

**MEDİKAL KODLARIN DERİN ÖĞRENME TABANLI
YÖNTEMLERLE KESTİRİMİ**

**PREDICTING MEDICAL CODES VIA DEEP
LEARNING-BASED METHODS**

MUSTAFA ARDA AYDEN

DOÇ. DR. SENİHA ESEN YÜKSEL

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2023

ÖZET

MEDİKAL KODLARIN DERİN ÖĞRENME TABANLI YÖNTEMLERLE KESTİRİMİ

Mustafa Arda AYDEN

Yüksek Lisans, ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ

Bölümü

Tez Danışmanı: Doç. Dr. Seniha Esen YÜKSEL

Ocak 2023, 84 sayfa

Günümüzde, derin öğrenme yöntemleri bilgisayarlı görü, konuşma tanımlama ve doğal dil işleme gibi birçok alanda kullanılmaktadır. Derin öğrenme yöntemleriyle yapılan kestirimler geleneksel makine öğrenimi yöntemlerine göre çoğu zaman daha başarılı çıktılar üretmektedir. Son zamanlarda sağlık alanında yayınlanan veri kümeleri, derin öğrenme yöntemlerinin özellikle medikal kodların kestirimi görevlerinde kullanılmasının önünü açmıştır. Ancak, bu amaç doğrultusunda yapılan literatür çalışmalarının genelinde sadece metin tabanlı veriler kullanılarak kestirimler gerçekleştirilmektedir. Bu çalışmada, hasta başvurularındaki medikal kodların kestirimine yönelik, hem metin verilerini hem de zaman serilerini kullanan, çok modlu bir yöntem önerilmiştir. Ayrıca, bu kapsamda literatürdeki en başarılı sonuçları üreten metin tabanlı derin öğrenme yöntemleri de ele alınmış ve önerilen çok modlu yaklaşım bu yöntemlerle de test edilmiştir. Sonuç olarak, değerlendirilen her bir yöntem için, her iki veri tipi de kullanıldığında F1 skoru anlamında daha başarılı sonuçların elde edildiği gösterilmiştir.

Keywords: Derin Öğrenme, Elektronik Sağlık Kayıtları, MIMIC-III, Hastalık Kestirimi,
ICD

ABSTRACT

PREDICTING MEDICAL CODES VIA DEEP LEARNING-BASED METHODS

Mustafa Arda AYDEN

**Master of Science, Department of ELECTRICAL AND ELECTRONICS
ENGINEERING**

Master of Science, Electrical and Electronics Engineering

Supervisor: Assoc. Prof. Seniha Esen YÜKSEL

Ocak 2023, 84 pages

Deep learning methods are used for prediction tasks in many areas such as computer vision, speech recognition, and natural language processing. Such methods give more flexible and powerful results than traditional machine learning methods. Improvements in the publicly available healthcare data sets lead to deep learning works to be increased in the healthcare domain especially for predicting the medical codes of patients. In this work, a deep learning-based multi-modal method is proposed to predict medical codes by using both text-based and time-series data. This method was developed with the help of publicly available MIMIC-III data set and gives competitive results with similar healthcare prediction methods which are using only text-based data. Furthermore, the proposed approach is also tested with some state-of-the-art text-based models and showed that using both types of data improves results in terms of F1 score.

Keywords: Deep Learning, Electronic Health Records, MIMIC-III, Diagnosis Prediction, ICD

TEŐEKKÜR

Tüm sabrıyla bana daima yol gösteren, değerli birikimleriyle çalışmanın bu aşamaya gelmesini sağlayan, tez danışmanım Doç. Dr. Seniha Esen YÜKSEL'e ve kıymetli fikirleriyle katkılarını sunan Uzm. Dr. Mehmet Eren YÜKSEL'e teşekkürü borç bilirim.

Her daim yanımda olarak bana güç veren sevgili eşim Özgü AYDEN'e, hayatım boyunca desteklerini esirgemeyerek bugünlere gelmemi sağlayan annem Berna AYDEN, babam Fatih AYDEN ve kardeşim Hazal AYDEN'e ayrıca teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	iv
İÇİNDEKİLER	v
ÇİZELGELER DİZİNİ.....	vii
ŞEKİLLER DİZİNİ	viii
KISALTMALAR	x
1. GİRİŞ	1
1.1. ICD Kodlama Sistemi	2
1.2. Tezin Amacı	3
1.3. Tezin Kapsamı ve Akışı	5
2. VERİ KÜMESİ	5
3. LİTERATÜR ÖZETİ	13
4. KULLANILAN DERİN ÖĞRENME MODELLERİ	19
4.1. Zaman Serileri İçin Kullanılan Derin Öğrenme Yöntemleri	19
4.1.1. RNN	19
4.1.2. Uzun-Kısa Vadeli Bellek (LSTM)	21
4.1.3. GRU	22
4.1.4. Evrişimli Sinir Ağları	24
4.2. Doğal Dil İşleme İçin Kullanılan Derin Öğrenme Yöntemleri	25
4.2.1. Word2Vec	25
4.2.2. Doc2Vec	28
4.2.3. Doc2VecC	28
4.2.4. Dönüştürücüler	29
4.2.5. BERT	30
4.2.6. Longformer	32
5. ÖNERİLEN YÖNTEMLER VE DENEYSEL SONUÇLAR.....	33

5.1. Sayısal Veri Tabanlı Sınıflandırma.....	35
5.1.0.1. Veri Ön İşleme.....	35
5.1.1. CNN İle Sayısal Verilerden ICD-9 Sınıflandırma	37
5.1.2. GRU İle Sayısal Verilerden ICD-9 Sınıflandırma	38
5.1.3. LSTM İle Sayısal Verilerden ICD-9 Sınıflandırma.....	40
5.2. Metin Tabanlı Sınıflandırma	40
5.2.0.1. Veri Ön İşleme.....	40
5.2.1. Word2Vec İle ICD-9 Sınıflandırma	41
5.2.2. BERT İle ICD-9 Sınıflandırma	46
5.2.3. Longformer İle ICD-9 Sınıflandırma.....	48
5.3. Sayısal ve Metin Tabanlı Verileri Birlikte Kullanarak Sınıflandırma	49
5.3.1. Longformer ve GRU ile Sınıflandırma	50
5.3.2. KEPT ve GRU ile Sınıflandırma	51
6. SONUÇ	53
KAYNAKLAR	57
EKLER.....	64
EK 1- Test Veri Kümesinde Yer Alan Örnek Bir Hasta Taburcu Notu ve Sonucu	64
EK 2 - Elde Edilen Hata Matrisleri.....	69
ÖZGEÇMİŞ	73

TABLolar

	<u>Sayfa</u>
Tablo 2.1 MIMIC-III Tabloları	10
Tablo 2.2 En Sık Görülen 50 ICD-9 Kodu Açıklamaları	11
Tablo 3.1 Skorlama Sistemlerinde Kullanılan Öznitelikler ve MIMIC-III Tabloları	14
Tablo 3.2 Literatürdeki çalışmaların Kıyaslanması	18
Tablo 4.1 Bire bir kodlama Örneği	25
Tablo 5.1 Sayısal Veriler İçin Kullanılan Veri Kümesindeki Öznitelikler	36
Tablo 5.2 Word2vec ile Metin Bazlı Sınıflandırıcı Sonuçları	44
Tablo 6.1 Çalışmada Önerilen Yöntemlerden Elde Edilen Sonuçlar	54
Tablo 6.2 Sonuçların Literatürdeki Diğer Çalışmalarla Karşılaştırılması	56

ŞEKİLLER

	<u>Sayfa</u>
Şekil 2.1	Filtrelenmiş Veri Kümesinde En Sık Görülen 50 ICD Kodu Sayıları .. 12
Şekil 2.2	Tüm Veri Kümesinde En Sık Görülen 50 ICD Kodu Sayıları 12
Şekil 4.1	Klasik RNN Diyagramı 20
Şekil 4.2	Zaman Serileri Sınıflandırıcısı Olarak Kullanılan RNN Diyagramı 20
Şekil 4.3	RNN hücresi [1] 21
Şekil 4.4	LSTM hücresi [1, 2] 23
Şekil 4.5	GRU hücresi [1, 3] 23
Şekil 4.6	Örnek Evrişimsel Sinir Ağı [4] 24
Şekil 4.7	Word2Vec Diyagramı [5] 26
Şekil 4.8	CBOW Diyagramı [5]..... 27
Şekil 4.9	Skip-Gram Diyagramı [5] 27
Şekil 4.10	Örnek Doc2Vec Diyagramı 29
Şekil 4.11	Temel Dönüştürücü Model Mimarisi [6] 31
Şekil 5.1	Sayısal verilerden ICD sınıflandırma amacıyla kullanılan CNN Modeli 37
Şekil 5.2	Sayısal verilerden ICD sınıflandırma amacıyla kullanılan CNN Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor 38
Şekil 5.3	Sayısal verilerden ICD sınıflandırma amacıyla kullanılan GRU Modeli 39
Şekil 5.4	Sayısal verilerden ICD sınıflandırma amacıyla kullanılan GRU Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor 39
Şekil 5.5	Sayısal verilerden ICD sınıflandırma amacıyla kullanılan LSTM Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor 40
Şekil 5.6	Word2Vec ile ICD sınıflandırıcı amacıyla kullanılan CNN Modeli 42
Şekil 5.7	Word2Vec ile ICD sınıflandırıcı amacıyla kullanılan dikkat mekanizmalı CNN Modeli 43
Şekil 5.8	Word2Vec ile ICD sınıflandırıcı amacıyla kullanılan GRU Modeli 43

Şekil 5.9	Sayısal Verilerden ICD Sınıflandırma Amacıyla Kullanılan Dikkat Mekanizmalı CNN Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor	44
Şekil 5.10	TSNE Uzayında Örnek Word2vec vektörlerinin Gösterimi.....	45
Şekil 5.11	PCA Uzayında Örnek Word2vec vektörlerinin Gösterimi	45
Şekil 5.12	BERT Tabanlı ICD-9 Sınıflandırıcı Modeli	47
Şekil 5.13	Metin tabanlı ICD sınıflandırıcı amacıyla kullanılan BERT Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor	48
Şekil 5.14	Metin tabanlı ICD sınıflandırıcı amacıyla kullanılan Longformer Modeli	49
Şekil 5.15	Longformer Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor	49
Şekil 5.16	Metin ve Sayısal Veri Tabanlı ICD Sınıflandırıcı Amacıyla Kullanılan Birleştirilmiş Model Diyagramı (Longformer & GRU).....	51
Şekil 5.17	Birleştirilmiş Model (Longformer) Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor.....	51
Şekil 5.18	Birleştirilmiş Model (KEPT) Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor.....	53
Şekil 6.1	GRU Modeli için Elde Edilen Hata Matrisi.....	70
Şekil 6.2	Longformer Modeli için Elde Edilen Hata Matrisi	71
Şekil 6.3	Birleştirilmiş Model için Elde Edilen Hata Matrisi.....	72

KISALTMALAR

- DSA** : **Derin Sinir Ađı**
- DDİ** : **Dođal Dil İřleme**
- ICD** : **International Classification of Diseases**
(Hastalıkların Uluslararası Sınıflaması)
- MIMIC** : **Medical Information Mart for Intensive Care**
Yođun Bakım için Tıbbi Bilgi Veri Kumesi
- CNN** : **Convolutional Neural Network**
(Evrifimsel Sinir Ađı)
- BERT** : **Bidirectional Encoder Representations from Transformers**
(Dönüřtürücülerden Çift Yönlü Kodlayıcı Temsilleri)

1. GİRİŞ

Hastaların gelecekteki sađlık durumlarının kestirimi derin öğrenme çalışmalarını için önemini koruyan bir konudur. Hasta yatışı esnasında elde edilen ve elektronik ortamlarda formatlı veya formatsız olarak saklanan veriler kullanılarak çeşitli kestirimler gerçekleştirilmektedir. Özellikle makine öğrenimi yöntemlerinin son zamanlarda artan başarısı bu alanda da hızlı, otomatik ve yüksek doğruluđa sahip kestirim yöntemlerini beraberinde getirmiştir. Bu çalışmalar hekimlere alternatif bir tanı mekanizması oluşturmanın aksine tanı süreçlerine yardımcı olma hedefi gözetilerek gerçekleştirilmektedir.

Lireratürdeki çalışmaların hedefleri hastanede kalış süresinin kestirimi, yaşam süresinin kestirimi ve sahip olunan hastalıkların kestirimi olmak üzere üç ana başlıktan oluşmaktadır. Gerçekleştirilen çalışmaların çođu bu görevlerden yalnızca birini ele alsa da, birden fazla görevi ortak bir şekilde çözümlenmeyi hedefleyen çalışmalara da rastlamak mümkündür.

Hastanede Kalış Süresinin Kestirimi:

Bu görev, yoğun bakım ünitelerinin zaman planlamalarının yapılması, her bir hasta için maliyet hesaplamalarının yapılması ve hasta memnuniyetini artırabilmek için önemli bir analizdir. Tahminlemesi yapılacak olan çıktının gün veya saat cinsinden sayısal bir deđer olması nedeniyle regresyon görevi olarak ele alınmaktadır.

Yaşam Süresinin Kestirimi:

Yaşam sürelerinin kestirimi, regresyon veya ikili sınıflandırma görevi olarak ele alınabilir. Süresinin sayısal olarak tahminlemesi ile elde edilen sonuçların düşük doğrulukta olması, ikili sınıflandırma görevlerine yoğunlaşan çalışmaların sayısını artırmıştır. Bu çalışmalara örnek olarak, hastanede yatış esnasında ölüm/yaşam tahminlemesinin yapılması veya belirli bir süre zarfında ölüm/yaşam tahminlemesinin yapılması gösterilebilir.

Medikal Kodların Kestirimi:

Tıbbi teşhislerde karışıklıkların önüne geçebilmek amacıyla bazı evrensel kodlama sistemleri kullanılmaktadır. Bu evrensel kodlama sistemlerinde literatürdeki her bir teşhis ve tedavinin kendine özgü bir kodu bulunmaktadır. Bu tezin ana konusu olan medikal kodların kestirimi, kodların yapısı itibariyle sınıflandırma görevi olarak ele alınmaktadır. Bazı teşhislerin birbirleriyle benzerlik göstermesi dolayısıyla her bir teşhisi sınıflandırmak yerine birden fazla teşhis kodunu içeren teşhis grubunu sınıflandırmak da mümkündür. Ayrıca her bir hasta başvurusu sonucunda birden fazla teşhis konulabileceği için genellikle çok etiketli ve çok sınıflı bir sınıflandırma görevi olarak ele alınmaktadır.

Medikal kodlar, genellikle sigorta ve faturalandırma işlemleri için kullanılmaktadır. Bu kodların hasta başvurularına atanmasında yapılan hatalar hastanelerde maddi kayıplara yol açmaktadır. Bu kodların atanması için medikal kodlama uzmanları görevlendirilmektedir. Medikal kodlama uzmanları genellikle taburcu notları okuyarak bu atama işlemlerini gerçekleştirmektedir. Ancak taburcu notlarının çok uzun metinlerden oluşması ve hasta yatış süreçlerini tam anlamıyla temsil etmemesi, uzmanların işlerini zorlaştırmaktadır. Derin öğrenme yöntemlerinin son zamanlarda artan başarısı, medikal kodların kestirimi görevinde de kullanılmalarının önünü açmıştır. Çeşitli derin öğrenme yöntemleri ile hem sürecin kısaltılması hem de hataların en aza indirilmesi hedeflenmektedir. Bu noktada çoğunlukla DDİ tabanlı derin öğrenme yöntemleri kullanılmakta, hasta yatışı esnasında elde edilen metin verilerinden yararlanılarak otomatik olarak medikal kodların kestirimini yapan sistemler üretilmektedir.

Bu tez kapsamında da, MIMIC-III veri kümesinde yer alan ve dünya çapında en yaygın olarak kullanılan medikal kodlama sistemi olan ICD kodlama sistemi temel alınmış ve ICD kodların kestirimi hedeflenmiştir.

1.1. ICD Kodlama Sistemi

ICD, hastalara konulan tanıların ve uygulanan tedavilerin sistematik kodlaması amacıyla kullanılan medikal kodlama sistemlerinden biridir. Açılımı Uluslararası İstatistiksel Hastalık

Sınıflandırması ve İlgili Sağlık Sorunları (International Statistical Classification of Diseases and Related Health Problems) olan bu kodlama sisteminin temelleri 1900'lü yılların başlarına dayanmaktadır ve başlangıçta her 10 yılda bir güncellenmesi planlanmıştır. 1948 yılından bu yana Dünya Sağlık Örgütü'nün sorumluluğunda derlenen bu sistemin yayınlanan son iki versiyonu olan ICD-9 ve ICD-10 günümüzde en sık kullanılan medikal kodlama sistemlerindedir. MIMIC-III veri kümesinde yer alan, dolayısıyla bu çalışmanın da temelini oluşturan ICD-9 kodlama sisteminde yaklaşık 13,000 farklı kod bulunmaktadır.

ICD-9 kodları 3,4 veya 5 basamaktan oluşmaktadır. 5 basamaklı kodların formatı XXX.XX şeklinde olup, ilk üç basamak hastalık kategorisi, son iki basamak ise iki alt kırılım halinde hastalık etiyolojisi için kullanılmaktadır. Diğer bir deyişle; 3 basamağa sahip kodlar ana hastalıkları temsil etmekte, 4. ve 5. basamaklar ise ana hastalıkların alt kollarını oluşturmaktadır. Örneğin, 290 ICD-9 kodu demans hastalığını, 290.1 kodu erken demans hastalığını, 290.12 kodu ise kuruntu özellikli erken demans hastalığını temsil etmek için kullanılmaktadır. Ek olarak, 3 basamaklı ana kodlar da kendi aralarında sınıflandırılmaktadır; bu kodlar hem hastalıklar hem de teşhisler için benzerliklerine göre 19 farklı gruba ayrılmıştır. Kod sayısının fazlalığından dolayı, literatürde sadece bu grupların tahminlemesine yönelik de çalışmalar yer almaktadır [7].

1.2. Tezin Amacı

Giriş bölümünde bahsedildiği gibi literatürdeki her bir teşhis ve tıbbi süreçlere sınıflandırma için çeşitli medikal kodlama sistemleri kullanılmaktadır. Bu medikal kodlama sistemlerinin amacı sigorta ve faturalandırma açısından tüm hastanelerin evrensel olarak kullanabildiği ortak bir yapı oluşturmak ve böylelikle olası karışıklıkların önüne geçebilmektir. Bu kodlama süreçleri hastanelerde klinik kodlama görevlileri tarafından yönetilmektedir. Görevliler her bir hasta yatışı sürecindeki verileri analiz etmekte ve sınıflandırma sistemlerinde yer alan kodları ilgili hasta başvurusuna atamaktadırlar. Ancak, bu akış insan faktörüne oldukça bağlı olup, süreç boyunca zaman kayıpları yaşanmaktadır. Ayrıca yapılacak hatalar sonucu, hastanelerin maddi kayıplara uğramaları da olasıdır. Kodlama sistemlerinde yer alan teşhis ve

tıbbi tedavi kodlarının çokluğu da bu süreçleri oldukça zorlaştırmaktadır. Dolayısıyla, klinik kodlama görevlilerine yardımcı olacak, hem zaman kazandıracak hem de olası hataların önüne geçebilecek çeşitli çalışmalar gerçekleştirilmektedir.

