KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TAKVİYELİ ÖĞRENME VE AÇIKLANABİLİR YAPAY ZEKA İLE SANAL KAN ŞEKERI İZLEME SİSTEMİNİN GELİŞTİRİLMESİ

ARSENE ADJEVI

KOCAELİ 2026

KOCAELİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TAKVİYELİ ÖĞRENME VE AÇIKLANABİLİR YAPAY ZEKA İLE SANAL KAN ŞEKERI İZLEME SİSTEMİNİN GELİŞTİRİLMESİ

ARSENE ADJEVİ

Doç. Dr. Serdar SOLAK		
Danışman,	**Kocaeli Üniv.**	**.....**
Doç. Dr. Mustafa Hikmet Bilgehan UÇAR		
Jüri Üyesi,	**Kocaeli Üniv.**	**.....**
Doç. Dr. Ekin EKİNCİ		
Jüri Üyesi,	**Sakarya Uygulamalı Bilimleri Üniv.**	**.....**

Tezin Savunulduğu Tarih: 08.01.2026

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmasında,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

■ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 124E863 no'lu proje kapsamında maddi/alt yapı desteği gerçekleştirilmiştir.

☐ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler .....tarafından..... no'lu proje kapsamında maddi/alt yapı desteği gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmayla ilgili koşullar bu beyana aykırı bir durum saptanması durumunda, ortaya çıkacak tüm yapısal ve yapısal sonuçlar kabul edilebilir görünümlerimdir.

Arsene ADJEVI

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri enstitü tarafından onaylanan lisansınız tezimin/projemin tamamı veya herhangi bir kısmı, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'nde kullanıma beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları tüm fikri mülkiyet hakları bende kalacak, tezimin/projemin tamamının ya da bir bölümdeki değişiklik makalesi, kitap, tebliğ, lisans, patent gibi aydınlatma kullanımı, danışmanımın isim hakkı saklı kalmasıyla ve her iki tarafın bilgisi dahilinde bana ait olacaktır.

Tezin/projenin kendi özgün çalışması olduğunu, haklarının ihlal edilmediğini ve tezinin/projenin tek yetkili sahibi gelişim beyanı ve taahhüdünü verir. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin verilmesi zorunlu metinlerin kullanılması yazılı izin alarak kullandığım ve isten suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan ***"Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge"*** kapsamında tezim aşağıda belirtilen koşullar dışında YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açın.

☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.

☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.

■ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

Arsene ADJEVI

ÖNSÖZ VE TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 124E863 numaralı proje kapsamında desteklenmiştir. Sağladıkları değerli destek için TÜBİTAK'a teşekkür ederim. Yüksek lisans sürecinde birlikte çalışma ayrıcalığına sahip olduğum, bilgi birikimi, açık fikirli yaklaşımı ve bilimsel titizliğiyle bana ilham kaynağı olan değerli danışmanım Sayın Doç. Dr. Serdar Solak'a en içten teşekkürlerimi ve sonsuz şükranlarımı sunarım. Bilimsel araştırmalarım süresince gösterdiği sabır, rehberlik ve alanındaki uzman yaklaşımı; akademik bakış açımı derinleştirmemde ve araştırma tutkusunu içselleştirmemde belirleyici olmuştur. Akademik altyapımın inşasında sunduğu benzersiz katkılar ve sürekli desteği için kendisine gönülden minnettarım. Proje ve araştırmalarımda birlikte çalıştığım Dr. Öğr. Üyesi Faruk Aktaş ve Doç. Dr. Mustafa Hikmet Bilgehan Uçar hocalarıma değerli katkıları için teşekkür ederim. Araştırma sürecinde benimle birlikte çalışan, bilgi ve deneyimlerini cömertçe paylaşarak paha biçilemez katkılar sunan değerli meslektaşım ve iş arkadaşım Abdiwahab Mohamed Abdirashid'e içtenlikle teşekkür ederim. Desteği, bu çalışmanın ilerlemesinde ve mesleki gelişimimde önemli bir rol oynamıştır. Tez komitesinde yer alan Doç. Dr. Ekin EKİNCİ hocama, yapıcı eleştiriler ve değerli görüşleri için teşekkür ederim. Ayrıca, bu süreçte her zaman yanımda olan, bana moral ve güç veren; özellikle annem ve ablam başta olmak üzere sevgili aileme sonsuz teşekkürlerimi sunarım. Fedakarlıkları, sabırları ve koşulsuz destekleri olmasaydı bu başarıların hiçbirine ulaşmam mümkün olmazdı. Son olarak, rahmetli abim Leonce'a en derin sevgi, teşekkür ve minnet duygularımı ifade etmek isterim. Allah rahmet eylesin; hatırası daima yoluma ışık olmaya devam edecektir.

Ocak-2026 Arsene ADJEVI

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI ii
ÖNSÖZ VE TEŞEKKÜR iii
ŞEKİLLER DİZİNİ v
TABLOLAR DİZİNİ vi
SİMGELER VE KISALTMALAR DİZİNİ vii
ÖZET viii
ABSTRACT ix
1. GİRİŞ 1
1.1. Araştırma Amaçları 2
1.2. Tez Katkıları 3
1.3. Tez Organizasyonu 4
2. LİTERATÜR TARAMASI 6
2.1. Derin Öğrenme Tabanlı Kan Şekeri Seviyesi Tahmini 6
2.2. Kan Şekeri Yönetimi için Takviyeli Öğrenme 8
2.3. Kan Şekeri Tahmininde SHAP Tabanlı Açıklanabilirlik 10
2.4. Kan Şekeri Tahmini için Açıklanabilir Takviyeli Öğrenme (XRL) 13
3. VERİ KÜMESİ ÖN İŞLEME 15
3.1. Kan Şekeri Değeri Ön İşleme 20
3.2. Bazal İnsülin Ön İşleme 21
3.3. Karbohidrat Verilerinin Ön İşlenmesi 24
3.4. Diğer Fizyolojik Sinyal Ön İşleme 26
3.5. Çok Değişkenli Giriş Verilerinin Pencereleme İşlemi 28
3.6. Eğitim-Test Verilerinin Bölünmesi 29
4. EVRİMSEL SİNİR AĞI MODELİN MİMARİSİ 32
5. SHAP DESTEKLİ GLUKOZ KONTROLÜ 34
6. POMDP AKTÖR-KRİTİK MODELİ 36
7. MODEL DEĞERLENDİRMESİ 40
8. DENEYSEL SONUÇLAR VE TARTIŞMA 43
8.1. Tahmin Edici ve Önleyici Modellerin Entegrasyonu 57
9. SONUÇLAR VE ÖNERİLER 61
KAYNAKLAR 63
KİŞİSELYAYIN VE ESERLER 68
ÖZGEÇMİŞ 69

ŞEKİLLER DİZİNİ

Şekil 3.1. Hasta 570'te kan şekeri dalgalanmalarının genel görünümü 20
Şekil 3.2. Hasta 570'te Humalog bazal insülin profilleri 23
Şekil 3.3. Hasta 559'da Novalog bazal insülin profilleri 23
Şekil 3.4. Hasta 559 için üretilmiş bazal insülin verisi 24
Şekil 3.5. Gerçek ve tahmini karbonhidrat alımının karşılaştırması 25
Şekil 3.6. Hasta 559 için GSR, sıcaklık, adım, nabız 27
Şekil 3.7. Yardımcı sinyallerin kan şekeri zamanına hizalanması. 27
Şekil 3.8. Hasta 559 için saatlik giriş ve tahmin penceresi. 29
Şekil 3.9. Zaman serisi için blok ve genişleyen pencere 29
Şekil 4.1. Bir saatlik kan şekeri tahmini için hafif evrişimli CNN ağı 32
Şekil 6.1. Kan şekeri Modülasyonu için SHAP Rehberli Aktör-Eleştirmen RL 38
Şekil 6.2. Aktör–Eleştirmen Kan Şekeri Yönetimi Mimarisi 39
Şekil 7.1. Önerilen Çerçevemizin Genel Görünümü 41
Şekil 8.1. Hasta 559 için farklı aralıklarda Clarke Error Grid 53
Şekil 8.2. Hasta 570 için farklı aralıklarda Clarke Error Grid 54
Şekil 8.3. 559 hastanin Shapley Açıklama (SHAP) değerleri 56
Şekil 8.4. RL ajanı: Özellik ayarları ve kan şekeri karşılaştırması 57
Şekil 8.5. Ajan davranışı: pozitif ve negatif ödüllerin grafiği 58

TABLOLAR DİZİNİ

Tablo 2.1. Derin Öğrenme Tabanlı Yaklaşımların Özeti 7
Tablo 2.2. Glukoz Yönetiminde Takviyeli Öğrenme 10
Tablo 2.3. Kan Şekeri Yönetiminde SHAP Çalışmalarının Özeti 11
Tablo 2.4. Mevcut RL kan şekeri yönetimi: eksikler, çözümler, sorunlar 14
Tablo 3.1. OhioT1DM Katılımcıların Demografi Cihaz Bilgileri 15
Tablo 3.2. OhioT1DM Veri seti özelliklerin birimleri ve ölçüm sıklığı 16
Tablo 3.3. 2018 kohortu özellik ve hasta başına veri 17
Tablo 3.4. 2020 kohortu özellik ve hasta başına veri 18
Tablo 3.5. OhioT1DM veri setinin seçmiş özelliklerine genel bakış 19
Tablo 3.6. Farklı hastalarda pencereleme yöntemleri karşılaştırması 30
Tablo 8.1. CNN modeli, RL ortamı, SHAP, eğitim ve kısıtlamalar 43
Tablo 8.2. Hasta Başına Eğitim Veri Setinin Tanımlayıcı İstatistikleri 45
Tablo 8.3. Farklı zamanlarda tek değişkenli RMSE ve MAE 47
Tablo 8.4. Çok değişkenli tahmin: Zaman aralıklarında göre RMSE ve MAE 48
Tablo 8.5. Çok Değişkenli Tahmin Hata Ölçütleri 49
Tablo 8.6. Tek Değişkenli RMSE ve MAE 50
Tablo 8.7. Önerilen yöntemin 30-60 dk tahmin karşılaştırması 52
Tablo 8.8. Önerilen yöntemin 30-60 dk çalışmalarla karşılaştırılması 53
Tablo 8.9. Hasta 570: Aralık başına Clarke Error Grid 56
Tablo 8.10. Önemli SHAP özellikleri ve beklenen fizyolojik etkiler 60

SİMGELER VE KISALTMALAR DİZİNİ

α : Öğrenme oranı
α_t : Zaman adımındaki eylem
β : Seçilen özelliğin artış birimi
δ : Zamansal fark hatası
$\mathbb{E}[\cdot]$: Beklenen değer
f : CNN tahmin modeli
g : Kan şekeri değeri
i : Özellik dizini
I : İnsülin dozu
k : Bozunma faktörü
D : Karbonhidrat alımı
o : Gözlem
ϕ : Özellik katkısı (SHAP değeri)
ϕ_c : Kritik (Critic) parametreleri
π : Politika
PG_a : Gerçek kan şekeri değeri
PG_n : Normal tahmini kan şekeri
PG_r : Düzenlenmiş tahmini kan şekeri
r : Ödül fonksiyonu
s : Durum
t : Zaman endeksi
V : Durum-değer fonksiyonu
ψ : Aktör (Actor) parametreleri
γ : İndirim faktörü

Kısaltmalar

CEG : Clarke Error Grid (Clarke Hata Izgarası)
CGM : Continuous Glucose Monitoring (Sürekli Kan Şekeri İzleme)
CNN : Convolutional Neural Network (Evrişimsel Sinir Ağı)
GSR : Galvanic Skin Response (Galvanik Cilt Tepkisi)
IDF : International Diet Federation (Uluslararası Diyabet Federasyonu'nun)
LSTM : Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MAE : Mean Absolute Error (Ortalama Mutlak Hata)
MDP : Markov Decision Process (Markov Karar Süreci)
MLP : Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
POMDP : Partially Observable Markov Decision Process (Kısmen Gözlemlenebilir Markov Karar Süreci)
RL : Reinforcement Learning (Takviyeli Öğrenme)
RMSE : Root Mean Square Error (Kök Ortalama Kare Hatası)
SHAP : SHapley Additive exPlanations (Shapley Katkısal Açıklamalar)
T1D : Type 1 Diabetes (Tip 1 Diyabet)
UCB : Upper Confidence Bound(Üst Güven Sınırı)
XRL : Explainable Reinforcement Learning(Açıklanabilir Takviyeli Öğrenme)

TAKVİYELİ ÖĞRENME VE AÇIKLANABİLİR YAPAY ZEKA İLE SANAL KAN ŞEKERI İZLEME SİSTEMİNİN GELİŞTİRİLMESİ

ÖZET

Diyabette kan glukoz düzeylerinin dengede tutulması; beslenme, fiziksel aktivite, stres ve tedavi uygulamaları gibi çok sayıda etkileşimli faktöre bağlı, dinamik bir süreçtir. Sürekli glukoz izleme sistemleri ve makine öğrenmesindeki ilerlemeler kısa vadeli glukoz tahminlerini iyileştirmiş olsa da, metabolik dinamikleri daha iyi temsil edecek sinyal ön işleme yöntemleri ile tahmin modellerinin önleyici müdahale stratejileriyle bütünleştirilmesi halen sınırlıdır. Bu çalışmada, yalnızca araştırma amaçlı bir karar destek çerçevesi önerilmektedir. Çerçeve; üstel bozunum tabanlı sinyal ön işleme, evrişimsel sinir ağı (CNN) ile kısa vadeli glukoz tahmini, SHAP tabanlı özellik atfı ve aktör–eleştirmen pekiştirmeli öğrenme (RL) ajanını bir araya getirmektedir. Kompakt CNN modeli glukoz tahmini üretirken, SHAP analizi en etkili girdileri belirlemekte ve bu bilgiler, sınırlı ve tek adımlı davranışsal ayarlamalar öneren RL ajanını yönlendirmektedir. SHAP rehberli RL yaklaşımının belirsizliği nedeniyle sistem klinik kullanım için uygun olmayıp simülasyon amaçlıdır. OhioT1DM veri kümesi üzerinde yapılan deneylerde, önerilen model hasta başına 74 KB model boyutu ve bir dakikadan kısa eğitim süresiyle, farklı tahmin ufuklarında güncel yöntemlerle karşılaştırılabilir RMSE performansı elde etmiştir. Beş ila yirmi dakikalık tahminlerde öngörülerin %98'inden fazlası Clarke Grid hatasının A ve B bölgelerinde yer almıştır. Önleyici bileşen, hedef aralığa yakın durumlarda vakaların %25'inde hiperglisemi ve hipoglisemiyi 10 dakika içinde düzeltebilmiştir. Bu çalışma, tahmin doğruluğu, uyarlanabilirlik ve şeffaflığı birleştirerek, açıklanabilir ve kişiselleştirilmiş dijital sağlık sistemlerine yönelik yenilikçi bir yaklaşım sunmaktadır.

Anahtar Kelimeler: Derin Takviyeli Öğrenme, Kan Şeker, Shapley Değerleri, Zaman Serisi Tahmini.

DEVELOPMENT OF A VIRTUAL BLOOD GLUCOSE MONITORING SYSTEM USING REINFORCEMENT LEARNING AND EXPLAINABLE ARTIFICIAL INTELLIGENCE

ABSTRACT

Maintaining stable blood glucose in diabetes is a dynamic process shaped by diet, physical activity, stress, and medication. Although advances in continuous glucose monitoring and machine learning have improved short-term glucose prediction, signal preprocessing to better capture metabolic dynamics and the integration of predictive models with proactive intervention strategies remain limited.

We present a research-only decision-support framework that combines exponential signal preprocessing, CNN-based glucose prediction, SHAP feature attribution, and an actor–critic reinforcement learning agent. A compact CNN forecasts short-term glucose levels, SHAP identifies the most influential inputs, and these attributions guide an RL agent that recommends bounded, single-step behavioral adjustments. Due to uncertainty in SHAP-guided RL, the framework is intended for simulation and not for clinical use.

Experiments on the OhioT1DM dataset show state-of-the-art RMSE across multiple prediction horizons with a model size of 74 KB per patient and training time under one minute. Over 98% of predictions fall within Clarke Error Grid Zones A and B for 5–20-minute forecasts. The preventive module corrected hyper- and hypoglycemia in 25% of cases within 10 minutes when predictions were near the target range (80–120 mg/dL ±10 mg/dL), and otherwise reduced deviations.

This work advances diabetes decision support by unifying accurate prediction, adaptive intervention, and transparency, and by leveraging Shapley values not only for interpretability but also to guide reinforcement learning toward personalized digital health tools.

Keywords: Deep Reinforcement Learning, Blood Glucose, Shapley Values, Time Series Prediction.

1.GİRİŞ

Diyabet, günümüzde en yaygın ve demografik olarak en hızlı büyüyen hastalıklardan biridir ve dünyanın her bölgesinde her yıl binlerce ölüme neden olmaktadır. Uluslararası Diyabet Federasyonu'nun (IDF) 2021 raporuna göre, dünya genelinde yaklaşık 537 milyon kişi diyabetle yaşamaktadır ve bu da küresel nüfusun yaklaşık %10,5'ini temsil etmektedir (Hossain ve diğ., 2024). IDF projeksiyonlarına göre, 2045 yılına kadar her 8 yetişkinden 1'i, yani yaklaşık 783 milyon kişi diyabetten etkilenecek ve bu da %46'lık bir artış anlamına gelmektedir. Doğrudan etkisinin ötesinde, diyabet, kardiyovasküler hastalık ve kronik böbrek hastalığı gibi ikincil komplikasyonların da önemli bir nedenidir ve dünya genelinde klinik ve ekonomik yükü artırmaktadır. Kök hücre tedavileri gibi iyileştirici yaklaşımlar son zamanlarda umut vaat etse de (Wang ve diğ., 2024), deneysel aşamada kalmaktadır ve yaygın olarak mevcut değildir. Çoğu hasta için etkili diyabet yönetimi, dikkatli izleme ve davranışsal düzenlemelere dayanmaya devam etmektedir. Tarihsel olarak, bu izleme, günde birden fazla ağrılı parmak delme işlemi gerektiren kan şekeri ölçüm cihazlarıyla gerçekleştirilmiştir (Mathew ve diğ. 2024). Son yıllarda, sürekli glukoz izleme (CGM) sistemleri daha az invaziv bir alternatif olarak ortaya çıkmıştır. Bu sistemler gerçek zamanlı kan şekeri okumaları sağlayarak daha iyi hastalık yönetimine olanak tanır, ancak yine de sınırlamaları vardır. CGM'ler öncelikle mevcut kan şekeri durumunu rapor eder, gelecekteki kan şekeri seyrine ilişkin eyleme geçirilebilir tahminler veya hastaların bundan sonra ne yapması gerektiği konusunda rehberlik sağlamaz. Bu nedenle, kan şekeri seviyelerini tahmin etmek için makine öğrenimi sürekli kan şekeri izleme verilerine yaygın olarak uygulanmıştır. Bununla birlikte, mevcut yöntemlerin çoğu kan şekeri tahminini tek değişkenli bir zaman serisi problemi olarak ele alır ve yalnızca geçmiş kan şekeri değerlerine dayanır. Gerçekte, kan şekeri dinamikleri insülin dağıtımı, karbonhidrat emilimi, fiziksel aktivite, stres ve sirkadiyen ritimler gibi birçok etkileşimli faktörden etkilenir. Bazı veri kümeleri çok modlu bilgiler içerirken (Marling ve Bunescu, 2020), kan şekeri izleriyle zamansal uyumsuzlukları, bunların etkili bir şekilde kullanılmasını zorlaştırır. Dahası, mevcut tahmin yaklaşımları genellikle hastaya uygulanabilir öneriler sunmadan sadece tahmin aşamasında kalmaktadır. Bu durum, gerçek dünya diyabet öz yönetiminde pratik kullanışlılıklarını sınırlamaktadır. Tez çalışmasında, kan şekeri izleme ile uygulanabilir karar desteği arasındaki boşluğu kapatmak için tahmin modellemesi, açıklanabilirlik ve takviyeli öğrenmeyi birleştiren

hibrit bir öneri sunulmaktadır. Çalışmada süreç, çok modlu girdileri (insülin uygulaması, karbonhidrat alımı, fiziksel aktivite ve fizyolojik sinyaller) derin öğrenmeye uygun, zamansal olarak hizalanmış zaman serilerine ön işleme tabi tutarak başlamaktadır. Daha sonra, bir tahmin aralığında kan şekeri yörüngelerini tahmin etmek için bir evrişimsel sinir ağı eğitilmektedir. Açıklanabilirliği artırmak için, her tahmin için Shapley değerleri hesaplanır ve bireysel özelliklerin tahmin edilen sonuca olan göreceli katkısı nicelleştirilir. Bu Shapley değerleri daha sonra takviyeli öğrenme sürecini yönlendirmek için kullanılmaktadır. Ajan, durumunu özellik matrisinin ve karşılık gelen Shapley atıflarının birleşimi olarak temsil etmektedir. Bu ortamda, aktör-eleştirmen ajanı, fizyolojik olarak anlamlı ayarlamalar üretmeyi öğrenir ve t + 10 anındaki tahmini kan şekeri seviyesini güvenli aralıkta tutmak veya eski haline getirmek için değişkenlerin nasıl değiştirilmesi gerektiğini belirtmektedir.

1.1. Araştırma Amaçları

Bu tezin amacı, hem kısa vadeli kan şekeri seyrini tahmin edebilen hem de açıklanabilir, uygulanabilir öneriler üretebilen hafif, çok modlu bir çerçeve geliştirerek, mevcut kan şekeri izleme teknolojilerinin klinik ve teknik sınırlamalarını ele almaktır. Bu amaçla, araştırma, insülin dağıtımı, karbonhidrat alımı, fiziksel aktivite ve fizyolojik sinyaller gibi heterojen ve zamansal olarak uyumsuz veri kaynaklarını hizalayarak sağlam tahmin modellemesini destekleyen çok modlu bir ön işleme hattı tasarlamayı hedeflemektedir. Ayrıca, yalnızca geçmiş kan şekeri değerlerine dayanmak yerine, çok modlu girdilerden yararlanan derin öğrenmeye dayalı bir tahmin modeli geliştirmeyi amaçlamaktadır. Bir diğer amaç ise, her bir özelliğin tahmin edilen kan şekeri sonuçları üzerindeki etkisini nicelleştirmek için Shapley değeri tabanlı açıklanabilirliği entegre ederek şeffaflığı ve klinik alaka düzeyini artırmaktır. Buna ek olarak, tez, Shapley atıflarını bir takviyeli öğrenme ajanının durum temsiline entegre etmeyi ve ajanın karar verme sırasında fizyolojik olarak önemli değişkenlere odaklanmasını sağlamayı amaçlamaktadır. Bu kapsamda, kontrol edilebilir değişkenleri ayarlamak için uyarlanabilir ve anlamlı öneriler üreten, yalnızca tahminden eyleme geçirilebilir karar desteğine doğru ilerleyen bir takviyeli öğrenme çerçevesi oluşturulmuştur. Son olarak, sistem, tahmin doğruluğu, açıklanabilirliği, güvenilirliği ve kan şekeri seviyesini güvenli bir aralıkta tutmada üretilen önerilerin pratik etkinliği açısından kapsamlı bir şekilde değerlendirilmiştir.

1.2. Tez Katkıları

Tez çalışması, kısa vadeli kan şekeri tahmini ve keşifsel karar destek sistemini desteklemek amacıyla hafif ve açıklanabilir bir yapay zeka çerçevesi önermektedir. Mevcut sürekli kan şekeri ölçüm sistemlerinin ve makine öğrenme yaklaşımlarının sınırlamalarından yola çıkan bu çalışma, aşağıdaki önemli katkıları sunmaktadır;

- Heterojen, gürültülü ve eş zamansız diyabetle ilgili sinyalleri, tahmine dayalı modelleme için uygun birleşik bir gösterime entegre eden, hafif, çok modlu bir ön işleme çerçevesi,
- Kısa vadeli kan şekeri tahmini için çok modlu bir derin öğrenme modeli, davranışsal ve fizyolojik girdileri birlikte modelleyerek yakın gelecekteki kan şekeri seyri tahminini iyileştirmek amacıyla tek değişkenli CGM tabanlı tahminin ötesine geçmesi,
- Shapley değerine dayalı açıklanabilirliğin kan şekeri tahminine uygulanması, her bir girdi değişkeninin tahmin edilen kan şekeri sonuçları üzerindeki etkisinin nicel olarak değerlendirilmesini sağlaması ve çok modlu modellerde şeffaflığı artırması,
- Özellik atıflarının ajanın durum temsiline dahil edildiği ve öğrenme sürecinin kan şekeri dinamiklerinin en etkili etkenlerine odaklanmasını sağlayan, SHAP rehberliğinde geliştirilmiş yeni bir takviyeli öğrenme çerçevesi sağlaması,
- Simüle edilmiş koşullar altında tahmin edilen kan şekeri seyrini güvenli bir aralığa yönlendirmeyi amaçlayan, kontrol edilebilir değişkenler için yorumlanabilir ayarlama önerileri üreten, keşifsel ve sınırlı bir karar destek mekanizması sunması,
- Çok modlu tahmin, SHAP tabanlı açıklama ve takviyeli öğrenmeyi gelecekteki karar destek sistemi geliştirme için birleşik bir araştırma çerçevesine entegre etmenin fizibilitesini gösteren kapsamlı bir deneysel değerlendirme sağlayacaktır.

Bu katkılar, toplu olarak hem çok modlu tahmin zorluğunu hem de mevcut diyabet yönetimi teknolojilerinde belirlenen eyleme geçirilebilir karar destek açığını ele almaktadır. Önerilen çerçeve, klinik uygulamadan ziyade gelecekteki araştırmalar için bir temel sağlamak amacıyla, yalnızca araştırma simülasyonu ve metodolojik keşif için tasarlanmıştır.

1.3. Tez Organizasyonu

Bu tez, çalışmanın farklı yönlerini sistematik biçimde ele alan dokuz ana bölümden oluşmaktadır.

Bölüm-1'de, araştırmanın genel çerçevesini sunmaktadır. Bu bölümde diyabet yönetiminin klinik önemi, mevcut kan şekeri izleme ve yönetim yaklaşımlarının sınırlamaları ve sanal kan şekeri izleme sistemlerine duyulan ihtiyaç ele alınmaktadır. Ayrıca araştırmanın amaçları açıkça tanımlanmakta, tezin özgün katkıları sıralanmakta ve çalışmanın genel organizasyonu özetlenmektedir.

Bölüm-2'de, tez kapsamında ele alınan konulara ilişkin mevcut çalışmaları kapsamlı biçimde incelenmektedir. Bu bölümde kan şekeri seviyesi tahmini yöntemleri, kan şekeri yönetimi için takviyeli öğrenme yaklaşımları, kan şekeri tahmininde SHAP tabanlı açıklanabilirlik yöntemleri ve kan şekeri tahmini için açıklanabilir takviyeli öğrenme (XRL) çalışmaları alt başlıklar halinde sunulmaktadır. İncelenen literatür, önerilen yöntemin bilimsel dayanağını ve konumlandırılmasını sağlamaktadır.

