirelik tanılarını otomatik şekilde önermeye yönelik ANN (Yapay Sinir Ağı) tabanlı bir model geliştirilmiş ve performansı değerlendirilmiştir. Japonya'daki kritik bakım birimlerinden 2014–2019 yılları arasında toplanan veriler ANN modeli ve Naive Bayes sınıflayıcı ile karşılaştırmalı olarak test edilmiştir. Dengesiz sınıfların etkisini azaltmak amacıyla örnek çoğaltma uygulanmış, modelin doğruluğunun 0,705 ile 0,911 arasında değiştiği raporlanmıştır. Sonuçlar, ANN modelinin metin tabanlı hemşirelik tanısı tahmininde Naive Bayes'e kıyasla üstün performans gösterdiğini ortaya koymuştur. Bu çalışma, doğal dil işleme ve makine öğreniminin hemşirelik karar süreçlerine entegre edilebileceğini göstermesi açısından önemli bir örnek sunmaktadır (Nishi et al 2025). Ancak model yalnızca metin verisine dayanmakta, dolayısıyla klinik, laboratuvar, fonksiyonel durum ve yaşam kalitesi gibi çok boyutlu verilerden yoksun kalmaktadır. Öte yandan bu tez çalışması kapsamında geliştirilen sistem, yalnızca kronik ağrı gibi tekil semptomlara odaklanmak yerine; fizyolojik parametreler, yaşamsal bulgular, laboratuvar değerleri, semptom bildirimleri, yaşam kalitesi ölçütleri, kırılabilirlik ve fonksiyonel durum gibi çok sayıda nitelikli öznelikle çalışarak, çok çeşitli hemşirelik tanılarını bir arada önermeyi amaçlamaktadır. Böylece hemşirelik karar süreci yalnızca metinle sınırlı kalmamakta; klinik gerçekliği daha kapsamlı yansıtan, veri temelli ve açıklanabilir bir klinik karar desteği sağlayarak kardiyometabolik multimorbiditesi olan yaşlı hastalarda bireyselleştirilmiş bakımın önünü açmaktadır.

6. SONUÇ VE ÖNERİLER

Bu araştırmada;

- Nitel görüşmelerden elde edilen bulgular, multimorbiditeye sahip yaşlı hastalara yönelik bakım süreçlerinde karmaşık gereksinimlerin bütüncül biçimde ele alınmasında güçlük yaşandığı ve kişiselleştirilmiş bakım sunumunun sınırlı kaldığı ve böylece KKDS geliştirilmesine yönelik ihtiyaç olduğu,
- Hastanede yatarak tedavi gören kardiyometabolik multimorbiditeli yaşlı hastaların semptom şiddetini değerlendirmek için geliştirilen KM-SŞÖ'nin geçerli ve güvenilir bir ölçme aracı olduğu,
- Bakım gereksinimlerini kırılabilirlik sınıf etiketine göre ikili sınıflamada (düşük ve yüksek düzey bakım gereksinimi) Random Forest ve XGBoost modellerinin; üçlü sınıflamada ise (düşük, orta, yüksek düzey bakım gereksinimi) Random Forest ve SVM modellerinin yüksek doğruluk performansı gösterdiği,
- SHAP öznitelik etki analizine göre yaşam kalitesi, semptom şiddeti, kalp hızı, kolesterol değeri, yaş, trigliserid değeri, BUN, düşme riski puanı, ağrı şiddeti, sağlık durumunu değerlendiren VAS skoru, sistolik kan basıncı, sodyum değeri, solunum sayısı, sigara içme durumu, TSH değeri, ilaç sayısı, SpO₂ değeri, ürik asit ve HbA1c değerinin bakım gereksinimlerini sınıflandırmada ön plana çıkan özellikler olduğu,
- Öznitelik-hemşirelik tanısı eşleştirmelerinin karar ağacı modeli ile test edilmesi sonucu ele alınan 10 hemşirelik tanısının yüksek doğruluk ve duyarlılık ile belirlenebildiği sonucuna varılmıştır.

Hemşirelik uygulamaları için öneriler;

- KM-SŞÖ'nin geçerli ve güvenilir bir ölçüm aracı olduğu sonucundan yola çıkarak kardiyometabolik hastalara bakım veren hemşirelere, hastaların semptom yükünü değerlendirmede hızlı ve güvenilir olan bu ölçeği kullanmaları önerilir.
- Karmaşık hasta profiline sahip yaşlı bireylerde bakım planlaması yapılırken, çoklu öz niteliklere dayalı makine öğrenimi tabanlı KKDS'lerden yararlanılması, hemşirelerin klinik karar alma süreçlerini kolaylaştırabilir ve bakım kalitesini artırabilir. Buradan yola çıkarak kişiselleştirilmiş ve bütüncül bakımın sağlanabilmesi için, hemşirelik tanılarının belirlenmesinde klinik verilerin sistematik şekilde değerlendirilmesine olanak sağlayan dijital karar destek mekanizmalarının yaygınlaştırılması önerilir.

Hemşirelik eğitimi için öneriler;

- Hemşirelerin veriye dayalı klinik karar verme becerilerini geliştirmek amacıyla, açıklanabilir YZ temelli sistemlerin hem lisansüstü hem de hizmet içi eğitim programlarına entegre edilmesi önem arz etmektedir. Bu kapsamda, KKDS'lerin kullanımına yönelik uygulamalı eğitimler planlanmalı; sistem çıktılarının hemşirelik bilgisi ve klinik gözlemi ile nasıl bütünleştirileceği örnek uygulamalarla gösterilerek bakım süreçlerine güvenle entegre edebilme yeterlilikleri artırılmalıdır.

Hemşirelik araştırmaları için öneriler;

- Geliştirilen KM-SŞÖ'nin ayaktan tedavi alan ve farklı semptom yüküne sahip diğer klinik ortamlardaki kardiyometabolik bireyler üzerinde uygulanması ve farklı kültür ve dile uygunluğunun test edilerek kullanımının genişletilmesi önerilir.
- Farklı klinik alanlardaki hemşirelik tanıılarını desteklemek amacıyla yeni öz nitelik setleri ile makine öğrenimi modelleri geliştirilerek model genellenebilirliği test edilmelidir.

- Geliştirilen karar destek sistemlerinin klinik ortamlarda uygulanabilirliği, hemşire kabulü ve hasta sonuçlarına etkisi uzunlamasına tasarlanacak nicel ve karma yöntemli araştırmalarla değerlendirilmelidir.
- Gelecek araştırmalarda, multimorbid yaşlı bireylerin bakım gereksinimlerinin daha derinlemesine anlaşılabilmesi için, elektronik sağlık kayıtları, hemşirelik dokümantasyonu ve hasta izlem verileri gibi çok kaynaklı klinik verilerin analizine dayalı tümevarımsal yaklaşımlarının kullanılması önerilmektedir. Büyük veri analitiği teknikleriyle yürütülecek bu tür çalışmalar, hemşirelik bakımında karşılaşılan karmaşık örüntülerin ortaya çıkarılmasına, bireyselleştirilmiş müdahalelerin tasarlanmasına ve dijital karar destek sistemlerinin daha işlevsel hale getirilmesine katkı sağlayacaktır.

7. ARAŞTIRMANIN SINIRLILIKLARI

Bu araştırmanın temel sınırlılıklarından biri, tek bir hastanenin yatan hasta bölümlerinden amaçlı örnekleme yöntemi kullanılarak veri toplanmasının çalışma popülasyonunun klinik temsiliyetini kısıtlamasıdır. Bu çalışmada bakım gereksinimlerini sınıflandırmada kullanılan veri seti, kesitsel bir tasarım çerçevesinde yalnızca belirli bir zaman noktasında toplanmış verilerden oluşmaktadır. Ek olarak, geliştirilen makine öğrenimi modellerinin, henüz gerçek zamanlı klinik uygulamalarda etkinliği test edilmemiştir. Bu nedenle, hastaların bakım gereksinimlerindeki değişimleri zaman içinde izlemek veya hemşirelik tanılarının klinik sonuçlara etkisini değerlendirmek mümkün olmamıştır. Ayrıca, bu çalışmada hemşirelik tanılarına karşılık gelen farklı öznelilik eşiklerinin birlikte görüldüğü gerçek hasta sayısının oldukça sınırlı olması nedeni ile sentetik veri üretimi gerçekleştirilmiştir. Bu yaklaşım, algoritmanın nadir görülen ama klinik açıdan kritik durumları tanıma kapasitesini artırmayı amaçlasa da, üretilen verilerin gerçek klinik varyasyonu her yönüyle yansıtmayabileceği göz önünde bulundurulmalıdır. Özellikle, değişkenler arası ilişkilerin sentetik örneklerde gerçeğe tam olarak karşılık gelmemesi, modelin dış geçerliliği üzerinde sınırlayıcı bir etki oluşturabilir. Bu nedenle, hemşirelik tanımlarını belirlemeye yönelik geliştirilen KKDS'nin gerçek hasta gruplarında ve klinik koşullarda doğrulanması, genellenebilirlik açısından önem taşımaktadır.