Bu tez çalışmasında da hastaların medikal kodlarının otomatik olarak tespit edilebilmesine yönelik olarak gerçekleştirilen literatürdeki çalışmalar incelenmiş ve MIMIC-III veri kümesi kullanılarak, sahip olunan hastalıkların kestirimi için bir yöntem önerilmiştir. Bu yöntemin çıktıları analiz edilmiş ve literatürdeki diğer çalışmalardan üstün olduğu noktalar ortaya konulmuştur.

Her makine öğrenimi çalışmasında olduğu gibi bu çalışma için de veri kümesinin niteliği, niceliği ve çeşitliliği büyük önem teşkil etmektedir. Sağlık kuruluşlarının sahip olduğu elektronik hasta kayıtları büyük bir veri kümesi oluşturmada yeterli olsalar da, bu verilerin sistematik bir şekilde elde edilmemesi derin öğrenme çalışmalarında etkili bir şekilde değerlendirilmelerinin önüne geçmiştir. Ancak, bir çok hastadan uzun süreler boyunca, sistematik bir şekilde alınan verilerle oluşturulan veri kümelerine de rastlamak mümkündür. MIMIC-III veri kümesi bu özelliklere sahip olması, sayısal olarak yeterli seviyede kayıt içermesi ve tüm araştırmacıların kullanımına açık olması dolayısıyla bu anlamdaki en önde gelen veri kümesi konumundadır.

Tez kapsamında MIMIC-III veri kümesi, metin bazlı veriler ve zamana bağlı sayısal veriler olmak üzere iki farklı başlıkta ele alınmış ve her iki veri tipini kullanan derin öğrenme tabanlı yöntemler ayrı ayrı analiz edilmiştir. İki veri tipi için de farklı derin öğrenme yöntemleri söz konusu veri kümesi ile eğitilmiş ve test edilmiştir. Çalışmada, küresel çapta en yaygın kullanılan ve MIMIC-III veri kümesinde yer alan, ICD kodlarının otomatik olarak tahminlemesi hedeflenmiştir.

Bu amaçla, iki veri tipi için en iyi sonucun elde edildiği derin öğrenme yöntemleri birleştirilmiş ve ortak bir model haline getirilerek, nihai yöntem olarak kullanılmıştır. Böylelikle, hem metin bazlı hem de sayısal verileri girdi olarak kullanarak, hastaların medikal kodlarının (ICD) kestirimini gerçekleştirebilen bir yöntem elde edilmiştir. Çalışma kapsamında, metin bazlı veriler ile elde edilen sonuçların, zaman serisi verilerine göre

daha başarılı sonuçlar verdiği gözlemlenmiştir. Ancak metin bazlı kestirim yapabilmek için kullanılan yöntemler sayısal verileri kullanan yöntemlerle birleştirildiğinde genel model başarısının arttığı sonucuna ulaşılmıştır. Bu sonucu genelleştirebilmek amacıyla, literatürdeki en başarılı sonuca sahip metin bazlı yöntemler temel alınarak da aynı yaklaşım test edilmiş ve bu yöntemlerin başarısının artırılabilirdiği gösterilmiştir.

1.3. Tezin Kapsamı ve Akışı

Tezin geri kalanı aşağıdaki gibi planlanmıştır.

- Bölüm 2.'de bu amaç doğrultusunda kullanılan MIMIC-III veri kümesine yönelik açıklamalar ve istatistiksel veriler aktarılmıştır.
- Bölüm 3.'te MIMIC-III kullanılarak gerçekleştirilen literatür çalışmaları değerlendirilmiştir.
- Bölüm 4.'te hem bu çalışma kapsamında kullanılan hem de benzer veri kümeleri için literatürde çeşitli örnekleri bulunan derin öğrenme yöntemleri aktarılmıştır. Bölüm 4.1.'de zaman serileri için kullanılan derin öğrenme yöntemlerinin, Bölüm 4.2.'de ise metin bazlı veriler için kullanılan derin öğrenme yöntemlerinin açıklamaları bulunmaktadır.
- Bölüm 5.'te tez çalışması kapsamında önerilen yöntemler yer almaktadır. Bölüm 5.1.'de MIMIC-III veri kümesinde yer alan sayısal veriler, Bölüm 5.2.'de ise metin verileri için önerilen yöntemler açıklanmış ve deneysel sonuçlardan bahsedilmiştir.
- Bölüm 6.'da elde edilen sonuçların değerlendirmesi yapılmıştır. Ayrıca sonuçların literatürdeki diğer çalışmalarla kıyaslaması da bu bölümde mevcuttur.

2. VERİ KÜMESİ

Bu tez kapsamında kullanılan MIMIC-III veri kümesi, Amerika Birleşik Devletleri'nde bulunan Beth Israel Deaconess Medical Center isimli bir eğitim hastanesinin yoğun bakım

ünitesinde, 2001 ve 2012 yılları arasında tedavi görmüş hastaların sağlık verilerinden oluşmaktadır. Veri kümesinde klinik notlar, zamana bağlı sayısal veriler ve zaman bağımsız sayısal veriler yer almaktadır. Veri kümesinde yer alan tablolara ilişkin isim ve açıklamalara Tablo 2.1’de yer verilmiştir.

Araştırmacılara tümüyle açık olarak yayınlanmış bu veri kümesinde 58,576 hasta başvurusuna ait veri bulunmaktadır. Bu başvuruların 53,423 tanesi yetişkin hastalara (15 yaş ve üzeri) aittir. Veri kümesi içerisinde tüm veriler ele alındığında yaş medyan değeri 65,68 yıl, hastane yatış süresi medyanı 7,08 gün, hastanede mortalite oranı ise %10,49’dur. Yetişkin hasta verileri içerisinde ilk başvuru oranı %83 olup, 38,425 farklı yetişkin hastaya ait veri bulunmaktadır. Bu çalışmada da yetişkin hasta verileri kullanılmış ve hastalar tekilleştirilmiştir. Bir hastanın birden fazla başvurusunun bulunması durumunda ilk başvuruları temel alınmıştır.

MIMIC-III ve benzeri veri kümelerinde, elektronik sağlık kayıtlarının yapısı gereği bazı problemler bulunmaktadır. Bu problemler; yüksek düzeyde eksik veri içermesi, her bir hasta verisinin çok boyutlu olması, gürültüsü yüksek verilerden oluşması ve rastgele hataların çokça bulunması olarak sıralanabilir. Her bir hasta şikayeti için test/tahlil tipi ve görüntüleme yöntemi gibi çok farklı parametre bulunmaktadır. Kimi hastalıkların teşhisi için bazı parametrelere ihtiyaç duyulurken, kimi hastalıkların teşhisi için ise farklı başka parametrelere ihtiyaç duyulmaktadır. Bu nedenle her bir hasta başvurusunda bir çok eksik veriye rastlanmaktadır. Elektronik sağlık verilerinden tahminleme yaparken bu durumun göz önünde bulundurulması gerekmektedir beraber, kullanılan ön işleme yöntemlerinin önemi artmaktadır.

Bu problemin önüne geçmek için çeşitli geleneksel ön işleme işlemleri kullanıldığı gibi, derin öğrenme tabanlı bir yöntem de öne sürülmüştür. Deep Patient [8] adı verilen bu yöntem eksik veri kümesini girdi olarak almakta, daha düşük boyutlu ve eksik verilerden arındırılmış bir veri kümesine dönüştürmektedir. Bu yöntemin temeli yığın gürültü giderici otokodlayıcılara [9] dayanmaktadır. Gürültü giderici otokodlayıcılar, girdi olarak verilen özniteliklerden rastgele olarak belirli bir kısmının silinmesinden kalan

veriler ile girdinin tamamını tahmin etmeye yönelik bir yöntemdir. Böylelikle, eğitildikten sonraki kullanımında, gerçekten eksik bir veri geldiğinde onu tamamlamayı öğreneceği düşünülmüştür. Deep Patient çalışmasında 3 adet ardışık gürültü giderici otokodlayıcıdan oluşan bir yığın gürültü giderici otokodlayıcı kullanılmıştır. Birbirlerine eş özelliklere sahip her bir otokodlayıcı ayrı ayrı eğitilmiş ve eğitimleri esnasında her bir girdinin %5 oranındaki özniteliği rastgele olarak sıfırlanmıştır. Model, çıktı olarak 500 boyutlu bir veri kümesi oluşturmaktadır ve veri kümesinde toplamda 60,238 öznitelik olduğu düşünüldüğünde ciddi derecede bir boyut düşürme işlemi uygulandığı söylenebilir. Bu işlem sonrası oluşan veri kümesi hem gürültüden hem de eksik verilerden arındırılmış bir yapıdadır. Elde edilen bu veri kümesine Deep Patient Veri Kümesi adı verilmiş, bu veri kümesi ile çeşitli deneyler yapılmış ve sonuçlar hem ham veri kümesinin hem de diğer geleneksel ön işleme işlemleriyle elde edilen veri kümelerinin sonuçlarıyla kıyaslanmıştır. Bu sonuçlar incelendiğinde Deep Patient adı verilen veri kümesinin, incelenen bütün görevlerde ham veri kümesine ve diğer yöntemlerle (PCA, GMM, K-means, ICA) elde edilen veri kümelerine oranla daha başarılı sonuçlar ürettiği gösterilmiştir. Deep Patient modeli, yığın gürültü giderici otokodlayıcıları medikal alanda kullanan ilk çalışma konumundadır. Ayrıca, çalışmanın göreve özgü olmayan bir öznitelik öğrenme yöntemi olarak da bu alanda kullanılan ilk model olduğu öne sürülmüştür. Ancak, modelin çıktısında elde edilen veri kümesinin zaman bilgisini kaybettiği düşünüldüğünde, zamana dayalı tahminleme görevlerinde kullanılamayacağını söylemek mümkündür. Dolayısıyla, söz konusu Deep Patient modeli bu çalışma kapsamında kullanılmamıştır. Ek olarak, yapılan çalışma sadece klasik bir makine öğrenimi yöntemi olan rastgele orman (random forest) yönteminde test edilmiş, herhangi bir derin öğrenme yöntemiyle nasıl bir sonuç verdiği gösterilmemiştir.

Bu tez çalışmasında, MIMIC-III veri kümesi, ICD-9 kodlarının hem metin hem de zamana bağlı sayısal veriler kullanılarak tahminlemesi hedeflendiği için girdi olarak; *noteevents*, *chartevents*, *inpuvents* ve *labevents* tabloları, çıktı olarak ise; *diagnoses_icd* ve *procedures_icd* tabloları kullanılmıştır. *Noteevents* tablosunda hasta yatış süreci boyunca elde edilen metin bazlı verilerin tamamı, diğer söz konusu tablolarda ise hastalardan belirli bir periyot ile elde edilen sayısal veriler bulunmaktadır.

Bu çalışmayla kıyaslanan literatürdeki diğer çalışmalarda *noteevents* tablosundaki sadece hasta taburcu notları ele alındığı için, tez kapsamında da metin tabanlı verilerden sadece hasta taburcu notları kullanılmıştır. Ayrıca, taburcu notları klinik kodlama görevlilerinin de temel aldıkları verilerin başında gelmektedir. *Noteevents* tablosundan elde edilen kısa bir örnek ham taburcu raporu aşağıda yer almaktadır;

167853 Admission Date: [**2151-7-16**] Discharge Date: [**2151-8-4**]

Service: ADDENDUM:

RADIOLOGIC STUDIES: Radiologic studies also included a chest CT, which confirmed cavitary lesions in the left lung apex consistent with infectious process/tuberculosis. This also moderate-sized left pleural effusion.

HEAD CT: Head CT showed no intracranial hemorrhage or mass effect, but old infarction consistent with past medical history.

ABDOMINAL CT: Abdominal CT showed lesions of T10 and sacrum most likely secondary to osteoporosis. These can be followed by repeat imaging as an outpatient.

[**First Name8 (NamePattern2) **] [**First Name4 (NamePattern1) 1775**] [**Last Name (NamePattern1) **], M.D. [**MD Number(1) 1776**]

Dictated By:[**Hospital 1807**] MEDQUIST36

D: [**2151-8-5**] 12:11 T: [**2151-8-5**] 12:21

Sayısal veriler elde edilirken, Purushothan ve arkadaşlarının [10] kullanmış oldukları adımlardan yararlanılmıştır. Bu veriler kullanılırken uygulanan veri ön işleme adımlarına Bölüm 5.1.0.1.'de değinilmiştir.

Veri kümesindeki bazı hastalar metin veri kümesinde bulunurken sayısal veri kümesinde yer almamaktadır. Bu durum göz önünde bulundurularak, veri kümesindeki hastalar filtrelenmiş ve hem sayısal hem de metin veri kümesinde yer alan hastalar temel alınmıştır.

Etiket verileri için ise literatürdeki çalışmalarla adil bir kıyaslama ortamı yaratabilmek adına, veri kümesinde en yaygın olarak görülen 50 ICD kodu kullanılmıştır. En sık görülen bu 50 ICD kodunun herhangi birine sahip olmayan hasta başvuruları da veri kümesinden

ıkarılmıřtır. Sonu olarak, elde edilen kodların listesi Tablo 2.2’de, grlme sayılarının istatistiĐi ise Őekil 2.1’de bulunmaktadır. Ayrıca filtrelenmemiř ham veri kmesindeki en sık grlen 50 ICD kodunun istatistiĐi de Őekil 2.2’de mevcuttur.

Elde edilen filtrelenmiř, nihai veri kmesinde 33330 adet farklı hastaya ait veri bulunmaktadır. Bu veri kmesine alıřmanın geri kalanında A Veri Kmesi adı verilmiřtir. Gerekleřtirilen her bir deney iin veri kmesi eĐitim kmesi, doĐrulama kmesi ve test kmesi olmak zere sırasıyla 0,7, 0,15, 0,15 oranlarıyla rastgele bir Őekilde blnmiř ve eĐitimler gerekleřtirilmiřtir. Adil bir kıyaslama ortamı yaratabilmek amacıyla, her deney iin aynı eĐitim, doĐrulama ve test kmeleri kullanılmıřtır.


Shi ve arkadařları [11] MIMIC-III veri kmesi kullanarak, taburcu raporlarından LSTM tabanlı ICD kod kestirimi alıřmasında eĐitim, doĐrulama ve test veri kmelerini sırasıyla 8066, 1728 ve 1729 hasta bařvurusunu temel alarak oluřturmuřlardır. Sonrasında ise bu veri kmesi eřitli modern alıřmalarda kullanılmıř ve nerilen yntemler bu veri kmesi zerinden raporlanmıřtır. Bu alıřmalar, Mullenbach ve arkadařları [12], Vu ve arkadařları [13], Yuan ve arkadařları [14], Yang ve arkadařları [15] tarafından gerekleřtirilen ve bu tez alıřmasında da incelenen alıřmalardır. Dolayısıyla nerilen yntemin sz konusu alıřmalarla kıyaslanabilmesi amacıyla, bu veri kmesiyle de deney gerekleřtirilmiřtir. Ancak, eĐitim kmesinde yer alan 2716 adet hasta bařvurusu, bu alıřma kapsamında oluřturan sayısal veri kmesinde yer almamaktadır. DoĐrulama ve test veri kmeleri iin ise eksik hasta bařvurusu sırasıyla 395 ve 400’dr. Bu hasta bařvuruları ıkarıldıĐında, eĐitim kmesi 5350, doĐrulama kmesi 1333, test veri kmesi ise 1329 hasta bařvurusundan oluřmuřtur. Bu filtrelenmiř veri kmesine alıřmanın geri kalanında iřaret edebilmek iin B Veri Kmesi adı verilmiřtir. B Veri Kmesini kapsayan ve yukarıda bahsedilen literatrdeki diĐer alıřmalarda kullanılmıř olan veri kmesine ise C Veri Kmesi adı verilmiřtir.

Tablo 2.1 MIMIC-III Tabloları


Tablo	Açıklama
ADMISSIONS	Hastane başvurusuna İlişkin Temel Bilgiler
CALLOUT	Yoğun Bakım Taburcu Planlama Bilgileri
ICUSTAYS	Yoğun Bakım Yatışına İlişkin Temel Bilgiler
PATIENTS	Hastalara İlişkin Temel Bilgiler
SERVICES	Hastaların Servis Transfer Bilgileri
TRANSFERS	Hastaların Oda Transfer Bilgileri
CAREGIVERS	Tıbbi Görevli Bilgileri
CHARTEVENTS	Zaman Bağımlı Grafik Veriler
DATETIMEEVENTS	Zaman Verileri
INPUTEVENTS.CV	Philips CareVue Sisteminden Elde Edilen Ölçümler
INPUTEVENTS.MV	iMDSof Metavision Sisteminden Elde Edilen Ölçümler
NOTEVENTS	Tanımlanmamış Not Verileri (EKG, Radyoloji ve Taburcu Notları gibi)
OUTPUTEVENTS	Çıktı Verileri
PROCEDUREEVENTS.MV	Metavision Sisteminde Yer Alan İşlemler #125
CPTEVENTS	Faturalandırma Amacıyla Kullanılan CPT Kodları #1000
DIAGNOSES.ICD	ICD-9 Tanı Kodları
DRGCODES	DRG Teşhis Kodları #467
LABEVENTS	Laboratuvar Ölçümleri
MICROBIOLOGYEVENTS	Mikrobiyoloji Ölçümleri
PRESCRIPTIONS	Reçete Kayıtları
PROCEDURES.ICD	ICD-9 Tıbbi İşlem Kodları
D.CPT	CPT Kodu Açıklamaları
D.ICD.DIAGNOSES	ICD-9 Teşhis Kodu Açıklamaları
D.ICD.PROCEDURES	ICD-9 Tıbbi İşlem Kodu Açıklamaları
D.ITEMS	Ölçüm Öğelerinin Kod Açıklamaları
D.LABITEMS	Labaratuvar Ölçüm Öğelerinin Açıklamaları