Bölüm-3'te, çalışmada kullanılan veri kümelerini ve çok değişkenli ön işleme adımlarını ayrıntılı olarak açıklamaktadır. Bu bölümde kan şekeri değerleri, bazal insülin, yemek verileri ile galvanik deri tepkisi, cilt sıcaklığı, kalp atış hızı ve adım sayısı gibi fizyolojik ve davranışsal sinyallerin ön işleme süreçleri sunulmaktadır. Ayrıca çok değişkenli giriş verilerinin pencereleme işlemi ve eğitim–test veri bölünmesi açıklanmaktadır.

Bölüm-4'te, kısa vadeli kan şekeri tahmini için geliştirilen CNN tabanlı tahmin modelinin mimarisini ve öğrenme sürecini ayrıntılandırmaktadır. Modelin girdi yapısı, katman konfigürasyonu ve tahmin performansı bu bölümde ele alınmaktadır.

Bölüm-5'te, tahmin modelinden elde edilen SHAP değerlerinin kan şekeri düzenleme sürecinde nasıl kullanıldığını açıklamaktadır. Bu bölümde özellik katkılarının hesaplanması, eyleme geçirilebilir özellik seçimi ve SHAP'ın pasif bir açıklama yönteminden aktif bir kontrol mekanizmasına dönüştürülmesi ayrıntılı olarak sunulmaktadır.

Bölüm-6'da kısmen gözlemlenebilir Markov karar süreci (POMDP) çerçevesinde tanımlanan aktör–kritik tabanlı takviyeli öğrenme modelini ele almaktadır. Durum, eylem

ve ödül tanımları ile hiyerarşik eylem uzayı ve öğrenme güncelleme mekanizmaları bu bölümde açıklanmaktadır.

Bölüm-7'de, geliştirilen tahmin ve kan şekeri düzenleme modellerinin deneysel değerlendirmesini sunmaktadır. Bu bölümde tahmin edici ve önleyici modellerin entegrasyonu, performans metrikleri, klinik açıdan anlamlı değerlendirmeler ve elde edilen sonuçların literatürle karşılaştırmalı tartışması yer almaktadır.

Bölüm-8'de, tez boyunca elde edilen bulguları özetlemekte, çalışmanın genel katkılarını vurgulamakta ve gelecekte yapılabilecek çalışmalar için öneriler sunmaktadır.

2.LİTERATÜR TARAMASI

2.1. Derin Öğrenme Tabanlı Kan Şekeri Seviyesi Tahmini

Derin öğrenme yaklaşımları, kısa vadeli kan şekeri tahmininde önemli ilerlemeler sağlamış, sıklıkla klasik otoregresif ve ileri beslemeli modelleme tekniklerinden daha iyi performans göstermiştir. İlk çalışmalar öncelikle tek değişkenli kan şekeri zaman serilerine odaklanmıştır. Örneğin, doğrusal olmayan otoregresif derin sinir ağları, geleneksel zaman serisi yöntemlerine kıyasla daha düşük RMSE elde etmiş ve yalnızca geçmiş kan şekeri verilerine dayanıldığında bile derin öğrenmenin etkinliğini göstermiştir (Asad ve diğ., 2021). Sonraki araştırmalar, tahmin doğruluğunu daha da artırmak için çok modlu zamansal bilgilerin entegrasyonuna doğru yönelmiştir. Fizyolojik ve davranışsal girdileri içeren LSTM–MLP füzyon topluluk modellerinin MAE, MAPE ve gözetim hatası metriklerini azalttığı gösterilmiştir (Khadem ve diğ., 2023). Benzer şekilde, CNN–LSTM hibrit mimarileri, özellikle kısa vadeli kan şekeri tahmini için DIAdvisor ve Replace-BG veri kümelerinde güçlü performans sergilemiştir (Jaloli ve diğ., 2023). Mimari füzyonun ötesinde, son çalışmalar hesaplama verimliliğine ve dağıtım uygulanabilirliğine vurgu yapmıştır. Sanal pediatrik hastalardan toplanan kan şekeri, insülin ve yemek verileri için optimize edilmiş CNN ve LSTM tabanlı tekrarlayan sinir ağı modelleri, uç cihaz dağıtımını mümkün kılmak için önerilmiştir (D'Antoni ve diğ., 2022). Sonuçları, LSTM modelinin TensorFlow Lite kullanılarak dağıtıldığında en iyi sayısal ve klinik doğruluğa ulaştığını, CNN modelinin ise 8 bitlik tamsayı formatında uygulandığında üstün klinik doğruluğa ulaştığını göstermiştir.

LSTM tabanlı modellerin daha fazla doğrulanması, OhioT1DM veri kümesi üzerinde değerlendirilen çok katmanlı tekrarlayan sinir ağı aracılığıyla sağlanmıştır. Bu model, sırasıyla 30 ve 60 dakikalık tahmin aralıkları için 14,76 mg/dL ve 25,48 mg/dL RMSE değerlerine ulaşarak yeterli kısa vadeli tahmin performansı sergilemiştir (Butt ve diğ., 2023).

Son yıllarda, hesaplama karmaşıklığını kontrol ederken doğruluğu artırmak için transformatörden ilham alan mimariler tanıtılmıştır. Özellik geliştirme modülü ve mikro ölçekli örtüşen dikkat mekanizmasını içeren BGformer, 60 ve 90 dakikalık tahmin aralıklarında MAE ve RMSE metrikleri kullanılarak, halka açık birçok kan şekeri tahmin modeliyle karşılaştırılmış ve rekabetçi bir performans sergilemiştir (Xue ve diğ., 2024).

Buna paralel olarak, invaziv olmayan kan şekeri tahmini için alternatif algılama yöntemleri araştırılmıştır. Sentetik fotopletismografi sensör verilerini kullanan hibrit bir Mamba–Mixture-of-Experts modeli, Clarke Error Grid metriğinin sonucuna dayalı A bölgesinde yüksek oranda tahmin ve çok düşük RMSE değerleri ile oldukça umut verici sonuçlar elde etmiştir (Şentürk ve diğ., 2025).

Literatür taramasının bu alt bölümünde tartışıldığı gibi, çok sayıda çalışma, gelişmiş makine öğrenimi ve derin öğrenme tekniklerini kullanarak kan şekeri seviyelerini yüksek doğrulukla tahmin etmeye odaklanmıştır. İncelenen çalışmaların yazarları, çalışma başlıkları, yayın yılları ve ana katkıları da dahil olmak üzere bir özeti Tablo 2.1'de sunulmuştur.

Bu çalışmalarda sunulan modeller büyük ölçüde reaktiftir. Yani, gelecekteki kan şekeri değerlerini tahmin ederler, ancak bunları etkilemek için stratejiler sunmazlar. Bu boşluk, tahmini uyarlanabilir kontrolle birleştiren takviyeli öğrenmeye dayalı destek sistemlerine olan ilgiyi artırmıştır. Bununla birlikte, çoğu takviyeli öğrenme çerçevesi, olasılıksal keşfin kısıtlanmak yerine teşvik edildiği oyun gibi stokastik karar ortamlarından kaynaklanmaktadır. Fizyolojik temellendirme ve sıkı doğrulama olmadan, tıbbi dozlama veya yaşam tarzı rehberliğine doğrudan çeviri güvenli değildir. Bu nedenle, tahmin doğruluğunu, yorumlanabilir atfı ve eylem odaklı akıl yürütmeyi birleştiren modelleri giderek daha fazla aramaktadır.

Tablo 2.1.Derin Öğrenme Tabanlı Yaklaşımların Özeti

Çalışma	Kullanılan Veri Kümesi	Yöntem	Elde Edilen Sonuçlar
Asad ve diğ., 2021	Tarihsel kan şekeri verileri	Nonlinear Autoregressive Deep Neural Networks (Tek değişkenli derin öğrenme)	Kısa vadeli tahminlerde RMSE değerleri, geleneksel zaman serisi yöntemlerine göre daha düşük; RMSE ≈ 18 mg/dL.
D'Antoni ve diğ., 2022	Kan şekeri, insülin ve yemek verileri	Lightweight CNN ve LSTM Modelleri	Klinik doğruluk %90'ın üzerinde, uç cihazlarda tahmin süresi ≈ 50 ms.
Khadem ve diğ., 2023	Entegre fizyolojik ve davranışsal sinyaller	Multimodal LSTM–MLP Fusion Ensemble	Kısa vadeli tahminlerde MAE ≈ 12 mg/dL, MAPE ≈ 7%, gözetim hatası azalmış.

Tablo 2.1.(Devam)Derin Öğrenme Tabanlı Yaklaşımların Özeti

Çalışma	Kullanılan Veri Kümesi	Yöntem	Elde Edilen Sonuçlar
Jaloli ve diğ., 2023	DIAdvisor ve Replace-BG veri kümeleri	CNN–LSTM Hibrit Modeller	Aralık odaklı tahminlerde RMSE ≈ 15 mg/dL, R^2 ≈ 0.88.
Butt ve diğ., 2023	OhioT1DM Dataset	Multi-Layer LSTM Network	30 dakikada RMSE = 14,76 mg/dL; 60 dakikada RMSE = 25,48 mg/dL.
Xue ve diğ., 2024	-	BGformer: Transformer-Based Model	Hesaplama karmaşıklığı azaltılmış; tahmin doğruluğu RMSE ≈ 13 mg/dL, MAE ≈ 10 mg/dL.
Şentürk ve diğ., 2025	Sentetik PPG sensör verileri	Hybrid Mamba–MoE Model	Clarke Error Grid'in A Bölgesi'nde %92 doğruluk; RMSE ≈ 12,5 mg/dL.

Bu tez çalışması, önleyici simülasyon stratejilerini keşfetmek için CNN tabanlı kan şekeri tahminini SHAP farkındalıklı politika öğrenimiyle birleştirmektedir.

2.2. Kan Şekeri Yönetimi için Takviyeli Öğrenme

Takviyeli öğrenme (RL), bir ajanın deneme-yanılma etkileşimleri yoluyla en uygun politikaları öğrenmek için bir ortamla etkileşim kurduğu, stokastik ortamlarda sıralı karar verme için güçlü bir paradigma olarak ortaya çıkmıştır (Naeem ve diğ., 2020). RL, otonom araçlar, doğal dil işleme ve sağlık hizmetleri gibi güvenlik açısından kritik sistemler de dahil olmak üzere çeşitli alanlarda başarıyla uygulanmış ve karmaşık ve dinamik karar verme görevleri için uygunluğunu göstermiştir (Srinivasan ve diğ., 2023).

Kan şekeri yönetiminde, RL tahmin modellerini uyarlanabilir kontrol stratejileriyle tamamlayarak proaktif müdahale için bir çerçeve sağlamaktadır. Sadece kan şekeri seyrini tahmin etmek yerine, RL tabanlı yaklaşımlar, insülin uygulaması, karbonhidrat alımı veya davranışsal faktörler gibi kontrol edilebilir değişkenlere zamanında ayarlamalar önermeyi amaçlamaktadır. Sonuç olarak, birçok çalışma, Tip 1 diyabet (T1D) yönetimi için RL'in uygulamasını araştırmıştır. Hettiarachchi ve diğ., açık öğün tahmini gerektirmeden kan şekeri kontrolünü otomatikleştirmek için tasarlanmış modüler bir derin takviyeli öğrenme algoritması olan G2P2C'yi sunmuştur (Hettiarachchi ve diğ., 2024). Yaklaşımları, uyarlanabilirliği ve sağlamlığı artırmak için farklı öğrenme ve

planlama aşamalarına sahip Yakınsal Politika Optimizasyonunu kullanmıştır. Benzer şekilde, Yamagata ve diğ., kan şekeri zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalamak için yankı durum ağlarını kullanmış ve takviyeli öğrenme çerçevesi içinde gerçek zamanlı adaptasyona olanak sağlamıştır (Yamagata ve diğ., 2020).

Domanski ve diğ., kodlayıcı-kod çözücü mimarilerini LSTM modelleriyle birleştirerek kan şekeri tahminini derin takviyeli öğrenme problemi olarak formüle etmiş ve yaklaşımlarını OhioT1DM veri kümesi üzerinde değerlendirmiştir (Domanski ve diğ., 2023). Takviyeli öğrenme yaklaşımlarının çoğu çevreyle çevrimiçi etkileşime dayanırken, Kim ve diğ., ile Viroonluecha ve diğ., yalnızca geçmiş verilere dayanan çevrimdışı takviyeli öğrenme yöntemleri önermiştir (Kim ve diğ., 2024; Viroonluecha ve diğ., 2023). Bu yaklaşımlar bir umut vaat etse de pratik klinik ortamlarda büyük ölçüde doğrulanmamıştır. Zhu ve diğ., hem tek hem de çift hormonlu insülin dağıtım sistemleri için derin takviyeli öğrenme modelleri geliştirmiş ve yaklaşımlarını FDA onaylı UVA/Padova simülatörünü kullanarak doğrulamıştır (Zhu ve diğ., 2022).

Literatür taramasının bu alt bölümünde, takviyeli öğrenme algoritmalarının uygulanmasına odaklanan ve oldukça umut verici sonuçlar veren çalışmaların sayısının giderek arttığı açıkça görülmektedir. Tablo 2.2, kan şekeri yönetimi araştırmalarında takviyeli öğrenme algoritmalarının kullanımının bir özetini sunmaktadır.

Bu RL tabanlı yöntemlerin gösterdiği uyarlanabilirliğe rağmen, kan şekeri düzenlemesi için mevcut algoritmaların çoğu öncelikle tek kontrol eylemi olarak insülin ayarlamasına odaklanmakta ve etkileşim halindeki birden fazla özelliği değiştirme konusunda sınırlı rehberlik sağlamaktadır. Bu sınırlamaları gidermek için, tezde önerilen yaklaşım, CNN tabanlı bir kan şekeri tahmincisinden türetilen SHAP tabanlı özellik atamasıyla takviyeli öğrenmeyi entegre etmektedir. SHAP değerleri, tahmin edilen kan şekeri sonuçlarını yönlendiren en etkili girdi özelliklerini belirlemek için kullanılır ve takviyeli öğrenme ajanı, stokastik, yalnızca araştırma amaçlı bir simülasyon ortamında bu özellikler için sınırlı ayarlamaların büyüklüğünü belirlemektedir. Bu entegrasyon, açıklanabilirliği artırmayı ve takviyeli öğrenme tabanlı karar desteğini insülin merkezli kontrolün ötesine genişletmeyi amaçlamaktadır.

Tablo 2.2. Glukoz Yönetiminde Takviyeli Öğrenme

Çalışma	Kullanılan Veri Kümesi	Yöntem	Elde Edilen Sonuçlar
Naeem ve diğ., 2020	Genel / teorik	Takviyeli öğrenme (RL)	Kuramsal katkı, uygulamalı sayısal performans raporlanmamıştır (teorik perspektif ve algoritma temelleri incelenmiştir).
Yamagata ve diğ., 2022	UVa/Padova simülatörü	Echo State Networks + Model-Based RL	RL algoritması, çoğu sanal tip-1 diyabet hastası profili için Basal-Bolus ve Derin Q-Learning'e eşit veya daha iyi kontrol sağlamıştır
Zhu ve diğ., 2022	UVa/Padova simülatörü	Deep RL (Tek ve çift hormon)	Hipoglisemi olayları önemli ölçüde azaldı.
Srinivasan ve diğ., 2023	Genel / teorik	Takviyeli öğrenme	Sağlık-kritik sistemlerde RL'nin uygulanabilirliği gösterilmiştir;
Domanski ve diğ., 2023	OhioT1DM veri kümesi	Deep RL (LSTM & encoder-decoder)	30 dakika ve 45 dakika tahminler için MAE geliştirmesi: 30 dak. ve 45 dak. için MAE, önceki en iyi çalışmalara göre sırasıyla %18.4 ve %22.5 iyileşti.
Viroonluecha ve diğ., 2023	UVa/Padova simülatörü (30 sanal hasta)	Offline RL (BCQ, CQL, TD3-BC)	Offline RL ile hedef aralıkta kalma (TIR): Minimum $\approx 61.6 \pm 0.3$ % ile 65.3 ± 0.5 % artış ($p < 0.001$) dengeleyici hipoglisemi artışı olmamıştır.

2.3. Kan Şekeri Tahmininde SHAP Tabanlı Açıklanabilirlik

İşbirlikçi oyun teorisinden türetilen Shapley değerleri, her bir girdi özelliğinin bir modelin tahminine katkısını nicelleştirerek kara kutu makine öğrenimi modellerini yorumlamak için yaygın olarak kullanılmaktadır (Li ve diğ., 2024). Bu kavram üzerine kurulu olan SHAP (SHapley Additive exPlanations), tutarlı ve teorik olarak temellendirilmiş bir şekilde özellik atıf puanları sağlayan öne çıkan bir açıklanabilirlik çerçevesidir. SHAP, kan şekeri tahmini ve öngörü görevlerinde giderek daha fazla kullanılan evrimsel sinir ağları (CNN'ler) dahil olmak üzere karmaşık modellerin yorumlanabilir analizini mümkün kılmaktadır. SHAP'ın uygulanabilirliği, tıp (Nohara ve diğ., 2022; Feretzakis ve diğ., 2024), tarım (Zhong ve diğ., 2024; Wadoux ve diğ., 2023; Hussein ve diğ., 2023), ulaşım ve tedarik zinciri yönetimi (Wang Y., 2023; Amuji ve diğ., 2023) dahil olmak

üzere birçok alana yayılmakta ve model açıklanabilirliğindeki çok yönlülüğünü ve etkinliğini göstermektedir.

Diyabet yönetimi araştırmalarında, çeşitli çalışmalar tahmin modellerinin şeffaflığını artırmak için SHAP değerlerinden yararlanmıştır. Ejiyi ve diğ., (2023), PIMA diyabet veri setine SHAP uygulayarak kan şekeri seviyesi, yaş ve vücut kitle indeksi (VKİ)'ni en etkili tahmin ediciler olarak belirlemiştir. Duckworth ve diğ., (2024), hipoglisemik ve hiperglisemik olayların gerçek zamanlı tahmininde SHAP ve XGBoost birlikte kullanarak kişiselleştirilmiş kontrol önerilerinin oluşturulmasını sağlamıştır. Mohanty ve diğ., (2024), SHAP tabanlı açıklamalarla entegre edildiğinde topluluk öğrenme modellerinin sağlamlığını göstermiştir. Ayrıca, Annuzzi ve diğ., (2024), yemek sonrası kan şekeri seviyeleri üzerindeki yemekle ilgili etkileri ölçmek için SHAP'ı derin öğrenme modelleriyle birlikte kullanarak beslenme faktörleri ve kan şekeri dinamikleri arasındaki karmaşık etkileşimleri ortaya koymuştur.

Bu alt bölüm, birçok araştırmacının kan şekeri yönetimi için makine öğrenimi modellerinde özellik katkılarını etkili bir şekilde yorumlamak amacıyla Shapley değerlerini benimsediğini daha da vurgulamaktadır. Tablo 2.3, literatürde incelenen temel çalışmaları özetlemektedir. Bu gelişmelere rağmen, mevcut SHAP tabanlı yaklaşımların çoğu, eyleme geçirilebilir müdahaleleri doğrudan bilgilendirmeden açıklanabilirlik sunan çalışmalardır

Tablo 2.3.Kan Şekeri Yönetiminde SHAP Çalışmalarının Özeti

Çalışma	Kullanılan Veri Kümesi	Yöntem	Elde Edilen Sonuçlar
Nohara ve diğ., 2022	Genel tıbbi modeller	SHAP ile açıklanabilir ML	Tıbbi tahmin modellerinde SHAP ile yorumlanabilirlik ve güvenilirlik arttırıldı.
Ejiyi ve diğ., 2023	PIMA Diyabet veri kümesi	SHAP ile açıklanabilir diyabet tahmini	SHAP analizi ile yaş, BMI ve glukoz en önemli belirleyiciler bulundu; doğruluk ve AUC gibi metrikler belirtilmemişti
Wadoux ve diğ., 2023	Tarım/çevre veri setleri	SHAP açıklanabilirliği	SHAP, karmaşık çevresel modellerde özellik önemini açıklar, ancak tıbbi sonuç verileri yok.

Tablo 2. 3. (Devam)Kan Şekeri Yönetiminde SHAP Çalışmalarının Özeti

Çalışma	**Kullanılan Veri Kümesi**	**Yöntem**	**Elde Edilen Sonuçlar**
Hüseyin ve diğ., 2023	Tarımsal veri setleri	SHAP açıklaması	Tarımsal tahminlerde şeffaflık ve güvenilirlik artışı göstermiştir.
Wang Y., 2023	Ulaşım ve tedarik zinciri verileri	SHAP açıklanabilir modeli	SHAP ile model yorumlanabilirliği arttırıldı, ancak sayısal performans metrikleri verilmemiştir.
Li ve diğ., 2024	Kara kutu ML modelleri	Shapley değerleri	SHAP/Shapley değerleriyle model açıklanabilirliği artırıldı; sayısal sonuçlara yer verilmemiştir.
Feretzakis ve diğ., 2024	Sağlık tahmin sistemleri	SHAP açıklanabilirliği	SHAP kullanılarak klinikte model yorumlanabilirliği iyileştirildi.
Zhong ve diğ., 2024	Tarımsal karar destek modelleri	SHAP açıklanabilirliği	Özellik önem analizi ve model açıklaması sağlandı.
Duckworth ve ark., 2024	CGM verisi (153 T1D kişi)	XGBoost + SHAP	Hipoglisemi AUROC: 0.998, Ortalama precision: 0.953; Hiperglisemi AUROC: 0.989, ort. precision: 0.931 (SHAP ile model açıklanabilirliği artırılmış).
Mohanty ve diğ,	Ensemble modeller	SHAP açıklanabilir topluluk öğrenim	Topluluk modellerinde sağlamlık ve yorumlanabilirlik artışı gösterilmiş; sayısal performans raporlanmadı.
Annuzzi ve diğ,	Postprandiyal kan şekeri dinamikleri	Derin öğrenme + SHAP	Yemek sonrası glukoz tepkisi özellik etkileri niceliksel modellerle açıklandı, ancak sayısal hata/performans metrikleri paylaşılmamıştır.
Amuji ve diğ,	Multimodal freight taşıma verileri	Shapley Value Cost Allocation Model	S1 koalisyonu maliyeti ₦17,16 milyon azaldı (%5,10 azalma); toplam 10 koalisyon için toplam maliyet ₦107,84 milyon azaldı (%6,15 düşüş).

. Buna karşılık, bu çalışma SHAP değerlerini doğrudan bir takviyeli öğrenme (RL)

çerçevesine entegre etmektedir. Özellikle, en yüksek mutlak SHAP katkısına sahip özellik seçilir ve RL ajanı müdahalenin hem büyüklüğünü hem de yönünü belirler. Bu hibrit CNN–SHAP–RL çerçevesi doğası gereği stokastiktir.

2.4. Kan Şekeri Tahmini için Açıklanabilir Takviyeli Öğrenme (XRL)

Açıklanabilir takviyeli öğrenme (XRL), açıklamaları dört temel boyuta ayırarak ajan karar verme süreçlerinin şeffaflığını artırmayı amaçlamaktadır. Bunlar, ajan modeli açıklaması, ödül açıklaması, durum açıklaması ve görev açıklamasıdır (Qing ve diğ., 2022). Ajan modeli açıklaması, öğrenilen politikanın iç mekanizmalarını açıklığa kavuşturmaya odaklanırken, ödül açıklaması ajanın öğrenme sürecini gözlemlenen sonuçlarla ilişkilendirir. Durum açıklaması, karar vermeyi önemli ölçüde etkileyen çevresel veya fizyolojik durumları (örneğin, son karbonhidrat alımı veya insülin dozu) belirlemektedir. Görev açıklaması ise ajanın performansını çeşitli senaryolar ve hedefler genelinde değerlendirir. Literatürde, Remman ve diğ., robotik sistemlerde bağlam duyarlı politika açıklamaları sağlamak için Nedensel SHAP yaklaşımını geliştirmiştir. Benzer şekilde, Ruggeri ve diğ., çoklu ajan ortamlarında işbirlikçi davranışları açıklamak için bir uygulama tabanlı Shapley değeri yöntemi tanıtmıştır. Bu ilerlemelere rağmen, kan şekeri yönetimine yönelik XRL yaklaşımlarının sayısı nispeten azdır.

Literatür taraması bölümünü özetleyecek olursak, mevcut çalışmaların büyük ölçüde tahmin doğruluğuna veya sonradan açıklanabilirliğe odaklandığını, önleyici veya eyleme geçirilebilir karar destek mekanizmalarını doğrudan içermediği görülmektedir. Literatür taramasına dayanarak, aşağıdaki eksiklikler ve tez çalışmasının katkıları:

- Tek özellikli RL: Önceki RL yaklaşımlarının çoğu yalnızca insülini düzenlemektedir. Bunu düzeltmek için, çalışmada kullanılan ajan birden fazla değiştirilebilir özelliği (insülin, karbonhidratlar, adımlar ve giyilebilir sinyaller) ayarlayabilir.
- Geniş ve iç içe geçmiş eylem alanı: Birçok değişkeni optimize etmek, takviyeli öğrenmenin eylem alanını karmaşık hale getirir. Mevcut yöntemler, SHAP'ı yalnızca son kullanıcılar için sonradan açıklanabilirlik amacıyla kullanmaktadır. Bunu düzeltmek için, epsilon-gradyan sezgisel yöntemlerine güvenmek yerine, ayarlama için en etkili özelliği seçerek takviyeli öğrenmenin eylem alanını azaltmak için SHAP değerleri kullanılmıştır.

- Deterministik / tamamen gözlemlenebilir varsayım: Birçok yaklaşım, tam gözlemlenebilirlik veya deterministik geçişleri varsaymaktadır. Bunu düzeltmek için, çerçevemiz kısmen gözlemlenebilir bir MDP'yi modelleyerek, RL'yi stokastik ve tamamen araştırma odaklı tutmaktadır.

Tablo 2.4'de, önerilen çerçevenin bu eksiklikleri nasıl giderdiğini ve aynı zamanda acil klinik uygulamaya geçişi engelleyen sınırlamaları nasıl ele aldığını özetlenmektedir.

Tablo 2.4.Mevcut RL kan şekeri yönetimi: eksikler, çözümler, sorunlar

Sınırlamalar	**Önerilen Çözüm**	**Geriye kalan**
Tek özellikli RL	Çoklu özellik optimizasyonu (insülin, karbonhidratlar, adımlar, giyilebilir cihaz sinyalleri)	Sadece araştırma amaçlıdır; klinik olarak doğrulanmamıştır.
Geniş ve iç içe geçmiş eylem alanı	SHAP rehberliğinde en etkili özelliği seçerek RL eylem alanının azaltılması	Stokastik RL olasılıksal kalır.
Deterministik/tamamen gözlemlenebilir varsayım	Kısmi gözlemlenebilir MDP modellemesi	Tahminler ve düzeltmeler olasılığa dayalıdır; gerçek hastalara genelleştirilemeyebilir.