KAYNAKLAR

- Abidi S, Cox J, Shepherd M, Abidi SSR. (2012). Using OWL ontologies for clinical guidelines based comorbid decision support. In: 45th Hawaii International Conference on System Sciences; 2012 Jan. p. 3030–3038. IEEE.
- Adomat R, Hewison A. (2004). Assessing patient category/dependence systems for determining the nurse/patient ratio in ICU and HDU: a review of approaches. *J Nurs Manag*, 12(5):299–308.
- Ahmadi M, Nopour R. (2022). Clinical decision support system for quality of life among the elderly: an approach using artificial neural network. *BMC Med Inform Decis Mak*, 22(1):293.
- Akbar S, Lyell D, Magrabi F. (2021). Automation in nursing decision support systems: a systematic review of effects on decision making, care delivery, and patient outcomes. *J Am Med Inform Assoc*, 28(11):2502–2513.
- Akturan S, Karahan Ö, Akman M. (2021). The prevalence of multimorbidity among adults aged 40 years and above in primary care setting: a cross-sectional study. *Konuralp Med J*, 13(3):563–569.
- Alonso-Morán E, Nuño-Solinis R, Onder G, Tonnara G. (2015). Multimorbidity in risk stratification tools to predict negative outcomes in adult population. *Eur J Intern Med*, 26(3):182–189.
- An R, Chang GM, Fan YY, Ji LL, Wang XH, Hong S. (2021). Machine learning-based patient classification system for adult patients in intensive care units: a cross-sectional study. *J Nurs Manag*, 29(6):1752–1762.
- Aubert CE, Schnipper JL, Roumet M, Marques-Vidal P, Stirnemann J, Auerbach AD, Donzé JD. (2020). Best definitions of multimorbidity to identify patients with high health care resource utilization. *Mayo Clin Proc Innov Qual Outcomes*, 4(1):40–49.

- Aygör HE, Fadıloğlu Ç, Şahin S, Aykar FŞ, Akçiçek F. (2018). Validation of Edmonton frail scale into elderly Turkish population. *Arch Gerontol Geriatr*, 76:133–137.
- Bagshaw SM, Stelfox HT, Johnson JA, McDermid RC, Rolfson DB, Tsuyuki RT, et al. (2015). Long-term association between frailty and health-related quality of life among survivors of critical illness: a prospective multicenter cohort study. *Crit Care Med*, 43(5):973–982.
- Banday MZ, Sameer AS, Nissar S. (2020). Pathophysiology of diabetes: an overview. *Avicenna J Med*, 10(4):174–188.
- Beal CC, Ogola G, Allen L. (2019). Validity and reliability of the responses to ischemic stroke symptoms questionnaire. *J Neurosci Nurs*, 51:287–291.
- Beam AL, Kohane IS. (2018). Big data and machine learning in health care. *JAMA*, 319(13):1317–1318.
- Beil M, Flaatten H, Guidet B, Sviri S, Jung C, de Lange D, Artigas A, Joannidis M, Van den Noortgate N, Marsh B, Oeyen S, Sigal S, Schefold JC, Van Heerden PV, Cecconi M. (2021). The management of multi-morbidity in elderly patients: ready yet for precision medicine in intensive care? *Crit Care*, 25(1):330.
- Berner ES, La Lande TJ. (2016). Overview of clinical decision support systems. In: Berner ES, editor. *Clinical decision support systems: theory and practice*. Cham: Springer; p. 1–17.
- Boateng GO, Neilands TB, Frongillo EA, Melgar-Quinonez HR, Young SL. (2018). Best practices for developing and validating scales for health, social, and behavioral research: a primer. *Front Public Health*, 6:149.
- Bradshaw C, Atkinson S, Doody O. (2017). Employing a qualitative description approach in health care research. *Glob Qual Nurs Res*, 4:2333393617742282.
- Brady AM, Byrne G, Horan P, Griffiths C, Macgregor C, Begley C. (2007). Measuring the workload of community nurses in Ireland: a review of workload measurement systems. *J Nurs Manag*, 15(5):481–489.

- Braun V, Clarke V. (2006). Using thematic analysis in psychology. *Qual Res Psychol*, 3(2):77–101.
- Bunn JG, Steell L, Hillman SJ, Witham MD, Sayer AA, Cooper R, McMorrow J, Burton JK, Stow D, Hanratty B. (2025). Approaches to characterising multimorbidity in older people accessing hospital care: a scoping review. *Eur Geriatr Med*, 1–15.
- Cesari M, Pérez-Zepeda MU, Marzetti E. (2017). Frailty and multimorbidity: different ways of thinking about geriatrics. *J Am Med Dir Assoc*, 18(4):361–364.
- Chang VT, Hwang SS, Thaler HT, Kasimis BS, Portenoy RK. (2004). Memorial Symptom Assessment Scale. *Expert Rev Pharmacoecon Outcomes Res*, 4:171–178.
- Chlap P, Min H, Vandenberg N, Dowling J, Holloway L, Haworth A. (2021). A review of medical image data augmentation techniques for deep learning applications. *J Med Imaging Radiat Oncol*, 65(5):545–563.
- Chaparala SP, Pathak KD, Dugyala RR, Thomas J, Varakala SP, Pathak K. (2025). Leveraging artificial intelligence to predict and manage complications in patients with multimorbidity: a literature review. *Cureus*, 17(1).
- Chen M, Decary M. (2020). Artificial intelligence in healthcare: an essential guide for health leaders. *Healthc Manage Forum*, 33(1):10–18.
- Cheng X, Ma T, Ouyang F, Zhang G, Bai Y. (2022). Trends in the prevalence of cardiometabolic multimorbidity in the United States, 1999–2018. *Int J Environ Res Public Health*, 19(8):4726.
- Choudhury A, Renjilian E, Asan O. (2020). Use of machine learning in geriatric clinical care for chronic diseases: a systematic literature review. *JAMIA Open*, 3(3):459–471.
- Clavelle JT, Sweeney CD, Swartwout E, Lefton C, Guney S. (2019). Leveraging technology to sustain extraordinary care: a qualitative analysis of meaningful nurse recognition. *J Nurs Adm*, 49(6):303–309.

- Cleeland CS, Mendoza TR, Wang XS, Chou C, Harle MT, Morrissey M, Engstrom MC. (2000). Assessing symptom distress in cancer patients. *Cancer*, 89:1634–1646.
- Clegg A, Young J, Iliffe S, Rikkert MO, Rockwood K. (2013). Frailty in elderly people. *Lancet*, 381(9868):752–762.
- Clerencia-Sierra M, Calderón-Larrañaga A, Martínez-Velilla N, Vergara-Mitxeltoarena I, Aldaz-Herce P, Poblador-Plou B, González-Rubio F, Prados-Torres A. (2015). Multimorbidity patterns in hospitalized older patients: associations among chronic diseases and geriatric syndromes. *PLoS One*, 10(7):e0132909.
- Damoiseaux-Volman BA, van der Velde N, Ruige SG, Romijn JA, Abu-Hanna A, Medlock S. (2021). Effect of interventions with a clinical decision support system for hospitalized older patients: systematic review mapping implementation and design factors. *JMIR Med Inform*, 9(7):e28023.
- de Carvalho EC, Eduardo AHA, Romanzini A, Simão TP, Zamarioli CM, Garbuio DC, Herdman TH. (2018). Correspondence between NANDA international nursing diagnoses and outcomes as proposed by the nursing outcomes classification. *Int J Nurs Knowl*, 29(1):66–78.
- De Groot HA. (1989). Patient classification system evaluation Part 1: Essential system elements. *J Nurs Adm*, 19(6):30–35.
- De Ville B. (2013). Decision trees. *Wiley Interdiscip Rev Comput Stat*, 5(6):448–455.
- de Wit HA, Mestres Gonzalvo C, Hurkens KP, Mulder WJ, Janknegt R, Verhey FR, van der Kuy PHM. (2013). Development of a computer system to support medication reviews in nursing homes. *Int J Clin Pharm*, 35(5):668–672.
- DeVellis RF, Thorpe CT. (2021). Scale development: theory and applications. Sage Publications.