Tablo 2.2 En Sık Görülen 50 ICD-9 Kodu Açıklamaları

ICD9 Kodu	Sayı	Kısa İsim	Uzun İsim	Tipi
4019	15030	Hypertension NOS	Unspecified essential hypertension	Tanı
3893	9476	Venous cath NEC	Venous catheterization, not elsewhere classified	Tıbbi İşlem
41401	9393	Crnry athrscrl natve vssl	Coronary atherosclerosis of native coronary ar...	Tanı
42731	8758	Atrial fibrillation	Atrial fibrillation	Tanı
4280	7933	CHF NOS	Congestive heart failure, unspecified	Tanı
3961	6177	Extracorporeal circulat	Extracorporeal circulation auxiliary to open heart surgery	Tıbbi İşlem
9604	6165	Insert endotracheal tube	Insertion of endotracheal tube	Tıbbi İşlem
25000	6113	DMII wo cmp nt st uncntr	Diabetes mellitus without mention of complicat...	Tanı
2724	6034	Hyperlipidemia NEC/NOS	Other and unspecified hyperlipidemia	Tanı
5849	5695	Acute kidney failure NOS	Acute kidney failure, unspecified	Tanı
966	5388	Enteral infus nutrit sub	Enteral infusion of concentrated nutritional substances	Tıbbi İşlem
9671	5340	Cont inv mec ven ;96 hrs	Continuous invasive mechanical ventilation for less than 96 consecutive hours	Tıbbi İşlem
9904	4967	Packed cell transfusion	Transfusion of packed cells	Tıbbi İşlem
51881	4904	Acute respiratry failure	Acute respiratory failure	Tanı
8856	4447	Coronar arteriogr-2 cath	Coronary arteriography using two catheters	Tıbbi İşlem
2720	4388	Pure hypercholesterolem	Pure hypercholesterolemia	Tanı
5990	4312	Urin tract infection NOS	Urinary tract infection, site not specified	Tanı
9672	4249	Cont inv mec ven 96+ hrs	Continuous invasive mechanical ventilation for 96 consecutive hours or more	Tıbbi İşlem
53081	4138	Esophageal reflux	Esophageal reflux	Tanı
3615	4086	1 int mam-cor art bypass	Single internal mammary-coronary artery bypass	Tıbbi İşlem
2859	3738	Anemia NOS	Anemia, unspecified	Tanı
2851	3310	Ac posthemorrhag anemia	Acute posthemorrhagic anemia	Tanı
3891	3191	Arterial catheterization	Arterial catheterization	Tıbbi İşlem
486	3134	Pneumonia, organism NOS	Pneumonia, organism unspecified	Tanı
2449	3086	Hypothyroidism NOS	Unspecified acquired hypothyroidism	Tanı
2762	2818	Acidosis	Acidosis	Tanı
3722	2768	Rflx sym dystroph lwr lmb	Reflex sympathetic dystrophy of the lower limb	Tanı
8872	2749	Dx ultrasound-heart	Diagnostic ultrasound of heart	Tıbbi İşlem
496	2733	Chr airway obstruct NEC	Chronic airway obstruction, not elsewhere clas...	Tanı
5070	2567	Food/vomit pneumonitis	Pneumonitis due to inhalation of food or vomitus	Tanı
3051	2485	Tobacco use disorder	Tobacco use disorder	Tanı
41071	2358	Subendo infarct, initial	Subendocardial infarction, initial episode of ...	Tanı
3324	2348	Closed bronchial biopsy	Closed [endoscopic] biopsy of bronchus	Tıbbi İşlem
99592	2330	Severe sepsis	Severe sepsis	Tanı
3723	2266	Conjunctivitis NOS	Conjunctivitis, unspecified	Tanı
V5861	2231	Long-term use anticoagul	Long-term (current) use of anticoagulants	Tanı
0389	2203	Septicemia NOS	Unspecified septicemia	Tanı
4240	2148	Mitral valve disorder	Mitral valve disorders	Tanı
9915	2120	Parent infus nutrit sub	Parenteral infusion of concentrated nutritional substances	Tıbbi İşlem
311	2116	Depressive disorder NEC	Depressive disorder, not elsewhere classified	Tanı
2875	2091	Thrombocytopenia NOS	Thrombocytopenia, unspecified	Tanı
2761	2039	Hyposmolality	Hyposmolality and/or hyponatremia	Tanı
5859	2037	Chronic kidney dis NOS	Chronic kidney disease, unspecified	Tanı
412	2004	Old myocardial infarct	Old myocardial infarction	Tanı
4241	2002	Partial esophagectomy	Partial esophagectomy	Tıbbi İşlem
40390	1976	Hy kid NOS w cr kid I-IV	Hypertensive chronic kidney disease, unspecifi...	Tanı
9971	1929	Therapeu plasmapheresis	Therapeu plasmapheresis	Tıbbi İşlem
4513	1920	Sm bowel endoscopy NEC	Other endoscopy of small intestine	Tıbbi İşlem
5119	1885	Biliary tr dx proc NEC	Other diagnostic procedures on biliary tract	Tıbbi İşlem
V1582	1873	History of tobacco use	Personal history of tobacco use	Tanı



Şekil 2.1 Filtrenilmiş Veri Kümesinde En Sık Görülen 50 ICD Kodu Sayıları



Şekil 2.2 Tüm Veri Kümesinde En Sık Görülen 50 ICD Kodu Sayıları

3. LİTERATÜR ÖZETİ

Bu alanda kullanılan geleneksel yöntemler, matematiksel bir formülle temsil edilen skorlama yöntemleridir. Hekimler tarafından belirlenmiş bazı kısıtlı öznitelikler kullanılarak hesaplanan skorlar, hastaların sağlık durumlarının kritiklik seviyesini ölçerek, yoğun bakım ünitesindeki ölüm/yaşam durumlarını tahmin etmede sağlık çalışanlarına yardımcı olmaktadır. Bu yöntemlerin başında SAPS [16], SOFA [17] ve APACHE [18] yöntemleri gelmektedir. Tablo 3.1’de bu üç yöntemde kullanılan özniteliklere yer verilmiştir.

Makine öğrenimi algoritmalarının başarılarının artmasıyla birlikte geleneksel yöntemlerden daha üstün sonuçlar üretebilecek yöntemler de öne sürülmüştür. Purushotham ve arkadaşları [10] bu alanda kullanılan literatürdeki çeşitli makine öğrenimi ve derin öğrenme yöntemlerini karşılaştırmış ve geleneksel skorlama yöntemlerine göre daha başarılı sonuçlar elde edildiğini göstermişlerdir. Söz konusu çalışmada derin öğrenme yöntemi olarak zamana bağlı verilerden kestirim yapmak için GRU tabanlı bir model kullanılmıştır. Ayrıca, MIMIC-III veri kümesi kullanılarak, farklı sayısal özniteliklere sahip üç ayrı alt veri kümesi oluşturulmuş, her bir veri kümesi için hastane mortalitesi, kısa zamanlı mortalite, uzun zamanlı mortalite, hastanede kalma süresi ve ICD kodu tahminleme görevleri analiz edilmiştir. İlk veri kümesinde SAPS skorlama sisteminde kullanılan 17 öznitelik, ikinci veri kümesinde SAPS skorlama sisteminde kullanılan özniteliklerin elde edildiği 20 ham öznitelik ve üçüncü veri kümesinde ise skorlama sistemlerinden bağımsız olarak 136 ham öznitelik kullanılmıştır. Sonuç olarak, özellikle öznitelik sayısının fazla olduğu ve ham verilerin kullanıldığı deneylerde derin öğrenme tabanlı yöntemlerin hem diğer makine öğrenimi hem de skorlama yöntemlerine göre, ele alınan her bir görev için daha başarılı sonuçlar ürettikleri ortaya konulmuştur. Dolayısıyla, bu tez çalışmasında da sayısal verilerden tahminleme görevi için en sık görülen 136 ham veri kullanılmıştır.

Elektronik sağlık kayıtlarını içeren veri kümeleri sadece sayısal verilerden oluşmamaktadır; bu veri kümelerinin çoğunda hastane başvurusu ve yatış esnasında elde edilen klinik notlara da rastlamak mümkündür. Özellikle MIMIC-III veri kümesinin büyük çoğunluğunun bu

Tablo 3.1 Skorlama Sistemlerinde Kullanılan Öznitelikler ve MIMIC-III Tabloları

Öznitelik	MIMIC-III Öznitelik No	MIMIC-III Öznitelik İsmi	MIMIC-III Tablo İsmi
Glasgow Koma Skalası	723	GCSVerbal	chartevents
	454	GCSMotor	chartevents
	184	GCS Eyes	chartevents
	223900	Verbal Response	chartevents
	223901	Motor Response	chartevents
	220739	Eye Opening	chartevents
Sistolik kan basıncı	51	Arterial BP [Systolic]	chartevents
	442	Manual BP [Systolic]	chartevents
	455	NBP [Systolic]	chartevents
	6701	Arterial BP #2 [Systolic]	chartevents
	220179	Non Invasive Blood Pressure systolic	chartevents
	220050	Arterial Blood Pressure systolic	chartevents
Kalp Atış Hızı	211	Heart Rate	chartevents
	220045	Heart Rate	chartevents
Vücut Isısı	678	Temperature F	chartevents
	223761	Temperature Fahrenheit	chartevents
	676	Temperature C	chartevents
	223762	Temperature Celsius	chartevents
PO2/FiO2 Oranı	50821	PO2	labevents
	50816	Oxygen	labevents
	223835	Inspired O2 Fraction (FiO2)	chartevents
	3420	FiO2	chartevents
	3422	FiO2 [Meas]	chartevents
	190	FiO2 set	chartevents
İdrar Çıktısı	40055	Urine Out Foley	outputevents
	43175	Urine	outputevents
	40069	Urine Out Void	outputevents
	40094	Urine Out Condom Cath	outputevents
	40715	Urine Out Suprapubic	outputevents
	40473	Urine Out IleoConduit	outputevents
	40085	Urine Out Incontinent	outputevents
	40057	Urine Out Rt Nephrostomy	outputevents
	40056	Urine Out Lt Nephrostomy	outputevents
	40405	Urine Out Other	outputevents
	40428	Orine Out Straight Cath	outputevents
	40086	Urine Out Incontinent	outputevents
	40096	Urine Out Ureteral Stent #1	outputevents
	40651	Urine Out Ureteral Stent #2	outputevents
	226559	Foley	outputevents
	226560	Void	outputevents
	226561	Condom Cath	outputevents
	226584	Ileoconduit	outputevents
	226563	Suprapubic	outputevents
	226564	R Nephrostomy	outputevents
	226565	L Nephrostomy	outputevents
	226567	Straight Cath	outputevents
226557	R Ureteral Stent	outputevents	
226558	L Ureteral Stent	outputevents	
227488	GU Irrigant Volume In	outputevents	
227489	GU Irrigant/Urine Volume Out	outputevents	
Serum Ure veya BUN	51006	Urea Nitrogen	labevents
WBC	51300	WBC Count	labevents
	51301	White Blood Cells	labevents
HCO3	50882	BICARBONATE	labevents
Sodium Seviyesi	950824	Sodium Whole Blood	labevents
	50983	Sodium	labevents
Potassium Seviyesi	50822	Potassium, whole blood	labevents
	50971	Potassium	labevents
Bilirubin Seviyesi	50885	Bilirubin Total	labevents
Yaş	-	intime	icustays
	-	dob	patients
Edinsel Bağışıklık Yetmezliği Sendromu	-	icd9_code	diagnoses_icd
Hematolojik Neoplazi	-	icd9_code	diagnoses_icd
Metastatik Kanser	-	icd9_code	diagnoses_icd
Yatış Şekli	-	curr_service	services
	-	ADMISSION_TYPE	admissions

notlardan oluştuğu söylenebilir. Dolayısıyla, derin öğrenme yöntemlerinin doğal dil işleme literatüründeki etkinliğinin artmasıyla birlikte bu alanda da çeşitli çalışmalar yürütülmüş ve klinik sağlık raporlarını temel alan kestirim yöntemleri geliştirilmiştir.

Huang ve arkadaşlarının [19] çalışmasında 30 günlük hastane geri yatış tahminlemesi için bir BERT [20] modeli öne sürülmüştür. Bu çalışmada MIMIC-III veri kümesinde bulunan

tahliye notları ve yoğun bakım süresince toplanan EKG ve radyoloji raporları gibi diğer klinik notlar kullanılmıştır. ClinicalBERT adı verilen bu yöntem ile yoğun bakım yatışı esnasındaki herhangi bir zamana kadar elde edilen metin tabanlı verilerle, hastanın tahliyesi durumunda geri yatış süresinin kestirimini yapmak mümkün kılınmıştır. ClinicalBERT modeli klinik alanda özelleştirilmiş bir BERT modelidir. BERT modeli transformatör kodlayıcı temelli bir yöntem olup, kelimelerin veya yazı öbeklerinin bağlamsal özellikleri gözetilerek vektörel hale getirilmesini sağlayan bir derin öğrenme modelidir. Bu model diğer derin öğrenme tabanlı doğal dil işleme yöntemlerinin aksine kelime dizilerini sağdan sola ve soldan sağa olmak üzere çift yönlü ele almaktadır, böylelikle kelimeler arasındaki ilişkinin daha keskin bir şekilde kestirilmesi hedeflenmiştir. Temel BERT modeli Wikipedia veri kümesi üzerinde eğitildiği ve söz konusu veri kümesinin medikal cümleleri tam anlamıyla temsil etmediği için önceden eğitilmiş BERT modelini kullanmak yerine MIMIC-III veri kümesi ilgili tabloları ile tekrardan bir model eğitimi gerçekleştirilmiştir. Temel BERT modelinin detaylı açıklamasına Bölüm 4.2.5.'den ulaşılabilir. Çalışmada elde edilen sonuçlar incelendiğinde ClinicalBERT modelinin, BERT, Bag-of-words ve BI-LSTM yöntemlerine oranla daha başarılı çıktılar ürettiği söylenebilir.

Jin ve arkadaşları [21] tarafından yayınlanan bir çalışmada ise hem metinsel hem de sayısal veriler aynı anda kullanılmıştır. Çok modlu bir derin öğrenme yönteminin öne sürüldüğü bu çalışmada hastane mortalitesi görevi ele alınmıştır. Sayısal veriler için bir LSTM modeli, metin tabanlı veriler için ise Doc2VecC [22] temelli bir derin öğrenme yöntemi kullanılmıştır. Eğitim aşamasında bu iki model birbirine bağlanmış ve iki modelin çıktısı olarak elde edilen vektörler tek bir vektörde birleştirilerek tam bağlantılı katmana giridi olarak verilmiştir. Böylelikle aynı anda hem sayısal hem de metinsel veriler aynı anda öğretilmiştir. Sayısal veriler için kullanılan LSTM temelli derin öğrenme ağına her bir hastanın 17 özniteliği için ilk 48 saat boyunca ikişer saatlik periyotlarla örneklendirilmiş zaman bağımlı verisi giridi olarak verilmiştir. Bu tez çalışması da çok araçlı bir yaklaşıma sahip olması dolayısıyla Jin ve arkadaşlarının çalışması ile paralellik göstermektedir. Ancak söz konusu çalışmada hastane mortalitesini tahminleme görevine yoğunlaşılırken, bu tez çalışmasında ise mortalite tahminlemesi yerine, ICD kodlarının tahminlemesi görevi üzerinde çalışılmıştır. Dolayısıyla,

Jin ve arkadaşlarının çalışması iki sınıflı tek etiketli bir görev olup, bu çalışma çok sınıflı çok etiketli bir problemin çözümünü hedeflemektedir. Jin ve arkadaşlarının çalışmasında, metin tabanlı verilerin öğrenilebilmesi için kullanılan derin öğrenme ağında, cümlelerin öğelerştirilebilmesi edilebilmesi amacıyla medikal NER tabanlı bir servis kullanılmıştır [23]. Sözlüksel öğelerştirilmiş metinler Doc2vecC modeline girdi olarak verilmiştir. Doc2vecC modeli bütün metnin vektörel bir temsilini çıkarmaya yönelik bir yöntemdir. Bu modelin eğitiminde her bir kelime çıktısı komşu kelimelerin yanı sıra rastgele seçilmiş kelimeler de girdi olarak verilmektedir. Rastgele vektörlerin de kullanılmasının yan etkisi olarak kelime vektörlerinin ortalamalarının doküman vektörünü temsil etmesi hedeflenmiştir. Doc2vecC modelinin sadece komşu kelimelerle eğitildiği düşünülüğünde, Doc2vecC modelinin doküman vektörünü temsil etmede daha başarılı olduğunu söylemek mümkündür. Ayrıca model, henüz eğitilmemiş yeni veriler için daha az efor gerektirmektedir. Genellikle duygu analizi, doküman sınıflandırma ve anlamsal ilişkinlik görevleri için kullanılan bu yöntem, çalışmada klinik metinlerin temsili için kullanılmıştır. MIMIC-III veri kümesinin kullanıldığı bu çalışmanın sonucu olarak, bu tarz bir çok modlu derin öğrenme yönteminin hastane mortalitesinin kestirimi konusunda karşılaştırılan diğer tek tip (sayısal veya metinsel) yöntemlere göre %2 daha başarılı bir sonuç verdiği gösterilmiştir.

Vu ve arkadaşları [13] metin verilerinden ICD kodunun kestirimi için etiket dikkat mekanizmalı bir derin öğrenme modeli önermişlerdir. Bu çalışmada, temel doğal dil işleme yöntemi olarak word2vec kullanılmıştır. Ayrıca, klinik notlardaki kelimelerin bağlamsal özelliklerini elde edebilmek amacıyla word2vec kelime vektörlerini girdi olarak alan bir BiLSTM modeli konumlandırılmıştır. Dikkat mekanizması için ise BiLSTM katmanının ardından etiket dikkat katmanı uygulanmış ve çıktı olarak kullanılacak her bir ICD kod etiketi için farklı bir vektör üretebilen yapı elde edilmiştir. Etiket dikkat katmanı olarak, Lin ve arkadaşları [24] tarafından önerilmiş olan biçimlendirilmiş öz-dikkat mekanizması temel alınmıştır. En sık görülen 50 ICD-9 kodu temel alındığında, bu çalışmanın sonuçlarının diğer dikkat mekanizmalı ağlara oranla daha başarılı sonuçlar verdiği görülmektedir.

Reys ve arkadaşları [25] da metin verilerinden ICD kodu tahminlemesi görevi için word2vec modelini temel alan çeşitli sınıflandırıcılar oluşturmuşlardır. MIMIC-III veri

kümesinden elde ettikleri metin bazlı raporlar ile bir sözlük oluşturmuşlar ve word2vec modelinin eğitimini tamamlamışlardır. Word2vec ile elde ettikleri rapor vektörlerini ise üç farklı sınıflandırıcı ile test etmişlerdir. Bu sınıflandırıcılar; evrişimsel sinir ağı tabanlı sınıflandırıcı, dikkat mekanizmalı evrişimsel sinir ağı tabanlı sınıflandırıcı ve GRU tabanlı bir sınıflandırıcıdır.

Yang ve arkadaşları [15] ise Longformer yöntemini temel alan *Knowledge Enhanced Prompt (KEPT)* yöntemi ile güçlendirilmiş bir derin öğrenme yöntemi önermişlerdir. DDİ yöntemi olarak Longformer tabanlı bir yöntem seçmelerini MIMIC-III veri kümesinde yer alan metinlerin diğer yöntemlerle tam olarak temsil edilemeyecek kadar büyük olmasıyla açıklamışlardır. Bu yöntemde, metinleri Longformer modeline girdi olarak verirken aynı zamanda ICD kod sınıflarının da bölütlenmiş hallerini de girdi olarak vermişlerdir. Dolayısıyla modelin MIMIC-III veri kümesinde yer alan metinlerle birlikte ICD kodlarını da öğrenmesini amaçlamışlardır.