Önerilen çerçeve, 10 dakikalık bir tahmin aralığı boyunca 80-120 mg/dL hedef aralığının dışındaki kan şekeri sapmalarını proaktif olarak önlemek için CNN tabanlı kan şekeri tahmini, SHAP güdümlü özellik seçimi ve Aktör-Eleştirmen takviyeli öğrenme ajanını entegre etmektedir. Bu yaklaşım, kişiselleştirilmiş diyabet yönetimi için açıklanabilir ve uyarlanabilir, araştırma odaklı simülasyonları geliştirmektedir.

3.VERİ KÜMESİ ÖN İŞLEME

Tez çalışmasında, Shapley değerleri tarafından yönlendirilen bir Aktör-Eleştirmen takviyeli öğrenme modeli ile tahmine dayalı bir CNN modelinin bir kombinasyonunu önermeyi amaçlamaktadır. Önerilen çerçeveyi doğrulamak için OhioT1DM veri seti (Marling ve Bunescu, 2020) kullanılmıştır. XML formatında sunulan OhioT1DM veri seti, kan şekeri seviyesi tahminine yönelik araştırmaları kolaylaştırmak amacıyla geliştirilmiştir. Amacına uygun olarak çeşitli çalışmalarda yaygın olarak kullanılmış ve çok sayıda kaynakta alıntı yapılmıştır.

Tablo 3.1, OhioT1DM veri seti ile ilgili, katılımcıların cinsiyeti, yaş aralığı, insülin pompası modeli ve veri toplama sırasında kullanılan kan şekeri sensörü markası da dahil olmak üzere veri toplama sürecine ilişkin genel bir bakış sunmaktadır.

Tablo 3.1.OhioT1DM Katılımcıların Demografi Cihaz Bilgileri

Kohort	İD	Cinsiyet	Yaş Aralığı (yıl)	İnsülin Pompası Modeli	Giyilebilir Sensör Bandı
2020	540	Erkek	20–40	630G	Empatica
	544	Erkek	40–60	530G	Empatica
	552	Erkek	20–40	630G	Empatica
	567	Dişi	20–40	630G	Empatica
	584	Erkek	40–60	530G	Empatica
	596	Erkek	60–80	530G	Empatica
2018	559	Dişi	40–60	530G	Temel
	563	Erkek	40–60	530G	Temel
	570	Erkek	40–60	530G	Temel
	575	Dişi	40–60	530G	Temel
	588	Dişi	40–60	530G	Temel
	591	Dişi	40–60	530G	Temel

Tablo 3.2, OhioT1DM veri setinde(Marling ve Bunescu, 2020) yer alan tüm özellikleri

isimleri, ölçüm birimleri ve ölçüm sıklıklarıyla birlikte özetlemektedir. Özellikler, glukoz seviyeleri ve insülin dozları gibi biyometrik ve metabolik veriler, uyku, egzersiz ve iş gibi yaşam tarzı bilgileri, ayrıca kalp atış hızı, cilt sıcaklığı ve ivme gibi giyilebilir sensör verilerini içermektedir.

Tablo 3.2. OhioT1DM Veri seti özelliklerin birimleri ve ölçüm sıklığı

Özellik Adı	**Açıklama**	**Birim / Ölçek**	**Ölçüm**
Kan şeker seviyesi	Sürekli glukoz izleme (CGM) verisi	Mg/dL	Her 5 dakikada bir
Parmak ucu ölçümü	Kendi kendine ölçülen kan şekeri	Mg/dL	Düzensiz (manuel)
Bazal Insülin	Sürekli bazal insülin infüzyon hızı	Birim/saat (U/saat)	Değişene kadar aktif
Geçici bazal Insülin	Geçici bazal insülin hızı	Birim/saat (U/saat)	0 = insülin durdurulmuş
Bolus Insülin	Verilen insülin (normal veya uzatılmış)	Birim (U)	Olay anında veya süre boyunca
Karbonhidrat	Öğün bilgisi ve karbonhidrat tahmini	Gram (g) karbonhidrat	Öğün tipi/zaman kategorik
Uyku	Uyku zamanı ve kalitesi	Kalite: {1,2,3}	1=Kötü, 2=Orta, 3=İyi
İş	İş başlangıç/bitiş ve fiziksel efor seviyesi	Yoğunluk: 1–10	Subjektif ölçek
Stresörler	Kendi bildirilen stres olayı	Sadece zaman damgası	Yoğunluk yok
Hipoglisemi olayı	Hipoglisemik epizot	Sadece zaman dilimi	Semptom yok
Hastalık	Kendi bildirilen hastalık	Sadece zaman dilimi	İkili olay
Temel kalp atış hızı	Kalp atış hızı	Dakikada atım (bpm)	Her 5 dakikada bir
Egzersiz	Egzersiz süresi ve yoğunluğu	Dakika; Yoğunluk 1–10	Subjektif ölçek

Tablo 3.2. (Devam) OhioT1DM Veri seti özelliklerin birimleri ve ölçüm sıklığı

Özellik Adı	**Açıklama**	**Birim / Ölçek**	**Ölçüm**
Temel GSR	Galvanik deri yanıtı	Mikrosiemens (µS)	1–5 dakikada bir ortalama
Temel cilt sıcaklığı	Cilt sıcaklığı	°F	1–5 dakikada bir ortalama
Temel hava sıcaklığı	Ortam sıcaklığı	°F	Her 5 dakikada bir
Temel adım sayısı	Adım sayısı	Sayı	Her 5 dakikada bir
Temel uyku	Sensör tarafından tespit edilen uyku	Zaman; kalite skoru	Kalite ölçüsüz
İvme	İvme büyüklüğü	G	Her 1 dakikada bir

Tablo 3.3.2018 kohortu özellik ve hasta başına veri

Özellik	**559**	**570**	**588**	**591**	**563**	**575**
Bazal insülin	195	147	82	142	99	148
Temel hava sıcaklığı	14519	14948	15560	14749	14527	15078
Temel GSR	14438	14938	15536	14741	14523	15032
Temel kalp atış hızı	14612	15048	15600	14944	14672	14144
Temel cilt sıcaklığı	14519	14948	15560	14749	14527	15078
Temel uyku	1279	1255	1319	1193	1097	1099
Temel adım sayısı	14924	15062	15921	14721	14679	14896
Bolus İnsülin	188	410	222	312	436	223
Parmak ucu ölçümü	215	313	684	510	649	321
Kan şeker seviyesi	13310	13727	15431	13607	14694	14456
Karbohidrat	179	169	258	253	156	288
Uyku	53	52	57	54	41	56
Egzersiz	27	25	41	0	27	28

Tablo 3.3 ve Tablo 3.4'te yer alan iki tablo, veri toplama dönemi boyunca her hasta için Bazal insülin, Temel hava sıcaklığı, Temel GSR, Temel kalp atış hızı, Temel cilt sıcaklığı, Temel uyku, Temel adım sayısı, Bolus İnsülin, Parmak ucu sıcaklığı, Temel şeker seviyesi, Karbohidrat, Uyku ve Egzersiz değerlerine ilişkin kaydedilen değerleri raporlamaktadır. Tablo 3.3 ve 3.4'ü analiz ederek, 2020 kohortunun daha az kayıtlı özellik ve çeşitli eksik değerler içerdiği gözlemlenmiştir. Özellikle, bazı hastalar uyku ve iş hakkında bilgi vermemişken, tüm hastalarda bu çalışma için kritik öneme sahip olan Temel kalp atış hızı ve Temel adım sayısı gibi temel değişkenlere ilişkin veriler eksiktir. Bu nedenle, 2020 yılında toplanan veri seti grubunu analizlerin dışında bırakılmış ve sadece 2018 yılında toplanan veri seti gruplarına odaklanılmıştır.

Tablo 3.4.2020 kohortu özellik ve hasta başına veri

Özellik	**559**	**570**	**588**	**591**	**563**	**575**
Bazal insülin	32	135	42	149	47	54
Temel hava sıcaklığı	0	0	0	0	0	0
Temel GSR	36035	67015	51204	48200	59761	43433
Temel kalp atış hızı	0	0	0	0	0	0
Temel cilt sıcaklığı	36035	671015	51196	48200	59760	43433
Temel uyku	14	66	38	46	50	-
Temel adım sayısı	0	0	0	0	0	-
Bolus İnsülin	396	173	672	367	322	246
Parmak ucu ölçümü	720	265	356	489	162	210
Kan şeker seviyesi	14843	13339	18160	13247	14815	13620
Karbohidrat	100	197	156	32	118	319
Uyku	0	55	40	54	41	52
Egzersiz	0	35	12	0	19	0

Bu çalışmada bazal insülin simülasyonu gerçekleştirildiğinden, daha yüksek sayıda kaydedilmiş bazal insülin girdisine sahip hastaları seçtik. Ayrıca, literatür taramasında

yer alan diğer çalışmalarla karşılaştırma yapmak amacıyla özellikle 559, 570, 591 ve 575 numaralı hastalar tercih edilmiştir. Daha fazla sayıda orijinal ölçüm, simüle edilmiş ara verilerin güvenilirliğini artırarak veri setinin gerçekçiliğini iyileştirmektedir. Önerilen çalışma umut verici sonuçlar gösterse de gerçek dünya klinik ortamlarında uygulanabilir olarak kabul edilmeden önce bağımsız veri setleri üzerinde ek doğrulama gerekli olacaktır. Bu tez çalışmasının asıl amacı, tahmine dayalı bir kan şekeri modelini önleyici bir takviyeli öğrenme çerçevesiyle entegre etmektir.

Tablo 3.5.OhioT1DM veri setinin seçmiş özelliklerine genel bakış

Özellik	**Tanım**	**Tip**
Kan şekeri Seviyesi	Sürekli Glukoz İzleme (CGM) verileri, 5 dakikalık aralıklarla kaydedilerek zaman içindeki kan şekeri dalgalanmalarını yakalar.	Giriş/Çıkış
Bazal İnsülin	Bazal insülinin sürekli infüzyon hızı. Belirlenen her hız, belirli bir zaman damgasından itibaren geçerliliğini korur. Ayarlanana kadar.	Giriş
Karbonhidrat Alımı	Kişinin kendi beyanına dayalı yemek tüketimi detayları; yiyecek türü, tüketim zamanı ve tahmini karbonhidrat içeriği dahil.	Giriş
Kalp Atış Hızı	Hastanın kalp atış hızı, dakikadaki atış sayısı (BPM) olarak ölçülür ve fizyolojik tepkiler hakkında bilgi sağlar.	Giriş
Galvanik Deri Tepkisi (GSR)	Elektro dermal aktivite, stres veya fizyolojik uyarılma nedeniyle deri iletkenliğindeki değişiklikleri yansıtır.	Giriş
Cilt Sıcaklığı	Hastanın Fahrenheit cinsinden kaydedilen cilt sıcaklığı, metabolik veya çevresel etkileri gösterebilir.	Giriş
Adım Sayısı	Atılan adım sayısı, fiziksel aktivite düzeyinin bir tahmini olarak kullanılır.	Giriş

Bu kapsamda, önleyici bileşen tahmine dayalı modelin çıktılarından yararlanırken,

tahmine dayalı bileşen öncelikle ön işleme tabi tutulması gereken çok değişkenli girdi verilerine ihtiyaç duyar. Bu çalışmada ele alınan özellikler Tablo 3.4'te özetlenmiştir.

Seçilen özellikler, kan şekeri dinamikleriyle potansiyel korelasyonlarının yanı sıra pratik önemlerine göre seçilmiştir. Özellikle, bu değişkenlerin çoğu ya hasta tarafından doğrudan değiştirilebilen faktörleri temsil eder ya da kan şekeri düzenlemesini etkileyen fizyolojik durumları yansıtmaktadır. Her bir özellik farklı ön işleme teknikleri gerektirebileceğinden, bu alt bölümde uygulanan ön işleme adımlarını ayrıntılı olarak açıklanmaktadır.

3.1. Kan Şekeri Değeri Ön İşleme

Kan şekeri özelliği, OhioT1DM veri setinde bulunan en eksiksiz sinyaldir. Tüm hastalar için her 5 dakikada bir, hassas zaman damgalarıyla birlikte kaydedilir. Bu özellik, bu çalışmada kullanılan tahmine dayalı modellemede birincil çıktı değişkeni olarak hizmet ettiğinden, zamansal tutarlılığı sağlamak için diğer tüm özelliklerin zaman damgaları kan şekeri zaman damgalarıyla hizalanmıştır. Şekil 3.1, bu çalışmaya dahil edilen 570 hastanın kan şekeri seviyelerindeki dalgalanmaları göstermektedir.

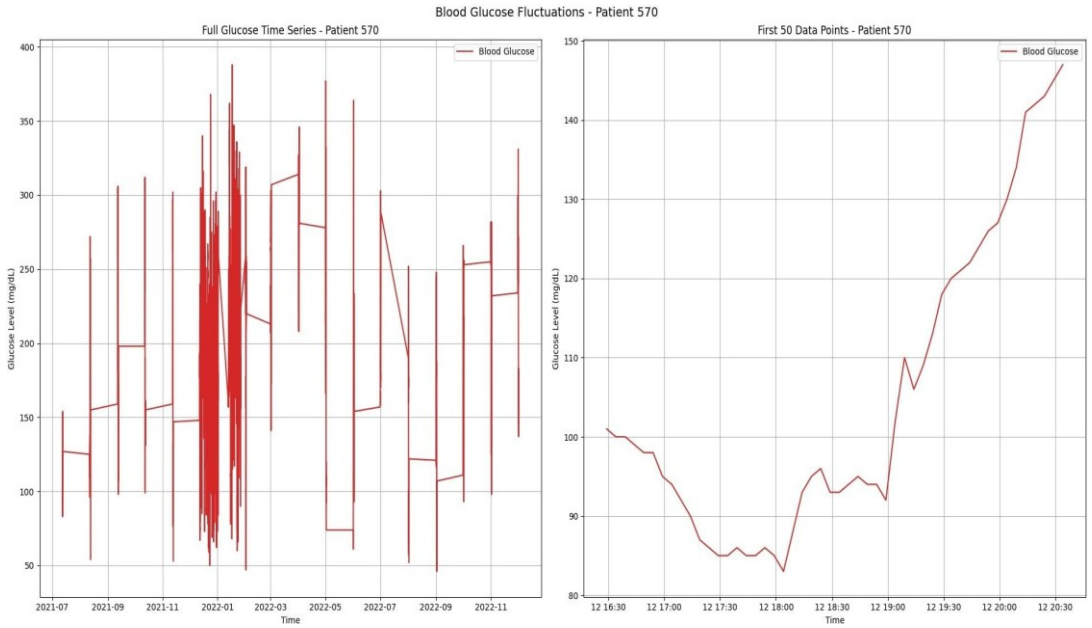

Şekil 3.1.Hasta 570’te kan şekeri dalgalanmalarının genel görünümü

3.2. Bazal İnsülin Ön İşleme

Bazal insülin, tip 1 diyabetli bireylerde bolus insülin uygulamasıyla birlikte kan şekeri seviyelerini sürekli olarak düzenlediği için, önerilen kan şekeri tahmin modelindeki temel girdi sinyallerinden birini oluşturmaktadır. Bu özelliği uygun şekilde ön işleme tabi tutmak için, öncelikle insan vücudundaki insülin emilimini ve kan şekeri-insülin dinamiklerini tanımlayan mevcut teorik modeller gözden geçirilmektedir.

Kan şekeri-insülin modellemesine matematiksel olarak yapılan en erken katkılardan biri, pankreas, kan şekeri ve periferik dokular arasındaki etkileşimleri tanımlayan fizyolojik parametreleri türeten Bolie (1961) tarafından yapılmıştır. Spesifik olarak, tahmin edilen ortalama parametreler α = 0,780 birim/ saat /birim, β = 0,208 birim/ saat /g, γ = 4,34 g/ saat /birim ve δ = 2,92 g/ saat /g idi. Daha sonraki kan şekeri-insülin modelleme araştırmalarının önemli bir kısmı bu temel çalışma üzerine hazırlanmıştır.

Daha yakın zamanlarda, Ma ve Li (2022), diyabetin patojenik mekanizmalarını daha iyi yakalamayı amaçlayarak, insülin bozunmasını temsil etmek için Michaelis-Menten formülasyonunu içeren basitleştirilmiş bir kan şekeri-insülin modeli önermişlerdir. Yaklaşımları sayısal simülasyonlarla doğrulandı. Benzer şekilde, Saber ve Alalyani (2022), analitik incelemeleri, çatallanma analizini ve kapsamlı sayısal simülasyonları vurgulayarak, iki zaman gecikmesini içeren bir kan şekeri-insülin etkileşim modeli geliştirmişlerdir. Bu matematiksel modeller değerli fizyolojik bilgiler sağlasa da, karmaşık formülasyonlara ve yoğun sayısal hesaplamalara dayanmaları nedeniyle hesaplama açısından zorlayıcıdır ve gerçek zamanlı veya veri odaklı modelleme çerçevelerinde uygulanmaları zordur. Sonuç olarak, bunların pratik makine öğrenimi süreçlerine doğrudan entegrasyonu zorlu olmaya devam etmektedir.

t, belirli bir zaman damgası t_0 verilen ilk infüzyon dozundan bir sonraki uygulamaya kadar kan dolaşımındaki insülin emilimini simüle eden üstel bozunma modelidir. Bazal insülin dozu I_0 için, zaman içindeki plazma konsantrasyonu Denklem (3.1) 'deki gibi yaklaşık olarak ifade edilebilir:

$$I(t) = I_0 . e^{-k(t-t_0)},\ t \geq t_0 \tag{3.1}$$

Burada k insülinin yarı ömrüyle ilgili bozunma sabitidir. Bu yöntemin etkinliği, Lispro

(hızlı etkili) ve NPH (orta etkili) insülin emilimini simüle ederek ara insülin verileri üretmek için kullanan Martínez-Delgado ve diğ., (2021) tarafından gösterilmiştir.

Daha ayrıntılı yaklaşımlar, çok daha doğru bir yaklaşım sağlamak için çift üstel bozunma kullanarak emilim ve dağıtım oranları gibi hastaya özgü parametreleri dahil edebilirken, bu, OhioT1DM veri kümesinde sağlanmayan parametreler gerektirir. Genel bir çift üstel model, Denklem (3.2)'deki gibi yazılabilir:

$$I(t) = Ae^{-k_a(t-t_0)} + Be^{-k_b(t-t_0)}, t \geq t_0 \quad (3.2)$$

Burada $k_a$ve k_b sırasıyla emilim ve eliminasyon hız sabitleridir ve A ve B ölçeklendirme faktörleridir.

Mevcut veri setine göre, hasta 570 Humalog kullanırken, hastalar 559, 591 ve 575 NovoLog kullanmaktadır; her ikisi de hızlı etkili insülinlerdir. Ürün özelliklerine göre, NovoLog'un tepe etki süresi 1-3 saat olup toplam etki süresi 3-5 saattir, Humalog ise 1-2 saatte tepe etki gösterir ve toplam etki süresi 2-4 saattir. Bu farmakokinetik özellikler kullanılarak, bazal insülin, her bir insülin tipinin yarı ömür aktivitesini yansıtan, Denklem (3.1) kullanılarak üstel olarak azalan bir fonksiyon olarak simüle edilebilir. Bir insülinin yarı ömrü ($t_{1/2}$), plazma konsantrasyonunun %50 azalması için gereken süreyi temsil eder. Bu parametre $t_{1/2}$, Denklem (3.3)'te gösterildiği gibi insülin kinetiğinin üstel modellemesi için bozunma sabiti k hesaplamak için kullanılabilir:

$$k = \frac{ln\,(2)}{t_{1/2}} \quad (3.3)$$

OhioT1DM veri setinde yer alan hızlı etkili insülinler için ortalama yarı ömürler Humalog (insülin lispro) için yaklaşık 1 saat ve NovoLog (insülin aspart) için 1,25 saattir. Bu ortalama yarı ömürler, sürekli infüzyonda bazal insülin azalmasını simüle etmek için basit ancak fizyolojik olarak anlamlı bir temel sağlamaktadır. Hızlı etkili insülinler tipik olarak bolus dozlar için kullanılsa da üstel azalma uygulamak, veri setindeki ayrık bazal hız ayarlamalarından fizyolojik olarak makul, sürekli bir bazal insülin sinyali üretmemizi sağlamaktadır. Bu yaklaşım, ayrıntılı emilim veya dağılım parametrelerinin yokluğunda insülin farmakokinetiğini modellemek için pratik ve hesaplama açısından verimli bir yöntem oluşturmaktadır. Bu yaklaşımın bir sınırlaması, veri setinde hastaya özgü

farmakokinetik parametrelerin bulunmaması nedeniyle, yaklaşık değerlerin gerçek fizyolojik insülin konsantrasyonlarından sapabilmesidir. Sonuç olarak, simüle edilmiş bazal insülin sinyali, bireysel hastalar için gerçek seviyelerden sapabilmektedir. Şekil 3.2 ve Şekil 3.3, orijinal bazal insülin verilerini ön işlenmiş sinyallerle birlikte göstermektedir

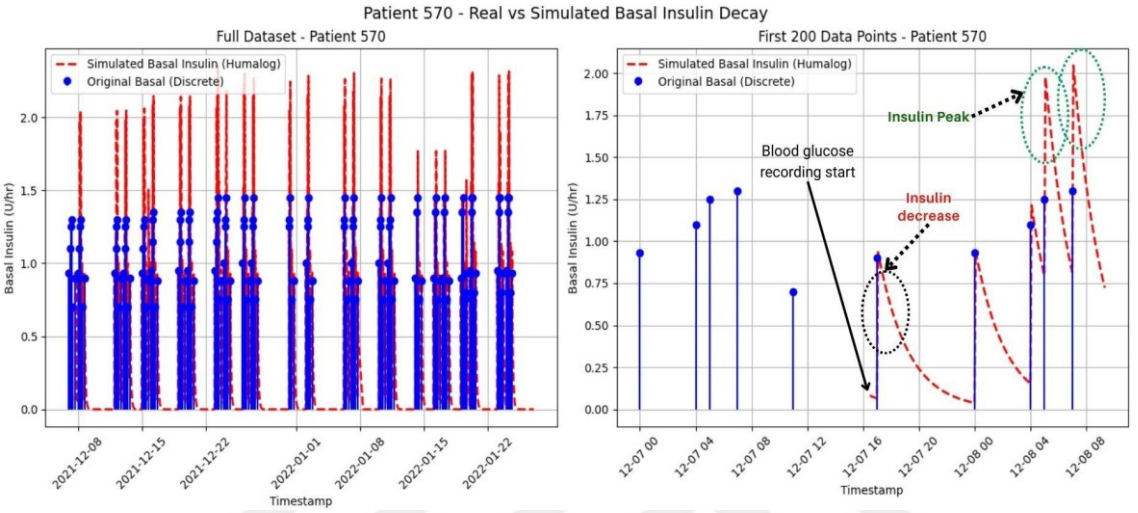

Şekil 3.2.Hasta 570'te Humalog bazal insülin profilleri

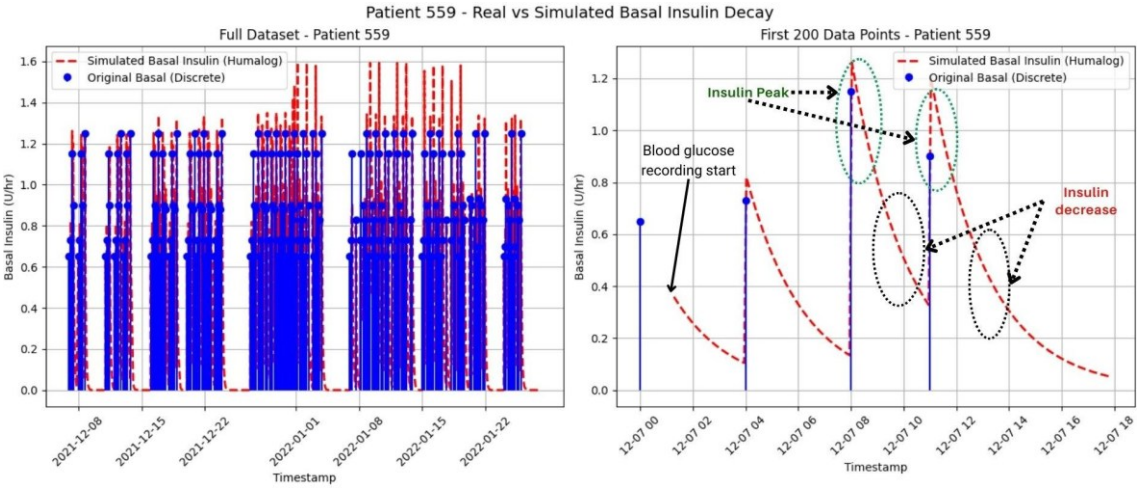

Şekil 3.3.Hasta 559'da Novalog bazal insülin profilleri

Şekil 3.2, Humalog insülin kullanan 570 numaralı hastaya, Şekil 3.3 ise Novalog insülin kullanan 559 numaralı hastaya karşılık gelmektedir. Bu şekillerde görüldüğü gibi, simülasyon, kan şekeri ölçümlerinin başlangıcından önce uygulanan son insülin dozuna dayanarak, kan şekeri kaydının başlangıcından itibaren azalmayı başlatmaktadır.

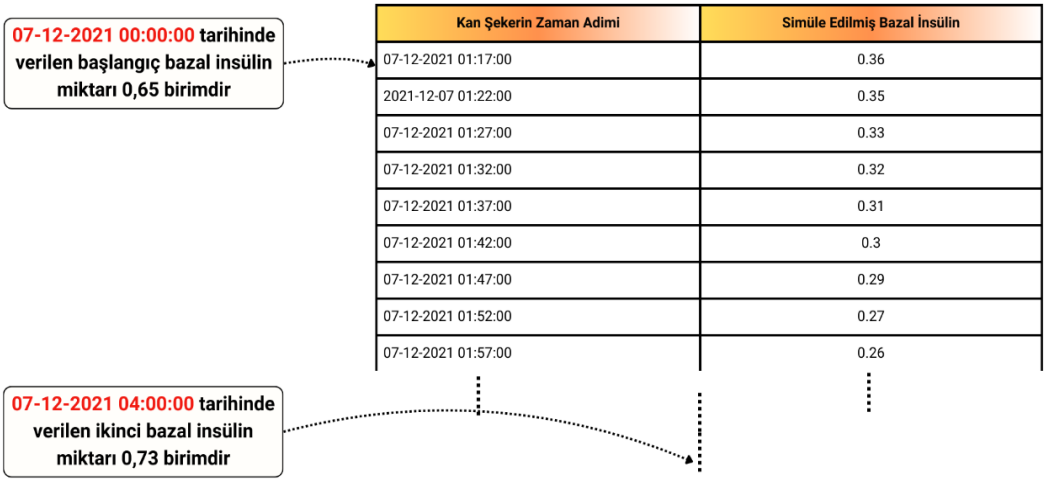

Şekil 3.4.Hasta 559 için üretilmiş bazal insülin verisi

Humalog'un Novalog'dan daha hızlı azaldığı açıktır. Grafikteki tepe noktaları, Michaelis-

Menten kinetiğini izleyerek, enjeksiyondan sonra insülinin gerçek davranışını temsil etmektedir. Hovorka ve diğ., (2004) tarafından geliştirilen doğrusal olmayan modelde de benzer bir tepe noktası deseni gözlemlenmektedir.