- Di Angelantonio E, Kaptoge S, Wormser D, Willeit P, Butterworth AS, Bansal N, Thompson SG, Danesh J. (2015). Association of cardiometabolic multimorbidity with mortality. *JAMA*, 314(1):52–60.
- Dixon D, Sattar H, Moros N, Kesireddy SR, Ahsan H, Lakkimsetti M, Doshi D. (2024). Unveiling the influence of AI predictive analytics on patient outcomes: a comprehensive narrative review. *Cureus*, 16(5).
- Docherty AB, Anderson NH, Walsh TS, Lone NI. (2016). Equity of access to critical care among elderly patients in Scotland: a national cohort study. *Crit Care Med*, 44(1):3–13.
- Dunlay SM, Chamberlain AM. (2016). Multimorbidity in older patients with cardiovascular disease. *Curr Cardiovasc Risk Rep*, 10(1):3.
- Edwardson SR, Giovannetti PB. (1994). Nursing workload measurement systems. *Annu Rev Nurs Res*, 12:95–123.
- El Assar M, Laosa O, Mañas LR. (2019). Diabetes and frailty. *Curr Opin Clin Nutr Metab Care*, 22(1):52–57.
- El Emam K, Mosquera L, Fang X, El-Hussuna A. (2024). An evaluation of the replicability of analyses using synthetic health data. *Sci Rep*, 14(1):6978.
- Ellis G, Whitehead MA, Robinson D, O'Neill D, Langhorne P. (2011). Comprehensive geriatric assessment for older adults admitted to hospital: meta-analysis of randomised controlled trials. *BMJ*, 343.
- Eriksen CU, Kamstrup-Larsen N, Birke H, Holding SA, Ghith N, Andersen JS, Frølich A. (2022). Models of care for improving health-related quality of life, mental health, or mortality in persons with multimorbidity: a systematic review of randomized controlled trials. *J Multimorb Comorb*, 12:26335565221134017.
- Fabício-Wehbe SCC, Schiaveto FV, Vendrusculo TRP, Haas VJ, Dantas RAS, Rodrigues RAP. (2009). Cross-cultural adaptation and validity of the Edmonton Frail Scale in a Brazilian elderly sample. *Rev Latinoam Enfermagem*, 17(6):1043–1049.

- Flo J, Landmark B, Tønnessen S, Fagerström L. (2019). Patient classification systems used to classify nursing intensity and assess nursing staffing resources in home health care: a scoping review. *Int J Nurs Stud*, 99:103361.
- Foà C, Guarnieri MC, Bastoni G, Benini B, Giunti OM, Mazzotti M, Artioli G. (2020). Job satisfaction, work engagement and stress/burnout of elderly care staff: a qualitative research. *Acta Biomed*, 91(Suppl 12):e2020014.
- Fortin M, Stewart M, Poitras ME, Almirall J, Maddocks H. (2012). A systematic review of prevalence studies on multimorbidity: toward a more uniform methodology. *Ann Fam Med*, 10(2):142–151.
- Fraccaro P, Casteleiro MA, Ainsworth J, Buchan I. (2015). Adoption of clinical decision support in multimorbidity: a systematic review. *JMIR Med Inform*, 3(1):e3503.
- Galicia-Garcia U, Benito-Vicente A, Jebari S, Larrea-Sebal A, Siddiqi H, Uribe KB, Martín C. (2020). Pathophysiology of type 2 diabetes mellitus. *Int J Mol Sci*, 21(17):6275.
- Gao K, Li BL, Yang L, Zhou D, Ding KX, Yan J, Zheng XP. (2021). Cardiometabolic diseases, frailty, and healthcare utilization and expenditure in community-dwelling Chinese older adults. *Sci Rep*, 11(1):7776.
- Garin N, Olaya B, Moneta MV, Miret M, Lobo A, Ayuso-Mateos JL, Haro JM. (2014). Impact of multimorbidity on disability and quality of life in the Spanish older population. *PLoS One*, 9(11):e111498.
- Gau GT, Wright RS. (2006). Pathophysiology, diagnosis, and management of dyslipidemia. *Curr Probl Cardiol*, 31(7):445–486.
- George D, Mallery M. (2010). *SPSS for Windows Step by Step: A Simple Guide and Reference*, 17.0 Update (10th ed.). Boston: Pearson.
- Giovannetti P, Johnson JM. (1990). A new generation patient classification system. *J Nurs Adm*, 20(5):33–40.

- Grąbczewski K. (2014). Meta-learning in decision tree induction (Vol. 1). Cham: Springer Int Publ.
- Green SB, Yang Y. (2015). Evaluation of dimensionality in the assessment of internal consistency reliability: Coefficient alpha and omega coefficients. *Educ Meas Issues Pract*, 34(4):14–20.
- Greenes RA, Bates DW, Kawamoto K, Middleton B, Osheroff J, Shahar Y. (2018). Clinical decision support models and frameworks: seeking to address research issues underlying implementation successes and failures. *J Biomed Inform*, 78:134–143.
- Grootenhuis PA, Snoek FJ, Heine RJ, Bouter LM. (1994). Development of a Type 2 Diabetes Symptom Checklist: a measure of symptom severity. *Diabet Med*, 11:253–261.
- Gu J, Chao J, Chen W, Xu H, Zhang R, He T, Deng L. (2018). Multimorbidity and health-related quality of life among the community-dwelling elderly: a longitudinal study. *Arch Gerontol Geriatr*, 74:133–140.
- Haines KJ, Hibbert E, McPeake J, Anderson BJ, Bienvenu OJ, Andrews A, Harhay MO. (2020). Prediction models for physical, cognitive, and mental health impairments after critical illness: a systematic review and critical appraisal. *Crit Care Med*, 48(12):1871.
- Hall JE, Granger JP, do Carmo JM, da Silva AA, Dubinion J, George E, Hall ME. (2012). Hypertension: physiology and pathophysiology. *Compr Physiol*, 2(4):2393–2442.
- Hasançebi B, Terzi Y, Küçük Z. (2020). Madde güçlük indeksi ve madde ayırt edicilik indeksine dayalı çeldirici analizi. *Gümüşhane Univ Fen Bilim Derg*, 10(1):224–240.
- Hassan N, Slight R, Slight S. (2022). Healthcare staff perceptions on using artificial intelligence predictive tools: a qualitative study. *BMJ Health Care Inform*, 29(Suppl1):A1–A12.
- Heo KN, Seok JY, Ah YM, Kim KI, Lee SB, Lee JY. (2023). Development and validation of a machine learning-based fall-related injury risk prediction

- model using nationwide claims database in Korean community-dwelling older population. *BMC Geriatr*, 23(1):830.
- Heydari A, Sharifi M, Moghaddam AB. (2019). Challenges and barriers to providing care to older adult patients in the intensive care unit: a qualitative research. *Open Access Maced J Med Sci*, 7(21):3682.
- Hirano T. (2018). Pathophysiology of diabetic dyslipidemia. *J Atheroscler Thromb*, 25(9):771–782.
- Holm AL, Berland AK, Severinsson E. (2016). Managing the needs of older patients with multimorbidity: a systematic review of the challenges faced by the healthcare services. *Open J Nurs*, 6(10):881–901.
- Hossain MM, Sharma R, Sultana A, Tasnim S, Faizah F. (2020). Globalising artificial intelligence for improved clinical practice. *Indian J Med Ethics*.
- Huckabay LM, Skonieczny R. (1981). Patient classification systems: the problems faced. *Nurs Health Care*, 2(2):89–102.
- Jebari-Benslaiman S, Galicia-García U, Larrea-Sebal A, Olaetxea JR, Alloza I, Vandenbroeck K, Martín C. (2022). Pathophysiology of atherosclerosis. *Int J Mol Sci*, 23(6):3346.
- Jia Y, Li D, Yu J, Liu Y, Li F, Li W, Wan Z. (2022). Subclinical cardiovascular disease and frailty risk: the atherosclerosis risk in communities study. *BMC Geriatr*, 22(1):321.
- Jin Y, Liang J, Hong C, Liang R, Luo Y. (2023). Cardiometabolic multimorbidity, lifestyle behaviours, and cognitive function: a multicohort study. *Lancet Healthy Longev*, 4(6):e265–e273.
- Jordan M, Hauser J, Cota S, Li H, Wolf L. (2023). The impact of cultural embeddedness on the implementation of an artificial intelligence program at triage: a qualitative study. *J Transcult Nurs*, 34(1):32–39.
- Juárez-García A, González-Muñoz EL, Aguirre-Moreno A. (2019). Validity, sensitivity and specificity of a scale to assess cardiovascular symptoms. *Cardiovasc Metab Sci*, 30:100–113.