Tablo 3.2 bu tez çalışmasında değerlendirilen literatür çalışmalarının hedef, kullanılan veri kümesi tipi ve DDİ yöntemi açısından kıyaslamasını göstermektedir.

Tablo 3.2 Literatürdeki çalışmaların Kıyaslanması

Çalışma	Yıl	Tahminleme Görevi					Veri Tipi			Kullanılan Temel Yöntem				
		ICD-9 Kod	ICD-9 Kod Grubu	Ölüm Oranı	Yatış Süresi	Hasta Geri Yatışı	Yapılandırılmış Sayısal	Yapılandırılmamış Metin	Her ikisi de	Doc2Vec	Doc2VecC	Bert	Word2Vec	Longformer
S. Purushotham [10]	2017	✓	✓	✓			✓		✓					
Mengqi Jin [21]	2018			✓				✓		✓				
J. Mullenbach [12]	2020	✓					✓					✓		
Kexin Huang [19]	2020					✓	✓				✓			
L. Franz [26]	2020	✓	✓				✓	✓			✓			
Thanh Vu [13]	2020	✓					✓					✓		
Arthur D. Reys [25]	2020	✓					✓							
Yang Liu[27]	2021	✓					✓				✓	✓		
Zhichao Yang [15]	2022	✓					✓						✓	
Zheng Yuan[14]	2022	✓					✓					✓		
Bu Tez Çalışması		✓						✓			✓	✓	✓	

4. KULLANILAN DERİN ÖĞRENME MODELLERİ

Yukarıdaki bölümlerde aktarıldığı gibi, bu tez kapsamında, hem doğal dil işleme hem de zaman serileri tabanlı derin öğrenme modelleri kullanılmıştır. Metin bazlı verilerin doğal dil işleme, sayısal verilerin ise zaman serileri modelleri ile sonuçlara katkı sağlamaları hedeflenmiştir. Bölüm 4.1.'de zaman serileri, Bölüm 4.2.'de ise doğal dil işleme çalışmalarında kullanılan modellerin detaylı incelemeleri mevcuttur. Bu noktada asıl amaç, her iki veri tipi için de girdi olarak verilen özniteliklerin kodlama vektörleriyle temsil edilmesidir.

4.1. Zaman Serileri İçin Kullanılan Derin Öğrenme Yöntemleri


Hastane yatışları esnasında tahlil ve elektronik ölçümler başta olmak üzere birçok sayısal veri toplanmaktadır. Bu sayısal verilerin çoğu hastaların durum değişimlerini analiz edebilmek için belirli bir periyot içerisinde sürekli olarak tekrarlanmaktadır. Dolayısıyla, bu verileri zamana bağlı olarak değerlendirmek gerekmektedir. Günümüzde zaman serileri için kullanılan bazı yöntemler aşağıda sıralanmıştır.

4.1.1. RNN


Yinelemeli sinir ağları (Recurrent Neural Networks) zaman serileri ile tahminleme yapma görevlerinde kullanılan temel derin öğrenme modellerinden biridir. Zaman serilerinin kestirimini temellerini oluşturan bu yöntemin ileri beslemeli ve evrişimli sinir ağlarından farkı bir hafıza mekanizmasına sahip olmasıdır. Bu hafıza mekanizması, hücrelerdeki girdilerin birbirlerine bağlı olmasıyla sağlanmaktadır. Zaman serisindeki t anındaki bir değişken için $t-1$ anındaki değişkenden hafıza değeri aktarılmaktadır, böylelikle modelin eğitim aşamasında hafıza vektörünün de öğrenilmesi sağlanmaktadır.

Klasik RNN model diyagramı Şekil 4.1'de bulunmaktadır. Diyagramda yer alan x^t t anındaki girdi değişkenini, y^t t anındaki çıktı değişkenini ve a^t ise t anındaki hafıza değişkenini

temsil etmektedir. Ancak bu çalışmada ele alınan görev, hastane yatışının tamamlanmasının ardından elde edilen ICD kodunun tahminlenmesine dayanmaktadır. Dolayısıyla her bir t anındaki çıktı kestiriminden ziyade, yalnızca $t+1$ anındaki çıktının kestirimi sağlanmalıdır. Bu tarz tahminleme görevlerine uygun olan yapı Şekil 4.2’de görülebilir. Bu şekilde de x^t t anındaki girdi değişkenini, a^t t anındaki hafıza değişkenini ve y^t ise t anındaki çıktı değişkenini temsil etmektedir.



Şekil 4.1 Klasik RNN Diyagramı



Şekil 4.2 Zaman Serileri Sınıflandırıcısı Olarak Kullanılan RNN Diyagramı

Şekil 4.3’te örneği gösterilen her bir hücrenin çıktısı Denklem 1 ile temsil edilmektedir.


$$a_t = f(a_{t-1}, x_t) \quad (1)$$

Vektörel olarak, bir aktivasyon fonksiyonu ile birlikte çıktı için Denklem 2 ortaya çıkmaktadır. Denklemde yer alan A hafıza vektörlerini, X girdi vektörlerini, W ise bu

vektörlerin katsayı vektörlerini temsil etmektedir. Denklemden aktivasyon fonksiyonu olarak tanh kullanılmıştır.

$$A_t = \text{aktivasyon}(W_{aa}A_{t-1} + W_{xa}X_t) \quad (2)$$

Şekil 4.3'te ise bir RNN hücresinin iç yapısı gösterilmiştir. RNN hücresi t anında girdi olarak x^t değişkenini almakta, bir önceki hücreden gelen a^t değişkeni ile çarpmakta ve elde edilen değeri tanh aktivasyon fonksiyonundan geçirerek hem o hücrenin çıktısını, hem de bir sonraki hücreye aktarılacak olan değeri temsil eden y^t ve a^t değişkenlerini üretmektedir.



Şekil 4.3 RNN hücresi [1]

4.1.2. Uzun-Kısa Vadeli Bellek (LSTM)

Bölüm 4.1.1.'te açıklanan RNN mimarisi, yapısı itibariyle bazı dezavantajlara sahiptir. Bu dezavantajların en temelinde kaybolan gradyan problemi yer almaktadır. Derin öğrenme literatüründe sıkça yer alan kaybolan gradyan problemi, kullanılan aktivasyon fonksiyonundan elde edilen değerler sifıra yakın olduğu için, ardışık tekrarlayan her bir işlem sonrası sifıra daha da yakınsaması durumudur. RNN yapılarında da, Denklem 2'den de anlaşılacağı üzere, zaman serilerinin uzunluğu arttıkça her bir hücrede elde edilen çıktı sifıra yakınsamaktadır, dolayısıyla önceki hücrelerden gelen hafıza bilgisi de kaybolmaktadır. Bu sorunun çözümü için LSTM ve GRU modelleri öne sürülmüştür. LSTM modelinde, RNN

modeline ek olarak unutma kapısı (forget gate), girdi kapısı (input gate), hücre durumu (cell state) ve çıktı kapısı (output gate) adı verilen yapılar kullanılmıştır. Şekil 4.4'te bu yapılarda kullanılan matematiksel ifadelerin yer aldığı görsel bulunmaktadır.

Unutma kapısı bilginin ne kadarının unutulacağını belirlemek için kullanılmaktadır. Bu kapıda bir önceki hücreden gelen değer (a_{t-1}), güncel değer (x_t) ile birleştirilerek sigmoid fonksiyona girdi olarak verilmektedir, sigmoid fonksiyondan elde edilen çıktı (f_t) sıfıra ne kadar yakınsa bilginin o kadar unutulacağı anlamı taşımaktadır.

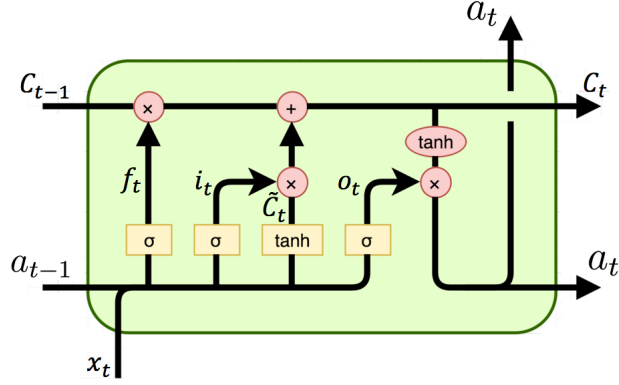
Girdi kapısı ise hücre durumunu güncellemek için kullanılmaktadır. Bir önceki hücreden gelen bilgi (a_{t-1}) güncel bilgi (x_t) ile birleştirilir ve unutma kapısında olduğu gibi bir sigmoid fonksiyonuna girdi olarak verilir. Girdi kapısından elde edilen değer (i_t) bire ne kadar yakınsa hücre durumunun o kadar güncelleneceği anlaşılmaktadır. Ek olarak, ağı düzenlemek için tanh fonksiyonu kullanılmaktadır. Tanh ve sigmoid fonksiyonlarından elde edilen değerler çarpılarak girdi kapısının çıktısı oluşturulmaktadır.

Hücre durumu taşınacak bilgilerin belirlenmesi için kullanılan bir yapıdır. Bu yapıda unutma kapısının çıktısı (f_t) bir önceki hücrenin çıktısıyla (c_{t-1}) çarpılır ve bu değer mevcut hücrenin girdi kapısından elde edilen değerle birleştirilir (c_t). Böylelikle bir sonraki hücreye aktarılacak (c_t) belirlenir.

Çıktı kapısı hücre durumu ile beraber bir sonraki hücreye aktarılacak bilgiyi belirler. Bu kapıda, bir önceki hücreden elde edilen veri (a_{t-1}) mevcut bilgi (x_t) ile birleştirilerek sigmoid fonksiyonundan geçer, sigmoid fonksiyonundan elde edilen değer (o_t) ise hücre durumunun alınılan değer tanh fonksiyonu uygulanmış hali ile birleştirilerek bir sonraki hücreye aktarılır (a_t).

4.1.3. GRU

GRU modeli, LSTM ile benzer bir yapıdadır. Bu modelde de çeşitli kapılar aracılığıyla RNN mimarisinde ortaya çıkan problemlerin çözümü hedeflenmiştir. GRU modelinde LSTM



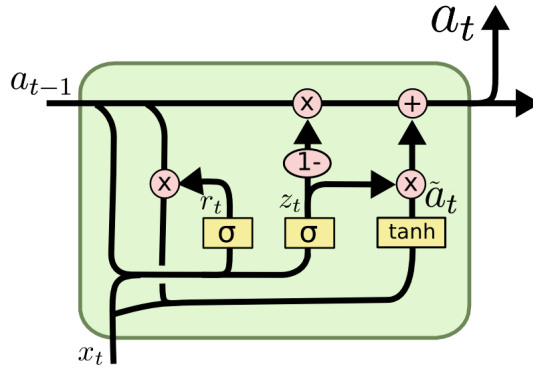
Şekil 4.4 LSTM hücresi [1, 2]

modelindeki kapılar yerine sıfırlama (reset gate) ve yenileme (update gate) kapıları olmak üzere iki tipte kapı yapısı kullanılmaktadır.

Güncelleme kapısı hangi bilgilerin atılacağına ve hangi bilgilerin korunacağına karar vermek için kullanılmaktadır.

Sıfırlama kapısı ise önceki hücrelerden ve güncel girdiden elde edilen bilgilerin ne kadarının unutulacağına karar vermek için kullanılmaktadır.

Şekil 4.5'te bir GRU hücresindeki matematiksel işlemlerin temsili bulunmaktadır.

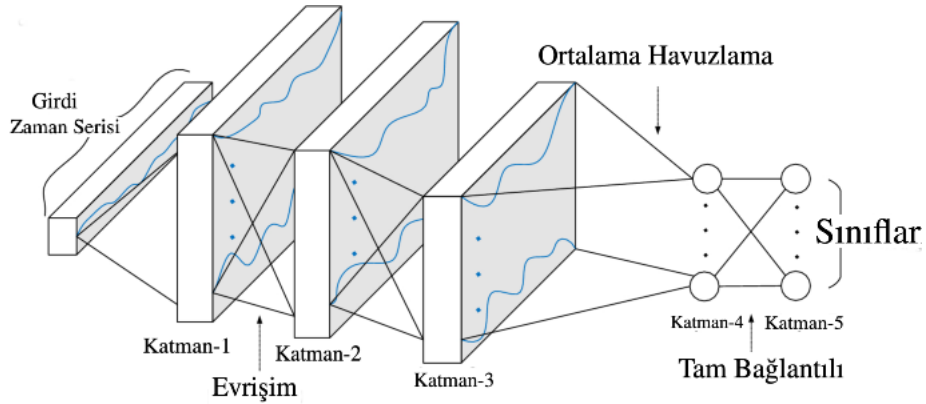


Şekil 4.5 GRU hücresi [1, 3]

4.1.4. Evrişimli Sinir Ağları

Günümüzde, genellikle nesne sınıflandırma ve bölütleme gibi çeşitli görüntü işleme görevleri için kullanılan evrişimli sinir ağları, tek boyutlu ve zamana bağlı verilerden kestirim yapmak için de kullanılmaktadır. Bu noktada kullanılan sinir ağları genellikle 1 boyutlu evrişimsel katmanlardan oluşmaktadır. Evrişimsel katmanlarda ardışık verilerin birbirleriyle olan ilişkileri temel alınarak girdi vektörüne kıyasla daha düşük özniteliğe sahip olan bir vektör üretilmektedir. Ağların çıktısından elde edilen bu yapı öznitelik öğrenme mekanizması olarak değerlendirilebilir. Genellikle ses ve finansal verilerin analizi gibi görevler için kullanılan tek boyutlu evrişimsel sinir ağları zamana bağlı yapısı itibariyle sayısal tıbbi verilerden otomatik tahminleme görevi için de kullanılabilir. Ayrıca bu alanda gerçekleştirilen bazı çalışmalarda GRU ve LSTM gibi modeller ile birlikte de kullanılarak daha keskin bir sonuç elde edilmesi de hedeflenmiştir [28, 29].

Şekil 4.6'da zaman serileri için kullanılan basit bir 1 boyutlu evrişimsel sinir ağı yapısı mevcuttur, bu yapıda ardışık n elemanlı bir seri sisteme girdi olarak verilmekte, üç adet evrişimsel katman ve bir adet ortalama havuzlama katmanı kullanılarak öznitelik vektörü elde edilmektedir. Sonraki katmanda ise sınıflandırıcı amacıyla tam bağlantılı katman kullanılmıştır.



Şekil 4.6 Örnek Evrişimsel Sinir Ağı [4]

4.2. Doğal Dil İşleme İçin Kullanılan Derin Öğrenme Yöntemleri

Dokümanlardan öznitelik öğrenimi doğal dil işleme çalışmaları kapsamında değerlendirilmiştir [30]. Bu öznitelikler öğrenilirken genel metin anlamlarını göz önünde bulundurmak gerekmektedir; birbirine yakın anlamlara sahip metinler benzer vektörlerle temsil edilmeli, birbirine zıt anlamlara sahip metinler ise karşıt vektörlerle temsil edilmelidir.

Doğal dil işleme yöntemlerinin temelinde bir sözlük oluşturmak ve bu sözlükte yer alan her bir eleman için sayısal bir vektör temsiliyetini elde etmek yatmaktadır. Ancak bu vektörlerin kelime anlamlarını temsil edebilme özelliği olmalıdır. Örneğin “kral” ve “kraliçe” kelimelerini temsil eden vektörler birbirlerine yakın doğrultuda olmalıdır. Ayrıca, matematiksel olarak; “kral” vektöründen “adam” vektörü çıkarılıp “kadın” vektörü eklendiğinde yaklaşık olarak “kraliçe” vektörünü vermelidir.

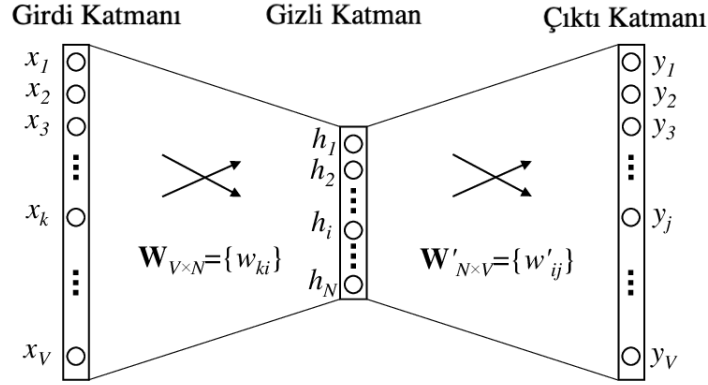
4.2.1. Word2Vec

2013 yılında literatürde yerini alan Word2Vec [31] yöntemi en temel derin öğrenme tabanlı doğal dil işleme yöntemlerinden biridir. Word2Vec yöntemi, metinler içerisindeki kelimelerin sıra ve bağlam özelliklerini gözeterek her bir kelime için sayısal bir vektör elde etmeye yarayan bir gözetimsiz öğrenme yöntemidir. Bu yöntemde, metin bazlı eğitim verilerindeki her bir sözcüğü içeren bir sözlük oluşturulur ve her biri için ayrı *bire bir kodlama* vektörleri üretilir. Bu vektörler sözlükteki kelime sayısı boyutundadır. Vektör içerisindeki her bir kelimenin ait olduğu eleman 1 geri kalan 0 olarak temsil edilmektedir. “Elma bir meyvedir” sözlüğü ile oluşturulan basit bir veri kümesindeki kelimeler için çıkarılan bire bir kodlama vektör örnekleri Tablo 4.1’de bulunabilir.

Tablo 4.1 Bire bir kodlama Örneği

elma	bir	meyvedir
1	0	0
0	1	0
0	0	1

Word2Vec modelinde, vektörler çıkarıldıktan sonra, her bir kelime vektörü modele girdi olarak, verilen her kelimenin komşu kelime vektörleri ise çıktı olarak verilmektedir. Böylelikle saklı katmanda elde edilen vektörün bağlamsal olarak temsil edildiği bir vektör elde edilmesi hedeflenmiştir. Şekil 4.7’de Word2Vec’e dair basit bir diyagram bulunmaktadır.