Şekil 3.4, 559 numaralı hasta için yeni oluşturulan insülin veri setinin bir örneğini göstermektedir. Görüldüğü gibi, ilk insülin enjeksiyonu 07-12-2021 tarihinde saat 00:00:00'da kan şekeri ölçümünün başlamasından bir saat önce 0,65 ünite dozunda uygulanmıştır. Kan şekeri ölçümünün başlangıcında, bazal insülin seviyesi 0,36 ünite olmuştur. Daha sonraki değerler, kan dolaşımındaki kalan insüline ve yeni uygulanan bazal insüline bağlı olarak 5 dakikalık aralıklarla oluşturulmuştur.

3.3. Karbohidrat Verilerinin Ön İşlenmesi

Besin alımı, sonraki kan şekeri dalgalanmalarının başlıca belirleyicilerinden biridir. Gelecekteki kan şekeri dinamiklerinin doğru tahmin edilmesi, iki temel diyet parametresinin dikkate alınmasını gerektirir: tüketilen karbonhidrat miktarı ve kan şekerin kan dolaşımına giriş hızını karakterize eden glisemik indeks (Glisemik Hedefler: Diyabette Tıbbi Bakım Standartları, 2022). Bununla birlikte, elimizdeki veri seti, glisemik indeks değerlerini doğrudan belirlemek için yeterli ayrıntı içermeyen, yalnızca

öğün türü (örneğin, kahvaltı, öğle yemeği, akşam yemeği veya atıştırmalık) ve toplam karbonhidrat içeriği gibi kaba bilgiler içermektedir. Bu sınırlamayı gidermek için, Martínez-Delgado ve diğ. (2021) yaklaşımını izleyerek, karbonhidrat emilim profilini yine üstel bir bozunma modeli kullanarak yaklaşık olarak hesaplanmıştır. Bu formülasyon, tüm hastalar ve öğün kategorileri için eşit şekilde uygulanır ve bu da onu bireyselleştirilmiş bir temsil yerine genelleştirilmiş bir temsil haline getirir. Pratikte, tahıllar, süt ürünleri, meyveler, baklagiller ve yumru kökler gibi gıdalar daha yavaş emilim gösterirken, şekerler, meyve suları, gazlı içecekler veya bal gibi maddeler çok daha hızlı emilir (Martínez-Delgado ve diğ., 2021). Sonuç olarak, önerilen yöntem karbonhidrat emilimindeki genel eğilimleri yakalasa da gerçek hastaya özgü glisemik yanıtlardan sapma gösterebilmektedir. Önerilen formülasyon Denklem (3.4)'te şu şekilde tanımlanmıştır:

$$D(t) = D_i e^{-k(t-t_i)} . 1_{t \geq t_i} \quad (3.4)$$

Bu ifadede, D_it anındaki gerçek karbonhidrat alımını temsil eder t_i, kalımın etkisinin zamanla ne kadar hızlı azaldığını kontrol eden bozunma oranıdır ve $1_{t \geq t_i}$bozunmanın yalnızca ilgili alımdan sonra başlamasını sağlayan bir gösterge fonksiyonudur.

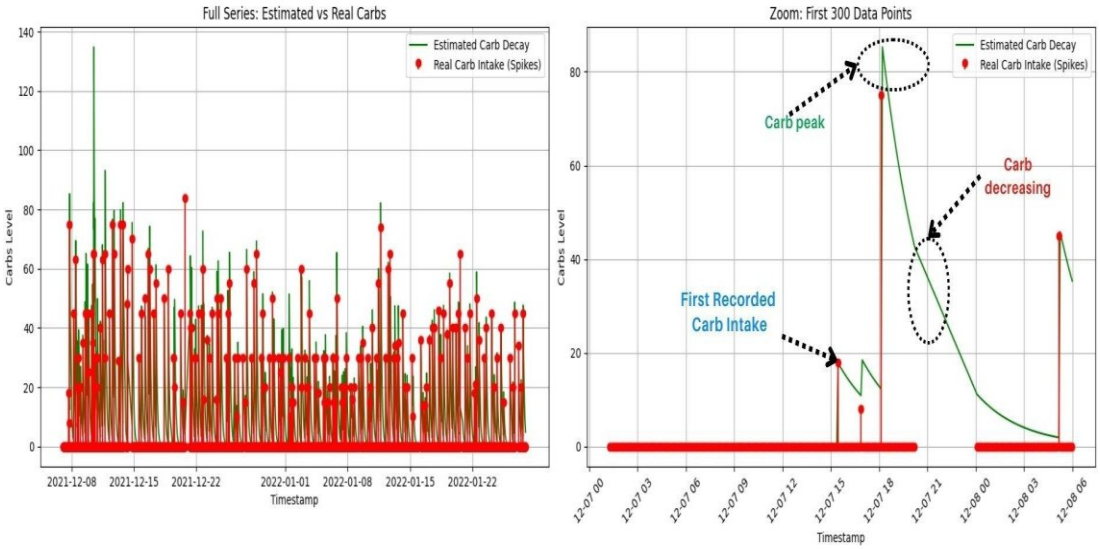

Şekil 3.5.Gerçek ve tahmini karbonhidrat alımının karşılaştırması

Denklem 3.5'te sunulduğu k değerine ait hesaplama sunulmaktadır. Örnek olarak, 559 numaralı hasta için bozunma sabiti, k, tahmini bir karbonhidrat sindirim yarı ömrüne dayanarak belirlenmiştir.

$$k = \frac{ln(2)}{t_{1/2}} = \frac{ln(2)}{120} \quad (3.5)$$

Burada yarı ömrün 120 dakika olduğu varsayılmıştır. Şekil 3.5'te gösterildiği gibi, tahmini değerler gerçek karbonhidrat emilim modelini yakından takip etmekte ve hasta 559 için üstel bozunma formülasyonunu kullanarak makul girdi sinyallerini yeniden oluşturma yeteneğini göstermektedir. Yeniden oluşturulan eğri beklenen dinamikleri yansıtırken, modellenmemiş faktörler ve bu yaklaşımda kullanılan sabit yarı ömür varsayımı nedeniyle sonuçlarda ufak tefek sapmalar olabilmektedir.

3.4. Diğer Fizyolojik Sinyal Ön İşleme

Galvanik deri tepkisi, cilt sıcaklığı, kalp atış hızı ve adım sayısı gibi özellikler, kan şekeri dalgalanmasını farklı şekillerde etkiler. Kajisa ve diğ., (2024) ve Eckstein diğ., (2022), kan şekeri seviyesi dalgalanmaları ile kalp atış hızı ölçümleri arasında güçlü bir ilişki olduğunu göstermiştir. Kan şekeri-galvanik deri tepkisi (GSR) dinamikleriyle ilgili olarak, Donelli ve diğ., (2021), galvanik deri direnci ölçümlerine dayalı, giyilebilir, invaziv olmayan bir kan şekeri izleme sistemi önermiştir. Wu ve diğ., (2023), de çalışmalarında bu güçlü ilişkiyi vurgulamıştır.

Kenny ve diğ., (2016), diyabette termoregülasyon çerçevesinde kan şekeri seviyeleri ile cilt sıcaklığı arasındaki ilişkiyi araştırmış ve vücut sıcaklığı değişimleri ile kan şekeri dinamikleri arasında açık bir korelasyon olduğunu göstermiştir.

Son olarak, çeşitli çalışmalar, genellikle adım sayısı kullanılarak ölçülen fiziksel aktivitenin kan şekeri seviyeleri üzerinde önemli bir etkiye sahip olduğunu göstermiştir. Cuthbertson ve diğ., (2022), günlük aktivite modellerinin kısa vadeli kan şekeri değişkenliği ile güçlü bir şekilde ilişkili olduğunu ve glisemik düzenlemede hareketin önemini vurguladığını bildirmiştir. Yu ve diğ., (2023) ayrıca, adım sayısının tahmin modellerine dahil edilmesinin, özellikle serbest yaşam koşullarında, kan şekeri tahmin performansını iyileştirdiğini göstermiştir. Daha yakın zamanda, Dubaj ve diğ., (2025), kişiselleştirilmiş kan şekeri tahminini geliştirmede fiziksel aktivite özelliklerinin rolünü vurgulayarak, bunların adaptif diyabet yönetim sistemleri için önemini göstermiştir.

Galvanik Deri Tepkisi (GSR) ile temel adım sayısı, temel cilt sıcaklığı ve kalp atış hızı için ek modellemeye gerek yoktur, çünkü bu özellikler de birincil özelliğimiz olan kan

şekeri seviyesine benzer şekilde 5 dakikalık aralıklarla kaydedilmiştir. Bununla birlikte, aynı kayıt sıklığını paylaşmalarına rağmen, bu özelliklerin zaman damgaları kan şekeri ölçümlerinin zaman damgalarıyla tam olarak örtüşmemektedir.

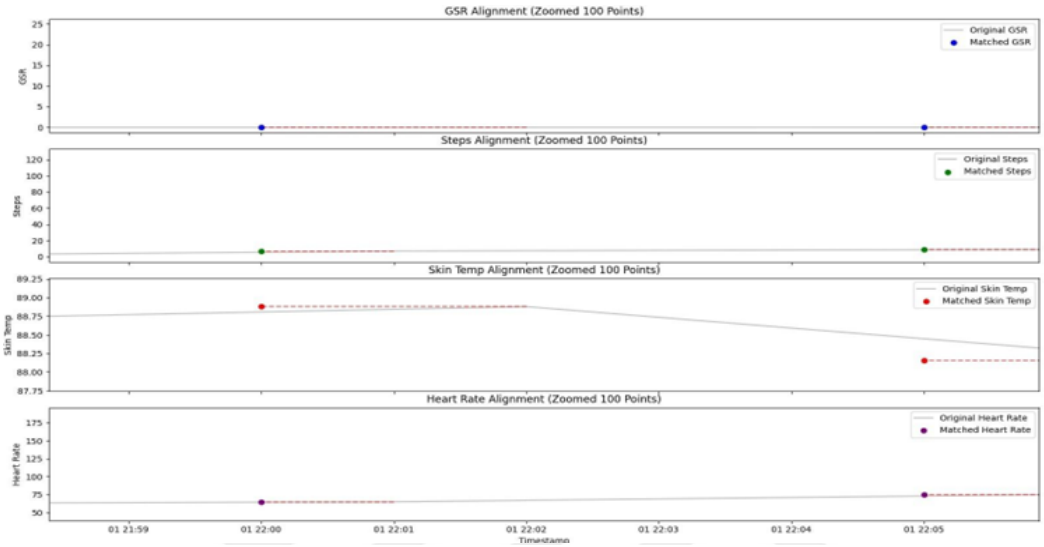

Şekil 3.7.Yardımcı sinyallerin kan şekeri zamanına hizalanması.

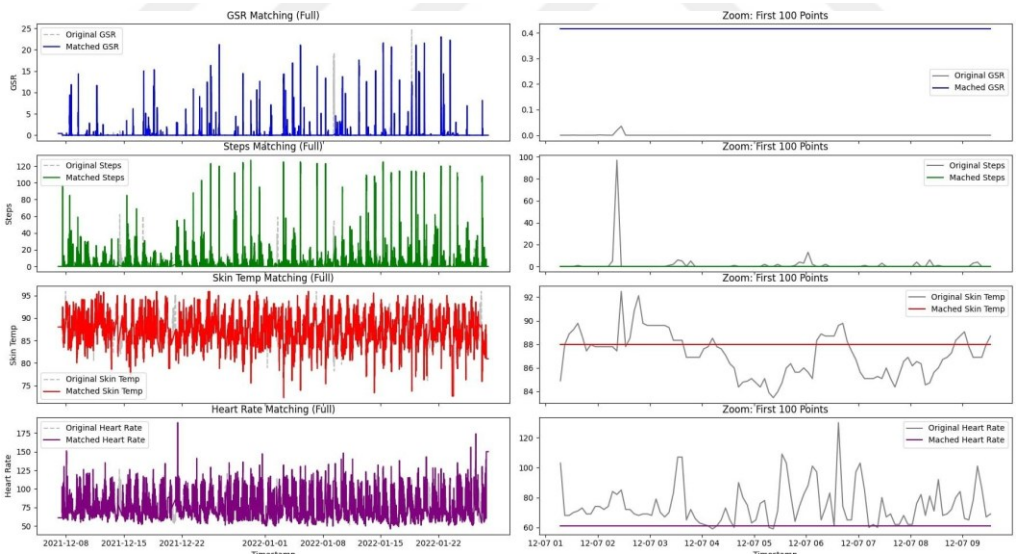

Şekil 3.6.Hasta 559 için GSR, sıcaklık, adım, nabız

Bu uyumsuzluğu gidermek için, her bir karşılık gelen kan şekeri seviyesi ölçümüne zaman olarak en yakın girişler seçilmiştir. Bu özelliklerin kaydı kan şekeri seviyesi ölçümlerinden önemli ölçüde daha geç başladığı durumlarda, eksik değerler tamamlanmıştır. Özellikle, GSR ve temel cilt sıcaklığı için kaydedilen değerlerin ortalamasını, temel adım sayısı ve kalp atış hızı için ise modunu kullanılmıştır. Adım sayısı özelliğindeki eksik değerleri doldurmak için modun kullanılmasının gerekçesi iki

yönlüdür. Birincisi, bu özellikler ayrık değerlerdir ve tamsayı değerler olarak temsil edilir. İkincisi, ortalama genellikle son derece düşüktür (örneğin, yaklaşık 0,0xx) ve anlamlı değildir. Sezgisel olarak, bir hasta uzun süreler boyunca dinlenme halinde kalabilir veya sabit bir kalp atış hızını koruyabilir, bu da tutarlı değerlere yol açarak modu daha temsili ve açıklanabilir bir seçim haline getirir. Şekil 3.6'da gösterildiği gibi, kan şekeri izlemeye başlamadan önce kaydedilen yardımcı sinyallerdeki (adım sayısı, cilt sıcaklığı, GSR ve kalp atış hızı) eksik değerler, temsili istatistikler kullanılarak doldurulmuştur. Özellikle, GSR (0,5), cilt sıcaklığı (88) ve kalp atış hızı (66) gibi sürekli özellikler için ortalama değerler uygulanırken, ayrık özellik olan adım sayısı için mod kullanılmış ve bu değer 0,0 olarak doldurulmuştur.

Şekil 3.7, 1 Ocak 2022 tarihine ait, yaklaşık 22:00 saatine ait bir örneği göstermektedir. Hasta 559 için kan şekeri seviyesi tam olarak 22:00'de kaydedilmiş olsa da en yakın karşılık gelen yardımcı ölçümler biraz daha sonra gerçekleşmiştir: GSR 22:02'de, adım sayısı 22:01'de, cilt sıcaklığı 22:02'de ve kalp atış hızı 22:01'de alınmıştır.

Bu çalışmada tutarlılık sağlamak için, tüm bu ölçümler kan şekeri zaman damgasına (22:00) göre hizalanmıştır.

3.5. Çok Değişkenli Giriş Verilerinin Pencereleme İşlemi

Önerilen tahmin çerçevesi, adım sayısı, bazal insülin, galvanik deri tepkisi, cilt sıcaklığı ve karbonhidrat alımı gibi çok değişkenli girdileri, önceki bir saatlik döneme ait kan şekeri seviyesiyle birlikte kullanmaktadır. Model, sonraki bir saatlik süre için kan şekeri seviyelerini tahmin etmek üzere tasarlanmıştır. Veri seti beş dakikalık aralıklarla örneklenmiş olduğundan, her girdi dizisi 6 değişken boyunca 12 zaman adımını temsil eden 12 × 6 boyutlu bir tensöre karşılık gelmektedir. İlişkili çıktı, gelecekteki kan şekeri seyrini yakalayan 12 × 1'lik bir vektördür. Şekil 3.8, 559 numaralı hastaya uygulanan pencereleme sürecinin bir örneğini göstermektedir. Bu çizimde,d burada 5 dakika örnekleme aralığını ifade etmektedir. Buna göre, tahmin aralıkları, elemanları 5 dakikanın katlarına karşılık gelen ve en fazla bir saate kadar uzanan bir vektör olarak ifade edilir.

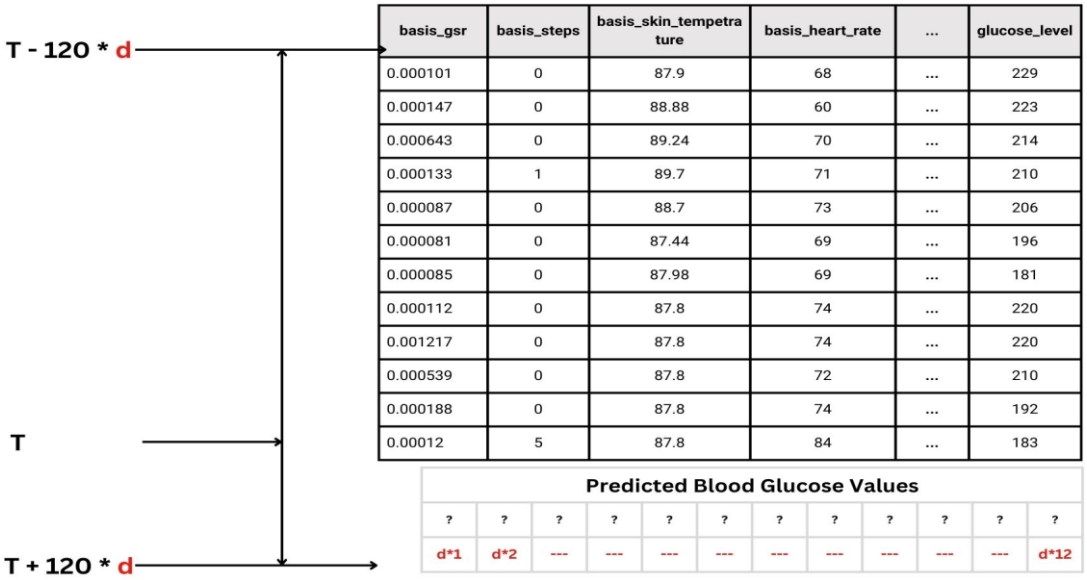

Şekil 3.8.Hasta 559 için saatlik giriş ve tahmin penceresi.

3.6. Eğitim-Test Verilerinin Bölünmesi

Zaman serisi verilerini eğitim ve test alt kümelerine ayırmak için çeşitli stratejiler mevcuttur. Tez çalışmasında, yaygın olarak kullanılan iki yaklaşım ele alınmaktadır: bloklu (veya kayan pencere) bölme ve genişleyen pencere bölme. Kayan pencere bölmede hem eğitim hem de test kümeleri sabit bir pencere boyutunu korumaktadır. Daha sonra pencere, veri kümesinin sonuna ulaşılana kadar yinelemeli olarak ileriye doğru kaydırılır. Buna karşılık, genişleyen pencere bölme, test kümesi boyutunu sabit tutarken, yeni gözlemler geldikçe eğitim kümesini kademeli olarak büyütür. Modelin performansı, verilerdeki zamansal değişimlere karşı sağlamlığı değerlendirmek için her iki yaklaşım altında da değerlendirilmiştir. Şekil 3.9, iki bölme stratejisi arasındaki farkı göstermektedir.

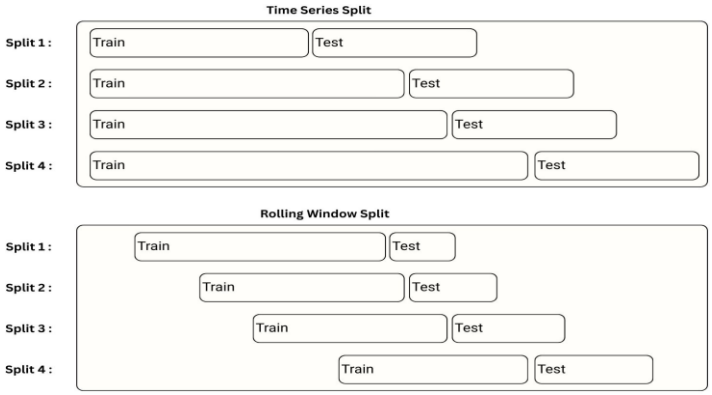

Şekil 3.9.Zaman serisi için blok ve genişleyen pencere

Hasta veri kümelerine uygulanan pencereleme stratejilerinin sonuçları Tablo 3.5'de özetlenmiştir.

Çalışmada, "scikit-learn'de" uygulanan TimeSeriesSplit yöntemi için, her hasta veri seti, her bir bölüm için sabit bir test boyutu için korunurken, kademeli olarak artan eğitim boyutlarıyla beş katmana ayrılmıştır. Bu sayede, verilerin zamansal yapısının korunmasını sağlarken, eğitim için mevcut olan tarihsel bağlamı genişletir. Buna karşılık, Rolling Window Split yöntemi, veri seti boyunca sabit boyutlu kayan bir pencereyi kaydırarak hasta başına daha fazla sayıda pencere oluşturmaktadır. Burada, eğitim seti uzunluğu sürekli ve 300 örnek olarak ayarlanırken, test seti 50 örnek içermektedir. Bu yaklaşım, sabit bir girdi-çıktı yapısını zorunlu kılarak, modelin birden fazla kayan aralıkta ince taneli değerlendirilmesine olanak tanımaktadır.

Tablo 3.6.Farklı hastalarda pencereleme yöntemleri karşılaştırması

Pencereleme Yöntemi	Hasta Kimliği	Toplam Pencereler	Eğitim veri seti boyutu	Test veri seti boyutu
TimeSeriesSplit	559	5	2217	2214
		5	4431	2214
		5	6645	2214
		5	8859	2214
		5	11073	2214
	575	5	2408	2405
		5	4813	2405
		5	7218	2405
		5	9623	2405
		5	12028	2405
	591	5	2264	2264
		5	4528	2264
		5	6792	2264
		5	9056	2264
		5	11320	2264

Tablo 3.6. (Devam)Farklı hastalarda pencereleme yöntemleri karşılaştırması

Pencereleme Yöntemi	Hasta Kimliği	Toplam Pencereler	Eğitim veri seti boyutu	Test veri seti boyutu
		5	2284	2284
		5	4568	2284
	570	5	6852	2284
		5	9136	2284
		5	11420	2284
	559	256	300	50
	575	282	300	50
Sürgülü Pencere Bölmesi	591	265	300	50
	570	268	300	50

4.EVRİMSEL SİNİR AĞI MODELİN MİMARİSİ

Hastaya özgü kan şekeri seviyelerini bir saatlik bir zaman dilimi içinde tahmin etmek için, hafif bir evrimsel sinir ağı (CNN) mimarisi kullanılmıştır. Uzun kısa süreli bellek (LSTM) ağları gibi daha derin modeller güçlü tahmin doğruluğu göstermiş olsa da önerilen yaklaşım hem doğruluğa hem de hesaplama verimliliğine öncelik vermektedir. Önerilen CNN modelleri kompakt ve hızlı bir şekilde eğitilmektedir. 1000 epoch için hasta başına yaklaşık 50 saniye ve yalnızca 74 Kilo byte'lık bir model boyutu üretmiştir. Buna karşılık, LSTM tabanlı temel model 14 dakika 7 saniye eğitim süresi ve yaklaşık 1 Mega byte disk alanı kaplamaktadır. Buna rağmen model daha düşük tahmin performansı elde etmektedir. Bu çalışmalara göre, verimliliğin ve ölçeklenebilirliğin kritik olduğu gerçek dünya uygulama senaryoları için tez çalışmasında önerilen hafif CNN tasarımının uygunluğu vurgulamaktadır.

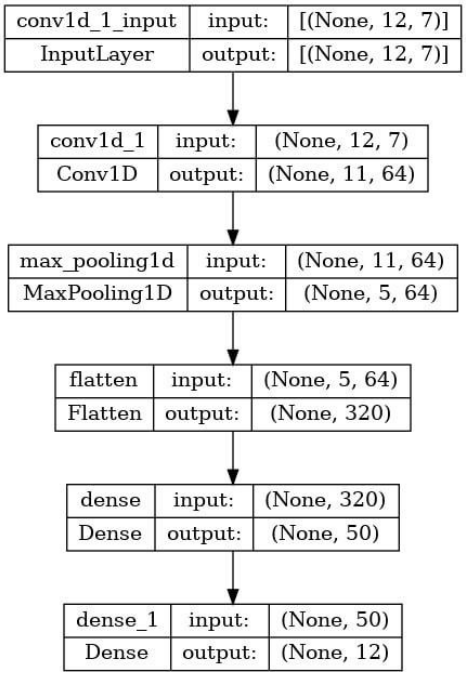

Şekil 4.1.Bir saatlik kan şekeri tahmini için hafif evrişimli CNN ağı

Önerilen hafif CNN mimarisinin özeti Şekil 4.1'de sunulmaktadır. Önerilen hafif CNN mimarisi, çok değişkenli giriş özelliklerini kullanarak bir saatlik kan şekeri seviyelerini verimli bir şekilde tahmin etmek için tasarlanmıştır. Model, kısa vadeli zamansal bağımlılıkları yakalayan 64 filtreli ve 2 çekirdek boyutlu 1 boyutlu bir evrişim katmanı (conv1d_1) ile başlamaktadır. Bu katman, (None, 11, 64) şeklinde bir çıktı üretir ve 960

eğitilebilir parametre içermektedir. Ardından, temel özellikleri korunurken zamansal boyutu azaltan 2 havuz boyutlu bir maksimum havuzlama katmanı (max_pooling1d) gelmektedir. Bu katmanda (None, 5, 64) şeklinde bir çıktı ile sonuçlanır. Havuzlanmış özellikler daha sonra 320 boyutlu bir vektöre düzleştirilmektedir. Çıkarılan özellikler arasındaki üst düzey etkileşimleri öğrenen 50 birimli ve ReLU aktivasyonlu yoğun bir katmandan (dense) geçirilir. Bu yoğun katman 16050 parametre içermektedir. Son olarak, yoğun bir çıktı katmanı (dense_1), 12 adımlı (1 saatlik) tahmin aralığına karşılık gelen 12 birim üretmekte ve 612 parametre içermektedir. Modeldeki toplam parametre sayısı 17622'dir (yaklaşık 68,84 Kilo byte) ve bunların tümü eğitilebilir durumdadır. Şekil 4.1'de görülebileceği üzere, giriş katmanı (None, 12, 7) şeklindedir. Aynı model, gerçek bir sanal CGM sistemini simüle etmek amacıyla, önceki kan şekeri düzeyi kullanılmadan aynı veri üzerinde (None, 12, 6) giriş boyutuna sahip olacak şekilde eğitilmiştir.