- Kahyaoğlu Süt H, Ünsar S. (2011). Is EQ-5D a valid quality of life instrument in patients with acute coronary syndrome? *Anatol J Cardiol*, 11(2).
- Kennedy I. (2022). Sample size determination in test-retest and Cronbach alpha reliability estimates. *Br J Contemp Educ*, 2(1):17–29.
- Khalifa M, Albadowy M, Iqbal U. (2024). Advancing clinical decision support: the role of artificial intelligence across six domains. *Comput Methods Programs Biomed Update*, 5:100142.
- Kishore K, Jaswal V, Kulkarni V, De D. (2021). Practical guidelines to develop and evaluate a questionnaire. *Indian Dermatol Online J*, 12(2):266–275.
- Kivelitz L, Schäfer J, Kanat M, Mohr J, Glattacker M, Voigt-Radloff S, Dirmaier J. (2021). Patient-centeredness in older adults with multimorbidity: results of an online expert Delphi study. *Gerontologist*, 61(7):1008–1018.
- Klompstra L, Ekdahl AW, Krevers B, Milberg A, Eckerblad J. (2019). Factors related to health-related quality of life in older people with multimorbidity and high health care consumption over a two-year period. *BMC Geriatr*, 19(1):1–8.
- Koller D, Schön G, Schäfer I, Glaeske G, van den Bussche H, Hansen H. (2014). Multimorbidity and long-term care dependency: a five-year follow-up. *BMC Geriatr*, 14(1):1–9.
- Komalasari R, Yoche MM. (2019). Quality of life of people with cardiovascular disease: a descriptive study. *Asian Pac Isl Nurs J*, 4(2):92.
- Kwon JY, Karim ME, Topaz M, Currie LM. (2019). Nurses “seeing forest for the trees” in the age of machine learning: using nursing knowledge to improve relevance and performance. *CIN: Comput Inform Nurs*, 37(4):203–212.
- Kyriazos T, Poga-Kyriazou M. (2023). Applied psychometrics: estimator considerations in commonly encountered conditions in CFA, SEM, and EFA practice. *Psychol*, 14(5):799–828.
- Laukka E, Hammarén M, Kanste O. (2022). Nurse leaders' and digital service developers' perceptions of the future role of artificial intelligence in

- specialized medical care: an interview study. *J Nurs Manag*, 30(8):3838–3846.
- Lawes CM, Vander Hoorn S, Rodgers A. (2008). Global burden of blood-pressure-related disease, 2001. *Lancet*, 371(9623):1513–1518.
- Lewington S, Clarke R, Qizilbash N, Peto R, Collins R. (2003). Age-specific relevance of usual blood pressure to vascular mortality. *Lancet*, 361(9366):1391–1392.
- Li Z. (2022). Extracting spatial effects from machine learning model using local interpretation method: an example of SHAP and XGBoost. *Comput Environ Urban Syst*, 96:101845.
- Liaw SY, Tan JZ, Lim S, Zhou W, Yap J, Ratan R, Chua WL. (2023). Artificial intelligence in virtual reality simulation for interprofessional communication training: mixed method study. *Nurse Educ Today*, 122:105718.
- Lincoln YS, Guba EG. (1991). *Naturalistic inquiry*. Thousand Oaks, CA: Sage Publications.
- Lippi G, Sanchis-Gomar F, Cervellin G. (2016). Chest pain, dyspnea and other symptoms in patients with type 1 and 2 myocardial infarction: a literature review. *Int J Cardiol*, 215:20–22.
- Liu E, Atkins MT, Chomik R, Judd B. (2023). The World Health Organization's impacts on age- friendly policymaking: a case study on Australia. *Aust J Soc Issues*, 58(3):714–728.
- Loh WY. (2014). Fifty years of classification and regression trees. *Int Stat Rev*, 82(3):329–348.
- Lu H, Dong XX, Li DL, Nie XY, Wang P, Pan CW. (2024). Multimorbidity patterns and health-related quality of life among community-dwelling older adults: evidence from a rural town in Suzhou, China. *Qual Life Res*, 33(5):1335–1346.

- Lundberg SM, Erion G, Chen H, DeGrave A, Prutkin JM, Nair B, Lee SI. (2020). From local explanations to global understanding with explainable AI for trees. *Nat Mach Intell*, 2(1):56–67.
- Ma T, He L, Luo Y, Fu D, Huang J, Zhang G, Bai Y. (2023). Frailty, an independent risk factor in progression trajectory of cardiometabolic multimorbidity: a prospective study of UK Biobank. *J Gerontol A Biol Sci Med Sci*, 78(11):2127–2135.
- Macieira TG, Yao Y, Keenan GM. (2021). Use of machine learning to transform complex standardized nursing care plan data into meaningful research variables: a palliative care exemplar. *J Am Med Inform Assoc*, 28(12):2695–2701.
- Macrì D, Ramacciati N, Comito C, Metlichin E, Giusti GD, Forestiero A. (2025). Enhancing chronic pain nursing diagnosis through machine learning: a performance evaluation. *CIN: Comput Inform Nurs*, 43(5):e01277.
- Maher RL, Hanlon J, Hajjar ER. (2014). Clinical consequences of polypharmacy in elderly. *Expert Opin Drug Saf*, 13(1):57–65.
- Majnarić LT, Babič F, O’Sullivan S, Holzinger A. (2021). AI and big data in healthcare: towards a more comprehensive research framework for multimorbidity. *J Clin Med*, 10(4):766.
- Marques MDC, Pires R, Perdigao M, Sousa L, Fonseca C, Pinho LG, Lopes M. (2021). Patient-centered care for patients with cardiometabolic diseases: an integrative review. *J Pers Med*, 11(12):1289.
- Martos-Benitez FD, Cordero-Escobar I, Soto-Garcia A, Betancourt-Plaza I, González-Martínez I. (2018). APACHE II score for critically ill patients with a solid tumor: a reclassification study. *Rev Esp Anesthesiol Reanim*, 65(8):447–455.
- Memon MA, Ting H, Cheah JH, Thurasamy R, Chuah F, Cham TH. (2020). Sample size for survey research: review and recommendations. *J Appl Struct Equ Model*, 4(2):i–xx.

- Merriam SB. (2018). Nitel araştırma: desen ve uygulama için bir rehber. (Çev. Ed. Turan S). Ankara: Nobel Akademik Yayıncılık.
- Michel M, Trafton J, Martins S, Wang D, Tu S, Johnson N, Goldstein MK. (2008). Improving patient safety using ATHENA-decision support system technology: The opioid therapy for chronic pain experience. *Advances in Patient Safety: New Directions and Alternative Approaches*, 4:Technology and Medication Safety.
- Moghadam MP, Moghadam ZA, Qazani MRC, Pławiak P, Alizadehsani R. (2024). Impact of artificial intelligence in nursing for geriatric clinical care for chronic diseases: a systematic literature review. *IEEE Access*, 12:1–15.
- Molsted S, Jensen TM, Larsen JS, Olesen LB, Eriksen SBM, Rehling T, Aadahl M. (2022). Changes of physical function and quality of life in patients with type 2 diabetes after exercise training in a municipality or a hospital setting. *J Diabetes Res*, 2022:5751891.
- Muhyaddin R, Abd-Alrazaq AA, Househ M, Alam T, Shah Z. (2020). The impact of clinical decision support systems (CDSS) on physicians: a scoping review. *The Importance of Health Informatics in Public Health during a Pandemic*, 470–473.
- Murphy SJ, Werring DJ. (2020). Stroke: causes and clinical features. *Medicine*, 48(9):561–566.
- Nguyen H, Manolova G, Daskalopoulou C, Vitoratou S, Prince M, Prina AM. (2019). Prevalence of multimorbidity in community settings: a systematic review and meta-analysis of observational studies. *J Comorb*, 9:2235042X19870934.
- Nieveen JL, Zimmerman LM, Barnason SA, Yates BC. (2008). Development and content validity testing of the Cardiac Symptom Survey in patients after coronary artery bypass grafting. *Heart Lung*, 37:17–27.
- Nishi R, Kashiwagi K, Yokota S, Ishii M, Miyo K. (2025). Construction and validation of artificial neural network model suggesting nursing diagnosis: a proof-of-concept study. *CIN: Comput Inform Nurs*, 43(6):e01293.