Şekil 4.7 Word2Vec Diyagramı [5]

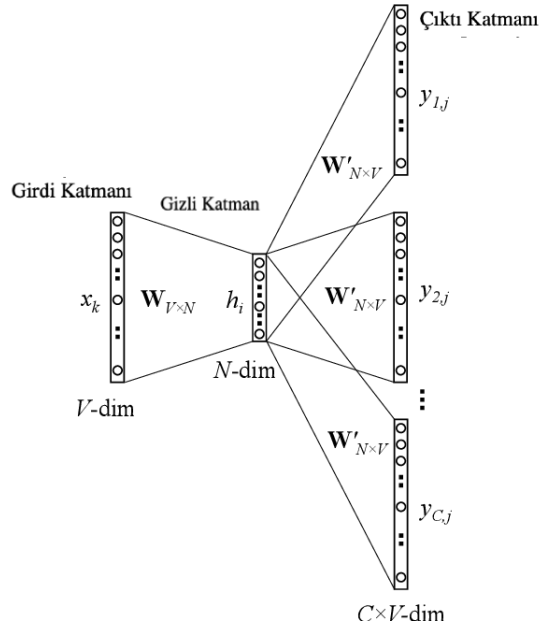
Word2Vec modelinde komşuluk ilişkileri açısından farklılaşan 2 adet yöntem kullanılabilir. Bunlar CBOW ve Skip-Gram olarak adlandırılmaktadır. İki yöntemde de ortak olarak pencere boyutu parametresi bulunmaktadır. Bu parametre her bir iterasyonda ele alınacak olan kelime sayısını belirlemektedir. CBOW yönteminde pencerenin ortasındaki kelime çıktı olarak kullanılmakta geri kalan kelimeler ise girdi olarak kullanılmaktadır (Şekil 4.8).

Skip-gram yönteminde ise pencerenin ortasındaki kelime girdi olarak kullanılmakta geri kalan kelimeler ise çıktı olarak kullanılmaktadır. (Şekil 4.9) Skip-gram yöntemi CBOW yöntemine göre daha yavaş olsa da, daha nadir rastlanan kelimelerin temsilinde başarı oranı daha yüksektir. Skip gram modelindeki amaç girdi olarak verilen her bir kelime için bağlam kelimelerinin tahmin edilme oranını en yüksek düzeye çıkarmaktır. Dolayısıyla, w_1, w_1, \dots, w_T dizisi için pencere boyutu olarak c kullanıldığında amaç fonksiyonu Denklem 3 ile temsil edilebilir.

$$\frac{1}{T} \sum_{t=1}^T \sum_{n=-c, n \neq 0}^{+c} \log p(w_{t+n}|w_t) \quad (3)$$



Şekil 4.8 CBOW Diyagramı [5]



Şekil 4.9 Skip-Gram Diyagramı [5]

Sonuç olarak, Word2Vec modeli, yukarıda bahsedilen iki yöntemden biri kullanılarak eğitildiğinde modelin ortasında yer alan saklı katmanda N boyutlu bir vektör oluşmaktadır.

Bu vektör, sözlükteki kelimelerin her biri için bağlam vektörlerini temsil etmektedir. Bu yöntem eğer bir sınıflandırma görevinin temeli olarak kullanılacaksa, saklı katmanda elde edilen vektör, bir sınıflandırıcıya girdi olarak verilerek sınıflandırma görevi gerçekleştirilebilir. Bu noktada kullanılan sınıflandırıcı karar destek vektör makinası gibi bir makine öğrenimi yöntemi olabildiği gibi tam bağlantılı veya evrişimsel katmanlara sahip bir sinir ağı da olabilir.

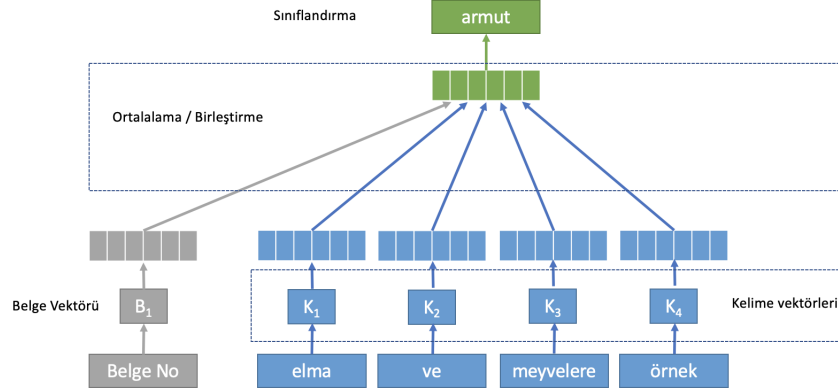
4.2.2. Doc2Vec

Doc2Vec [32] yöntemi Word2Vec yöntemi kullanılarak oluşturulmuş, doküman temsilini sağlayan bir yöntemdir. Bu yöntemde de Word2Vec CBOW yönteminde olduğu gibi her bir kelime çıktısı için komşu kelimeler girdi olarak verilmektedir. Ancak, Word2Vec yöntemine ek olarak eğitim kümesindeki her bir paragraf/metin için tekil bir numara (paragraf ID) da girdi olarak kullanılmaktadır. Buradaki asıl amaç metinlerde yer alan kelimelerin bağlamsal özellikleri öğrenilirken bir yandan da toplam metinlerin vektörlerini çıkarabilmektir. Eğitim süreci tamamlandığında, paragrafların bağlamsal özelliklerini oluşturan sayısal bir vektör elde edilmektedir. “Elma ve armut meyvelere örnek olarak gösterilebilir.” cümlesi için oluşturulmuş ve pencere boyutu 4 olarak kullanılmış örnek bir Doc2Vec diyagramı Şekil 4.10’da bulunmaktadır.

Ancak, Doc2Vec modelinin bazı dezavantajları da mevcuttur. En önemli dezavantajı, eğitim kümesinde kullanılmayan yeni bir paragraf için eğitim sürecinin tekrar edilmesi gerekliliğidir. Bu dezavantaj dolayısıyla test aşamasında da eğitim için ciddi bir zaman kaybı söz konusudur. Ayrıca yeni paragrafların içeriğine bağlı olarak, bağlam sözlüğünün sürekli güncellenmesi gerekmektedir.

4.2.3. Doc2VecC

Doc2Vec modelinde bahsedilen, her yeni paragraf için tekrardan eğitim gerektirmesi dezavantajı sebebiyle Chen ve arkadaşları [22] tarafından Doc2VecC modeli ortaya



Şekil 4.10 Örnek Doc2Vec Diyagramı

konulmuştur. Doc2VecC modeli özellikle daha önce model tarafından görülmemiş metinlerin vektörel bir temsilini çıkarmaya yönelik bir yöntemdir. Doc2Vec modeli ile benzerlik gösteren bu modelin eğitiminde her bir kelime çıktısı için komşu kelimelerin yanı sıra metin içerisinde rastgele seçilmiş kelimeler de girdi olarak verilmektedir. Rastgele kelime vektörlerinin de kullanılmasının yan etkisi olarak, kelime vektörlerinin ortalamalarının doküman vektörünü temsil etmesi hedeflenmiştir. Doc2Vec modelinin sadece komşu kelimeler ile eğitildiği göz önünde bulundurulduğunda, Doc2VecC modelinin doküman vektörünü temsil etmede daha başarılı olduğunu söylemek mümkündür. Modelin rastgele seçilmiş kelimelerle eğitilebildiği ve kelime vektör ortalamalarının paragrafların temsilinde kullanılabildiği düşünüldüğünde, henüz eğitilmemiş yeni veriler için daha az efor gerektirdiği söylenebilir. Bu yöntem, genellikle duygu analizi, doküman sınıflandırma ve anlamsal ilişkinlik görevleri için kullanılmaktadır.

4.2.4. Dönüştürücüler

Son zamanlarda doğal dil işleme hedefiyle kullanılan derin öğrenme modelleri genelde dönüştürücü tabanlı yöntemlerdir. 2017 yılında *Attention Is All You Need* [6] makalesinde tanıtılan dönüştürücü modelleri yukarıda bahsedilen diğer yöntemlere oranla daha kararlı sonuçlar vermektedir. Genel olarak dizi tabanlı verilerden çıkarım yapılabilme amacıyla

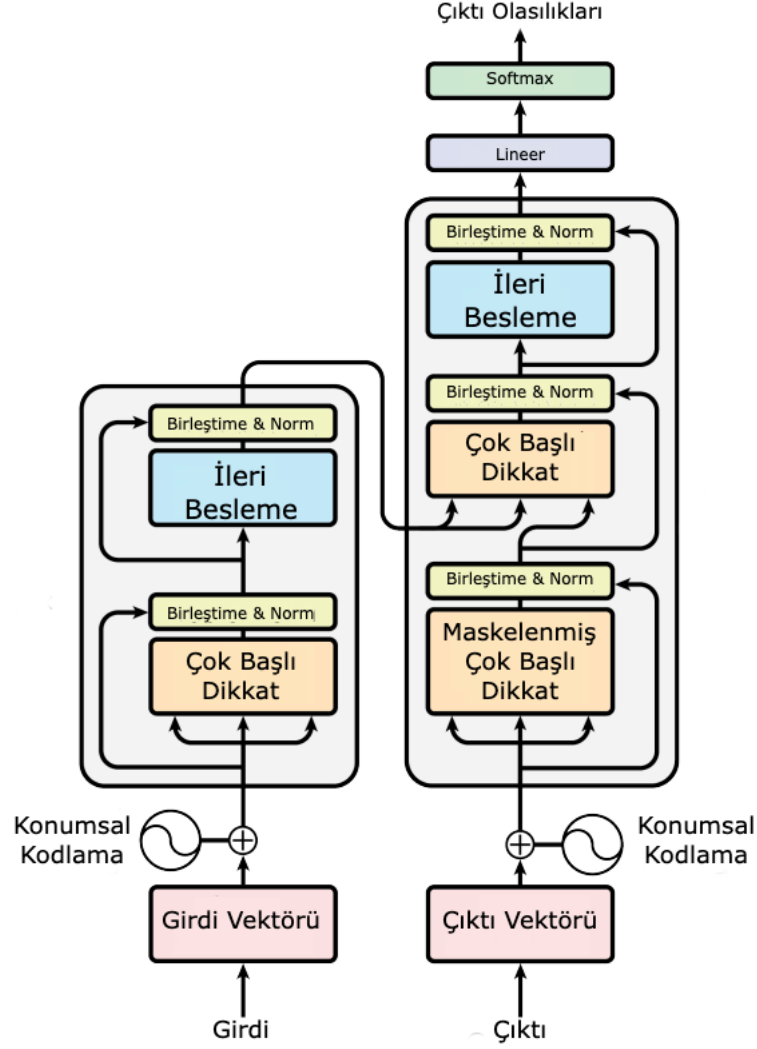
geliştirilmiş olan dönüştürücüler, doğal dil işleme görevlerinin yanı sıra, bilgisayarlı görü görevlerinde de kullanılmaktadır.

Dönüştürücülerin temelinde dikkat mekanizması yer almaktadır. Dikkat mekanizmaları, doğal dil işleme modellerine girdi olarak verilen serilerin, kullanıldığı görev için daha anlamlı noktalarına odaklanmak için kullanılmaktadır. Bu alandaki temel çalışmada öne sürülen dönüştürücü modelinde 6 kodlayıcı, 6 çözücü modül bulunmaktadır. Bu modüllerde ileri beslemeli sinir ağlarına ek olarak çok başlı öz dikkat ve maskelenmiş çok başlı öz dikkat katmanları da kullanılmıştır. Bu katmanlar, RNN gibi diğer modellerin aksine, verilerin paralel işlenmesine olanak sağlamıştır. Böylelikle, eğitim süreci hızlandırılmış bir dikkat mekanizması elde edilmiştir. Şekil 4.11’de bir kodlayıcı (sol) ve bir çözücü (sağ) modülden oluşan katmanın mimarisi gösterilmiştir. Kodlayıcıda iki adet alt katman bulunmaktadır. Bu katmanlar çok başlı dikkat ve tam bağlantılı ileri beslemeli katmanlardır. Çözücü ise üç farklı alt katmandan oluşmakta olup, bu katmanlar sırasıyla maskelenmiş çok başlı dikkat, çok başlı dikkat ve tam bağlantılı ileri beslemeli katmanlardır.

Güncel DDİ yöntemlerinde dönüştürücü yapısı sık sık kullanılmaktadır. Bu çalışmada, dönüştürücü tabanlı olarak, BERT modeli ve Longformer modeli ele alınmıştır.

4.2.5. BERT

Çift Yönlü Kodlayıcı Beyanı (Bidirectional Encoder Representations from Transformers) modeli [20] Google araştırmacıları tarafından geliştirilmiş, dönüştürücü tabanlı bir doğal dil işleme modelidir. Word2Vec modelinde, Bölüm 4.2.1.’de bahsedildiği gibi, sözlükteki her kelime için bir öznitelik vektörü üretilmektedir ve bu öznitelik vektörü, kelimenin cümledeki anlamından bağımsız olarak, aynı kelime için her zaman aynı vektörü üretmektedir. Dolayısıyla, Word2Vec modeli, kelimelerin farklı cümlelerde kazandıkları farklı anlamları yansıtmada zayıf kalmaktadır. Örnek vermek gerekirse; “Ağacın neredeyse bütün dal-ları kırılmış.” ve “Denizaltı denize ilk dal-ışını gerçekleştirdi.” cümlelerinde yer alan “dal” kelimesi iki farklı anlamda kullanılmıştır. Ancak word2vec modeliyle öznitelik öğrenimi gerçekleştirildiğinde, iki cümlede de yer alan dal kelimesi aynı vektörle temsil



Şekil 4.11 Temel Dönüştürücü Model Mimarisi [6]

edilmektedir. Bu örnekte sesteş bir kelime örneği gösterilmiştir, ancak kelimeler sesteş olmasa bile, bir kelimenin farklı cümlelerde farklı ağırlıklıkları ve anlamsal özellikleri olabilmektedir. Bu noktada BERT modeli, farklı anlamsal özellikleri temsil edebilmek için kullanılan bir yöntemdir. Ek olarak, bu model sadece kelimelerin vektörlerini üretmek için değil, cümlelerin veya paragrafların vektörlerini elde etmek için de kullanılabilir. BERT yöntemi kullanıldığında, bir model ile hem kelimelerin hem de paragrafların

sayısallaştırılmış vektörlerini çıktı olarak alabilmek mümkündür. Temel BERT modelinde kelimeler ve paragraflar 768 boyutlu bir vektörle temsil edilmektedir. Temel BERT modelinden türetilmiş benzer modeller de genellikle 768 boyutlu temsil vektör çıktıları üretmektedir. Ancak, saklı katman parametreleri değiştirilerek daha büyük veya küçük boyuta sahip vektörlerle de kelimeleri ve paragraflar temsil edilebilmektedir.

Başlangıçta *BERT-Base* ve *BERT-Large* olmak üzere temel olarak 2 adet BERT modeli öne sürülmüştür. *BERT-Base* modelinde 12 adet kodlayıcı modülü *BERT-Large* modelinde ise 24 adet kodlayıcı bulunmaktadır. Dolayısıyla, *BERT-Large* modeli daha fazla parametreye sahip olmakla beraber daha kesin sonuçlar üretebilmektedir. Ancak *BERT-Large* modeli için daha fazla veri gerekmekte ve sözlük/metin sayısı az olduğu durumlarda *BERT-Base* modelinin kullanılması daha uygun görülmektedir.

4.2.6. Longformer

BERT gibi dönüştürücü tabanlı doğal dil işleme yöntemleri oldukça başarılı çıktılar üretseler de bu yöntemlerin çoğu paragraf gibi uzun dizileri işleme konusunda yetersiz kalmaktadır. Temel BERT modeli en fazla 512 sözlüksel ögeye (token) sahip dizileri işleyebilmektedir. Longformer [33] ise bu sorunun önüne geçebilmek ve uzun dizileri de girdi olarak kullanarak bir sonuç üretebilmek amacıyla geliştirilmiş dönüştürücü tabanlı bir yöntemdir. Daha uzun dizileri girdi olarak kullanabilmek amacıyla, bu yöntemde diğer dönüştürücü tabanlı yöntemlere ek olarak farklı dikkat yöntemleri de modele eklenmiştir. Bu yöntemler aşağıda sıralanmıştır.

Kayan Pencere ile Dikkat:

Bu yöntem 1 boyutlu bir evrişimsel katmanlardan oluşmaktadır. Pencere boyutu w olarak belirlendiğinde her bir sözlüksel ögenin w komşuluğunda yer alan sözlüksel ögelerle bir gizli katman yaratılmaktadır. Ayrıca, katman sayısı l olarak belirlenirse, her bir sözlüksel öge için $l \times w$ boyutunda bir gizli katman ortaya çıkmaktadır. Bu gizli katmanlar her bir sözlüksel öge için çevre sözlüksel ögelerden elde edilen bir dikkat mekanizması olarak görülebilir.

Genişlemeli Kayan Pencere ile Dikkat:

Genişlemeli kayan pencere terimi genellikle evrimsel katmanlar için kullanılan bir ifade olup amacı çıktıda girdiye dair daha fazla bilgi elde edilmesidir. Longformer yönteminde de amaç her bir sözlüksel öge için kullanılan dikkat mekanizmasının kapsam alanlarının daha geniş olmasıdır. Genişlemesiz kayan pencerelere göre kullanılan katmanların bilgiyi aktarma kapasitesinin daha yüksek olması, daha az katman kullanarak toplam işlem karmaşıklığını azaltmaya yardımcı olmaktadır.

Genel Dikkat ve Genişlemeli Kayan Pencere ile Dikkat:

Yukarıda aktarılan yöntemler dikkat mekanizmaları açısından yeterli gibi gözükse de uzun terimlerin dizilerin temsilini daha iyi sağlayabilmek için ek olarak bir de genel dikkat mekanizması eklenmiştir.

Sonuç olarak, Lonformer yönteminin, hem hesaplama hem de hafıza anlamında verimli olduğu belirtilmiştir. Ayrıca diğer uzun paragraf işleme yöntemlerinin aksine, bu yöntem sınıflandırma gibi kodlama görevlerinde de kullanılabilir.

5. ÖNERİLEN YÖNTEMLER VE DENEYSEL SONUÇLAR

Bu çalışmada, MIMIC-III veri kümesinde yer alan hem zamana bağlı sayısal veriler hem de metin tabanlı klinik notlar temel alınmış olup, bu veriler ICD kodlarının tahminlemede kullanılmıştır. Öncelikle her ikisi ayrı görevler olarak ele alınmış ve model eğitimi gerçekleştirilmiştir. Bu iki görevde ayrı ayrı en iyi sonucu veren derin öğrenme modelleri, ana görevde kullanılacak alt modeller olarak değerlendirilmiş ve iki model birleştirilerek daha keskin sonuçlar elde edilmesi hedeflenmiştir. Bu iki alt derin öğrenme ağının çıktıları bir tam bağlantılı katmanda birleştirilmiştir. Kullanılacak alt derin öğrenme modelleri belirlendikten ve ön işleme işlemleri uygulandıktan sonra model bir bütün halinde eğitilmiştir. Görevin çok etiketli-çok sınıflı bir yapıda olması dolayısıyla her bir modelin

eđitimi esnasında hata fonksiyonu olarak logit fonksiyonlu ikili apraz entropi fonksiyonu (binary cross entropy with logit loss) kullanılmıřtır.