5.SHAP DESTEKLİ GLUKOZ KONTROLÜ

ϵ-greedy veya UCB gibi geleneksel stokastik stratejiler kullanılarak ortam doğrudan keşfedilmez. Bunun yerine, eylem seçimi SHAP'tan türetilen özellik atamalarıyla yönlendirilmektedir. SHAP, her giriş değişkeni f_i ye bir değer atmaktadır. Toplamsal değer ϕ_i Denklem (5.1)'de gösterildiği gibi, önceden eğitilmiş tahmin modeli tarafından üretilen tahmini kan şekeri seviyesine katkısını temsil etmektedir.

$$x_t = \{f_1, f_2, f_3, \dots, f_n\}, \Phi_t = \{\phi_1, \phi_2, \phi_3, \dots, \phi_n\} \quad (5.1)$$

Burada, ϕ_i, kan şekeri tahminini yukarı doğru iten bir özelliği gösterirken, ϕ_i <0, kan şekeri üzerindeki etkinin azaldığını gösterir. Aşırı pozitif etki hiperglisemiye yol açabilirken, güçlü negatif katkı hipoglisemiye doğru bir gidişi gösterebilir. Bu nedenle, özellik seçimi ham işaretli değerden ziyade büyüklüğü (mutlak değeri) dikkate alınmalıdır. Belirli bir zaman adımında en etkili fizyolojik değişkene etki etmek için, ajan, Denklem (5.2)'de en yüksek mutlak SHAP katkısına sahip özelliği seçer:

$$i^* = argmax|\phi_i| \quad (5.2)$$

Bu, sistemin, etkisinin kan şekeri yükseltici veya düşürücü olmasına bakılmaksızın, normo-glycemia sapmaya en çok neden olan değişkeni hedeflemesini sağlamaktadır. Baskın özelliği belirledikten sonra, ikinci düzey eylem, onu artırıp artırmayacağına karar vermektedir. Bu yön, Denklem (5.3) ile gösterilen SHAP katsayısının işaretinden doğrudan çıkarılır:

$$a^{(2)} = \begin{cases} -\beta_{i^*} \ , \ \phi_{i^*} > 0 \\ +\beta_{i^*} \ , \phi_{i^*} < 0 \end{cases} \quad (5.3)$$

$\phi_{i^*} > 0$ Özellik kan şekeri seviyesini hedef değerin üzerine çıkarırken, $\phi_{i^*} < 0$ diğer özellik kan şekeri seviyesini hedef değerinin altına düşürmektedir.

Bu nedenle, temsilci tarafından seçilen hiyerarşik eylem, Denklem (5.4)'te olduğu gibi kısa bir şekilde ifade edilebilir:

$$a_t = \left(i^*, \begin{cases} sign(\phi_{i^*}).\beta_{i^*} \\ sign(-\phi_{i^*}).\beta_{i^*} \end{cases}\right) \quad (5.4)$$

Burada $|-\phi_{i^*}|$ hangi özelliğin değiştirileceğini seçerken, ise $sign(\phi_{i^*})$ euglisemik hedef değer aralığı sapmasını azaltmak için özelliğin nasıl değiştirilmesi gerektiğini

belirlemektedir. Bu entegrasyon sayesinde SHAP, pasif bir yorumlama aracından aktif bir kontrol mekanizmasına dönüşerek, kör keşif yapmadan anlamlı müdahale sıralamasına olanak tanımaktadır. Bu yaklaşım, gerçek zamanlı kan şekeri modülasyon sistemleri için gerekli özelliklere sahip ilkeleri arama karmaşıklığını azaltır.

6.POMDP AKTÖR-KRİTİK MODELİ

Kan şekeri düzenlemesini, altta yatan durumun gizli olduğu ve yalnızca kan şekeri gözleminin mevcut olduğu kısmen gözlemlenebilir bir Markov karar süreci (POMDP) olarak tez çalışmasında formüle edilmiştir. Ajan, bir saatlik giyilebilir cihaz ve metabolik sinyalleri temsil eden kayan bir geçmiş penceresi tutmaktadır. Her karar adımında, bu tensörün son satırı (en son 5 dakika) ayarlanabilirken, daha eski satırlar sabit kalmaktadır. Gözlemlenebilir durum olan kan şekeri konsantrasyonu Denklem (6.1) ile gösterilmektedir:

$$O_t = BG_t,\ O_t \in [40{,}400] \tag{6.1}$$

Ajanın çalışma durumu Denklem (6.2) ile gizli özellik geçmişidir:

$$s_t = h_t \in R^{12\times 6} \tag{6.2}$$

Kısmi gözlemlenebilirlik nedeniyle, fizyolojinin tamamı bilinmemektedir; geçmiş tamponu bir inanç durumu vekili görevi görmektedir. Model, Denklem (6.3)'te olduğu gibi sonraki 10 dakikalık kan şekeri seyrini tahmin edecektir:

$$\hat{g}_{t:t+2} = CNN(h_t) \tag{6.3}$$

SHAPDeepExplainer, özellik katkılarını elde etmek için bir sonraki tahmin edilen duruma uygulanır ϕ_i. Denklem (5.2)'de sunulduğu gibi, mutlak değere göre en etkili özelliği seçilmiştir.

Sürekli değerli kontrol yerine, eylem alanı sabit 1 birimlik artışlara ayrıştırılır. Seçilen her özellik, karşılık gelen beta ağırlığıyla ölçeklendirilmiş tam olarak bir adım kadar değiştirilir. Fizyolojik uygunluğu sağlamak ve gerçekçi olmayan eylem büyüklüklerini önlemek için, tüm ayarlanmış özellik değerleri, Denklem (6.4)'te sunulduğu gibi önceden tanımlanmış sınırlar içinde kırpılır:

$$a_t = sign(\phi_{i^*}).\beta_{i^*}, \qquad x_{t+1} = clip(x_t(i^*), low_{i^*}, high_{i^*}) \tag{6.4}$$

β ={bazal insülin : 0.5, karbonhidrat : 10, adım : 100, gsr : 0.05, cilt sıcaklığı : 0.5, kalp atış hızı : 5}, düşük={0.0, 0.0, 0.0, 0.0, 15.0, 30.0}, yüksek={20.0, 500.0, 20000.0, 5.0, 120.0, 220.0}.

Beta ağırlıkları, hastaların geçmiş özellik dağılımları kullanılarak her hasta için

özelleştirilebilir. Bu da kontrol politikasını yeniden eğitmeye gerek kalmadan bireyselleştirilmiş müdahale büyüklüğüne olanak tan CNN ayrıca, bir eylemin sonuçlarını değerlendirmek için ajan içinde kullanılır. Ödül, Denklem (6.5)'te gelecekteki aralıkta hedef kan şekeri *G'ye* doğru iyileşmeyi yansıtır:

$$r_t = \begin{cases} +100, & 80 < \hat{g}_{t+1} < 120 \\ -10, & \hat{g}_{t+1} \leq 70 \text{ (hypoglycemia risk)} \\ -10, & \hat{g}_{t+1} \geq 250 \text{ (hyperglycemia risk)} \\ +5, & |\, \hat{g}_{t+1} - 110 \,| \text{ decreasing or increasing} \end{cases} \tag{6.5}$$

Ödül fonksiyonu, r_t takviyeli öğrenme ajanını kan şekerini güvenli ve optimal bir aralıkta tutmaya yönlendirmek ve tehlikeli sapmaları engellemek için tasarlanmıştır. Ajan, tahmin edilen kan şekeri $\hat{g}_t$ 80-120 mg/dL hedef aralığına düştüğünde +100 gibi yüksek bir pozitif ödül alır ve bu da öglisemik güçlü bir şekilde teşvik eder. Tersine, 70 mg/dL'nin altında veya 250 mg/dL'nin üzerinde tahmin edilen kan şekeri değerleri, sırasıyla hipoglisemi ve hiperglisemi risklerini temsil eden -10'luk negatif bir değerle cezalandırılır. Ek olarak, 110 mg/dL'lik orta hedef değerinden mutlak sapma azaldığında +5 gibi daha küçük bir pozitif ödül verilir ve bu da kan şekeri henüz optimal aralığa ulaşmamış olsa bile, kan şekerinin kademeli olarak optimal aralığa doğru yönlendiren müdahaleleri teşvik etmektedir.

Aktör-Eleştirmen ajanı hem aktör hem de eleştirmen bileşenlerini sırayla güncelleyerek kümülatif gelecekteki ödülü optimize etmek üzere eğitilir. Zamansal fark hatası Denklem (6.6)'da tanımlandığı gibidir:

$$\delta_t = r_t + \gamma V_\theta(s_{t+1}) - V_\theta(s_t) \tag{6.6}$$

Burada $V_\theta(s_t)$, eleştirmenin durum değerine ilişkin tahmini s_t, r_t anlık ödül ve γ Ayarlama faktörüdür. Hiyerarşik demet eylem uzayında $a_t = (a_t^{(1)}, a_t^{(2)})$, eleştirmen güncellemesi, Denklem (6.7)'de olduğu gibi karesel TD hatasını azaltmaya odaklanır:

$$\theta \leftarrow \theta + \alpha_c \nabla_\theta \delta_t^2 \tag{6.7}$$

Denklem (6.8) 'de gösterildiği gibi, seçilen eylem demetinin log-olasılığına göre

avantajla ağırlıklandırılmış olarak güncellenirken:

$$\omega \leftarrow \omega + \alpha_a \nabla_\omega \log \pi_\omega(a_t \mid s_t)\ \delta_t \tag{6.8}$$

Özelliklerin hiyerarşik seçimini ve olasılıksal ayarlamayı yansıtan denklem, Denklem (6.9)'de gösterilmektedir:

Algorithm 1 Glukoz Modülasyonu için SHAP Rehberli Actor–Critic RL

Require: Eğitilmiş CNN kestiricisi f_θ, geçmiş pencere $H_t \in \mathbb{R}^{12\times 6}$, beta haritası β, özellik sınırları [low, high], öğrenme oranları α_a, α_c, Ayarlama faktör γ, maksimum adım sayısı N, bölüm sayısı E

Ensure: SHAP rehberli özellik ayarlaması için aktör politikası π_ϕ ve eleştirmen V_ψ

Actor–Critic ağ parametrelerini başlat: (ϕ, ψ)
for bölüm $e = 1 \ldots E$ **do**
  Ortamı sıfırla ve geçmiş penceresini H_t olarak başlat
  for adım $t = 1 \ldots N$ **do**
    Bir sonraki glukoz yörüngesini tahmin et: $\hat{G}_{t:t+2} \leftarrow f_\theta(H_t)$
    CNN kullanarak H_t üzerinde SHAP değerlerini ϕ_i hesapla
    Mutlak katkısı en yüksek olan özelliği seç: $i^\star = \arg\max_i |\phi_i|$
    Eylem yönünü belirle: $a_t = \text{sign}(-\phi_{i^\star}) \cdot \beta_{i^\star}$
    Eylemi H_t'nin son satırına uygula ve sınırlar içinde kırp:

$$H_t[-1, i^\star] \leftarrow \text{clip}(H_t[-1, i^\star] + a_t,\ \text{low}_{i^\star},\ \text{high}_{i^\star})$$

    Değiştirilmiş son satır ile H_t'yi kaydırarak yeni geçmiş penceresini H_{t+1} oluştur
    Ödül hesaplaması için glukozu tahmin et: $\hat{g}_{t+1} \leftarrow f_\theta(H_{t+1})$
    Ödülü r_t aşağıdaki gibi hesapla:

$$r_t = \begin{cases} +100 & 80 < \hat{g}_{t+1} < 120 \\ -10 & \hat{g}_{t+1} \le 70 \text{ (hipoglisemi riski)} \\ -10 & \hat{g}_{t+1} \ge 250 \text{ (hiperglisemi riski)} \\ +5 & |\hat{g}_{t+1} - 110| \downarrow \end{cases}$$

    Geçişi kaydet: $(H_t, i^\star, r_t, H_{t+1})$
  end for
  Tüm adımlar için Ayarlama edilmiş getirileri hesapla: $R_t = r_t + \gamma R_{t+1}$
  for her bir kayıtlı geçiş $(H_t, i^\star, r_t, H_{t+1})$ için **do**
    Avantajı hesapla: $A_t = R_t - V_\psi(H_t)$
    Aktörü güncelle: $\phi \leftarrow \phi + \alpha_a \nabla_\phi \log \pi_\phi(i^\star \mid H_t) \cdot A_t$
    Eleştirmeni güncelle: $\psi \leftarrow \psi - \alpha_c \nabla_\psi (A_t)^2$
  end for
end for

Şekil 6.1.Kan şekeri Modülasyonu için SHAP Rehberli Aktör-Eleştirmen RL

$$\pi_\omega(a_t \mid s_t) = \pi_\omega\left(a_t^{(1)} \mid s_t\right) \cdot \pi_\omega\left(a_t^{(2)} \mid a_t^{(1)}, s_t\right) \tag{6.9}$$

Ajan, öğrenme oranı $\alpha = 10^{-3}$, Ayarlama faktörü $\gamma = 0.99$ ve bölüm başına maksimum 20 adım ile Adam optimizasyon algoritması kullanılarak eğitilir. Eğitim başlangıçta 500 bölüm için planlanmış olsa da deneyleri hızlandırmak için bu çalışmada 50 bölüme düşürülmüştür. Hiyerarşik eylemlerin sıralı seçimini ve güncellenmesini kapsayan genel eğitim döngüsü, Algoritma 6.1'de özetlenmiştir.

Şekil 6.1, Aktör-Eleştirmen Takviyeli Öğrenme Ağının mimarisini göstermektedir.

Paylaşılan bir kodlayıcı, girdi durumlarını, SHAP özelliklerini ve tahmin edilen kan şekeri gizli bir temsile dönüştürmektedir.

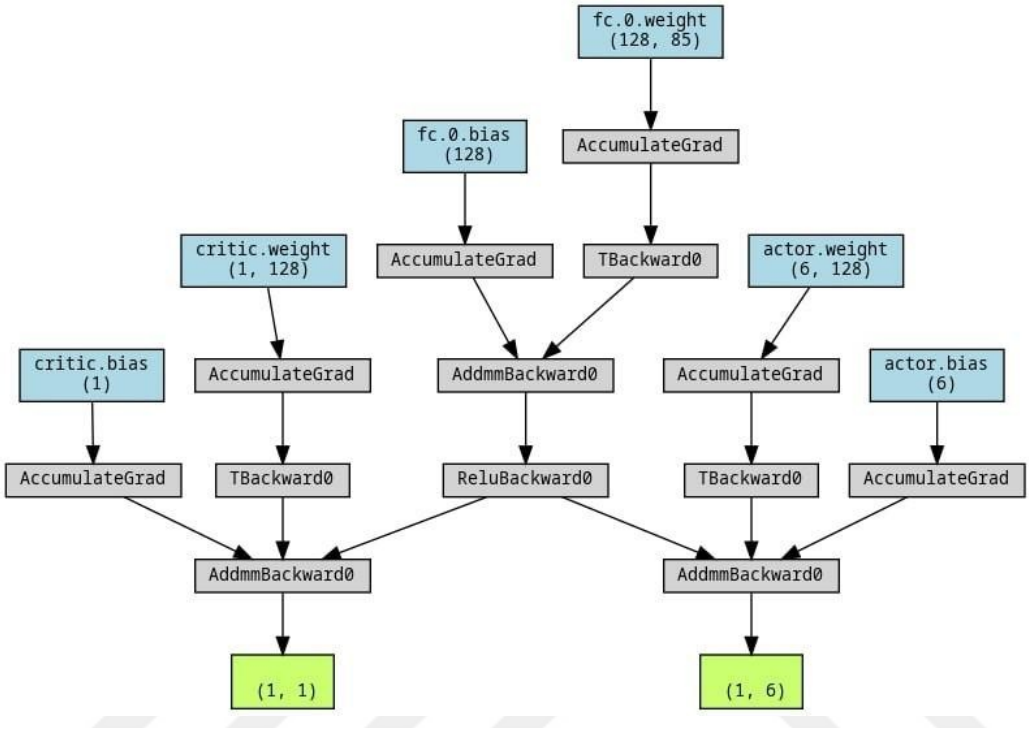

Şekil 6.2. Aktör–Eleştirmen Kan Şekeri Yönetimi Mimarisi

7.MODEL DEĞERLENDİRMESİ

Önerilen modelin çok değişkenli kan şekeri tahmin performansını değerlendirmek için, Ortalama Mutlak Hata (MAE) ve Karekök Ortalama Kare Hata (RMSE) nicel ölçütleri kullanılmıştır. Bu istatistiksel ölçümlere ek olarak, klinik önem değerlendirmesi için Clarke Error Grid kullanılmaktadır. Kan şekeri modelinin tahmin performansını değerlendirmek için kullanılan değerlendirme ölçütleri, Denklem (7.1) ve (7.2)'de sunulmaktadır.

$$\mathrm{MAE} = \frac{1}{N}\sum_{i=1}^{N} |\,\mathrm{BGL}_i - \widehat{\mathrm{BGL}_i}\,| \tag{7.1}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(\mathrm{BGL}_i - \widehat{\mathrm{BGL}_i})^2} \tag{7.2}$$

Yukarıdaki denklemlerde, BGL_i zaman adımındaki gerçek kan şekeri seviyesini i, $\widehat{BGL_i}$ karşılık gelen tahmin edilen değeri ve $\frac{1}{N}\sum$ gözlemlenen kan şekeri seviyelerinin ortalamasını ifade etmektedir. Toplam tahmin sayısı N, Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) gibi standart istatistiksel ölçütler modelin genel tahmin doğruluğunu ölçmektedir. Tahmin hatalarının potansiyel klinik sonuçlarını ele almak için, kan şekeri tahminlerinin klinik kabul edilebilirliğini değerlendirmek için yaygın olarak kullanılan Clarke Error Grid (CEG) analizini de çalışmada sunulmuştur.

Clarke Error Grid, tahmin hatalarının tedavi kararları üzerindeki potansiyel etkisini, tahmin alanını referans ölçümlerden sapmaların ciddiyetine ve klinik etkilerine göre A'dan E'ye kadar etiketlenmiş beş farklı bölgeye ayırarak değerlendirmektedir.

- A bölgesi, klinik olarak doğru tahminleri temsil eder. Bu bölgedeki tahmin edilen kan şekeri değerleri, referans ölçümlerinin %20'si içindedir veya hem tahmin edilen hem de gerçek değerler hipoglisemik aralıktadır (70 mg/dL'nin altında). Bu tahminler doğru tedavi kararlarına yol açar ve klinik kullanım için güvenli kabul edilir.
- B Bölgesi, referans değerlerinden sapma gösteren ancak uygunsuz tedaviye yol açmayacak tahminleri içerir. A Bölgesindeki tahminlere göre daha az kesin olsalar da B Bölgesindeki tahminler klinik olarak kabul edilebilir ve zarara yol açma olasılıkları düşüktür.
- C bölgesi, gereksiz tedaviye yol açabilecek tahminleri kapsar. Bu aşırı düzeltmeler,

tahmin edilen kan şekeri seviyesinin gerçek değerden önemli ölçüde farklı olması durumunda ortaya çıkar ve potansiyel olarak gerekli olmayan müdahalelere yol açabilir.

- D Bölgesi, tehlikeli kan şekeri anormalliklerinin tedavi edilememesine veya tespit edilememesine yol açabilecek hataları temsil eder. Bu, hipoglisemi veya hiperglisemin mevcut olduğu ancak model tarafından algılanmadığı ve önemli klinik risk oluşturduğu durumları içerir.
- E bölgesi, tahmin edilen değerin klinik ihtiyaca ters düşen bir tedaviye yol açabileceği en tehlikeli hataları ifade eder. Örneğin, gerçek kan şekeri seviyesi hipoglisemik iken hiperglisemi tahmin edilmesi, kan şekerinin daha da düşmesine ve potansiyel olarak tıbbi bir acil duruma yol açabilir.

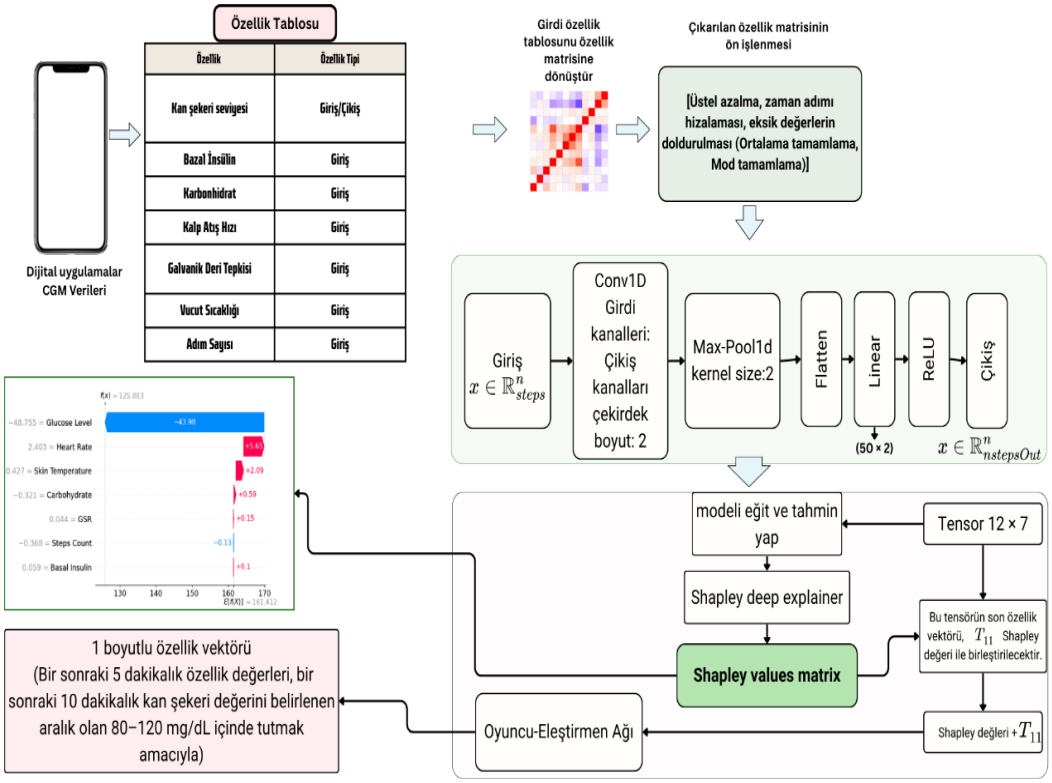

Şekil 7.1.Önerilen Çerçevemizin Genel Görünümü

Pratikte, A ve B bölgeleri klinik olarak kabul edilebilir olarak değerlendirilirken, C, D veya E bölgelerine düşen tahminler giderek daha yüksek klinik risk gösterir ve kabul edilemez olarak değerlendirilir. Algoritmik uygulama için, CEG, her bir tahmin edilen kan şekeri değerinin karşılık gelen referans ölçümüyle karşılaştırılmasıyla hesaplanır. Tahmin edilen-referans çiftleri, Tian ve diğ. (2024) tarafından tanımlanan eşiklere göre

bölgelere atanır. Bu çalışmada, Clarke Error Grid hesaplaması, her bir tahmin-referans çiftini değerlendiren ve bölgelerin dağılımını çıktı olarak veren, açık kaynaklı Python paketi clarke_error_grid kullanılarak uygulanmıştır. Bu yaklaşım, tahminlerin klinik olarak güvenli bölgelere (A ve B) mi yoksa riskli bölgelere (C-E) mi ne sıklıkla düştüğünün nicel bir değerlendirmesini sağlar ve böylece geleneksel istatistiksel ölçütleri klinik olarak anlamlı bir değerlendirme ile tamamlamaktadır.

Şekil 7.1, önerilen hafif CNN–SHAP–RL çerçevesini grafiksel olarak göstermektedir. Bu çerçevede hafif CNN, kısa vadeli kan şekeri yörüngelerini tahmin etmekte; SHAP değerleri en etkili özellikleri belirlemekte, Aktör–Kritik tabanlı takviyeli öğrenme ajanı ise yalnızca araştırma amaçlı, stokastik bir ortamda son gözlemlenen özellik vektörüne uygulanacak ayarlamaların büyüklüğünü optimize etmektedir

8.DENEYSEL SONUÇLAR VE TARTIŞMA

Önerilen yönteme ait deneysel çalışmalar, 1 TB depolama alanına, 16 çekirdekli Intel Core i5 CPU'ya ve NVIDIA RTX 3050 GPU'ya sahip bir Linux sistemi (Parrot 6.1.0-1parrot1-amd64, SMP PRE-EMPT_DYNAMIC, Parrot 6.1.15-1parrot1, x86_64 GNU/Linux) üzerinde gerçekleştirildi. Tüm uygulamalarda TensorFlow 2.15.0, Keras 2.15.0, NumPy 1.26.4, Pandas 1.5.3, Matplotlib 3.10.3 ve Scikit-learn 1.6.1 kullanıldı. Tablo 8.1'te, hafif CNN tahmin modelinin, RL ortamının ve eğitim prosedürünün temel ayrıntılarını özetlemektedir. Veri setinde yer alan tüm veriler, fizyolojik özelliklerin kan şekeri ölçümleriyle senkronizasyonu ve eksik değerlerin ele alınması da dahil olmak üzere, açıklandığı gibi ön işleme tabi tutulmuştur.

Tablo 8.1.CNN modeli, RL ortamı, SHAP, eğitim ve kısıtlamalar

Bileşen	**Ayrıntılar/Kurulum**	**Kalan Hususlar**
Tahmin Modeli (CNN)	**Giriş**: (12 zaman adımı, 6 özellik) **Katmanlar**: Conv1 D(64 filtre, çekirdek=2, ReLU)-MaxPooling1 D(2)- Düzleştirme -Yoğun(50, ReLU)-Yoğun(12, çıkış) **Optimizasyoncu**: Adam öğrenme oranı: 0,001 **Kayıp**: Ortalama Kare Hata (MSE) Eğitim dönemleri: Katlama başına 200 (TimeSeriesSplit 5-fold)	Hastaya özel ayarlama, doğruluğu artırabilir. Model şu anda yalnızca kan şekeri tahmin ediyor. Araştırma veri setiyle sınırlıdır; yeni hastalara genellemesi test edilmemiştir.
RL Ortamı	Sanal Kan şekeri Ortamı (POMDP) **Gözlem**: Son zaman dilimindeki özellikler (bazal insülin, karbonhidrat, adım sayısı, GSR, cilt sıcaklığı, kalp atış hızı) **Eylem**: (özellik indeksi, yön) SHAP rehberliğinde özellik seçimi ile **Ödül**: Hedefe yakın kan şekeri seviyesi, hipoglisemi/hiperglisemi için cezalar. **Tarihçe**: 12 adımlı pencere	RL rastgele bir yöntemdir; sonuçları klinik olarak doğrulanmamıştır. SHAP yalnızca hangi özelliğin ayarlanması gerektiği konusunda yol gösterir; fizyolojik güvenliği sağlamaz. Aşırı özellik değişiklikleri kırpma ile sınırlandırılmıştır; daha gerçekçi kısıtlamalar eklenebilir.