- O'Connor S. (2022). Artificial intelligence for older adult health: opportunities for advancing gerontological nursing practice. *J Gerontol Nurs*, 48(12):3–5.
- Ogundimu EO, Altman DG, Collins GS. (2016). Adequate sample size for developing prediction models is not simply related to events per variable. *J Clin Epidemiol*, 76:175–182.
- Onwuegbuzie AJ, Collins KM. (2007). A typology of mixed methods sampling designs in social science research. *Qual Rep*, 12(2):281–316.
- Otieno P, Asiki G, Wilunda C, Wami W, Agyemang C. (2023). Cardiometabolic multimorbidity and associated patterns of healthcare utilization and quality of life: results from the Study on Global AGEing and Adult Health (SAGE) Wave 2 in Ghana. *PLOS Glob Public Health*, 3(8):e0002215.
- Ovbiagele B, Nguyen-Huynh MN. (2011). Stroke epidemiology: advancing our understanding of disease mechanism and therapy. *Neurotherapeutics*, 8(3):319–329.
- Padley M, Madden T, Kothari P, Hall J, Pate MJ, Brown T. (2020). Implementation and maintenance of an established clinical decision support tool algorithm: challenges and recommendations from a prospective cohort study. *Curr Orthop Pract*, 31(6):593–594.
- Palinkas LA, Horwitz SM, Green CA, Wisdom JP, Duan N, Hoagwood K. (2015). Purposeful sampling for qualitative data collection and analysis in mixed method implementation research. *Adm Policy Ment Health*, 42:533–544.
- Parker L, Moran GM, Roberts LM, Calvert M, McCahon D. (2014). The burden of common chronic disease on health-related quality of life in an elderly community-dwelling population in the UK. *Fam Pract*, 31(5):557–563.
- Patton MQ. (2015). *Qualitative Research & Evaluation Methods: Integrating Theory and Practice*. 4th ed. Thousand Oaks, CA: Sage Publications.
- Pezoulas VC, Zaridis DI, Mylona E, Androutsos C, Apostolidis K, Tachos NS, Fotiadis DI. (2024). Synthetic data generation methods in healthcare: a review on open-source tools and methods. *Comput Struct Biotechnol J*, 23:2892–2910.

- Podgorica N, Pjetri E, Müller AW, Perkhofer S. (2024). Difficulties and challenges experienced by nurses in eldercare institutions in Albania: a qualitative content analysis. *PLOS One*, 19(3):e0300774.
- Pollack LM, Wang M, Leung MYM, Colditz G, Herrick C, Chang SH. (2020). Obesity-related multimorbidity and risk of cardiovascular disease in the middle-aged population in the United States. *Prev Med*, 139:106225.
- Rabin R, Charro FD. (2001). EQ-SD: a measure of health status from the EuroQol Group. *Annals of Medicine*, 33(5):337–343.
- Rachel H, Francesco S. (2018). Factors associated with and the impact of burnout in nursing and residential home care workers for the elderly. *Acta Bio Medica: Atenei Parmensis*, 89(Suppl 7):60.
- Rawshani A, Rawshani A, Franzén S, Eliasson B, Svensson AM, Miftaraj M, Gudbjörnsdóttir S. (2017). Mortality and cardiovascular disease in type 1 and type 2 diabetes. *New England Journal of Medicine*, 376(15):1407–1418.
- Reijer AHD, Otter PW, Jacobs JP. (2024). An heuristic scree plot criterion for the number of factors. *Statistical Papers*, 65(6):3991–4000.
- Renne I, Gobbens RJ. (2018). Effects of frailty and chronic diseases on quality of life in Dutch community-dwelling older adults: a cross-sectional study. *Clinical Interventions in Aging*, 13:325–334.
- Rezaei-Shahsavarloo Z, Atashzadeh-Shoorideh F, Ebadi A, Gobbens RJ. (2021). Factors affecting missed nursing care in hospitalized frail older adults in the medical wards: a qualitative study. *BMC Geriatrics*, 21(1):1–12.
- Rivera-Almaraz A, Manrique-Espinoza B, Ávila-Funes JA, Chatterji S, Naidoo N, Kowal P, Salinas-Rodríguez A. (2018). Disability, quality of life and all-cause mortality in older Mexican adults: association with multimorbidity and frailty. *BMC Geriatrics*, 18(1):1–9.
- Rolfson DB, Majumdar SR, Tsuyuki RT, Tahir A, Rockwood K. (2006). Validity and reliability of the Edmonton Frail Scale. *Age and Ageing*, 35(5):526–529.

- Rony MKK, Kayesh I, Bala SD, Akter F, Parvin MR. (2024). Artificial intelligence in future nursing care: exploring perspectives of nursing professionals—a descriptive qualitative study. *Heliyon*, 10(4):eXXXXXXX.
- Rushton CA, Kadam UT. (2014). Impact of non-cardiovascular disease comorbidity on cardiovascular disease symptom severity: a population-based study. *International Journal of Cardiology*, 175(1):154–161.
- Sabry F. (2023). *Clinical Decision Support System: Fundamentals and Applications*. Vol. 259. One Billion Knowledgeable.
- Saizen Y, Ikuta K, Katsuhisa M, Takeshita Y, Moriki Y, Kasamatsu M, Takeya Y. (2024). Impact of nurse-led interprofessional work in older patients with heart failure and multimorbidity: A retrospective cohort study. *Am Heart J Plus*, 38:100361.
- Sakakibara BM, Obembe AO, Eng JJ. (2019). The prevalence of cardiometabolic multimorbidity and its association with physical activity, diet, and stress in Canada: evidence from a population-based cross-sectional study. *BMC Public Health*, 19(1):1–9.
- Sanchis-Gomar F, Perez-Quilis C, Leischik R, Lucia A. (2016). Epidemiology of coronary heart disease and acute coronary syndrome. *Ann Transl Med*, 4(13):256.
- Sathyanarayana S, Mohanasundaram T. (2024). Fit indices in structural equation modeling and confirmatory factor analysis: reporting guidelines. *Asian J Econ Bus Account*, 24(7):561–577.
- Sattar N. (2013). Revisiting the links between glycaemia, diabetes and cardiovascular disease. *Diabetologia*, 56(4):686–695.
- Saxena T, Ali AO, Saxena M. (2018). Pathophysiology of essential hypertension: an update. *Expert Rev Cardiovasc Ther*, 16(12):879–887.
- Schreiber JB. (2021). Issues and recommendations for exploratory factor analysis and principal component analysis. *Res Social Adm Pharm*, 17(5):1004–1011.

- Seeger DL, Amato MG, Frits M, Iannaccone C, Mugal A, Chang F, Rotenstein LS. (2024). A Machine Learning Technology for Addressing Medication-Related Risk in Older, Multimorbid Patients. *Am J Manag Care*, 30(8).
- Sewpaul R, Mbewu AD, Fagbamigbe AF, Kandala NB, Reddy SP. (2021). Prevalence of multimorbidity of cardiometabolic conditions and associated risk factors in a population-based sample of South Africans: a cross-sectional study. *Public Health Pract (Oxf)*, 2:100193.
- Shahzad F, Mannan A, Javed AR, Almadhor AS, Baker T, Al-Jumeily D. (2022). Cloud-based multiclass anomaly detection and categorization using ensemble learning. *J Cloud Comput Adv Syst Appl*, 11(1):74.
- Shorey S, Ang E, Ng ED, Yap J, Lau LST, Chui CK. (2020). Communication skills training using virtual reality: A descriptive qualitative study. *Nurse Educ Today*, 94:104592.
- Shorten C, Khoshgoftaar TM, Furht B. (2021). Text data augmentation for deep learning. *J Big Data*, 8(1):101.
- Shrestha N. (2021). Factor analysis as a tool for survey analysis. *Am J Appl Math Stat*, 9(1):4–11.
- Shu L, Yan H, Wu Y, Yan T, Yang L, Zhang S, Hu P. (2024). Explainable machine learning in outcome prediction of high-grade aneurysmal subarachnoid hemorrhage. *Aging (Albany NY)*, 16(5):4654.
- Singh K, Nashwan AJ. (2025). Artificial Intelligence-driven solutions: revolutionizing patient care in multimorbidity management. *Discov Health Syst*, 4(1):1–5.
- Singh-Manoux A, Fayosse A, Sabia S, Tabak A, Shipley M, Dugravot A, Kivimäki M. (2018). Clinical, socioeconomic, and behavioural factors at age 50 years and risk of cardiometabolic multimorbidity and mortality: a cohort study. *PLoS Med*, 15(5):e1002571.
- Souza-Pereira L, Ouhbi S, Pombo N. (2021). A process model for quality in use evaluation of clinical decision support systems. *J Biomed Inform*, 123:103917.