Bölüm 5.1.'de sayısal veriler kullanılarak gerekleřtirilen alıřmalar, Bölüm 5.2.'de metin tabanlı veriler kullanılarak gerekleřtirilen alıřmalar, Bölüm 5.3.'te ise her iki veri tipi birlikte kullanılarak gerekleřtirilen alıřmalar ve bu alıřmalardan elde edilen sonular yer almaktadır. Kullanılan yöntemler bu bölümlerin alt bařlıkları halinde verilmiřtir. Bu alt bölümlerde, kullanılan her bir yöntem iin model mimari diyagramları da yer almaktadır. Bu diyagramlardaki *none* ve ? parametreleri öbek (batch) boyutunu temsil etmekte olup, deney altyapısına göre deđiřiklik gösterebilmektedir.

Model bařarılarının ölçümenmesinde F1 skoru (Denklem 4) temel alınmıř ve deneylerin sonuları bu metrik ile kıyaslanmıřtır. Bu metrik duyarlılık (Denklem 5) ve keskinlik (Denklem 6) parametrelerinin harmonik ortalamaları ile elde edilmektedir, dolayısıyla sınıflandırıcıların hem duyarlılık hem de keskinlik metrikleriyle kıyaslanabilmesine imkan sađlamaktadır. Problemin ok sınıflı ve ok etiketli bir yapıda olması sebebiyle de Mikro F1 skoru kullanılmıřtır. Mikro F1 skoru, sınıfların ađırlıklı ortalamaları ile elde edilen F1 skorunu temsil etmektedir. Tablolarda yer alan F1 skorları, sınıfların ađırlıklı ortalamalarıyla elde edilmiř Mikro F1 metriđini temsil etmektedir.

$$F1 \text{ Skoru} = \frac{2 \times \text{Duyarlılık} \times \text{Keskinlik}}{\text{Duyarlılık} + \text{Keskinlik}} \quad (4)$$

$$\text{Duyarlılık} = \frac{\text{Dođru Pozitif}}{\text{Dođru Pozitif} + \text{Yanlıř Negatif}} \quad (5)$$

$$\text{Keskinlik} = \frac{\text{Dođru Pozitif}}{\text{Dođru Pozitif} + \text{Yanlıř Pozitif}} \quad (6)$$

alıřmaya dahil edilen her bir yöntem iin model eđitimleri Nvidia 3090 TI ekran kartı kullanılarak PyTorch [34] kütüphanesi ile gerekleřmiřtir. Sayısal verilerin ön iřleme iřlemleri iin Pandas [35], metin tabanlı verilerin ön iřleme iřlemleri iin ise NLTK [36]

kütüphaneleri kullanılmıştır. DDİ işleme yöntemleri için önceden eğitilmiş modeller ise huggingface kütüphanesi ile elde edilmiştir. Her bir deney sonucunun analizi için scikit-learn [37] kütüphanesi kullanılmıştır.

5.1. Sayısal Veri Tabanlı Sınıflandırma

Sayısal veri tabanlı sınıflandırma görevi için CNN, GRU ve LSTM tabanlı üç ayrı yöntem kullanılmış ve sonuçları analiz edilmiştir. Bu modellerin deneysel altyapı detaylarına sırasıyla Bölüm 5.1.1.'den, Bölüm 5.1.2.'den ve Bölüm 5.1.3.'ten ulaşılabilir ulaşılabilir.

5.1.0.1. Veri Ön İşleme

Veri kümesindeki sayısal öznitelik seçimi ve ön işleme işlemlerinde Purushothan ve arkadaşlarının [10] çalışmasındaki en kapsamlı öznitelik seti kullanılmıştır. MIMIC-III veri kümesi kullanarak elde edilen bu alt veri kümesinde 20.000'den fazla hasta başvurusunda yer alan 136 adet zamana bağlı öznitelik mevcuttur. Bu özniteliklere Tablo 5.1'de yer verilmiştir. Veri kümesindeki bazı öznitelik isimleri hem büyük harfle hem de küçük harfle yazılmış bir şekilde yer alabilmektedir, dolayısıyla tablodaki isimler veri kümesinde olduğu gibi bırakılmıştır. Ayrıca, bire bir aynı isime sahip öznitelikler de bulunduğu için, bazı öznitelikler tek bir isimle yer almaktadır. Tablodaki öznitelikler hasta yatışından itibaren 24 saatlik bir süre zarfı için ele alınmış ve birer saatlik dilimler halinde örneklenmiştir. Dolayısıyla elde edilen sayısal verilerin zamana bağlı ve 136x24 boyutunda olduğunu söylemek mümkündür.

MIMIC-III veri kümesinde yer alan sayısal tablolar yapıları itibariyle Bölüm 2.'de anlatıldığı gibi bazı sorunlara sahiptir. Bu sorunların en başında yüksek eksik veri oranları ve aynı özniteliği temsil eden verilerin birden farklı tablolarda yer almaları durumudur. Dolayısıyla, ön işleme işlemlerinde bu durumun göz önünde bulundurulması gerekmektedir. Bu noktada, birden fazla tabloda yer alınan öznitelikler, Purushothan ve arkadaşlarının [10] çalışmasında olduğu gibi tek bir öznitelik altında birleştirilmiştir. Ayrıca eksik veriler için, eğer bir hasta başvurusunda herhangi bir zaman diliminde o öznitelik yer alıyorsa sırasıyla ileri ve geri doldurma işlemleri uygulanmıştır. Eğer bir hasta başvurusunda o özniteliğin hiçbir zaman

Tablo 5.1 Sayısal Veriler İçin Kullanılan Veri Kümesindeki Öznitelikler

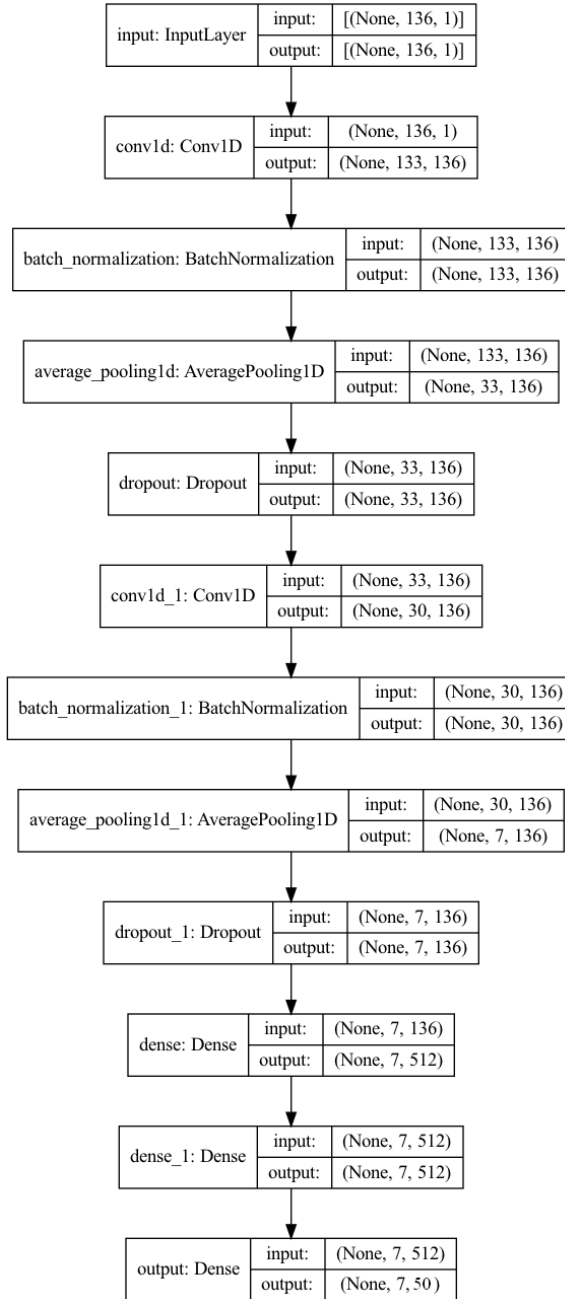
Albumin 5	Pre-Admission	Bisacodyl
Fresh Frozen Plasma	TF Residual	Docusate Sodium
Lorazepam (Ativan)	urinary output sum	Humulin-R Insulin
Calcium Gluconate	HEMATOCRIT	Metoprolol Tartrate
Midazolam (Versed)	PLATELET	Pantoprazole
Phenylephrine	HEMOGLOBIN	ArterialBloodPressurediastolic
Furosemide (Lasix)	MCHC	ArterialBloodPressuremean
Hydralazine	MCH	RespiratoryRate
Norepinephrine	MCV	AlarmsOn
Magnesium Sulfate	RED BLOOD CELLS	MinuteVolumeAlarm-Low
Nitroglycerin	RDW	Peakinsp.Pressure
Insulin - Regular	CHLORIDE	PEEPset
Morphine Sulfate	ANION GAP	MinuteVolume
Potassium Chloride	CREATININE	GLUCOSE
Gastric Meds	MAGNESIUM, TOTAL	weight
D5 1/2NS	CALCIUM	height
LR	PHOSPHATE	glucose
Solution	INR(PT)	spo2 peripheral
Sterile Water	PT	arterial pressure mean
Piggyback	PTT	diastolic blood pressure mean
OR Crystalloid Intake	LYMPHOCYTES	ie ratio mean
PO Intake	MONOCYTES	fiO2
GT Flush	NEUTROPHILS	body temperature
KCL (Bolus)	BASOPHILS	heart rate
Magnesium Sulfate (Bolus)	EOSINOPHILS	systolic blood pressure abp mean
epinephrine	PH	gcseyes
vasopressin	BASE EXCESS	gcsmotor
dopamine	CALCULATED TOTAL CO2	gcsverbal
midazolam	PCO2	SkinCare
fentanyl	SPECIFIC GRAVITY	RespAlarm-High
propofol	LACTATE	SpO2DesatLimit
Gastric Tube	ALANINE AMINOTRANSFERASE (ALT)	PulmonaryArteryPressurediastolic
Stool Out Stool	ASPARATE AMINOTRANSFERASE (AST)	TidalVolume(set)
Urine Out Incontinent	ALKALINE PHOSPHATASE	PulmonaryArteryPressuresystolic
Ultrafiltrate	ALBUMIN	HeartRateAlarm-Low
Fecal Bag	pao2	Glucosefingerstick
Chest Tube #1	serum urea nitrogen level	O2Flow
Chest Tube #2	white blood cells count mean	PulmonaryArteryPressuremean
Jackson Pratt #1	serum bicarbonate level mean	RespiratoryRate(Set)
OR EBL	sodium level mean	CentralVenousPressure
potassium level mean	bilirubin level	MeanAirwayPressure
hgb	chloride	TidalVolume(observed)
peep	Aspirin	MinuteVolumeAlarm-High
Packed Red Blood Cells		

dilimi için bir kaydı yoksa, diğer hasta başvurularının ortalamalarıyla doldurma işlemi uygulanmıştır.

Aşağıda, bu tez çalışmasında sayısal verilerden tahminleme görevi için kullanılan her bir modelin açıklamaları ve sonuçlarına yer verilmiştir. Her bir model, bu çalışmada sayısal verilere sahip olan filtrelenmiş A Veri Kümesi ile eğitilmiş, eğitim esnasında optimizasyon

algoritması olarak $1e-5$ başlangıç öğrenme oranıyla *ADAM* [38] kullanılmıştır.


5.1.1. CNN İle Sayısal Verilerden ICD-9 Sınıflandırma



Şekil 5.1 Sayısal verilerden ICD sınıflandırma amacıyla kullanılan CNN Modeli

Bu modelde, zamana bağılı sayısal veriler ile tahminleme için bir boyutlu bir CNN modeli kullanılmıştır. 1x4 boyutlu filtreler ile 4 saatlik zaman aralıkları ardışık olarak işlenmiş, böylelikle her bir başvurudaki 4 saatlik değişimlerin zaman boyutunu kaybetmeden tahminlemeye katkı sağlamaları hedeflenmiştir. Modelde toplamda 2 adet CNN katmanı kullanılmıştır. CNN katmanlarının ardından, kaybolan gradyan probleminin önüne geçmek için *Batch Normalization* katmanı, aşırı öğrenme probleminin önüne geçmek için ise sırasıyla *Average Pooling* ve *Dropout* katmanları kullanılmıştır. Sınıflandırıcı amacıyla 3 adet tam bağlantılı katman kullanılmış olup ilk iki tam bağlantılı katmanda 512, son katmanda ise 50 nöron bulunmaktadır. Model diyagramı Şekil 5.1’de verilmiştir.

Model eğitimi esnasında her bir eğitim turu için elde edilmiş kayıp, doğruluk ve F1 skor verileri Şekil 5.2’de yer almaktadır. Sonuç olarak, doğrulama F1 skoru temel alındığında en iyi değer 330. eğitim turunda 0.39 olarak elde edilmiştir. Bu model için test F1 skoru 0.38 olarak raporlanmıştır.

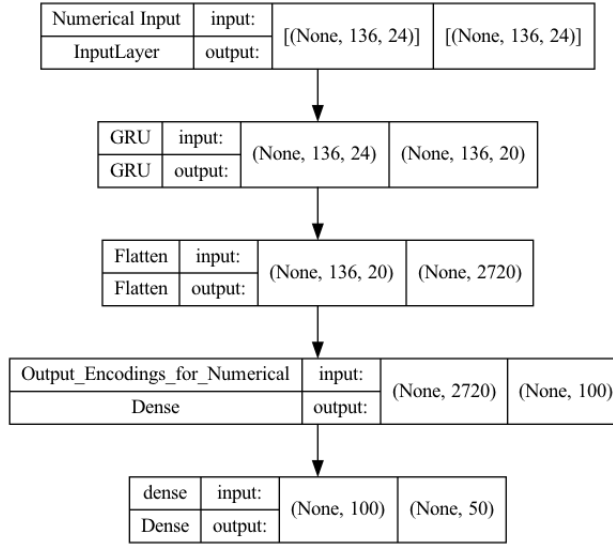


Şekil 5.2 Sayısal verilerden ICD sınıflandırma amacıyla kullanılan CNN Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skoru

5.1.2. GRU İle Sayısal Verilerden ICD-9 Sınıflandırma


Elde edilen veri kümesi zamana bağılı verilerden oluştuğundan, GRU modeli için uygun bir yapıdadır. Bu noktada, ICD kodu tahminleme görevi için önerilen model, her biri 20 gizli katmana sahip 2 katmanlı bir GRU modelidir. GRU modelinden elde edilen öznelilikler

RELU aktivasyon fonksiyonunun ardından tam bağlantılı bir katmana girdi olarak verilmiş ve sınıflandırma modeli tamamlanmıştır. Model diyagramı Şekil 5.3'te bulunmaktadır.



Şekil 5.3 Sayısal verilerden ICD sınıflandırma amacıyla kullanılan GRU Modeli

GRU modelinin eğitim turları boyunca elde edilen kayıp, doğruluk ve F1 skor eğrileri Şekil 5.2'de yer almaktadır. Sonuç olarak, doğrulama F1 skoru temel alındığında en iyi değer 200. eğitim turunda 0.44 olarak elde edilmiştir. Bu model için test F1 skoru 0.45 olarak raporlanmıştır. GRU modeliyle, bu tez çalışmasında sayısal verilerden kestirim yapmak amacıyla kullanılan diğer modellere oranla kayıp ve F1 skoru açısından daha başarılı bir sonuç alındığı görülmektedir.




Şekil 5.4 Sayısal verilerden ICD sınıflandırma amacıyla kullanılan GRU Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor

5.1.3. LSTM İle Sayısal Verilerden ICD-9 Sınıflandırma

Bu yöntemde de temel olarak Bölüm 5.1.2.'de aktarılan GRU modeline benzer bir yöntem kullanılmıştır. Ancak modeldeki GRU katmanları, genel yapısı ve çalışma prensibi Bölüm 4.1.2.'de aktarılan LSTM katmanlarıyla değiştirilmiştir. Böylelikle, LSTM modelinin ürettiği sonuçlar gözlemlenmiştir.

Kullanılan LSTM tabanlı model için elde edilen kayıp, doğruluk ve F1 skor eğrileri Şekil 5.5'te yer almaktadır. Sonuç olarak, doğrulama F1 skoru temel alındığında en iyi değer 57. eğitim turunda 0.40 olarak elde edilmiştir. Bu model için test F1 skoru 0.42 olarak raporlanmıştır.



Şekil 5.5 Sayısal verilerden ICD sınıflandırma amacıyla kullanılan LSTM Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skoru

5.2. Metin Tabanlı Sınıflandırma

Metin bazlı sınıflandırma görevi için Bölüm 6.'da detaylı açıklamaları yapılan yöntemler uygulanmıştır. Bu yöntemler sırasıyla Word2Vec, BERT ve Longformer tabanlı yöntemlerdir.

5.2.0.1. Veri Ön İşleme

Bölüm 2.'de aktarıldığı gibi MIMIC-III veri kümesinde yer alan metin bazlı raporlardan yalnızca taburcu raporları kullanılmıştır. Veri ön işleme işlemleri için, her bir taburcu raporundaki tarih, saat ve özel karakterler silinmiş ve bütün harfler küçültülmüştür.

Bu tez kapsamında metin bazlı verilerden ICD-9 kodu sınıflandırmasına yönelik kullanılan modellerin ve uygulanan deneylerin açıklamaları aşağıda sıralanmıştır. Bu deneylerin her biri için A Veri Kümesi kullanılırken Longformer yöntemi için literatürdeki diğer çalışmalarla adil bir kıyaslama yaratılabilmesi amacıyla ek olarak B Veri Kümesi ile de deneyler tekrarlanmıştır. Bu bölümde yer alan ön işleme işlemleri detayları aktarılan her bir deney için aynı şekilde uygulanmıştır.

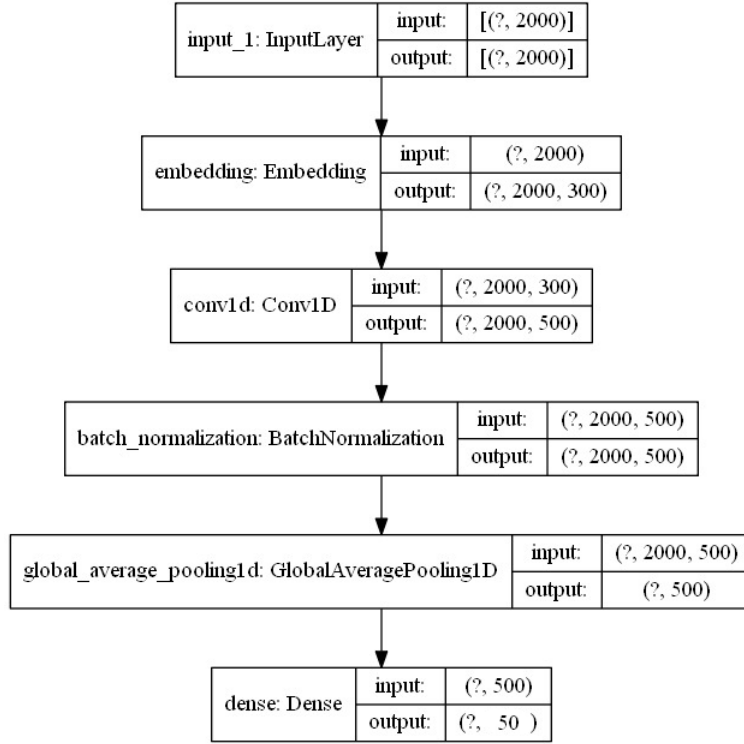
5.2.1. Word2Vec İle ICD-9 Sınıflandırma

Word2Vec modeli çalışmasında öncelikle veri kümesinde yer alan kelimelerle 1522 elemanlı bir sözlük oluşturulmuştur. Bu sözlük ve eğitim kümesi kullanılarak Word2Vec modeli eğitilmiştir. Word2Vec modeli eğitilirken, büyük veri kümelerinde daha başarılı olması sebebiyle Skip-Gram yöntemi kullanılmıştır. Word2Vec ile ICD sınıflandırma görevinin deneyleri esnasında Reys ve arkadaşlarının [25] açık kaynak kodlu çalışması altyapı olarak kullanılmıştır. Dolayısıyla, her bir metin için ilk 2000 kelime temel alınmış, geri kalan kelimeler silinerek sabit bir girdi vektörü kullanılması amaçlanmıştır. Saklı katman olarak 300 birimlik bir tam bağlantılı kullanılmış ve her bir kelimenin 300 boyutlu bir vektör halinde temsil edilmesi sağlanmıştır.