Tablo 8.1.(Devam)CNN modeli, RL ortamı, SHAP, eğitim ve kısıtlamalar

Bileşen	Ayrıntılar/Kurulum	Kalan Hususlar
SHAP Özellik Atfı	**Yöntem**: Shapley Toplamsal Açıklamalar (SHAP) **Giriş**: CNN tahmin penceresi (12×6) **Çıktı**: Değiştirilebilir her değişken için özellik önem puanları **Rol**: RL ajanını, ayarlama için en etkili özelliği seçmesi konusunda yönlendirir.	SHAP, son kullanıcılar için model yorumlana-bilinirliği sağlamak amacıyla değil, eylem seçimi için kullanılır. Tek adımlı özellik seçimi ötesinde etkileşim etkilerini nicel olarak ölçmez. Güvenilirlik, CNN'nin tahmin doğruluğuna bağlıdır.
Eğitim Kurulumu	Donanım: Intel Core i5 (16 çekirdekli), NVIDIA RTX 3050, 1 TB depolama. İşletim Sistemi: Linux Parrot 6.1 Python 3.11 ortamı Kütüphaneler: TensorFlow 2.15, Keras 2.15, NumPy 1.26, Pandas 1.5, Matplotlib 3.10, Scikit-learn 1.6 Çapraz doğrulama: TimeSeriesSplit (5 katlı)	Eğitim süresi veri setinin boyutuna bağlı olarak değişebilir. GPU, CNN eğitimini hızlandırır ancak zorunlu değildir. Tekrarlanabilirlik, rastgele tohum kontrolüne bağlıdır.

Elde edilen yeni veri setine ait tanımlayıcı istatistiklerin özeti Tablo 8.2'te sunulmaktadır. Tabloda görüldüğü gibi, tüm hastalar için her bir özelliğin minimum, maksimum, ortalama, standart sapma ve sayım değerleri rapor edilmiştir.

Tanımlayıcı istatistiklerden elde edilen önemli bir gözlem, kaydedilen maksimum kan şekeri değerlerinin 400 mg/dL'yi aşmamasıdır. Bu, kan şekeri tahminlerinin klinik doğruluğunu değerlendirmek için yaygın olarak kullanılan Clarke Error Grid'ndaki x ekseninin üst sınırıyla uyumludur. Önerilen çalışma, henüz klinik uygulamada doğrudan kullanılmaya hazır olmasa da bu tutarlılık veri seti dağılımının klinik olarak anlamlı olduğunu göstermektedir. Dahası, tüm özelliklerin minimum değerleri sıfırdan büyük veya sıfıra eşittir. Bu da ön işleme sürecinin bozuk veya anormal değerleri etkili bir şekilde ortadan kaldırdığını doğrulamaktadır. Bu da veri setinin sonraki modelleme görevleri için güvenilirliğini daha da desteklemektedir.

Tablo 8.2.Hasta Başına Eğitim Veri Setinin Tanımlayıcı İstatistikleri

Hasta	İstatistik	Bazal İnsülin	Karbonhidratlar	Adım Sayısı	GSR	Cilt Sıcaklığı	Kalp Atış Hızı	Kan şekeri
	Toplam	13310	13310	13310	13310	13310	13310	13310
	Ortalama	0.3121	15.0788	3.5393	0.3853	87.4436	74.8630	167.2289
	Standart	0.3305	14.6323	14.7446	1.9792	3.5821	17.1688	69.9145
	Minimum	0.0000	0.0000	0.0000	0.0001	72.3200	46.0000	40.0000
559	%25	0.0000	4.1500	0.0000	0.0001	85.1000	62.0000	111.0000
	%50	0.2100	10.6200	0.0000	0.0001	87.2600	69.0000	159.0000
	%75	0.5100	21.8900	0.0000	0.0006	90.1400	85.0000	210.0000
	Maksimum	1.5800	134.7700	127.0000	23.0200	95.9000	189.0000	400.0000
	Toplam	13727	13727	13727	13727	13727	13727	13727
	Ortalama	0.2745	34.0928	2.2450	0.5260	86.624	83.7377	192.946
	Standart	0.4397	38.1935	7.4056	2.5673	3.3468	10.8945	64.0959
	Minimum	0.0000	0.0000	0.0000	0.0000	72.500	58.0000	40.0000
570	%25	0.0000	2.9300	0.0000	0.0000	85.460	76.0000	109.000
	%50	0.0100	21.2600	0.0000	0.0001	86.900	85.000	195.000
	%75	0.4200	53.3800	0.0000	0.0001	88.520	88.000	241.000
	Maksimum	2.3600	223.3800	110.000	28.280	100.22	143.00	388.000
	Toplam	14456	14456	14456	14456	14456	14456	14456
	Ortalama	0.1813	21.9720	0.2292	87.1690	87.1690	83.0144	143.3358
	Standart	0.2764	21.3761	1.3997	2.8841	2.8841	10.9718	60.4025
	Minimum	0.0000	0.0000	0.0000	0.0001	72.8600	56.0000	40.0000
575	%25	0.0000	3.2400	0.0000	0.0001	85.2800	76.0000	99.0000
	%50	0.0000	16.7700	0.0000	0.0001	87.8000	85.0000	133.0000
	%75	0.3100	34.4800	10.0000	0.0001	88.5200	88.0000	178.0000
	Maksimum	1.8900	145.7900	97.0000	21.0800	97.5200	176.0000	400.0000
	Toplam	13607	13607	13607	13607	13607	13607	13607
	Ortalama	0.3120	14.3788	2.7307	2.0613	87.7384	69.1687	153.7515
	Standart	0.3948	15.0833	8.9726	4.8584	3.0000	11.6480	56.9372
	Minimum	0.0000	0.0000	0.0000	0.0000	76.1000	45.0000	40.0000
591	%25	0.0000	1.4050	0.0000	0.0005	86.0000	62.0000	109.0000
	%50	0.1100	9.9900	0.0000	0.0305	88.5200	70.0000	147.0000
	%75	0.5600	22.9350	0.0000	0.9977	89.0600	72.0000	192.0000
	Maksimum	1.7500	95.3200	127.000	28.4600	102.200	151.0000	397.0000

Önerilen çalışmada kullanılan hafif CNN modeline ait sonuçlar, Tablo 8.3 ve 8.4'te özetlenmiştir. Tablo 8.3, geçmiş kan şekeri ölçümlerini kullanarak (farklı zamanlarda tek değişkenli), gelecekteki kan şekeri seviyelerini tahmin etmek için elde edilen sonuçları sunmaktadır. Tablo 8.4, farklı zaman aralıklarında çok değişkenli kan şekeri tahmin sonuçları yer almaktadır. Burada, fizyolojik ve davranışsal özelliklerin tamamı girdi değişkenleri olarak dahil edilmiştir.

Sonuçları analiz ederken, çok değişkenli çerçevenin genel olarak tahmin aralıkları boyunca daha istikrarlı ve daha düşük hata metrikleri elde edildiği gözlemlenmiştir. Özellikle, kan şekeri değerlerinin yanı sıra ek bağlamsal özellikler de dahil edildiğinde Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Hata (MAE) sürekli olarak daha düşük kalmaktadır. Bu da insülin veya karbonhidrat alımı gibi yardımcı sinyallerin tahmin doğruluğunu artırmadaki önemini vurgulamaktadır.

Öte yandan, yalnızca kan şekeri geçmişinin girdi olarak kullanıldığı tek değişkenli çerçeve, tahmin sırasında zaman dilimi uzadıkça daha yüksek tahmin belirsizliği ve artan hata göstermektedir. Bu durum, güven aralıklarının önemli ölçüde genişlediği 30 ve 60 dakikalık dilimlerinde en belirgindir. Genel olarak, karşılaştırmalı analiz, çok değişkenli çerçeveye birden fazla özelliğin dahil edilmesinin hem kısa hem de uzun vadeli kan şekeri tahmin güvenilirliğini artırdığını, tek değişkenli çerçevenin ise basitliğin değerini gösterdiğini ancak daha uzun zaman dilimi doğruluğun azalması pahasına olduğunu doğrulamaktadır. Öte yandan, kayan pencere bölme yöntemini kullanarak tahmine dayalı evrimsel sinir ağı modelimizi değerlendirmek için, tüm hastalarda ilk 5 bölme örneği seçilmiştir. Temel tek değişkenli ve önerilen çok değişkenli modelin sonuçları Tablo 8.5 ve 8.6'de özetlenmiştir. Bu durumda da çok değişkenli model, tüm hastalar ve tahmin süreleri boyunca tek değişkenli modele göre sürekli olarak daha iyi performans göstermektedir. Kısa vadeli tahminler (5 ve 10 dakika) için, çok değişkenli modelin RMSE değeri, tek değişkenli modele göre ortalama %10-30 daha düşüktür. MAE ise benzer şekilde %8-25 oranında azalma göstermektedir. Bu, birden fazla özelliğin dahil edilmesinin, modelin altta yatan dinamikleri daha iyi yakalamasına ve genel tahmin hatasını azaltmasına olanak sağladığını göstermektedir. Orta vadeli tahminler (30 dakika) için, çok değişkenli modelin avantajı daha belirgindir. RMSE %15-35, MAE ise %12-30 oranında azalırken, bu durum geleceğe yönelik tahminlerde daha iyi bir sağlamlık göstermektedir. Daha uzun süreler (60 dakika) için, beklendiği gibi her iki modelde de hata artışı yaşanmaktadır. Ancak çok değişkenli model, RMSE ve MAE değerlerinin tek değişkenli modele göre sürekli olarak daha düşük olmasıyla açık bir avantaja sahiptir.

Tablo 8.3.Farklı zamanlarda tek değişkenli RMSE ve MAE

Hasta	Bölmek	5 dakika		10 dakika		30 dakika		60 dakika	
		RMSE	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**
559	1	16,41 ± 6,88	12,91 ± 0,42	18,95 ± 7,65	14.19 ± 0.52	32,21 ± 10,01	24,04 ± 0,89	49,05 ± 12,92	36,90 ± 1,35
	2	13,58 ± 6,85	9,12 ± 0,42	17,50 ± 7,84	11,84 ± 0,54	30,81 ± 10,08	21,77 ± 0,91	45,24 ± 13,35	33,30 ± 1,28
	3	15,63 ± 7,26	9,55 ± 0,52	21,51 ± 8,92	13,73 ± 0,69	37,86 ± 12,58	26,69 ± 1,12	54.11 ± 15.76	40,40 ± 1,50
	4	10,76 ± 4,24	7,84 ± 0,31	14,42 ± 4,97	10,76 ± 0,40	27,30 ± 8,01	20,34 ± 0,76	44,41 ± 12,56	32,97 ± 1,24
	5	10.30 ± 6.11	6,06 ± 0,35	13,44 ± 6,83	8,26 ± 0,44	24,89 ± 8,74	17,15 ± 0,75	38,47 ± 11,17	28,68 ± 1,07
575	1	13,26 ± 3,87	10,56 ± 0,32	15.04 ± 4.33	11.31 ± 0.40	25,86 ± 6,83	19,46 ± 0,68	40,03 ± 9,73	30,75 ± 1,03
	2	10.32 ± 4.86	5,95 ± 0,34	13,74 ± 6,08	8,17 ± 0,44	24,69 ± 8,19	16,77 ± 0,73	35,54 ± 9,77	26,46 ± 0,95
	3	14,22 ± 7,45	7,93 ± 0,47	18,52 ± 8,58	10,80 ± 0,61	31,87 ± 10,52	21,83 ± 0,93	46,67 ± 13,69	34.18 ± 1.27
	4	13,84 ± 8,90	6,82 ± 0,48	16,95 ± 9,59	9,31 ± 0,57	28,91 ± 11,74	18,64 ± 0,88	44,45 ± 14,30	31.08 ± 1.27
	5	11.31 ± 4.54	6,65 ± 0,37	15,33 ± 6,03	9,36 ± 0,49	27.03 ± 8.37	19.31 ± 0.76	39,98 ± 10,48	31,21 ± 1,00
591	1	10,50 ± 4,44	7,35 ± 0,31	13,59 ± 5,39	9,66 ± 0,39	25,22 ± 8,68	17,91 ± 0,73	39.11 ± 12.23	28.09 ± 1.12
	2	11,74 ± 5,48	8,66 ± 0,33	13,86 ± 6,02	9,72 ± 0,41	24,38 ± 7,49	17,87 ± 0,68	38,38 ± 9,88	29,22 ± 1,03
	3	19,62 ± 10,15	11,55 ± 0,65	25,90 ± 11,35	16,34 ± 0,83	41,94 ± 16,22	27,34 ± 1,31	57,49 ± 18,51	40,52 ± 1,68
	4	17.15 ± 7.44	11.04 ± 0.54	22,51 ± 8,95	14,28 ± 0,72	36,47 ± 11,69	25,88 ± 1,06	45,55 ± 12,04	35,20 ± 1,19
	5	8,61 ± 3,28	6,01 ± 0,25	11,66 ± 3,91	7,92 ± 0,31	24.10 ± 6.77	15.19 ± 0.60	33,34 ± 8,72	21,99 ± 0,81
570	1	14,64 ± 5,91	8,42 ± 0,49	19.20 ± 7.41	11,44 ± 0,63	29,37 ± 10,65	17,75 ± 0,96	33.11 ± 10.23	23.01 ± 0.98
	2	7,15 ± 2,24	5,06 ± 0,21	9,88 ± 2,85	7,07 ± 0,28	18,92 ± 5,38	13,41 ± 0,55	29,87 ± 8,35	21,27 ± 0,86
	3	10,50 ± 4,77	6,99 ± 0,32	13,36 ± 5,40	8,99 ± 0,41	23.18 ± 7.29	16,32 ± 0,68	34,81 ± 10,11	25.01 ± 0.99
	4	7,70 ± 2,52	5,49 ± 0,22	10,58 ± 3,31	7,59 ± 0,30	20,58 ± 6,05	15.00 ± 0.58	32,53 ± 8,89	24,27 ± 0,89
	5	9,05 ± 2,93	6,81 ± 0,25	11.00 ± 3.40	7,92 ± 0,31	22,81 ± 6,59	16,69 ± 0,64	29,57 ± 8,20	21,99 ± 0,81

Tablo 8.4.Çok değişkenli tahmin: Zaman aralıklarında göre RMSE ve MAE

Hasta	Bölmek	5 dakika		10 dakika		30 dakika		60 dakika	
		RMSE	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**
559	1	6,04 ± 2,99	14,23 ± 0,55	12,69 ± 3,85	4,36 ± 0,62	18,81 ± 5,61	13,45 ± 0,72	30,98 ± 6,12	22,31 ± 1,25
	2	6,89 ± 3,21	14,77 ± 0,62	11,54 ± 4,22	4,90 ± 0,58	17,60 ± 5,40	14.12 ± 0.80	31,25 ± 6,30	23.14 ± 1.32
	3	7,21 ± 3,47	13,98 ± 0,59	13.08 ± 4.60	5.12 ± 0.61	19,40 ± 6,12	13,67 ± 0,74	31,62 ± 6,48	21,88 ± 1,28
	4	5,87 ± 2,74	13,56 ± 0,50	10,92 ± 3,99	4,45 ± 0,47	16,85 ± 5,20	14,33 ± 0,77	30,55 ± 6,00	24.02 ± 1.40
	5	6,32 ± 3,01	14.10 ± 0.53	11.21 ± 4.12	4,63 ± 0,49	17.10 ± 5.44	13,88 ± 0,69	31.10 ± 6.22	22,75 ± 1,30
575	1	6,20 ± 3,67	13,65 ± 0,47	10.11 ± 4.27	4,48 ± 0,39	15.80 ± 5.11	14.05 ± 0.71	30,72 ± 5,90	21,50 ± 1,20
	2	6,75 ± 3,89	14,22 ± 0,52	10,90 ± 4,56	4,62 ± 0,42	16.30 ± 5.43	13,89 ± 0,68	30,95 ± 6,12	23.01 ± 1.35
	3	7,92 ± 4,11	14,55 ± 0,58	12.18 ± 4.80	5,00 ± 0,46	17.12 ± 5.80	14,48 ± 0,75	31,42 ± 6,34	22,80 ± 1,28
	4	7.11 ± 3.76	13,99 ± 0,49	11,74 ± 4,61	4,85 ± 0,44	16,85 ± 5,50	13,72 ± 0,70	30,88 ± 6,10	21,97 ± 1,22
	5	6,88 ± 3,55	14,05 ± 0,50	11.05 ± 4.39	4,60 ± 0,41	16,45 ± 5,28	14,20 ± 0,73	31,15 ± 6,25	22,60 ± 1,26
570	1	7,25 ± 4,01	13,78 ± 0,51	12,62 ± 4,72	5,22 ± 0,47	18,44 ± 5,97	14.01 ± 0.76	31,55 ± 6,45	23,25 ± 1,30
	2	6,33 ± 3,12	14.05 ± 0.55	11,90 ± 4,50	5,00 ± 0,44	17,98 ± 5,65	13,65 ± 0,69	30,78 ± 6,22	22.10 ± 1.20
	3	6,89 ± 3,40	14,33 ± 0,57	12.05 ± 4.68	5,15 ± 0,46	18,25 ± 5,89	14,22 ± 0,77	31,20 ± 6,30	24.05 ± 1.35
	4	6,44 ± 3,01	13,90 ± 0,52	11,42 ± 4,21	4,85 ± 0,41	17,55 ± 5,44	13,88 ± 0,71	30,66 ± 6,05	22,45 ± 1,28
	5	6,12 ± 2,92	14.10 ± 0.53	11,25 ± 4,15	4,80 ± 0,40	17,40 ± 5,38	14.12 ± 0.75	31.05 ± 6.15	23,15 ± 1,32
591	1	6,55 ± 3,20	14.00 ± 0.54	11,48 ± 4,40	4,92 ± 0,43	17,82 ± 5,70	13,98 ± 0,73	31,30 ± 6,28	22,80 ± 1,29
	2	6,10 ± 3,01	13,75 ± 0,50	11.05 ± 4.18	4,70 ± 0,40	17,25 ± 5,44	14.05 ± 0.70	30,95 ± 6,18	23,05 ± 1,31
	3	6,78 ± 3,38	14,22 ± 0,55	12.00 ± 4.65	5.10 ± 0.45	18.10 ± 5.85	13,88 ± 0,72	31,48 ± 6,35	22,50 ± 1,27
	4	6,45 ± 3,11	13,85 ± 0,51	11,38 ± 4,38	4,88 ± 0,42	17,65 ± 5,56	14.12 ± 0.76	30,85 ± 6,12	21,95 ± 1,24
	5	6,20 ± 2,95	13,92 ± 0,53	11.12 ± 4.25	4,75 ± 0,41	17,35 ± 5,40	14.00 ± 0.71	31.05 ± 6.20	22,60 ± 1,30

Tablo 8.5.Çok Değişkenli Tahmin Hata Ölçütleri

Hasta	Bölmek	5 dakika		10 dakika		30 dakika		60 dakika	
		RMSE	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**
559	1	11.12 ± 6.87	5,78 ± 0,52	15,74 ± 7,81	9,42 ± 0,63	29,88 ± 7,05	17,32 ± 0,97	30,15 ± 6,05	17,85 ± 1,10
	2	8,85 ± 6,80	4,48 ± 0,43	13,38 ± 7,88	7,75 ± 0,56	28,95 ± 6,60	16,92 ± 0,85	29,88 ± 6,10	17.12 ± 1.08
	3	11.45 ± 7.35	4,33 ± 0,57	16.30 ± 8.98	7,45 ± 0,73	30.18 ± 7.20	17,50 ± 0,93	29,95 ± 6,15	17,45 ± 1,12
	4	7,20 ± 4,30	3,80 ± 0,36	9,55 ± 5,25	5.10 ± 0.44	27,75 ± 6,10	16,65 ± 0,82	28,05 ± 6,00	17,22 ± 1,06
	5	7,15 ± 6,60	2,78 ± 0,40	9,92 ± 7,40	4,45 ± 0,49	26,80 ± 6,90	16,20 ± 0,80	27,95 ± 5,95	17,15 ± 1,05
575	1	6,25 ± 3,65	3,18 ± 0,32	10.15 ± 4.25	4,50 ± 0,40	25,85 ± 5,85	15,45 ± 0,72	25,95 ± 5,80	15,50 ± 0,95
	2	7,40 ± 5,35	2,76 ± 0,40	10,75 ± 6,45	5.10 ± 0.49	26,25 ± 6,20	15,85 ± 0,82	26.10 ± 6.00	15,80 ± 1,00
	3	10,90 ± 7,65	4,25 ± 0,53	15,40 ± 8,70	7,28 ± 0,66	29,20 ± 7,45	16,95 ± 0,97	29.05 ± 6.25	17.05 ± 1.05
	4	9,40 ± 6,10	3,68 ± 0,50	13,40 ± 7,85	6,55 ± 0,61	28,65 ± 7,15	16,50 ± 0,90	28,50 ± 6,15	16,48 ± 1,00
	5	8,05 ± 5,10	3,10 ± 0,42	11,50 ± 6,50	5.12 ± 0.53	27,55 ± 6,65	16,30 ± 0,83	27,60 ± 6,05	16,35 ± 1,03
570	1	13.10 ± 6.50	6,80 ± 0,57	17,60 ± 8,20	9,75 ± 0,70	28,40 ± 7,55	17,90 ± 0,97	28,25 ± 6,10	17,85 ± 1,05
	2	3,10 ± 2,35	0,99 ± 0,23	5,75 ± 3,00	2,98 ± 0,30	23,25 ± 5,60	14,28 ± 0,57	23,50 ± 5,40	14,25 ± 0,63
	3	6,00 ± 4,50	2,60 ± 0,34	8,60 ± 5,00	4,52 ± 0,41	27,40 ± 6,95	15.10 ± 0.70	27,50 ± 6,50	15.15 ± 0.72
	4	5,70 ± 2,95	3,50 ± 0,28	9,25 ± 3,95	6,15 ± 0,37	26,75 ± 7,30	14,80 ± 0,72	26,85 ± 6,80	14,85 ± 0,75
	5	3,45 ± 2,95	1,03 ± 0,25	5,85 ± 3,50	2,63 ± 0,33	23,60 ± 6,10	14.15 ± 0.61	23,50 ± 5,90	14.18 ± 0.63
591	1	9.10 ± 5.20	4,98 ± 0,42	10,55 ± 5,60	6.10 ± 0.46	26,20 ± 6,85	16,22 ± 0,84	26,25 ± 6,30	16,25 ± 0,85
	2	6.10 ± 5.10	2,50 ± 0,35	9,25 ± 5,70	4,88 ± 0,43	25,95 ± 6,40	15,78 ± 0,77	25,85 ± 6,15	15,80 ± 0,78
	3	14.40± 10.20	5,65 ± 0,68	19.45 ± 11.45	8,70 ± 0,85	30,75 ± 8,50	18,98 ± 1,02	30,60 ± 7,95	18,95 ± 1,05
	4	12,70 ± 7,70	6,00 ± 0,58	18.10 ± 9.10	9,50 ± 0,75	29,55 ± 7,40	17,75 ± 0,94	29,60 ± 6,95	17,70 ± 0,95
	5	3,95 ± 3,40	1,26 ± 0,27	7,00 ± 4,10	3,60 ± 0,36	24,25 ± 6,00	15,73 ± 0,71	24.10 ± 5.90	15,70 ± 0,70

Tablo 8.6.Tek Değişkenli RMSE ve MAE

Hasta	Bölmek	5 dakika		10 dakika		30 dakika		60 dakika	
		RMSE	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**	**RMSE**	**MAE**
559	1	13.19 ± 7.66	10,85 ± 2,16	13,87 ± 7,98	11,49 ± 2,23	17,72 ± 10,54	14,27 ± 3,02	16,34 ± 9,48	13,36 ± 2,70
	2	33,45±19,9	26,04 ± 6,02	42,10 ± 24,14	33,91 ± 7,17	50,64 ± 28,27	41,41 ± 8,37	49,71 ± 28,37	40,28 ± 8,36
	3	10,96 ± 8,41	7,24 ± 2,36	11,60 ± 9,13	7,70 ± 2,49	12.01 ± 9.47	8,28 ± 2,50	15.20 ± 12.16	10,24 ± 3,22
	4	4,78 ± 2,74	3,88 ± 0,80	5,51 ± 3,13	4,52 ± 0,91	5,93 ± 3,30	5,01 ± 0,92	6,90 ± 3,53	6,04 ± 0,96
	5	6,13 ± 4,05	5,06 ± 1,00	8,79 ± 5,71	7,47 ± 1,33	9,41 ± 5,88	8,29 ± 1,28	9,98 ± 6,44	8,74 ± 1,38
575	1	27.71±18.1	21.13 ± 5.15	31,61 ± 20,13	24,69 ± 5,66	42,96 ± 26,94	33,99 ± 7,54	41.05 ± 25.79	32,46 ± 7,22
	2	24.82±10.4	23,66 ± 2,15	28,27 ± 12,07	26,88 ± 2,51	28,98 ± 12,24	27,61 ± 2,53	31,73 ± 12,85	30,52 ± 2,50
	3	12,85 ± 7,83	10,45 ± 2,15	13,86 ± 8,88	10,70 ± 2,53	14.12 ± 9.25	10,65 ± 2,66	14,56 ± 9,90	10,70 ± 2,83
	4	16.40± 9.79	13,23 ± 2,78	17,63 ± 10,05	14,62 ± 2,83	21,63 ± 11,97	18,38 ± 3,27	22.08 ± 12.33	18,89 ± 3,29
	5	12,63 ± 6,91	10,85 ± 1,85	11.07 ± 6.37	9,48 ± 1,64	13,92 ± 7,84	11,79 ± 2,60	20,65 ± 10,69	19.01 ± 2.79
570	1	11,55 ± 9,74	7,52 ± 2,52	13,94 ± 11,74	9,27 ± 2,99	13,84 ± 11,64	9,48 ± 2,89	18,58 ± 13,13	14,58 ± 3,31
	2	15.37± 7.48	13,58 ± 2,07	10,54 ± 5,15	9,44 ± 1,35	13,28 ± 6,16	11,99 ± 1,64	16,75 ± 8,04	14,92 ± 2,18
	3	5,63 ± 3,12	4,75 ± 0,87	8,66 ± 4,43	7,60 ± 1,19	8,91 ± 4,66	7,68 ± 1,30	7,79 ± 3,92	6,78 ± 1,10
	4	8,02 ± 4,94	6,26 ± 1,44	9,29 ± 5,94	6,92 ± 1,78	10,32 ± 6,47	7,99 ± 1,87	12,72 ± 7,38	10,55 ± 2,04
	5	16.83± 8.52	14,74 ± 2,33	18.21 ± 9.15	16.02 ± 2.49	19.87 ± 9.86	17,68 ± 2,60	21,35 ± 10,59	19.01 ± 2.79
591	1	14,63 ± 9,60	10,73 ± 2,86	14,49 ± 9,36	10,73 ± 2,79	15,65 ± 10,38	11.30 ± 3.11	16,46 ± 10,59	12.05 ± 3.22
	2	13,94 ± 7,18	12,25 ± 1,91	17,47 ± 8,52	15,37 ± 2,38	20,38 ± 9,50	18.30 ± 2.58	24.01 ± 10.90	21,57 ± 3,02
	3	16,26 ± 9,14	13,46 ± 2,62	18,27 ± 10,77	14,83 ± 3,07	21,32 ± 11,73	17,91 ± 3,32	21,33 ± 12,16	17,52 ± 3,49
	4	23,54±12,92	19,94 ± 3,59	25.81 ± 14.37	21,47 ± 4,11	27,44 ± 15,32	22,70 ± 4,42	30.17 ± 16.79	24,86 ± 4,91
	5	19.85± 9.39	17,60 ± 2,63	22,20 ± 10,44	19,73 ± 2,92	22.11 ± 10.52	19,72 ± 2,87	31,73 ± 14,50	28.18 ± 4.19

Çalışmada, hastaya özgü eğilimler de ortaya çıkmaktadır: 559 numaralı hasta her iki modelde de nispeten düşük hatalar sergileyerek daha tahmin edilebilir dinamikler gösterirken, 570 ve 591 numaralı hastalar daha büyük tutarsızlıklar göstererek daha yüksek değişkenlik veya daha gürültülü sinyaller sergilemektedir. Tüm hastalarda, çok değişkenli model, ek ilişkili özelliklerden yararlanarak hem doğruluğu (daha düşük RMSE) hem de güvenilirliği (daha düşük MAE) tek değişkenli temel modele göre iyileştirmektedir. Hem zaman serisi veri bölme yöntemi hem de kayan pencere yöntemi kullanılarak modelin çapraz doğrulanmasıyla, eksik özelliklerin yoğun bir şekilde ön işlenmesinin ve bu özellikler kullanılarak kan şekeri tahminlerinin yapılmasının faydalı olduğu sonucuna varabiliriz. Tablo 8.7 ve 8.8'te, önerilen tahmine dayalı hafif CNN modelinin, 30 dakikalık ve 60 dakikalık tahmin aralıklarında kan şekeri tahmini için mevcut en gelişmiş modellerle karşılaştırmalı analizini sunmaktadır.
Önerilen yöntemin performansı, hem 30 dakikalık hem de 60 dakikalık tahmin dilimlerinde diğer yaklaşımlarla karşılaştırılmıştır. 30 dakikada ortalama RMSE = 7,75 ± 0,38 mg/dL ve MAE = 13,99 ± 0,81 mg/dL, 60 dakikada ise RMSE = 31,07 ± 0,11 mg/dL ve MAE = 22,74 ± 0,31 mg/dL değerlerini vermektedir.