- Stewart R. (2019). Cardiovascular disease and frailty: what are the mechanistic links?. *Clin Chem*, 65(1):80–86.
- Sum G, Salisbury C, Koh GCH, Atun R, Oldenburg B, McPake B, Lee JT. (2019). Implications of multimorbidity patterns on health care utilisation and quality of life in middle-income countries: cross-sectional analysis. *J Glob Health*, 9(2):020413.
- Sun Z, Wang G, Li P, Wang H, Zhang M, Liang X. (2024). An improved random forest based on the classification accuracy and correlation measurement of decision trees. *Expert Syst Appl*, 237:121549.
- Sutton RT, Pincock D, Baumgart DC, Sadowski DC, Fedorak RN, Kroeker KI. (2020). An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ Digit Med*, 3(1):17.
- Temraz M, Keane MT. (2022). Solving the class imbalance problem using a counterfactual method for data augmentation. *Mach Learn Appl*, 9:100375.
- The EuroQoL Group. (1990). EuroQol-a new facility for the measurement of health-related quality of life. *Health Policy*, 16(3):199–208.
- Thorndike RM. (1995). Book review: psychometric theory by Jum Nunnally and Ira Bernstein New York: McGraw-hill, 1994, xxiv+752 pp. *Appl Psychol Meas*, 19(3):303–305.
- Türkiye İstatistik Kurumu (TÜİK). (2023). Türkiye Yaşlı Profili Araştırması, 2023. <https://data.tuik.gov.tr/Bulten/Index?p=Turkiye-Yasli-Profil-Arastirmasi-2023-53809>, Erişim tarihi: 20.06.2025.
- Türkiye İstatistik Kurumu (TÜİK). (2024). Ölüm ve Ölüm Nedeni İstatistikleri, 2024. <https://data.tuik.gov.tr/>, Erişim tarihi: 20.06.2025.
- Van der Aa MJ, van den Broeke JR, Stronks K, Plochg T. (2017). Patients with multimorbidity and their experiences with the healthcare process: a scoping review. *J Comorb*, 7(1):11–21.

- van Oostrom SH, Gijsen R, Stirbu I, Korevaar JC, Schellevis FG, Picavet HSJ, Hoeymans N. (2016). Time trends in prevalence of chronic diseases and multimorbidity not only due to aging: data from general practices and health surveys. *PLoS One*, 11(8):e0160264.
- Varghese J, Kleine M, Gessner SI, Sandmann S, Dugas M. (2018). Effects of computerized decision support system implementations on patient outcomes in inpatient care: a systematic review. *J Am Med Inform Assoc*, 25(5):593–602.
- Varma MN. (2025). Predictive analysis of bus ticket price by using random forest comparing with support vector machine. In: *Hybrid and Advanced Technologies*. CRC Press, p.487–492.
- Vetrano DL, Palmer K, Marengoni A, Marzetti E, Lattanzio F, Roller-Wirnsberger R, Joint Action ADVANTAGE WP4 Group. (2019). Frailty and multimorbidity: a systematic review and meta-analysis. *J Gerontol A Biol Sci Med Sci*, 74(5):659–666.
- Violán C, Bejarano-Rivera N, Foguet-Boreu Q, Roso Llorach A, Pons-Vigués M, Martín Mateo M, Pujol-Ribera E. (2016). The burden of cardiovascular morbidity in a European Mediterranean population with multimorbidity: a cross-sectional study. *BMC Fam Pract*, 17:1–12.
- Wang Y, Li R, Yuan L, Yang X, Lv J, Ye Z, He T. (2023). Association between diabetes complicated with comorbidities and frailty in older adults: A cross-sectional study. *J Clin Nurs*, 32(5–6):894–900.
- Weber S. (2007). A qualitative analysis of how advanced practice nurses use clinical decision support systems. *J Am Acad Nurse Pract*, 19(12):652–667.
- Webster F, Rice K, Bhattacharyya O, Katz J, Oosenbrug E, Upshur R. (2019). The mismeasurement of complexity: provider narratives of patients with complex needs in primary care settings. *Int J Equity Health*, 18:1–8.
- Wengrofsky P, Lee J, Makaryus AN. (2019). Dyslipidemia and its role in the pathogenesis of atherosclerotic cardiovascular disease: Implications for

- evaluation and targets for treatment of dyslipidemia based on recent guidelines. In: IntechOpen. doi:10.5772/intechopen.85772.
- Whitehead L, Palamara P, Allen J, Boak J, Quinn R, George C. (2022). Nurses' perceptions and beliefs related to the care of adults living with multimorbidity: A systematic qualitative review. *J Clin Nurs*, 31(19–20):2716–2736.
- Whitehead L, Palamara P, Babatunde- Sowole OO, Boak J, Franklin N, Quinn R, Allen J. (2023). Nurses' experience of managing adults living with multimorbidity: A qualitative study. *J Adv Nurs*, 79(7):2514–2524.
- Willadsen TG, Siersma V, Nicolaisdottir DR, Jarbol D, Guassora AD, Reventlow S. (2021). Symptom burden in multimorbidity: a population-based combined questionnaire and registry study from Denmark. *BMJ Open*, 11:e041877.
- Wright JC, Plenderleith L, Ridley SA. (2003). Long- term survival following intensive care: subgroup analysis and comparison with the general population. *Anaesthesia*, 58(7):637–642.
- Wu J, Xue E, Huang S, Fu Y, Chen D, Shao J, Ye Z. (2023). Facilitators and barriers of integrated care for older adults with multimorbidity: a descriptive qualitative study. *Clin Interv Aging*, 18:1973–1983.
- Yang K, Hou R, Zhao J, Wang X, Wei J, Pan X, Zhu X. (2023). Lifestyle effects on aging and CVD: a spotlight on the nutrient-sensing network. *Ageing Res Rev*, 92:102121.
- Yarnall AJ, Sayer AA, Clegg A, Rockwood K, Parker S, Hindle JV. (2017). New horizons in multi-morbidity in older adults. *Age Ageing*, 46(6):882–888.
- Younas A, Inayat S. (2024). Alleviating suffering of individuals with multimorbidity and complex needs: A descriptive qualitative study. *Nurs Ethics*, 31(2–3):189–201.
- Yudkovicz JJ, Minster RL, Barinas-Mitchell E, Christensen K, Feitosa M, Barker MS, Kuipers AL. (2021). Pleiotropic effects between cardiovascular

- disease risk factors and measures of cognitive and physical function in long-lived adults. *Sci Rep*, 11(1):17980
- Zador Z, Landry A, Cusimano MD, Geifman N. (2019). Multimorbidity states associated with higher mortality rates in organ dysfunction and sepsis: a data-driven analysis in critical care. *Crit Care*, 23:1–11.
- Zhang S, Meng L, Qiu F, Yang JD, Sun S. (2018). Medication-related risk factors associated with health-related quality of life among community-dwelling elderly in China. *Patient Prefer Adherence*, 12:529–537.
- Zhang H, Duan X, Rong P, Dang Y, Yan M, Zhao Y, Pei L. (2022). Effects of potential risk factors on the development of cardiometabolic multimorbidity and mortality among the elderly in China. *Front Cardiovasc Med*, 9:966217.
- Zhang X, Paz I, Nebot À, Mugica F, Romero E. (2023). Ad-RuLer: A novel rule-driven data synthesis technique for imbalanced classification. *Appl Sci*, 13(23):12636.
- Zhang X, Liao Y, Zhang D, Liu W, Wang Z, Jin Y, Wei J. (2025). Predicting frailty in older patients with chronic pain using explainable machine learning: A cross-sectional study. *Geriatr Nurs*, 61:699–708.
- Zhang Y, Haghani A. (2015). A gradient boosting method to improve travel time prediction. *Transp Res Part C Emerg Technol*, 58:308–324.
- Zhao Y, Zhang H, Liu X, Desloge A, Wang Q, Zhao S, Tzoulaki I. (2023). The prevalence of cardiometabolic multimorbidity and its associations with health outcomes among women in China. *Front Cardiovasc Med*, 10:922932.
- Zheng Y, Zhou Z, Wu T, Zhong K, Hu H, Zhang H, Liu W. (2023). Association between composite lifestyle factors and cardiometabolic multimorbidity in Chongqing, China: A cross-sectional exploratory study in people over 45 years and older. *Front Public Health*, 11:1118628.