Word2Vec modelinin eğitimi tamamlandıktan sonra model öznitelik öğrenimi matrisine dönüştürülmüş ve sınıflandırıcı modelinde temel olarak bu matris ile çalışılmıştır. Sınıflandırma amacıyla kullanılan her bir girdi için kelime temsil vektörleri çıkarılmıştır. Bu vektörlerden sınıflandırma yapmak amacıyla ise amacıyla ise Reys ve arkadaşlarının [25] çalışmasında olduğu gibi CNN, Dikkat Mekanizmalı CNN ve GRU modelleri kullanılmış ve üç ayrı model için sonuçlar analiz edilmiştir.

Altyapı olarak kullanılan çalışma, çıktıda üretilen vektörün boyutu bakımından farklılık göstermektedir. Çıktı vektör boyutları da bu veri kümesine göre değiştirilmiştir.

CNN modelinde 1 boyutlu 500 birimlik bir CNN katmanı kullanılmıştır. Modeli kararlı hale getirmek için batch normalizasyon katmanı, overfitting probleminden kaçınmak için

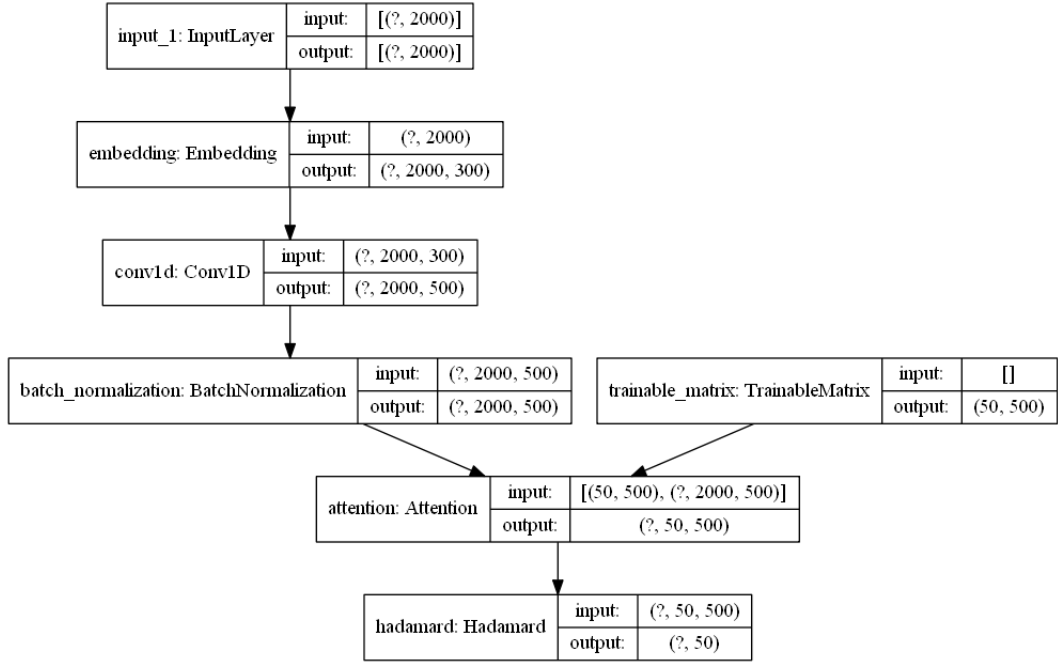


Şekil 5.6 Word2Vec ile ICD sınıflandırıcı amacıyla kullanılan CNN Modeli

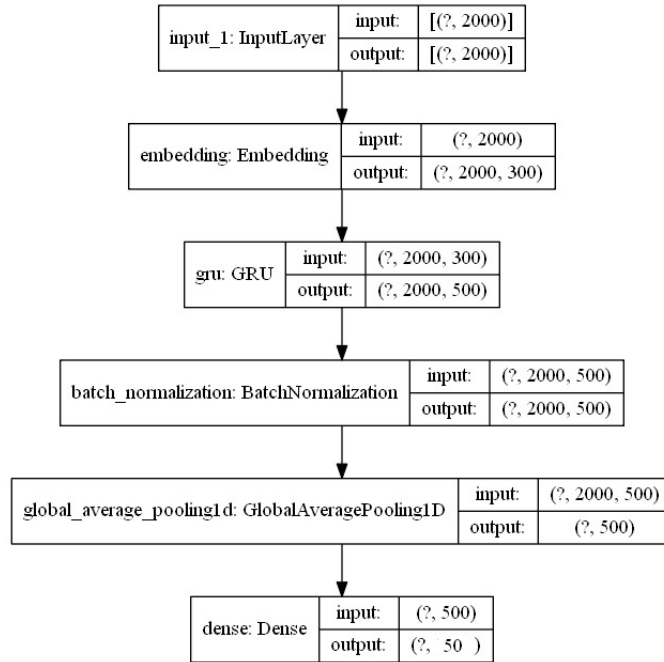
ise ortalama havuzlama katmanı kullanılmıştır. Model diyagramı Şekil 5.6'da gösterilmiştir. Eğitim aşamasında aktivasyon fonksiyonu olarak *Tanh*, optimizasyonu olarak *Adam*, öğrenme oranı olarak ise 0.001 ve 0.0001 arasında değişken oranlar kullanılmıştır.

Dikkat mekanizmalı CNN modelinde 1 boyutlu 500 birimlik bir CNN katmanı, batch normalizasyon ve dikkat katmanı ile birlikte kullanılmıştır. Model diyagramı Şekil 5.7'de yer almaktadır. Eğitim esnasında optimizasyonu olarak CNN modelindeki parametrelerle Adam tercih edilmiştir.

GRU modelinde de GRU katmanı yine batch normalizasyon ve ortalama havuzlama yöntemleriyle birlikte konumlandırılmıştır. Model diyagramı Şekil 5.8'de bulunabilir. Eğitim için optimizasyonu olarak burada da *Adam* kullanılmıştır.



Şekil 5.7 Word2Vec ile ICD sınıflandırıcı amacıyla kullanılan dikkat mekanizmalı CNN Modeli




Şekil 5.8 Word2Vec ile ICD sınıflandırıcı amacıyla kullanılan GRU Modeli

Eđitimi gerekleřtirilen Word2Vec modeline girdi olarak verilen bazı kelimelerin TSNE uzayındaki vektörel gösterimleri Őekil 5.10’da, PCA uzayındaki vektörel gösterimleri ise 5.11’de bulunabilir. Bu gösterimlerden, genellikle birbiriyle aynı kelime öbeklerinde yer alan kelimelerin benzer matematiksel konumlarda oldukları sonucuna ulařılabilir. Örneđin, TSNE uzayında “heart” ve “rate” kelimeleri birbirlerine ok yakın noktalarda konumlanmıřlardır.


Bu modelden elde edilen vektörleri sınıflandırma amacıyla kullanılan üç farklı sınıflandırıcıya ait keskinlik, duyarlılık ve F1 skoru sonuçları ise Tablo 5.2’de bulunmaktadır. Sonuçlar deđerlendirildiđinde, dikkat mekanizmalı CNN modelinin sınıflandırıcılar ierisinde en başarılı yöntem olduđu söylenebilir. Bu modelin eđitimine iliřkin kayıp, dođruluk ve F1 skor eđrileri Őekil 5.9’da yer almaktadır.

Tablo 5.2 Word2vec ile Metin Bazlı Sınıflandırıcı Sonuçları

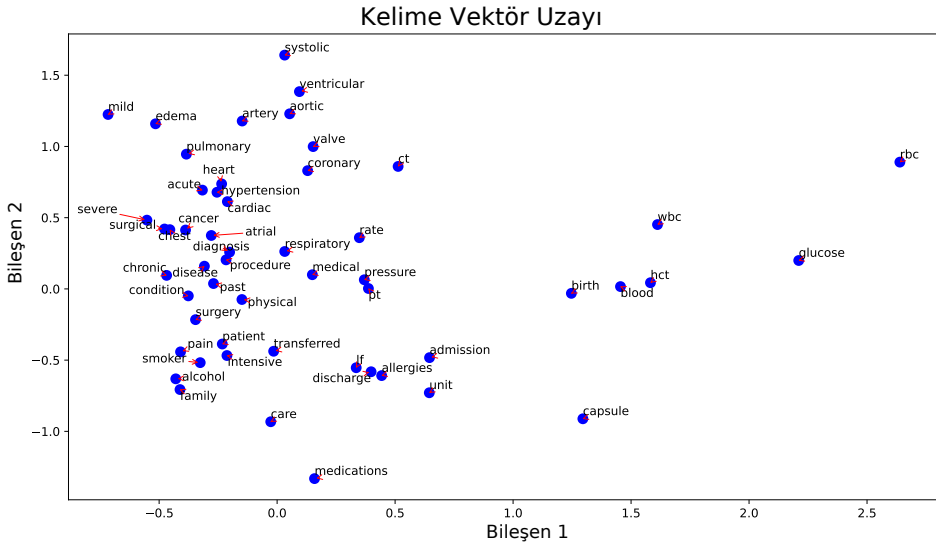
	Keskinlik	Duyarlılık	F1 Skoru	Eđitim Turu
CNN	0.56	0.57	0.57	4
Dikkat Mekanizmalı CNN	0.60	0.62	0.61	5
GRU	0.59	0.62	0.60	9



Őekil 5.9 Sayısal Verilerden ICD Sınıflandırma Amacıyla Kullanılan Dikkat Mekanizmalı CNN Modeli Sonuç Eđrileri, a) Kayıp, b) Dođruluk, c) F1 Skor



Şekil 5.10 TSNE Uzayında Örnek Word2vec vektörlerinin Gösterimi



Şekil 5.11 PCA Uzayında Örnek Word2vec vektörlerinin Gösterimi

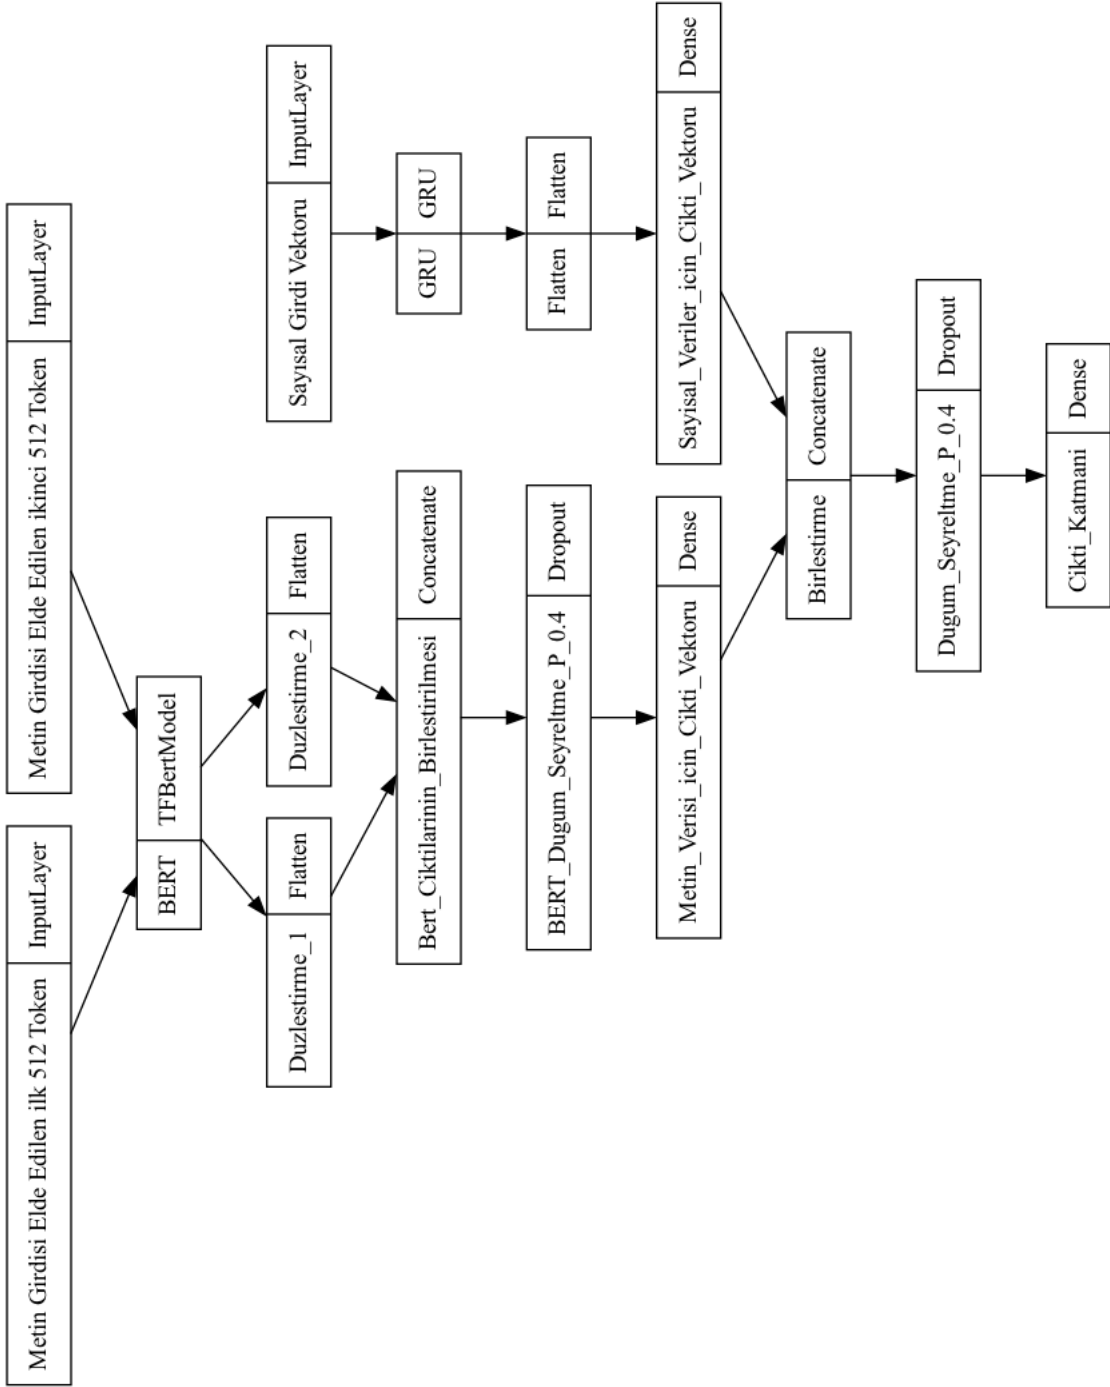
5.2.2. BERT İle ICD-9 Sınıflandırma

BERT ile ICD-9 sınıflandırma yönteminde, MIMIC-III veri kümesindeki metin sayısının diğer doğal dil işleme görevlerine oranla daha az olması nedeniyle *BERT-Base* modeli temel alınmıştır. Bölüm 4.2.'de belirtildiği gibi BERT modeline en fazla 512 sözlüksel ögeye sahip diziler girdi olarak verilebilmektedir. MIMIC-III veri kümesi ise daha uzun serilere sahip metinlerden oluşmaktadır. Bu noktada, verilerin ortalama uzunluğu 1528 kelime, medyan değeri ise 1415 kelimedir. Bu tarz uzun verileri BERT ile kullanabilmek için önerilen yöntemlerden biri yalnızca ilk 512 sözlüksel ögeyi girdi olarak kullanmaktır, ancak bu durumda geri kalan vektörler temsil edilememektedir. Bu çalışmada ise girdi olarak kullanılan metinler yığınlara ayrılmış ve 2 adet 512 sözlüksel ögeye sahip yığın ayrı ayrı kullanılmış ve BERT sonucu oluşan çıktıları birleştirilmiştir. Tek bir BERT modeli 768 boyutlu bir gizli katmandan oluşmaktadır. ICD-9 sınıflandırma görevi kapsamında, bu gizli katman BERT modeline girdi olarak verilen metinlerin öznitelikleri olarak değerlendirilmiştir. Çalışmada bir metin iki yığın kullanıldığı için kullanılan metinlerin her biri 1x1528 boyutlu bir vektör ile temsil edilmiştir. Elde edilen bu vektör bir adet tam bağlantılı katmanda kullanılarak, sınıflandırma görevi sağlayacak model oluşturulmuştur. Modelin diyagramı Şekil 5.12'de mevcuttur.


Modelde kullanılan BERT öznitelik çıkarımı alt modeli için önceden eğitilmiş bir model olan *BERT-Base-Uncased* modeli kullanılmıştır. BERT makalesinde önerilen bu model *wikipedia* ve *book corpus* [39] veri kümeleri kullanılarak eğitilmiş temel BERT modelidir. Model, girdi olarak sadece küçük harfleri almaktadır, dolayısıyla veri ön işleme işlemlerinde bu durum göz önünde bulundurulmuş ve büyük harfler küçük harflere dönüştürülmüştür.

Model eğitimi esnasında optimizasyon algoritması olarak *Adam*, öğrenme oranı olarak ise $1e-5$ kullanılmıştır.

BERT tabanlı ICD sınıflandırma için kayıp, doğruluk ve F1 skor eğrileri Şekil 5.13'te yer almaktadır. Sonuç olarak, en yüksek doğrulama F1 skoru 5. eğitim turunda, 0.52 olarak elde edilmiştir. Bu model için test F1 skoru 0.54 olarak raporlanmıştır.