Şekil 8.1 ve 8.2'de sunulan Clarke Error Grid Analizi, kan şekeri tahminine yönelik tüm tahmin dilimlerinde önerilen modelin performansını göstermektedir. Her tahmin edilen değer, karşılık gelen referans değere karşı bir dağılım grafiğinde çizilmiştir ve Clarke Error Grid'i, daha önce açıkladığımız gibi tahminlerin klinik doğruluğunu ve güvenliğini yansıtan farklı bölgelere ayrılmıştır.

Sonuçlar, modelin daha kısa zaman dilimlerinde (5 ila 20 dakika) yüksek güvenilirlikle çalıştığını açıkça göstermektedir. Tahminlerin %98'inden fazlası klinik olarak kabul edilebilir A ve B bölgelerine düşmektedir. Bu, modelin kısa vadeli kan şekeri seviyesi tahminleri için uygunluğunu ve klinik karar verme süreçlerinde potansiyel gerçek dünya uygulanabilirliğini göstermektedir. Bununla birlikte, tahmin aralıkları 30 ve 60 dakikaya çıktıkça, tahminlerin C, D ve E bölgelerine doğru belirgin bir şekilde kaydığı görülmektedir. Bu durum, bu çalışmalar için değerlendirdiğimiz mevcut çalışmalarda da gözlemlenmiştir.

Tablo 8.7.Önerilen yöntemin 30-60 dk tahmin karşılaştırması

Çalışmalar		**Giriş Özellikleri**	**Hasta**	**30 dakikalık aralıkta**		**60 dakikalık aralıkta**	
				RMSE	**MAE**	**RMSE**	**MAE**
			559	18.773 ± 0.179	–	33.696 ± 0.365	–
Martinsson ve diğ, (2020)	LSTM	CGM	591	20.294 ± 0.107	–	32.083 ± 0.182	–
			575	21.675 ± 0.218	–	33.823 ± 0.268	–
			570	15.959 ± 0.374	–	28.468 ± 0.834	–
			559	16,86 ± 0,14	10,37 ± 0,10	33.11 ± 1.14	22,63 ± 0,48
Shuvo ve İslam, (2023)	DM- StackLSTM	CGM, FG, BI, Karbonhidratlar	591	17.01 ±0.11	11,78 ± 0,10	31,35 ±0,07	27,47 ± 0,24
						32,93 ± 0,34	22,90 ± 0,18
			570	13,23 ± 0,08	8,85 ± 0,09	27,62 ± 0,29	19,34 ± 0,18
			559	19,69 ± 0,19	13,51 ± 0,18	33,93 ± 0,48	23,82 ± 0,28
Khadem ve diğ, (2023)	Nested-DE	Kan şekeri, Fiziksel Enerji, İnsülin, Karbonhidratlar	591	23,08 ± 0,10	16,52 ± 0,07	35,68 ± 0,21	27,69 ± 0,12
						37,05 ± 0,62	26,29 ± 0,28
			570	18,57 ± 0,22	13.11 ± 0.12	31,61 ± 0,60	22,60 ± 0,54
			559	19,76 ± 6,91	13,88 ± 0,6	31.05 ± 6.25	22,75 ± 1,30
Önerilen Yöntem	**CNN**	**CGM, İnsülin,**	591	17,21 ± 6,02	14.00 ± 0.71	22,60 ± 1,26	22,60 ± 1,30
		Adımlar, Karbonhidratlar, Kalp Atış Hızı , GSR, Cilt Sıcaklığı	575	20,54 ± 6,68	14,20 ± 0,73	31,15 ± 6,25	22,60 ± 1,26
			570	16,57 ± 6,13	14.12± 0.75	31.05 ± 6.15	23,15 ± 1,32

Bu eğilim, daha uzun zaman dilimlerinde tahmin güveninde ve doğruluğunda bir düşüşe işaret etmekte olup, modelin uzun vadeli tahminler için daha az güvenilir olduğunu ve uzun vadeli kan şekeri tahminleri için yalnızca ona güvenilmemesi gerektiğini göstermektedir.

Tablo 8.8.Önerilen yöntemin 30-60 dk çalışmalarla karşılaştırılması

Çalışmak	**30 dakika Aralık**		**60 dakika Aralık**	
	RMSE	**MAE**	**RME**	**MAE**
Yang ve diğer, (2022)	18.930 ± 2.155	-	31.793 ± 3.431	-
Zhang ve diğ, (2021)	17.52	10.91	26.44	18.43
Li ve diğer, (2020)	19.28 ± 2.76	-	31,83 ± 3,49	-
Tena ve diğ, (2021)	19,94 ± 2,19	14,37 ± 1,48	34,99 ± 5,28	26.01 ± 3.63
Önerilen Yöntem	**17,75 ± 0,38**	**13,99 ± 0,11**	**31.07 ± 0.11**	**22,74 ± 0,31**

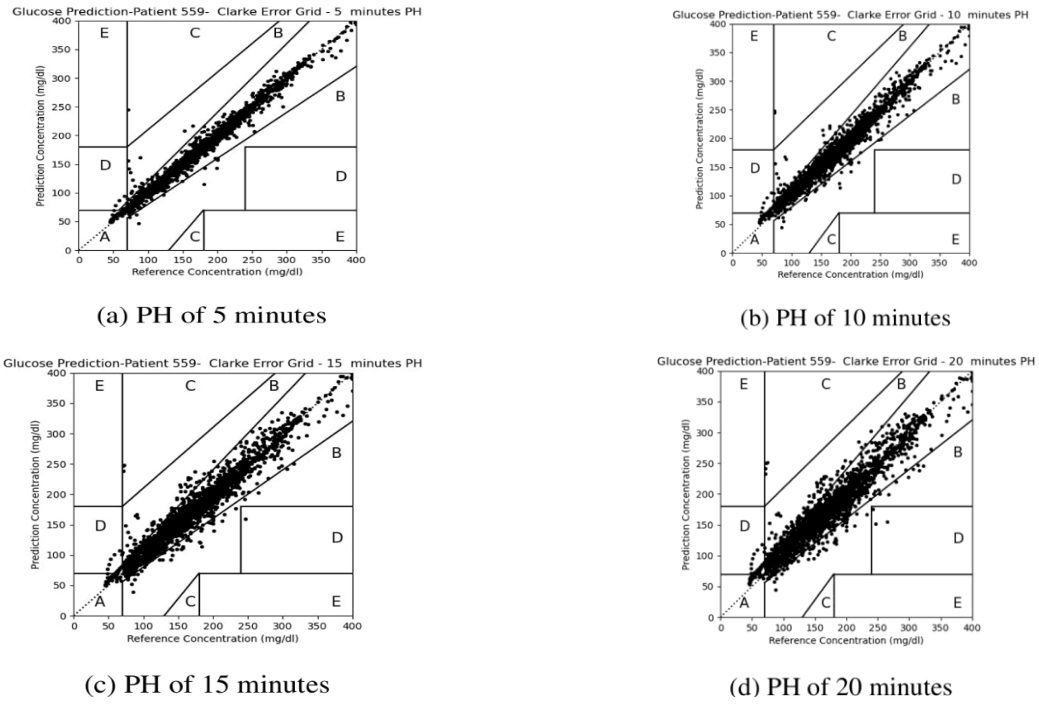

(a) PH of 5 minutes

(b) PH of 10 minutes

(c) PH of 15 minutes

(d) PH of 20 minutes

Şekil 8.1.Hasta 559 için farklı aralıklarda Clarke Error Grid

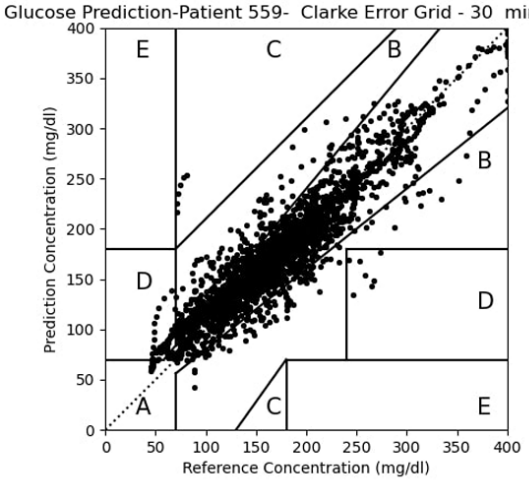

(e) PH of 30 minutes

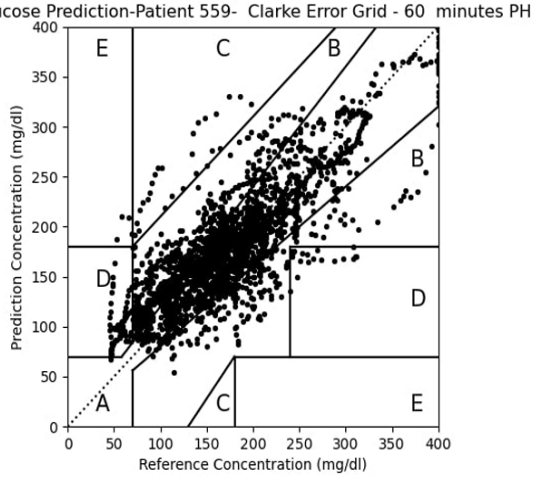

(f) PH of 60 minutes

Şekil 8.1.(Devam)Hasta 559 için farklı aralıklarda Clarke Error Grid

Tablo 8.9'da 5 ila 60 dakika arasında değişen farklı tahmin aralıkları (PH) boyunca hasta 570 için Clarke Error Grid analizini sunmaktadır. Her PH için tablo, A'dan E'ye kadar olan bölgelere düşen tahmin edilen kan şekeri değerlerinin sayısını ve yüzdesini göstermektedir. A Bölgesi klinik olarak doğru tahminleri, B Bölgesi zararsız hataları ve C, D ve E Bölgeleri giderek daha tehlikeli hataları temsil etmektedir. Sonuçlar, tahminlerin çoğunun tüm zaman dilimlerinde A ve B Bölgelerinde kaldığını, tahmin zaman dilimi uzadıkça A Bölgesinde kademeli bir azalma ve buna karşılık B Bölgesinde bir artış olduğunu göstermektedir.

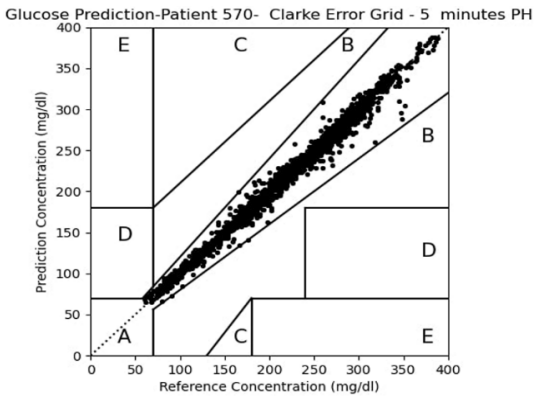

(a) PH of 5 minutes

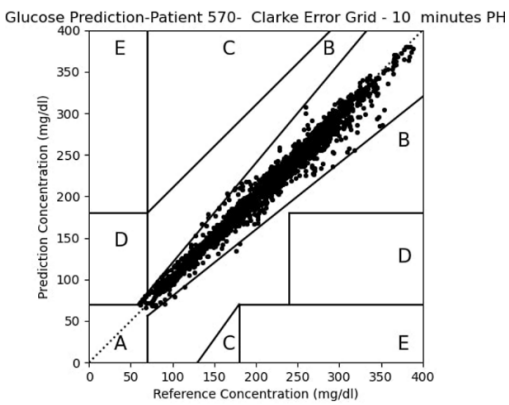

(b) PH of 10 minutes

Şekil 8.2.Hasta 570 için farklı aralıklarda Clarke Error Grid

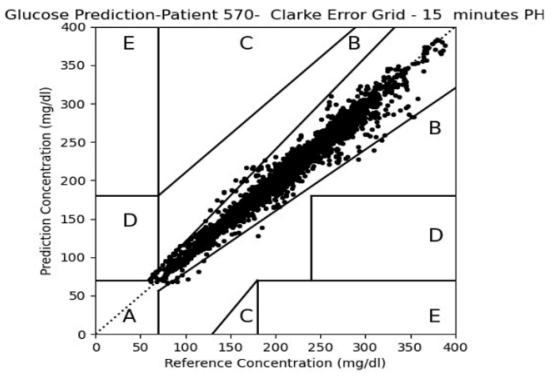

(c) PH of 15 minutes

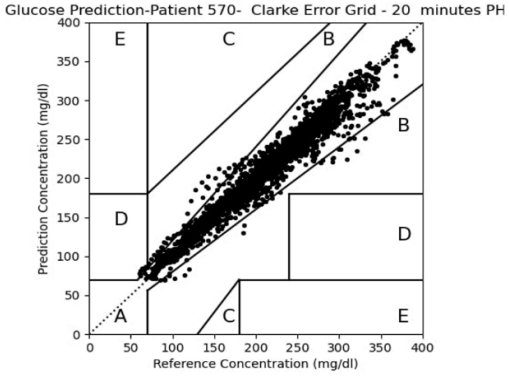

(d) PH of 20 minutes

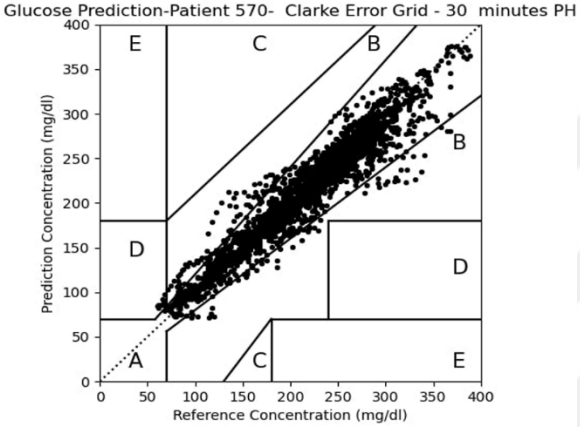

(e) PH of 30 minutes

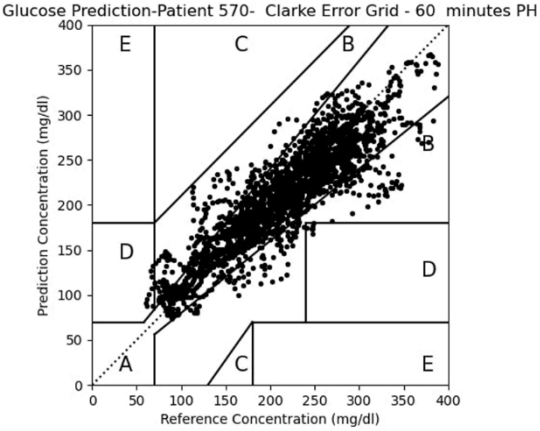

(f) PH of 60 minutes

Şekil 8.2.(Devam)Hasta 570 için farklı aralıklarda Clarke Error Grid

Şekil 8.3, bireysel özelliklerin farklı girdi zaman serisi grupları ve çeşitli tahmin zaman dilimi boyunca modelin tahminlerini nasıl etkilediğini göstermektedir. Y ekseni tüm girdi özelliklerini listelerken, X-ekseni temel model tahminini temsil eder ve $E[f(x)]$. her özelliğin katkısı ayrı renk kodlarına sahiptir. Kırmızı, tahmine olumlu bir etkiyi gösterirken, mavi ise olumsuz bir katkıyı gösterir. Şekil 8.3-a, 8.3-b ve 8.3-c alt şekillerinde gözlemlendiği gibi, kan şekeri özelliği nihai tahmine oldukça olumlu bir katkıda bulunma eğilimindedir. Tersine, şekil 8.3-d alt şeklinde, kan şekeri yüksek bir Shapley büyüklüğüne sahip olmasına rağmen çıktıyı olumsuz etkiler. Bu analiz, zaman serisi tahmin görevlerinde, özellikle çok değişkenli modellerde, her özelliğin katkısının önemi ve yönünün farklı girdi örnekleri arasında önemli ölçüde değişebileceğini göstermektedir. Bu nedenle, t anında model çıktısını etkileyen özellikteki herhangi bir değişiklik, değiştirilmiş değerler bir sonraki tahmin için girdi olarak alınırsa, bir sonraki

tahmini kökten değiştirebilir.

Tablo 8.9.Hasta 570: Aralık başına Clarke Error Grid

PH (dk)	A Bölgesi (%)	B Bölgesi (%)	C Bölgesi (%)	D Bölgesi (%)	E Bölgesi (%)
5	2699 (99.1%)	24 (0.9%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
10	2623 (96.3%)	89 (3.3%)	0 (0.0%)	11 (0.4%)	0 (0.0%)
15	2627 (96,5%)	86 (3.2%)	0 (0.0%)	10 (0.4%)	0 (0.0%)
20	2622 (96.3%)	93 (3.4%)	0 (0.0%)	8 (0.3%)	0 (0.0%)
25	2535 (93.1%)	177 (6,5%)	0 (0.0%)	11 (0.4%)	0 (0.0%)
30	2516 (92.4%)	196 (7.2%)	0 (0.0%)	11 (0.4%)	0 (0.0%)
35	2438 (89.5%)	274 (10.1%)	0 (0.0%)	11 (0.4%)	0 (0.0%)
40	2392 (87.8%)	320 (11.8%)	0 (0.0%)	11 (0.4%)	0 (0.0%)
45	2342 (86.0%)	369 (13.6%)	0 (0.0%)	12 (0.4%)	0 (0.0%)
50	2275 (83.5%)	435 (16.0%)	0 (0.0%)	13 (0.5%)	0 (0.0%)
55	2180 (80.1%)	529 (19.4%)	0 (0.0%)	14 (0.5%)	0 (0.0%)
60	2097 (77.0%)	608 (22.3%)	1 (0.0%)	17 (0.6%)	0 (0.0%)



Şekil 8.3. 559 hastanin Shapley Açıklama (SHAP) değerleri

8.1. Tahmin Edici ve Önleyici Modellerin Entegrasyonu

Tahmin modeli oluşturulduktan sonra, Aktör-Eleştirmen, takviyeli öğrenme çerçevesine yerleştirilir. Bu entegrasyonun amacı, takviyeli öğrenme ajanının, kan şekeri dinamiklerini istikrarlı tutmak için hangi girdi özelliklerinin ayarlanması gerektiğini belirlemesini sağlamaktır. Daha önce tartışıldığı üzere, takviyeli öğrenme ajanının görevi, PGn 10 dakikalık bir tahmin aralığında (PH) tahmin edilen kan şekeri seviyesini artırmak veya azaltmak için seçilen özellik vektörü bileşenlerini değiştiren optimal bir politika öğrenmektir.

Batch (Feature Adjustments)	PG_n	PG_a	PG_r	Optimum Feature	Target Hit
$\begin{bmatrix} 0 & 6 & 0 & 0 & 91 & 62 & 204 \\ 0 & 6 & 0 & 0 & 91 & 70 & 200 \\ 0 & 6 & 0 & 0 & 90 & 66 & 194 \\ 0 & 6 & 9 & 0 & 91 & 82 & 168 \\ 0 & 6 & 11 & 0 & 88 & 73 & 141 \\ 0 & 5 & 13 & 0 & 87 & 72 & 129 \\ 0 & 5 & 8 & 0 & 86 & 71 & 107 \\ 0 & 40 & 2 & 0 & 86 & 70 & 101 \\ 0 & 39 & 0 & 0 & 87 & 62 & 121 \\ 0 & 37 & 0 & 0 & 88 & 57 & 143 \\ 0 & 36 & 0 & 0 & 89 & 56 & 156 \\ 0 & 35 & 0 & 0 & 89 & 58 & 161 \end{bmatrix}$	164.88	162	158.85	$\begin{bmatrix} 0.1 \\ 35.37 \\ 0.0 \\ 0.0 \\ 89.06 \\ 58.0 \end{bmatrix}$	0%
$\begin{bmatrix} 0 & 8 & 0 & 14 & 89 & 69 & 96 \\ 0 & 7 & 0 & 17 & 89 & 67 & 99 \\ 0 & 7 & 2 & 14 & 89 & 72 & 101 \\ 0 & 7 & 1 & 13 & 87 & 78 & 104 \\ 0 & 7 & 8 & 6 & 87 & 83 & 104 \\ 0 & 6 & 8 & 6 & 87 & 83 & 102 \\ 0 & 6 & 8 & 6 & 87 & 83 & 97 \\ 0 & 6 & 8 & 6 & 87 & 83 & 95 \\ 0 & 6 & 1 & 0 & 83 & 74 & 94 \\ 0 & 28 & 1 & 0 & 83 & 74 & 92 \\ 0 & 27 & 1 & 0 & 83 & 74 & 86 \end{bmatrix}$	90.35	101	89.19	$\begin{bmatrix} 0 \\ 27.48 \\ 1 \\ 0 \\ 82.94 \\ 74 \end{bmatrix}$	100%
$\begin{bmatrix} 0 & 8 & 0 & 0 & 86 & 74 & 92 \\ 0 & 8 & 1 & 0 & 85 & 67 & 92 \\ 0 & 7 & 0 & 0 & 85 & 59 & 93 \\ 0 & 7 & 0 & 0 & 86 & 58 & 86 \\ 2 & 7 & 0 & 0 & 87 & 59 & 83 \\ 2 & 7 & 0 & 0 & 88 & 61 & 86 \\ 2 & 7 & 0 & 0 & 88 & 69 & 93 \\ 1 & 6 & 0 & 1 & 88 & 63 & 103 \\ 1 & 6 & 0 & 4 & 88 & 60 & 108 \\ 1 & 6 & 0 & 0 & 89 & 60 & 113 \\ 1 & 6 & 0 & 0 & 90 & 61 & 118 \\ 1 & 6 & 0 & 0 & 90 & 62 & 122 \end{bmatrix}$	122.10	116	119.66	$\begin{bmatrix} 1.5 \\ 5.78 \\ 0.0 \\ 0.02 \\ 89.6 \\ 62.0 \end{bmatrix}$	25%
$\begin{bmatrix} 0.34 & 23.41 & 17 & 22.1 & 86 & 82 & 85 \\ 0.33 & 22.75 & 12 & 20.94 & 85.28 & 79 & 78 \\ 0.32 & 22.11 & 2 & 21.06 & 85.1 & 74 & 72 \\ 0.32 & 57.47 & 7 & 17.82 & 85.82 & 80 & 67 \\ 0.30 & 55.85 & 0 & 23.92 & 86.54 & 66 & 68 \\ 0.29 & 54.25 & 0 & 26.28 & 86.9 & 67 & 65 \\ 0.29 & 52.7 & 0 & 25.5 & 87.62 & 65 & 64 \\ 0.28 & 51.2 & 0 & 24.54 & 87.26 & 65 & 63 \\ 0.28 & 49.74 & 0 & 23.5 & 87.8 & 66 & 62 \\ 0.27 & 48.34 & 1 & 22.78 & 87.8 & 66 & 62 \\ 0.26 & 46.96 & 0 & 21.16 & 87.98 & 64 & 64 \\ 0.25 & 45.61 & 3 & 20.14 & 87.8 & 64 & 66 \end{bmatrix}$	75.28 34	72	83.19	$\begin{bmatrix} 1.02 \\ 42.4 \\ 2 \\ 28.16 \\ 64.0 \\ 62.0 \end{bmatrix}$	18%

Şekil 8.4.RL ajanı: Özellik ayarları ve kan şekeri karşılaştırması

Amaç, bu tahmin edilen değeri istenen hedef seviyeye doğru düzenlemektir. PGr; bu seviye bundan sonra "düzenlenmiş kan şekeri" olarak adlandırılacaktır. Karşılaştırma için, karşılık gelen gerçek kan şekeri ölçümü (PGa) ile gösterilir. Bu deneyler için, bu yapılandırma, hasta 591'in veri setinin neredeyse tamamını kapsadığı için Zaman Serisi Bölme 5'e karşılık gelen tahmin modeli kullanılmıştır. Her bölüm, test setinden rastgele seçilen 12 × 6'lık bir toplu pencere ile başlatılır. Takviyeli öğrenme modeli, ajanın tahmin edilen sonuç üzerinde hiçbir etkisi olmayan eylemleri keşfetmek için zaman kaybetmediği anlamına gelen Hedefli Keşif özelliğine sahip olduğundan, Biriken ödül, epsilon-greedy probleminde alışık olduğundan çok daha doğrusal görünmekte çünkü keşif pişmanlığı (Exploration Regret) çok yüksek değildir. Hipoglisemi, hiperglisemi ve normal kan şekeri seviyeleri de dahil olmak üzere birden fazla durumdaki RL performansının ayrıntılı bir özeti Şekil 8.4'te sunulmuştur.

Deneyler sırasında, tahmin edilen kan şekeri seviyesi tanımlanan aralığın çok dışında olduğunda, takviyeli öğrenme ajanının sıklıkla yerel minimuma takıldığı gözlemlenmiştir. Bu gibi durumlarda, aynı eylemi tekrarlamış ve kan şekeri seviyesinde hedef aralığa ulaşmak için yetersiz kalmış ve yalnızca küçük iyileştirmelerle sonuçlanmıştır. Bu davranış beklenen bir süreçti, çünkü bir insanın aşırı bir kan şekeri değerini (örneğin, 300 mg/dL) sadece 10 dakika içinde 80-120 mg/dL aralığına düşürmesi pratikte imkansızdır. Bunun yerine, düzenleme sağlamak kademeli ayarlamalar gerektirir.