Zhou K, Wang A, Yi K. (2025). Cardiometabolic multimorbidity and frailty in middle-aged and older adults: a cross-nationally harmonized study. *Front Public Health*, 13:1565682.

Zisberg A, Rayan-Gharra N, Danial-Saad A, Rogozinski A, Fraiman PS, Segel-Karpas D. (2024). Age-Friendly Healthcare: An Evolutionary Concept Analysis. *J Clin Nurs*, 33(12):4635–4650.

Zolnoori M, McDonald MV, Barrón Y, Cato K, Sockolow P, Sridharan S, Topaz M. (2021). Improving patient prioritization during hospital-homecare transition: protocol for a mixed methods study of a clinical decision support tool implementation. *JMIR Res Protoc*, 10(1):e20184.



EKLER

EK 1

Nitel/Birinci Aşama Etik Kurul İzni



EK 2

Ölçek Geliştirilmesi/İkinci Aşama Etik Kurul İzni



EK 3

Klinik Karar Destek Sistemi Geliştirilmesi/Üçüncü Aşama Etik Kurul İzni



EK 4
Arařtırma Uygulama İzni



EK 5.

Hemşire Görüşme Formu (Araştırmanın Birinci/Nitel Aşaması)

Görüşmecı numarası:.....

Görüşmenin yapıldığı yer:

Görüşmenin tarihi:

Görüşmenin saati ve süresi:

Bireysel Özellikler

Yaşınız:.....

Cinsiyetiniz: () Kadın () Erkek

Öğrenim durumunuz: () Lise/Önlisans () Lisans () Yüksek lisans ()
Doktora

Kaç yıldır hemşire olarak çalışıyorsunuz?.....

Çalışılan servis adı: () Kardiyoloji Servisi () İç Hastalıkları Servisi () İç
Hastalıkları YBÜ

() Nöroloji Servisi () Nöroloji-İnme YBÜ

Çalıştığınız yoğun bakım/serviste ortalama kaç hastaya bakım veriyorsunuz?

Yazınız.....

Nitel Görüşme Soruları

1.Yaşlı çoklu kardiyometabolik hastalığı olan bireylerin bakım verirken yaşadığınız zorluklar nelerdir?

2.Yaşlı çoklu kardiyometabolik hastalığı olan bireylerin bakım gereksinimlerini sınıflandırmanın gerekliliği hakkında düşünceleriniz nelerdir? Anlatır mısınız?

3.Yaşlı çoklu kardiyometabolik hastalığı olan bireylere bakım verirken hemşirelik tanımlarını nasıl önceliklendiriyorsunuz? Anlatır mısınız?

4.Yaşlı çoklu kardiyometabolik hastalığı olan bireylerin bakım gereksinimlerini sınıflandırma ve önceliklendirmeye yönelik bir karar destek sistemi nasıl geliştirebilir, bu konudaki düşünceleriniz nelerdir?

5.Bir karar destek sistemi geliştirilmesinin yaşlı çoklu kardiyometabolik hastalığı olan bireylerin tedavi ve bakım sürecine nasıl katkıları olur?



EK 6

Veri Toplama Formu (Araştırmanın İkinci/Ölçek Geliştirme Aşaması)

Kardiyometabolik Multimorbiditesi Olan Bireylerde Semptom Şiddeti Ölçeği

Aşağıdaki ölçekte kardiyometabolik (koroner kalp hastalığı, inme, diyabet ve hipertansiyon hastalıklarından en az iki tanesine yönelik tanısı olan) **çoklu hastalığı** olan bireylerde görülen belirtiler yer almaktadır. **Son bir ay içinde** bu belirtileri yaşadysanız, bu belirtilerin sizi ne kadar **rahatsız ettiğini** ilgili kutucuğu işaretleyerek belirtiniz.

Son bir ay (4 Hafta) içinde aşağıdaki belirtileri yaşadınız mı?	Yaşadıysanız sizi ne kadar rahatsız etti?				
	0 (hiç)	1 (hafif)	2 (orta)	3 (şiddetli)	4 (çok)
1 Ağız kuruluğu					
2 Bacaklarda şişlik/ödem					
3 Baş ağrısı					
4 Baş dönmesi					
5 Bayılma					
6 Bilinç bulanıklığı, anlamada güçlük					
7 Bulanık/çift görme					
8 Burun kanaması					
9 Denge, koordinasyon ve yürüme zorluğu					
1 Ellerde veya ayaklarda uyuşma/karınalanma					
1 Göğüste ağrı, yanma ve sıkışma hissi					
1 Halsizlik / yorgunluk					
1 Huzursuzluk hissi					
1 Kafada karışıklık, dikkat dağınıklığı, hafıza, hatırlama sorunları					
1 Kalp çarpıntısı					
1 Kaygı/endişe hissi					
1 Kol veya bacaklarda güç/his kaybı					
1 Konuşma güçlüğü					
1 Kulak çınlaması					
2 Kusma					
2 Nefes darlığı					
2 Sık idrara çıkma					
2 Aşırı terleme					
2 Uyku hali/sersemlik hissi					
2 Uykuya dalma/sürdürme güçlüğü					

Ölçek Puanlama: Her maddede işaretlenen rakamlar toplanır. Ölçekten alınabilecek puan **0-100** arasında değişmektedir. Toplam puanın artması çoklu hastalığı olan bireylerde semptom şiddetinin daha yüksek olduğunu göstermektedir.

EQ-5D-3L Genel Yaşam Kalitesi Ölçeği

A- Hareket ederken (yürürken)	
1()	Yürürken, hiç bir güçlük çekmiyorum
2()	Yürürken bazı güçlüklerim oluyor
3()	Yatalağım
B- Kendi Kendine Bakabilme (yıkınırken veya giyinirken)	
1()	Kendime bakmakta güçlük çekmiyorum
2()	Kendi kendime yıkınırken veya giyinirken bazı güçlüklerim oluyor
3()	Kendi kendime yıkanacak veya giyinebilecek durumda değilim
C- Olağan işler (örneğin, iş, ders çalışma, ev işleri, aile içi veya boş zaman faaliyetleri)	
1()	Olağan işlerimi yaparken herhangi bir güçlük çekmiyorum
2()	Olağan işlerimi yaparken bazı güçlüklerim oluyor
3()	Olağan işlerimi yapabilecek durumda değilim
D- Ağrı/rahatsızlık	
1()	Ağrı veya rahatsızlığım yok
2()	Orta derecede ağrı veya rahatsızlıklarım var
3()	Aşırı derecede ağrı veya rahatsızlıklarım var
E- Endişe / Moral Bozukluğu	
1()	Endişeli veya moral bozukluğu içinde değilim
2()	Orta derecede endişeliyim veya moralim bozuk
3()	Aşırı derecede endişeliyim veya moralim çok bozuk

En iyi
sağlık durumu
100
90
80
70
60
50
40
30
20
10
0
En kötü
sağlık durumu

**Bugünkü
sağlık
durumunuz?**

EK 7**Uzmanlar Listesi (Ölçek Maddelerinin Değerlendirilmesi)**

Uzman Ad Soyad	Uzmanlık Alanı
Prof. Dr. Mehmet AKMAN	Dahili Tıp Bilimleri Bölümü, Aile Hekimliği Anabilim Dalı
Prof. Dr. Selçuk YAYLACI	Dahili Tıp Bilimleri Bölümü, İç Hastalıkları Anabilim Dalı
Prof. Dr. Ayfer KARADAKOVAN	İç Hastalıkları Hemşireliği
Prof. Dr. Selda ÇELİK	İç Hastalıkları Hemşireliği
Prof. Dr. Serap ÜNSAR	İç Hastalıkları Hemşireliği
Prof. Dr. Sibel KARACA SİVRİKAYA	İç Hastalıkları Hemşireliği
Prof. Dr. Papatya KARAKURT	Hemşirelik Esasları
Prof. Dr. Yasemin TOKEM	İç Hastalıkları Hemşireliği
Prof. Dr. Feride TAŞKIN YILMAZ	İç Hastalıkları Hemşireliği
Prof. Dr. Zehra GÖK METİN	İç Hastalıkları Hemşireliği
Doç. Dr. Sevdâ Efil	İç Hastalıkları Hemşireliği
Dr. Öğr. Üyesi Gülay YILDIRIM	İç Hastalıkları Hemşireliği
Dr. Öğr. Üyesi Nurhan ÖZPANCAR ŞOLPAN	İç Hastalıkları Hemşireliği
Dr. Öğr. Üyesi Vacide AŞIK ÖZDEMİR	İç Hastalıkları Hemşireliği
Dr. Fatih ÇELEBİ	Geriatri Uzmanı

EK 8

Veri Toplama Formu (Araştırmanın Üçüncü/Klinik Karar Destek Sistemi Geliştirilmesi Aşaması)

Hasta Bilgi Formu

Sosyodemeografik sorular:

1. Kaç yaşındasınız? () Evet () Hayır
.....
(Evetse tanı süresi.....)
2. Cinsiyetiniz: a) Kadın b) Erkek
3. Eğitim durumunuz:
a) Okur-yazar b) Ortaöğretim c) Lise d) Lisans e) Lisans üstü
4. Sigara içme alışkanlığı:
a) İçiyor b) Hiç içmemiş c) Bırakmış
5. Alkol içme alışkanlığı:
a) İçiyor b) Hiç içmemiş c) Bırakmış
6. Boy:.....Kilo:.....
BKİ:
3. Diyabet (şeker hastalığı):
() Evet () Hayır
(Evetse tanı süresi.....)
4. İnme (felç):
() Evet () Hayır
(Evetse tanı süresi.....)
5. Dislipidemi (yüksek kolesterol):
() Evet () Hayır
(Evetse tanı süresi.....)
6. İlaç sayısı:.....
7. Ağrı Şiddeti:.....
8. Düşme Riski Puanı:.....

Hastalık ile ilgili sorular:

1. Koroner kalp hastalığı (geçirilmiş kalp krizi öyküsü/damar tıkanıklığı/anjiyo/stent):
() Evet () Hayır
(Evetse tanı süresi.....)
2. Hipertansiyon (yüksek tansiyon):

Fizyolojik Parametreler:

Kan Basıncı (Sistolik):.....

Kan Basıncı (Diyastolik):.....

Kalp Hızı (nabız):.....

Solunum Sayısı:.....

O2 Satürasyonu:.....

Laboratuvar Bulguları:

Hemoglobin:.....

Açlık kan glikozu:.....

HbA1c:.....

Sodyum:.....

Potasyum:.....

Kreatinin:.....

Kan Üre Nitrojen:.....

Ürik asit:.....

Kolestrol:.....

Trigliserid:.....

HDL:.....

LDL:.....

TSH:.....

KM-SŞÖ total semptom puanı:.....

EQ-5D-3L total yaşam kalitesi
puanı:...

EQ-5D-3L VAS sağlık durumu:.....

Edmonton Kırılabilirlik Ölçeği

Kırılabilirlik Alanı	Madde	0 Puan	1 Puan	2 Puan
Bilişsel durum	Lütfen bu çizili dairenin bir saat olduğunu düşünün. Sizden sayıları doğru yerlerine koymanızı ve sonra elinizle 11'i 10 geçeyi göstermenizi istiyorum.	Hata yok	Küçük yerleştirme hataları	Diğer hatalar
Genel sağlık durumu	Geçen yıl kaç defa hastaneye yattınız?	0	1-2	>2
	Genel olarak sağlığınıza nasıl tanımlarsınız?	Mükemmel, çok iyi, iyi	İdare eder	Kötü
Fonksiyonel bağımsızlık	Aşağıdaki aktivitelerin kaçında yardıma ihtiyacınız olur? - Yemek hazırlama - Alışveriş yapma - Ulaşım - Telefon - Ev temizliği - Çamaşır - Yıkamak - Paranın idaresi - İlaç almak	0-1	2-4	5-8
Sosyal Destek	Yardıma ihtiyacınız olduğunda size yardım edebilecek ve istekli herhangi birine güvenebiliyor musunuz?	Her zaman	Bazen	Hiç
İlaç kullanımı	Düzenli olarak 5 veya daha fazla farklı ilaç kullanıyor musunuz?	Hayır	Evet	
	Zaman zaman reçeteli ilaçlarınızı almayı unutuyor musunuz?	Hayır	Evet	
Beslenme	Son zamanlarda giysilerinizde bollaşmaya neden olacak kadar kilo kaybınız oldu mu?	Hayır	Evet	

Ruh Hali	Kendinizi sıklıkla üzgün veya depresif hisseder misiniz?	Hayır	Evet	
Kontinans	İstemsiz idrar kaçırma probleminiz var mı?	Hayır	Evet	
Fonksiyonel Performans	Sizden bu sandalyeye rahatça oturmanızı rica ediyorum. Size "gidin" dediğim zaman ayağa kalkın ve zeminde işaretli yere kadar (ortalama 3 metre) rahat ve güvenli yürüyün ve geri dönüp sandalyeye oturun. Süresi değerlendirilir.	0-10 sn	11-20 sn /	>20 saniye veya hastanın isteksizliği veya yardıma ihtiyaç duyması
Toplam	Toplam skor kolonların skorları toplamıdır			

EK 9

Uzmanlar Listesi (Klinik Karar Destek Sistemi Geliştirilmesi için Öznitelik- Hemşirelik Tanı Eşleşmesi)

Uzman Ad Soyad	Uzmanlık Alanı
Prof. Dr. Serap ÜNSAR	İç Hastalıkları Hemşireliği
Prof. Dr. Feride TAŞKIN YILMAZ	İç Hastalıkları Hemşireliği
Prof. Dr. Zehra GÖK METİN	İç Hastalıkları Hemşireliği
Prof. Dr. Yurdanur DİKMEN	Hemşirelik Esasları
Dr. Öğr. Üyesi Fatma TANRIKULU	Hemşirelik Esasları
Öğr. Gör. Dr. Funda EROL	Hemşirelik Esasları

Sayın Hocam;

“Kardiyometabolik Multimorbidesi olan Yaşlı Hastalarda Bakım Gereksinimlerini Sınıflandırma ve Hemşirelik Tanılarını Belirlemeye Yönelik Bir Karar Destek Sisteminin Geliştirilmesi” isimli doktora öğrencimin tezi kapsamında sizin uzman görüşünüze ihtiyaç duymaktayız. Bu doktora tezi ile hastanede yatarak tedavi gören en az iki tane kardiyometabolik hastalık tanısı (Koroner kalp hastalığı, hipertansiyon, diyabet, inme, dislipidemi) olan 65 yaş üstü yaşlı hastaların bakım gereksinimlerini sınıflandırma ve hemşirelik tanılarını belirlemeye yönelik makine öğrenimi tabanlı ile bir klinik karar destek sistemin geliştirilmesi amaçlanmıştır.

Bu kapsamda makine öğreniminde öznitelik olarak kullanılmak üzere; *yaş, cinsiyet, eğitim durumu, sigara içme, alkol kullanma, beden kitle indeksi (BKİ), her bir kardiyometabolik hastalık varlığı ve tanı süresi (KKH, hipertansiyon, DM, inme ve dislipidemi), kullanılan ilaç sayısı, düşme risk puanı, ağrı şiddeti, sistolik ve diyastolik kan basıncı, kalp hızı, solunum sayısı, oksijen saturasyonu (SpO2), hemoglobin, açlık kan glikozu, HbA1c, sodyum, potasyum, kreatinin, ürik asit, kan üre nitrojen (BUN) düzeyleri, kolesterol, trigliserid, HDL, LDL, TSH değerleri ile Kardiyometabolik Multimorbiditeli Hastalarda Semptom Şiddeti Ölçeği puanları ve EQ-5D-3L Genel Yaşam Kalitesi Ölçeği puanları* dahil olmak üzere 40 öngörücü değişken belirlenmiştir.

Model tahmini için kontrol skalası (etiket) olarak Edmonton Kırılgnalık Ölçeği kullanılmıştır. Araştırma 700 hasta ile veri toplama süreci tamamlanmıştır. Hastaların kırılgnalık düzeylerine göre öncelikle bakım gereksinimleri sınıflandırılacak (düşük, orta, yüksek, çok yüksek) ve sonrasında hemşirelik

tanılarını önerebilecek bir makine öğrenimi tabanlı klinik karar destek sistemi geliştirilecektir. Makine öğrenimi analiz aşaması için aşağıda yer alan öngörücü değişkenlere göre belirlenen 10 hemşirelik tanısının her birini “Uygun Değil”, “Düzeltilmesi Gerekir”, ve “Uygun” seçeneklerinden birini işaretleyerek değerlendirmeniz ve varsa ilave önerilerinizi açıklama sütununda belirtmeniz çalışmamıza bilimsel katkı sağlayacaktır.

Değerli katkılarınız için çok teşekkür ederiz.



ÖZGEÇMİŞ