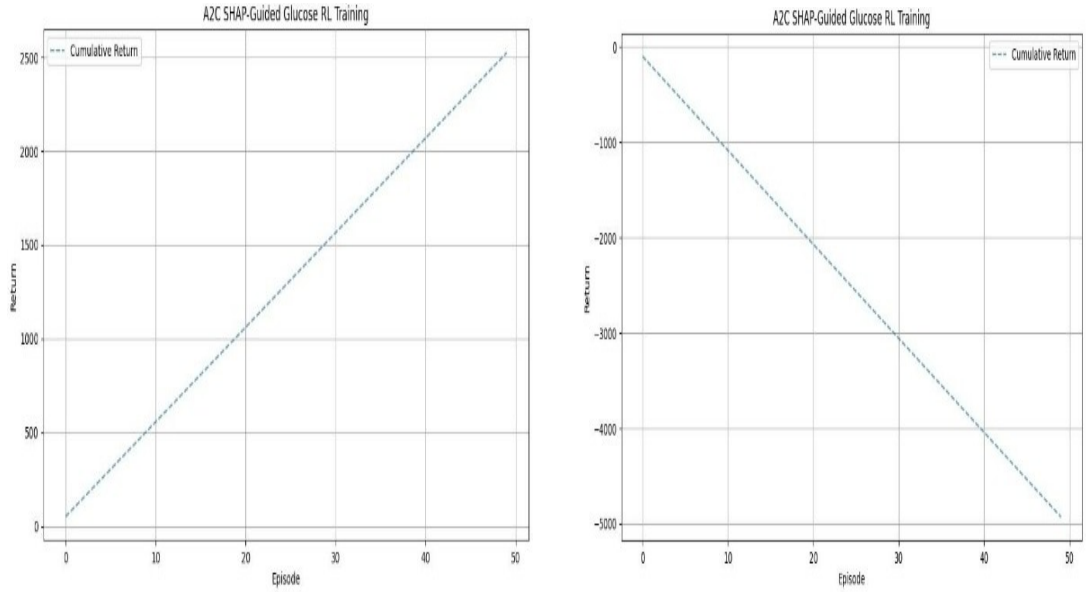

Şekil 8.5.Ajan davranışı: pozitif ve negatif ödüllerin grafiği

Takviyeli öğrenme modelinin önerdiği optimal özellik vektörünü takip ederek ve buna göre eylemler uygulayarak, kan şekeri değeri kademeli olarak güvenli bölgeye yaklaşabilir. Şekil 8.4'te bildirilen başarılı hedef isabet yüzdesi, ajanın kan şekeri seviyelerini istenen aralığa düzenleyebildiği durumların oranını yansıtmaktadır. %0 hedef isabet durumunda, Şekil 8.5'te gösterildiği gibi iki farklı senaryo gözlemlendi. İlk senaryoda, ajan kan şekeri değerini hedef aralığa tam olarak getirememiş ancak onu daha da yaklaştırmayı başarmıştır. Bu da pozitif bir kümülatif ödülle yansıtıldı. İkinci senaryoda, ajan sadece aralığa ulaşamamakla kalmayıp, aynı zamanda kan şekeri değerini tekrar tekrar daha da uzaklaştırmıştır. Bu da negatif kümülatif ödüllerle sonuçlandı. Tahmin edilen kan şekeri değeri zaten hedef aralıkta olduğunda, ajan değerleri aralığın dışına asla itmeyen değişiklikler uygulayarak bu durumu koruma eğilimindeydi. Sonuç olarak, bu tür durumlardaki tüm girişimler başarılı kabul edilmiştir. Şekil 8.4 ayrıca, tablonun üçüncü satırında gösterildiği gibi, tahmin edilen kan şekeri değerinin 122,10 mg/dL (hiperglisemi) olduğu durum için %25'lik bir hedef isabet oranını da göstermektedir. Burada, ajan, tahmini tanımlanan hedef aralığa başarıyla düşüren optimal bir girdi yapılandırmasını girişimlerin %25'inde belirledi. Son durumda, RL ajanı, tahmin edilen 10 dakikalık kan şekeri değeri 75,28 mg/dL olduğunda hipoglisemiyi düzeltmeye çalıştı. En uygun özellik kombinasyonunu bularak, denemelerin %18'inde tahmini 83,19 mg/dL'ye yükseltmiştir. Performans değerlendirmesi, her bölüm için adım başına başarılı deneme sayısına dayanmakta olup, 50 bölüm × 20 adıma karşılık gelmektedir.

Tablo 8.10, model tarafından en yüksek SHAP atıf puanlarına atanan en önemli girdi özelliklerini özetlemekte ve kan şekeri regülasyonu bağlamında beklenen fizyolojik yorumlarını ortaya koymaktadır. Listelenen özellikler, örneğin son kan şekeri değerleri, kan şekeri değişim hızı, vücuttaki insülin miktarı, karbonhidrat alımı ve fiziksel aktivite, glisemik dinamikleri doğrudan etkilediği bilinen değişkenlerdir. SHAP, her bir özelliğin CNN modelinin tahminine nasıl katkıda bulunduğunu nicemlendirirken, tablo bu özelliklerin kan şekerini fizyolojik olarak nasıl etkilediğine dair genel olarak anlaşılan kısa bir açıklama sunarak modelin öğrendiği atıfları bağlamlandırmaya yardımcı olur.

Tablo 8.10.Önemli SHAP özellikleri ve beklenen fizyolojik etkiler

Özellikler	Fizyolojik Etki
Önceki kan şekeri	CGM'nin zamansal dinamikleri nedeniyle kısa vadeli kan şekeri seviyeleri, son sensör değerlerine büyük ölçüde bağlıdır.
Vücutta insülin (IOB)	Dolaşımdaki aktif insülin, kan şekeri alımını artırarak ve karaciğerden salgılanan kan şekeri miktarını baskılayarak kan şekerini düşürür.
Karbonhidrat alımı	Karbonhidratlar, emilim hızı ve glisemik yüke bağlı olarak kan şekeri konsantrasyonunu artırır.
Adımlar / fiziksel aktivite	Fiziksel aktivite, iskelet kasının kan şekeri alımını artırır ve kan şekeri seviyelerini anlık olarak düşürebilir.
Kan şekeri eğimi	Pozitif bir eğim genellikle yemek sonrası kan şekeri artışını gösterirken, negatif bir eğim insülin etkisini veya fiziksel aktiviteyi yansıtır.
Kalp atış hızı	Kalp atış hızındaki artış, genellikle fiziksel aktiviteyi, stres yanıtını veya hormonel değişiklikleri yansıtarak kan şekeri seviyelerini dolaylı olarak etkileyebilir.

9.SONUÇLAR VE ÖNERİLER

Bu çalışmada, seçilen girdi özelliklerini modüle ederek klinik olarak tanımlanmış sağlıklı bir aralıkta tahmin edilen kan şekeri seviyelerini düzenlemek üzere tasarlanmış, açıklanabilir ve yönlendirilmiş bir takviyeli öğrenme çerçevesini önerilmiştir. Temel tahmin modeli, kan şekeri seviyelerini tahmin etmede yüksek doğruluk göstererek, 30 dakikalık tahmin zaman diliminde sırasıyla 17,75 ± 0,38 mg/dL ve 13,99 ± 0,11 mg/dL, 60 dakikalık zaman diliminde ise sırasıyla 31,07 ± 0,11 mg/dL ve 22,74 ± 0,31 mg/dL ortalama RMSE ve MAE değerlerine ulaştığı gözlemlenmiştir. Bu sonuçlar, Tablo 8.8'de özetlendiği gibi, mevcut en gelişmiş yöntemler ve yaklaşımlara kıyasla kabul edilebilir bir performans göstermektedir. Bu çalışmanın amacı, en yüksek tahmin performansını elde etmek değil, aksine değerlendirme metrikleri ve Clarke Error Grid analiziyle kanıtlandığı gibi güvenilir tahminler sağlayan basit bir model geliştirmektir. Takviyeli öğrenme ajanı, tahmin modelinden türetilen Shapley değerlerine göre, giriş özellik vektörünün seçilen bileşenlerini yinelemeli olarak ayarlamak üzere eğitilmiştir. Bu yaklaşım, tahmin edilen kan şekeri değerini (PGn) 10 dakikalık bir tahmin aralığı içinde hedef aralığa (PGr) doğru yönlendirmektedir. Birden fazla giriş grubu üzerinde yapılan analiz, ajanın müdahale stratejisini, ilk tahminin hedef aralığa yakınlığına göre dinamik olarak uyarlayabildiğini göstermiştir. Özellikle, ajan hipoglisemik tahminleri etkili bir şekilde azaltarak 8 mg/dL'ye kadar artırabildi ve hiperglisemik değerleri 6 mg/dL'ye kadar düşürebildi. Bu da geniş bir glisemik sapma yelpazesini yönetme potansiyelini vurgulamaktadır. Bu sonuçlara rağmen, önerilen çerçeve henüz klinik uygulamaya hazır değildir. Veri ön işleme sırasında yapılan kısıtlamalar neticesinde bazı tahmini yaklaşımları içerdiğinden önyargılara yol açabilecek faktörlerin bulunmaktadır. Örneğin, takviyeli öğrenme ajanının doğrudan gözlemlenen kan şekeri seviyeleri yerine tahmin edilen değerler üzerinde işlem yapması, tekrarlayan tahmin belirsizliğine yol açması yer almaktadır.

Ayrıca, test seti tek bir kohorttan/veri seti gruplarından yalnızca dört hastayı içermektedir. Elde edilen bulgular farklı demografik özellikler, tedaviler, sensörler veya bölgeler arasında genelleştirilemeyebilir. Bireysel değişkenliği hesaba katmak için subjektif duyarlı doğrulama yapılmıştır. Bu bulgular, kişiselleştirilmiş kan şekeri yönetimini sağlamak için takviyeli öğrenmeyi açıklanabilir tahmin modelleriyle birleştirmenin

potansiyelini vurgulamaktadır. Gelecekteki çalışmalar, birincil tahmin modelinin girdi olarak kan şekeri değerlerine doğrudan erişim olmadan eğitildiği büyük özel veri kümeleri toplayarak tamamen sanal bir kan şekeri düzenleme sistemi geliştirmeye odaklanacaktır. Bu yaklaşım, takviyeli öğrenme ajanını, başlangıçta elverişsiz koşullar altında bile, tahmin edilen kan şekeri seviyelerini hedef aralığına getirebilecek optimal müdahale ilkeleri belirlemede zorlayacaktır.

KAYNAKLAR

Amuji, H. O., Onwuegbuchunam, D. E., Okeke, K. O., Ojutalayo, J. F., Nwachi, C. C. ve Mustapha, A. M. (2024). Shapley Value Cost Allocation Model For Multimodal Freight Transport *Carriers. Tt, 2024* (1), 53–63.

Annuzzi, G., Apicella, P., Arpaia, L., Bozzetto, S., Criscuolo, E., De Benedetto, M., Pesola, M. ve Prevete, R. (2024). Exploring Nutritional Influence On Blood Glucose Forecasting For Type 1 Diabetes Using Explainable AI. *IEEE J. Biomed. Health Inform*., *28* (5), 3123–3133.

Adjevi, A., & Solak, S. (2025). ConvLSTM-Based Time Series Prediction of Blood Glucose Levels Using SimGlucose Simulation Data. *International Journal of Advanced Natural Sciences and Engineering Researches*, *9(*11).

Asad, M., Qamar, U. ve Abbas, M. (2021). Blood Glucose Level Prediction Of Diabetic Type 1 Patients Using Nonlinear Autoregressive Neural Networks. *J. Healthc. Eng.,* 2021, 1–7.

Bolie, V. W. (1961). Coefficients Of Normal Blood Glucose Regulation. *J. Appl. Physiol., 16* (5), 783–788.

Butt, H., Khosa, I. ve Iftikhar, M. A. (2023). Feature Transformation For Efficient Blood Glucose Prediction In Type 1 Diabetes Mellitus Patients. *Diagnostics*, *13* (3), 340.

Cuthbertson, C. C., Moore, C. C., Sotres-Alvarez, D., Heiss, G., Isasi, C. R., Rahmani, Y. M., Carlson, J. A., Gallo, L. C., Llabre, M. M., Garcia-Bedoya, O. L., Farelo, D. G. ve Evenson, K. R. (2022). Associations Of Steps Per Day And Step Intensity With The Risk Of Diabetes: The Hispanic Community Health Study / Study Of Latinos (HCHS/SOL). *Int. J. Behav. Nutr. Phys. Act*., *19* (1), 46.

D'Antoni, F., Merone, M., Piemonte, V., Iannello, G. ve Sicilia, R. (2022). Prediction Of Glucose Concentration In Children With Type 1 Diabetes Using Neural Networks: An Edge Computing Application. *Bioengineering, 9* (5), 183.

Domanski, P., Ray, A., Firouzi, F., Lafata, K., Chakrabarty, K. ve Pflüger, D. (2023). Blood Glucose Prediction For Type-1 Diabetics Using Deep Reinforcement Learning. 2023 *IEEE International Conference On Digital Health (ICDH),* 339–347.

Donelli, M., Espa, G., Feraco, P. ve Manekiya, M. (2021). Wearable Non-Invasive Blood Glucose Monitor System Based On Galvanic Skin Resistance Measurement. *Electron. Lett*., *57* (24), 901–902.

Dubaj, M., Bigosiński, K., Caliński, M., Raniewicz, M. ve Porada, D. (2025). Small Steps, Big Changes: The Impact Of Daily Step Counts On Diabetes Prevention And Management — A Systematic Review. *Clin. Diabetol*., *14* (1), 56–64.

Duckworth, C., Guy, M. J., Kumaran, A., O'Kane, A. A., Ayobi, A., Chapman, A.,

Eckstein, M. L., Brockfeld, A., Haupt, S., Schierbauer, J. R., Zimmer, R. T., Wachsmuth, N. B., Zunner, B. E. M., Zimmermann, P., Erlmann, M., Obermayer-Pietsch, B., Aberer, F. ve Moser, O. (2022). Acute Changes In Heart Rate Variability To Glucose And Fructose Supplementation In Healthy Individuals: A Double-Blind Randomized Crossover Placebo-Controlled Trial. *Biology (Basel), 11* (2), 338.

Ejiyi, C. J., Qin, Z., Amos, J., Ejiyi, M. B., Nnani, A., Ejiyi, T. U., Agbesi, V. K., Diokpo, C. ve Okpara, C. (2023). A Robust Predictive Diagnosis Model For Diabetes Mellitus Using Shapley-Incorporated Machine Learning Algorithms. *Healthcare Analytics, 3*, 100166.

Feretzakis, G., Sakagianni, A., Anastasiou, A., Kapogianni, I., Bazakidou, E., Koufopoulos, P., Koumpouros, Y., Koufopoulou, C., Kaldis, V. ve Verykios, V. S. (2024). Integrating Shapley Values Into Machine Learning Techniques For Enhanced Predictions Of Hospital Admissions. *Appl. Sci. (Basel)*, *14* (13), 5925.

Hettiarachchi, C., Malagutti, N., Nolan, C. J., Suominen, H. ve Easkalaki, E. (2024). G2P2C — A Modular Reinforcement Learning Algorithm For Glucose Control By Glucose Prediction And Planning In Type 1 Diabetes. Biomed. Signal Process. *Control*, *90*, 105839.

Hossain, M. J., Al-Mamun, M. ve Islam, M. R. (2024). Diabetes Mellitus, The Fastest Growing Global Public Health Concern: Early Detection Should Be Focused. *Health Sci. Rep., 7* (3).

Hovorka, R., Canonico, V., Chassin, L. J., Haueter, U., Massi-Benedetti, M., Fed Erici, M. O., Pieber, T. R., Schaller, H. C., Schaupp, L., Vering, T. ve Wilinska, M. E. (2004). Nonlinear Model Predictive Control Of Glucose Concentration In Subjects With Type 1 Diabetes. *Physiol. Meas*., *25* (4), 905–920.

Hussein, E. E., Zerouali, B., Bailek, N., Derdour, A., Ghoneim, S. S. M., Santos, C. A. G. ve Hashim, M. A. (2025). Harnessing Explainable AI For Sustainable Agriculture: SHAP-Based Feature Selection In Multi-Model Evaluation Of Irrigation Water Quality Indices. *Water*, *17* (1).

Jaloli, M. ve Cescon, M. (2023). Long-Term Prediction Of Blood Glucose Levels In Type 1 Diabetes Using A CNN-LSTM-Based Deep Neural Network. *J. Diabetes Sci. Technol*., *17* (6), 1590–1601.

Kajisa, T., Kuroi, T., Hara, H. ve Sakai, T. (2024). Correlation Analysis Of Heart Rate Variations And Glucose Fluctuations During Sleep. *Sleep Med*., *113*, 180–187.

Kenny, G. P., Sigal, R. J. ve McGinn, R. (2016). Body Temperature Regulation In Diabetes. *Temperature (Austin), 3* (1), 119–145.

Khadem, H., Nemat, H., Elliott, J. ve Benaissa, M. (2023). Blood Glucose Level Time

Series Forecasting: Nested Deep Ensemble Learning Lag Fusion. *Bioengineering*, *10* (4), 487.

Kim, T., Suk, H. ve Kim, S. (2024). Offline Reinforcement Learning Methods For Real-World Problems. Advances In Computers, *Elsevier*, 285-315.

Li, K., Liu, C., Zhu, T., Herrero, P. ve Georgiou, P. (2020). GluNet: A Deep Learning Framework For Accurate Glucose Forecasting. *IEEE Journal Of Biomedical And Health Informatics*, *24* (2), 414–423.

Li, M., Sun, H., Huang, Y. ve Chen, H. (2024). Shapley Value: From Cooperative Game To Explainable Artificial Intelligence. *Auton. Intell. Syst*., *4* (1).

Ma, M. ve Li, J. (2022). Dynamics Of A Glucose-Insulin Model. *J. Biol. Dyn*., *16* (1), 733–745.

Marling, C. ve Bunescu, R. (2020). The OhioT1DM Dataset For Blood Glucose Level Prediction: Update 2020. *CEUR Workshop Proceedings*, *2675*, 71–74.

Martínez-Delgado, L., Munoz-Organero, M. ve Queipo-Alvarez, P. (2021). Using Absorption Models For Insulin And Carbohydrates And Deep Leaning To Improve Glucose Level Predictions. *Sensors (Basel)*, *21* (16), 5273.

Marshall, P. ve Boniface, M. (2024). Explainable Machine Learning For Real-Time Hypoglycemia And Hyperglycemia Prediction And Personalized Control Recommendations. *J. Diabetes Sci. Technol*., *18* (1), 113–123.

Martinsson, J., Schliep, A., Eliasson, B. ve Mogren, O. (2020). Blood Glucose Prediction With Variance Estimation Using Recurrent Neural Networks. *J. Healthc. Inform.* Res., *4* (1), 1–18.

Mathew, T. K., Zubair, M. ve Tadi, P. (2024). Blood Glucose Monitoring. Treasure Island (FL): *StatPearls Publishing*.

Naeem, M., Rizvi, S. T. H. ve Coronato, A. (2020). A Gentle Introduction To Reinforcement Learning And Its Application In Different Fields. *IEEE Access*, 8, 209320–209344.

Nohara, Y., Matsumoto, K., Soejima, H. ve Nakashima, N. (2022). Explanation Of Machine Learning Models Using Shapley Additive Explanation And Application For Real Data In Hospital. *Computer Methods And Programs In Biomedicine*, *214*, 106584.

Qing, Y., Liu, S., Song, J., Wang, H. ve Song, M. (2022). A Survey On Explainable Reinforcement Learning: Concepts, Algorithms, Challenges. *ArXiv Preprint* ArXiv:2211.06665.

Remman, S. B., Strümke, I. ve Lekkas, A. M. (2022). Causal Versus Marginal Shapley Values For Robotic Lever Manipulation Controlled Using Deep Reinforcement Learning. 2022 *American Control Conference* (ACC), 2683–2690.

Ruggeri, F., Emanuelsson, W., Terra, A., Inam, R. ve Johansson, K. H. (2024). Rollout-Based Shapley Values For Explainable Cooperative Multi-Agent Reinforcement Learning. 2024 *IEEE International Conference On Machine Learning For Communication And Networking* (ICMLCN), 227–233.

Saber, S. ve Alalyani, A. (2022). Stability Analysis And Numerical Simulations Of IVGTT Glucose-Insulin Interaction Models With Two Time Delays. *Mathematical Modelling And Analysis, 27* (3), 383–407.

Shuvo, M. M. H. ve Islam, S. K. (2023). Deep Multitask Learning By Stacked Long Short-Term Memory For Predicting Personalized Blood Glucose Concentration. *IEEE Journal Of Biomedical And Health Informatics*, *27* (3), 1612–1623.

Srinivasan, A. (2023). Reinforcement Learning: Advancements, Limitations, And Real-World Applications. *International Journal Of Scientific Research In Engineering And Management*, *07* (08).

Şentürk, Ü., Adıgüzel, G. ve Polat, K. (2025). Hybrid Mamba-MoE Model For Non-Invasive Blood Glucose Prediction. Computers And Electrical Engineering, *127*, 110549.

Tena, F., Garnica, O., Lanchares, J. ve Hidalgo, J. I. (2021). Ensemble Models Of Cutting-Edge Deep Neural Networks For Blood Glucose Prediction In Patients With Diabetes. *Sensors (Basel)*, *21* (21), 7090.

Tian, T., Aaron, R. E., Kohn, M. A. ve Klonoff, D. C. (2024). The Need For A Modern Error Grid For Clinical Accuracy Of Blood Glucose Monitors And Continuous Glucose Monitors. *J. Diabetes Sci. Technol*., *18* (1), 3–9.

Viroonluecha, P., Egea-Lopez, E. ve Santa, J. (2023). Evaluation Of Offline Reinforcement Learning For Blood Glucose Level Control In Type 1 Diabetes. *IEEE Access*, *11*, 104643–104655.

Wadoux, A. M. J.-C., Saby, N. P. A. ve Martin, M. P. (2023). Shapley Values Reveal The Drivers Of Soil Organic Carbon Stock Prediction. *SOIL*, 9 (1), 21–38.

Wang, S., Li, T., Ju, J., Wang, Y., Fu, J., Sun, Z., Zhang, M., Hou, J., Zhang, Z., Zhao, J., Guan, Y., Zhang, W., Chen, J., Shen, Z., Wei, R. ve Deng, H. (2024). Transplantation Of Chemically Induced Pluripotent Stem-Cell-Derived Islets Under Abdominal Anterior Rectus Sheath In A Type 1 Diabetes Patient. *Cell*.

Wang, Y. (2023). A Collaborative Approach Based On Shapley Value For Carriers In The Supply Chain Distribution. *Heliyon*, *9* (7), e17967.

Wu, J., Liu, Y., Yin, H. ve Guo, M. (2023). A New Generation Of Sensors For Non-Invasive Blood Glucose Monitoring. *Am J Transl Res*, *15*, 3825–3837.

Xue, Y., Guan, S. ve Jia, W. (2024). BGformer: An Improved Informer Model To

Enhance Blood Glucose Prediction. *Journal Of Biomedical Informatics*, *157*, 104715.

Yamagata, T., O'Kane, A., Ayobi, A., Katz, D., Stawarz, K., Marshall, P., Flach, P. ve Santos-Rodríguez, R. (2020). Model-Based Reinforcement Learning For Type 1 Diabetes Blood Glucose Control.

Yu, P., Ni, X., Xu, L., Zhang, L., Cao, L., Chen, Q., Hu, Y., Qian, K., Li, X., Li, X. ve Gu, J. (2023). Impact Of Daily Step Count On Diabetes Management And Complications Among Elderly Individuals- Jiangsu Province, China, 2020-2022. *China CDC Wkly*., *5* (45), 1006–1011.

Zhang, K., Xu, P. ve Zhang, J. (2020). Explainable AI In Deep Reinforcement Learning Models: A SHAP Method Applied In Power System Emergency Control. 2020 *IEEE 4th Conference On Energy Internet And Energy System Integration (EI2),* 711–716.

Zhang, M., Flores, K. B. ve Tran, H. T. (2021). Deep Learning And Regression Approaches To Forecasting Blood Glucose Levels For Type 1 Diabetes. *Biomed. Signal Process. Control*, *69*, 102923.

Zhong, L., Guo, X., Ding, M., Ye, Y., Jiang, Y., Zhu, Q. ve Li, J. (2024). SHAP Values Accurately Explain The Difference In Modeling Accuracy Of Convolution Neural Network Between Soil Full-Spectrum And Feature-Spectrum. *Comput. Electron. Agric.*, *217*, 108627.

Zhu, T., Li, K., Herrero, P. ve Georgiou, P. (2021). Basal Glucose Control In Type 1 Diabetes Using Deep Reinforcement Learning: An In-Silico Validation. *IEEE Journal Of Biomedical And Health Informatics*, *25* (4), 1223–1232.

KİŞİSELYAYIN VE ESERLER

Adjevi, A., Abdirashid, A. M., Aktaş, F., Ucar, M. H. B., & Solak, S. (2026). Explainable reinforcement learning for glucose monitoring based on shapley value analysis. *Computer Methods and Programs in Biomedicine, 278*, 109266.

Adjevi, A., & Solak, S. (2025). ConvLSTM-Based Time Series Prediction of Blood Glucose Levels Using SimGlucose Simulation *Data. International Journal of Advanced Natural Sciences and Engineering Researches*,*9*(11).

Solak, S., Abdirashid, A. M., **Adjevi, A**., & Sahu, A. K. (2024). Robust data hiding method based on frequency coefficient variance in repetitive compression. *Engineering Science and Technology, an International Journal, 56*, 101756.

Ucar, M. H. B., **Adjevi, A.,** Aktaş, F., & Solak, S. (2024). Utilizing IoMT-Based Smart Gloves for Continuous Vital Sign Monitoring to Safeguard Athlete Health and Optimize Training Protocols. *Sensors*, *24*(20), 6500.

ÖZGEÇMİŞ

Arsene Adjevi, Kocaeli Üniversitesi Fenbilimleri Enstitüsü Bilişim Sistemleri Müh. ABD yüksek lisans öğrencisidir. Takviyeli öğrenme, yüksek performanslı hesaplama ve oyun teorisi konularında uzmanlaşmıştır. WORK3 Technology (MedixBot Ltd.) ve GoTogetherAI'de R&D ve ML mühendisliği deneyimi ile gerçek zamanlı, enerji verimli ve adaptif gömülü sistemler ile dağıtık ML platformları geliştirmiştir. Sistem-bilinçli makine öğrenimi, multi-agent sistemler ve hesaplama offloading gibi alanlarda güçlü bir teknik altyapıya sahip olup, Python, C/C++, CUDA ve Docker gibi araçları etkin kullanmaktadır. Yayınları arasında "Explainable Reinforcement Learning for Glucose Monitoring" ve IoMT tabanlı sağlık izleme sistemleri yer almakta, Türkiye Bursları ile desteklenmiş ve üç dilde (Fransızca, Türkçe, İngilizce) konuşmaktadır.