Şekil 5.12 BERT Tabanlı ICD-9 Sınıflandırıcı Modeli

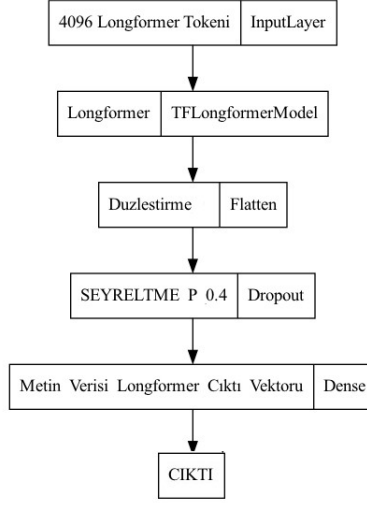


Şekil 5.13 Metin tabanlı ICD sınıflandırıcı amacıyla kullanılan BERT Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor


5.2.3. Longformer İle ICD-9 Sınıflandırma

Longformer modeli ile ICD-9 sınıflandırma yönteminde, iki farklı önceden eğitilmiş model temel alınmıştır. Bu modellerin ilki Longformer makalesinde tanıtılan temel Longformer modelidir [33], bu model WikiHow [40] and TriviaQA [41] veri kümeleri kullanılarak eğitilmiştir. İkinci model ise, klinik çalışmalara yönelik geliştirilmiş olan Clinical-Longformer [42] modelidir; bu modelin yapısı temel longformer modeliyle aynı mimaride olup kullanılan veri kümesi bakımından farklılaşmaktadır. Clinical-Longformer modeli bu çalışmada da kullanılan MIMIC-III veri kümesi ile eğitilmiş durumdadır. Bu tez kapsamında, ICD-9 kodlarının tahminlenmesi için iki Longformer modeli önceden eğitilmiş model olarak kullanılmıştır. Ancak daha az eğitim turu gerektirmesi ve temel Longformer yöntemine oranla daha başarılı sonuçlar ortaya koyması nedeniyle Clinical-Longformer'ın önceden eğitilmiş modelinin kullanıldığı yöntem temel alınmıştır. Bu modelin çıktısı bir seyreltme katmanına girdi olarak verilmiş sonrasında ise sınıflandırma amacıyla tam bağlantılı bir katman yerleştirilmiştir (Şekil 5.14).

Clinical-Longformer tabanlı modelin eğitimi esnasında elde edilen kayıp, doğruluk ve F1 skor eğrileri Şekil 5.15'te yer almaktadır. Sonuç olarak, en yüksek doğrulama F1 skoru 7. eğitim turunda 0.64 olarak raporlanmıştır. Bu değer, tez çalışmasında metin verileri için kullanılan modeller arasında temel veri setinden (A Veri Seti) elde edilen en yüksek skordur.



Şekil 5.14 Metin tabanlı ICD sınıflandırıcı amacıyla kullanılan Longformer Modeli



Şekil 5.15 Longformer Modeli Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor

5.3. Sayısal ve Metin Tabanlı Verileri Birlikte Kullanarak Sınıflandırma

Hem sayısal hem de metin tabanlı veriler kullanılarak ICD kodu kestirimi yapabilmek amacıyla 5.1. ve 5.2. bölümlerinden elde edilen yöntemler birleştirilmiş ve bu modeller kullanılarak yeni bir model oluşturulmuştur. Sayısal veriler için en iyi sonucun elde edildiği yöntem GRU tabanlı yöntem, metin bazlı veriler için ise en iyi sonucun elde edildiği yöntem

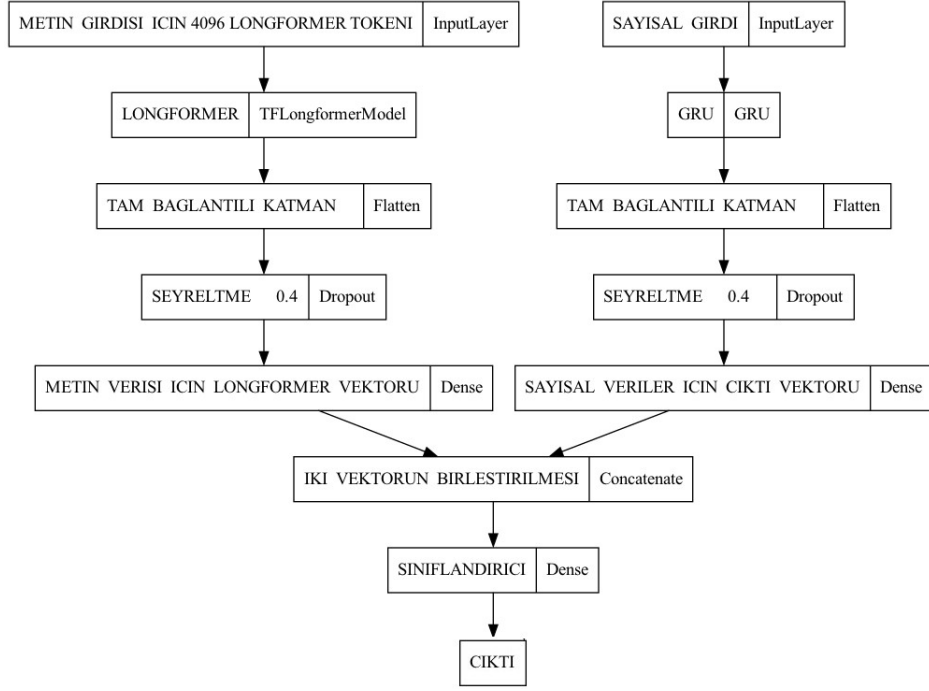
Longformer tabanlı yöntemdir. Dolayısıyla, Longformer ve GRU modelinden oluşan bir birleştirilmiş model nihai model olarak kullanılmıştır. Lonformer ve GRU kullanarak elde edilmiş birleştirilmiş modelin sonuçları 5.3.1.'de yer almaktadır.

Ayrıca, önerilen yöntem literatürdeki en iyi sonucun elde edildiği DDİ yöntemi olan KEPT (Knowledge Enhanced Prompt) temel alınarak da değerlendirilmiş ve sonuçlar raporlanmıştır. Bu modelin açıklaması ve birleştirilmiş yöntemden elde edilen sonuçlar da 5.3.2.'de bulunmaktadır.


5.3.1. Longformer ve GRU ile Sınıflandırma

Longformer ve GRU temel alınarak oluşturulmuş modelin diyagramı Şekil 5.16'da yer almaktadır. Ana modelde kullanılan alt modeller birer öznitelik çıkarımı modeli olarak kullanılmış, elde edilen öznitelikler birleştirilerek her bir hasta için genel bir öznitelik vektörü elde edilmiştir. Bu vektör hem sayısal hem de metin bazlı verilerin temsilini oluşturmaktadır. 1x100 boyutlu bu öznitelik vektörü seyreltme ve tam bağlantılı katman ile birlikte kullanılmıştır. İki alt model için de temel alınan deneylerde en iyi sonucun elde edildiği modeller önceden eğitilmiş model olarak değerlendirilmiştir. Sonuç modeli eğitilirken hem bu alt modellerde ince ayarlama yapılmış hem de yeni eklenen katmanlar sınıflandırılma görevi için baştan itibaren eğitilmiştir. Kullanılan alt modellerde olduğu gibi burada da Adam optimizasyon algoritması $1e-5$ öğrenme oranıyla kullanılmıştır. Doğrulama, test ve eğitim setleri için diğer deneylerle aynı hastane başvuruları temel alınmıştır.

Longformer tabanlı birleştirilmiş model için elde edilen sonuç eğrileri Şekil 5.17'de yer almaktadır. Bu modelde en iyi doğrulama F1 skoru 18. eğitim turunda 0.68 oranıyla elde edilmiştir. Test kümesinde ise 0.69 olarak raporlanan F1 skoru, bu tez çalışmasında A Veri Kümesi için elde edilen en yüksek F1 skoru niteliğindedir.



Şekil 5.16 Metin ve Sayısal Veri Tabanlı ICD Sınıflandırıcı Amacıyla Kullanılan Birleştirilmiş Model Diyagramı (Longformer & GRU)



Şekil 5.17 Birleştirilmiş Model (Longformer) Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor

5.3.2. KEPT ve GRU ile Sınıflandırma

Bu çalışmada elde edilen sonuçları genelleştirebilmek amacıyla literatürdeki en başarılı sonucun elde edildiği KEPT (Knowledge Enhanced Prompt) yöntemi kullanılarak da deneyler gerçekleştirilmiştir. KEPT yöntemi Yang ve arkadaşları [15] tarafından, ICD kodlama amacıyla önerilmiş başka bir Longformer tabanlı dil modelidir. Bu yöntemde, çok sınıflı görevler için alternatif bir yaklaşım geliştirilmiştir. Geliştirilen yaklaşımda,


Longformer modeline taburcu raporlarının yanı sıra, tahmin edilmesi hedeflenen ICD kodlarının açıklamaları da girdi olarak verilmiştir. Bu noktada, öncelikle taburcu notlarının ve ICD kod açıklamalarının sözlüksel öğeleri (token) önceden eğitilmiş Clinical-Longformer yöntemi ile elde edilmiştir. Ayrıca, ICD kod açıklamaları girdi olarak verilirken, sözlüksel öğelendirilmiş açıklamaların sonuna [MASK] sözlüksel ögesi eklenerek bu sözlüksel ögenin dil modeli tarafından tahmin edilmesini hedeflenmiştir. Çıktıda ise her bir hasta başvurusu için sahip olunan ICD kod açıklaması “yes” sözlüksel ögesiyle, sahip olunmayan ICD kod açıklamaları “no” sözlüksel ögesiyle temsil edilerek bire bir kodlama benzeri bir yapı oluşturulmuştur. Böylelikle çıktıda, dil modelinin “yes” olarak tahmin edildiği [MASK] sözlüksel öğeleri tahmin edilen ICD kodu olarak, ‘no’ olarak tahmin edilen [MASK] sözlüksel öğeler ise tahmin edilmeyen ICD kodu olarak elde edilmiştir.

Bu tez çalışmasında, KEPT modeli için Yang ve arkadaşları tarafından eğitilmiş ve paylaşılmış model önceden eğitilmiş model olarak kullanılmıştır. Model, 5.1.’de belirtilen GRU modeli ile birleştirilmiş ve bir sınıflandırıcı katmanı kullanılarak ICD kodlarının kestirimi hedeflenmiştir. Bu noktada KEPT modelinin parametreleri sabitlenirken, GRU ve sınıflandırıcı katmanlarının parametreleri sabitlenmemiş ve söz konusu parametrelerin tekrar eğitilmesi sağlanmıştır.

KEPT ve GRU kullanarak elde edilmiş birleştirilmiş modelin eğitimleri, Bölüm 2.’de aktarılan ve adil bir kıyaslama ortamı yaratabilmek amacıyla üretilen, filtrelenmiş B Veri Kümesi ile gerçekleştirilmiştir. Bu veri kümesi temel KEPT çalışmasında kullanılan veri kümesinden içerdiği hasta başvuru sayısı bakımından farklılık gösterse de önerilen yöntemi genelleştirebilmek açısından yeterli konumdadır.

Eğitim sonucunda, en iyi doğrulama sonuçları 8. eğitim turunda elde edilmiştir. Bu eğitim turunda, doğrulama veri kümesi için doğruluk, Mikro F1 skoru, keskinlik ve duyarlılık değerleri sırasıyla 0.94, 0.75, 0.75 ve 0.74 olmuştur. Elde edilen test Mikro F1 skoru ise 0.75’tir. Bu metriklerin eğitim esnasında elde edilen grafikleri 5.18’de yer almaktadır.

Ayrıca, önerilen yöntemin sonuçlarının sadece metin bazlı verileri girdi olarak alan KEPT modeli ile de kıyaslanması için bu çalışmada kullanılan, önceden eğitilmiş temel KEPT



Şekil 5.18 Birleştirilmiş Model (KEPT) Sonuç Eğrileri, a) Kayıp, b) Doğruluk, c) F1 Skor

modeli, söz konusu test veri kümesi ile test edilmiştir. Bu model için elde edilen Mikro F1 skoru, keskinlik ve duyarlılık değerleri sırasıyla 0.93, 0.73, 0.74 ve 0.72 olmuştur.

Sonuç olarak, KEPT modeli temel alındığında da sayısal verilerin eklenmesiyle sonuçların yükseldiği gözlemlenmiş ve bu tez çalışmasında önerilen yöntem KEPT modeli ile doğrulanmıştır.

6. SONUÇ

Tez kapsamında, hem metin hem de sayısal tabanlı yöntemler önerilmiş ve bu yöntemler içerisinde en iyi sonucun elde edildiği yöntemlerle birleştirilmiş model oluşturulmuştur. Bu modellerin kıyaslaması Tablo 6.1'de yer almaktadır. Bu çalışmada önerilen ve eğitimi gerçekleştirilen, sayısal veriler için en iyi sonucun alındığı yöntem 0.45 F1 oranıyla GRU tabanlı model, metin bazlı veriler için en iyi sonucun alındığı yöntem ise 0.64 F1 oranıyla Longformer tabanlı modeldir. Birleştirilmiş modelde ise iki yöntemden de yukarıda bir F1 skoru 0.69 oranıyla elde edilmiştir. Ayrıca, 5.3.2.'de belirtildiği gibi literatürdeki en başarılı yöntem olan KEPT modelini de temel alarak birleştirilmiş model oluşturulmuş ve bu model de sayısal verileri girdi olarak alan GRU modeli ile birleştirilmiştir. Ancak bu çalışma kapsamında KEPT modelinin eğitimi gerçekleştirilmemiş, Yang ve arkadaşları tarafından elde edilmiş model önceden eğitilmiş model olarak olduğu gibi kullanılmıştır. Tablo 6.1'de

bu modelin de sonuçları yer almaktadır. Bu sonuçlar çalışmada elde edilen en başarılı sonuç konumundadır.

		Kayıp (BCE with Logit)	Doğruluk	Keskinlik	Duyarlılık	Mikro F1
Veri Tipi	Model					
Sadece Sayısal Veriler	CNN	22.17	0.88	0.24	0.56	0.34
	GRU	13.45	0.89	0.36	0.61	0.45
	LSTM	15.35	0.89	0.32	0.55	0.40
Sadece Taburcu Notları	Word2Vec	10.09	0.92	0.61	0.62	0.61
	BERT	9.47	0.93	0.44	0.69	0.54
	Longformer	10.61	0.92	0.56	0.75	0.64
	KEPT	9.16	0.93	0.74	0.72	0.73
Sayısal Veriler & Taburcu Notları	Birleştirilmiş Model (Longformer)	9.32	0.93	0.61	0.76	0.69
	Birleştirilmiş Model (KEPT)	8.67	0.94	0.76	0.74	0.75

Tablo 6.1 Çalışmada Önerilen Yöntemlerden Elde Edilen Sonuçlar

Bu çalışmada ayrıca DDİ algoritmalarının ürettiği maksimum token uzunluğunun da önemli olduğu ortaya konulmuştur. Hasta taburcu notlarının 512 token ile temsil edilemeyecek kadar uzun olması, BERT yönteminden alınan sonucun daha başarısız olmasına neden olmuştur. Ek olarak, raporların vektörlendirilmesi için iki adet BERT modeli ile maksimum token sayısı 1024'e çıkarılsa da sonuçlar yetersiz kalmıştır. Bu çıkarım Yang ve arkadaşlarının [15] çalışmasındaki çıkarım ile de paralellik göstermektedir. Ayrıca Biswas ve arkadaşları [43], Zhang ve arkadaşları [44], Pascual ve arkadaşları [45] da çalışmalarında MIMIC-III veri kümesinden elde edilen taburcu notlarını temsil etmek için daha yüksek boyutlu token vektörlerin kullanılması gerekliliğini göstermişlerdir.

Sayısal veriler için oluşturulan modeller değerlendirildiğinde, yalnızca sayısal verilerin kullanımının bu kestirim görevi için yetersiz olduğunu söylemek mümkündür. Ancak, bu

veriler metin tabanlı verilere ek olarak kullanıldığında genel başarıyı artırdıkları açıkça görülebilir.

Birleştirilmiş modelden (Longformer & GRU) elde edilen örnek bir sonuç Ek 1’de yer almaktadır. Bu örnekte girdi olarak verilen taburcu notunun ham haline karşılık alınan sonuç ve tahmin edilmesi hedeflenen ICD kod etiketleri bulunmaktadır.

Sayısal ve metinsel yöntemlerin sonuçları incelendiğinde, kestirimi yapılan çoğu sınıf için metin bazlı yöntemlerin başarılı olduğu gözlemlense de, bazı sınıflar için sayısal verilerin çok daha iyi sonuçlar ürettiği söylenebilir. Tablo 6.1’de (EK-2) sayısal veriler için kullanılan GRU modelinin her bir sınıf için test veri kümesi hata matrisi bulunmaktadır. Tablo 6.2’de (EK-2) ise metin bazlı veriler için kullanılan Longformer tabanlı yöntemden elde edilen test veri kümesi hata matrisi yer almaktadır. Bu hata matrislerinden anlaşılacağı üzere, sayısal veri tabanlı yöntem ile 17 adet sınıfta 0.2’nin altında F1 skoru elde edilmiştir. Bu sayı metin tabanlı sınıflandırıcıda 8, birleştirilmiş modelde ise 3’tür. 2859 ICD kodlu Anemia NOS (Kansızlık) hastalığı her üç model için en başarısız sınıf olmuştur. Bu sınıf için sayısal veriler ile 0.05, metin bazlı veriler ile 0, birleştirilmiş veriler ile 0.02 F1 skoru elde edilmiştir. Dolayısıyla, bu yöntemlerle tahmin edilmesi en zor olan hastalığın “kansızlık” hastalığı olduğu söylenebilir. Üç veri tipi için de başarılı sonucun aldığı sınıf ise 3961 ICD koduyla Mitral stenoz/aort insuf (Aort Yetmezliği) hastalığıdır, bu sınıf için her bir veri tipi ile yaklaşık 1.0 F1 skoru elde edilmiştir.

Bu tez çalışmasının ana amacı, metin bazlı verilerden DDİ işleme yoluyla gerçekleştirilen çalışmaların başarısını, sayısal verileri de dahil ederek artırmaktır. Bu noktada, metin bazlı veriler ile kestirim sonuçlarının aktarıldığı Bölüm 5.2. ve birleştirilmiş yöntemin sonuçlarının bulunabileceği Bölüm 5.3.’deki sonuç grafiklerinden anlaşılacağı üzere Mikro F1 skoru anlamında %5’e yakın bir iyileşme söz konusudur. Dolayısıyla hedeflenen sonuca ulaşıldığını söylemek mümkündür.

Sonuçları sınıf bazlı olarak daha detaylı bir şekilde değerlendirebilmek için Ek 6.’de yer alan hata matrislerini her bir sınıf için ayrı ayrı incelemek gerekmektedir. Söz konusu matrisler incelendiğinde, 28 adet sınıfta Mikro F1 skorunun arttığı gözlemlenmiştir. En çok artış

yaşanan ICD kodları 2875 ve 2761 ICD kodlarıdır, bu kodlar sırasıyla Thrombocytopenia (Trombositopeni - kandaki trombosit sayısının azlığı) ve Hyposmolality (Hipoosmolalite - sıvı fazlalığı veya sodyum kaybı) hastalıklarını temsil etmektedir. 22 adet sınıfta ise Mikro F1 skorunun sabit kaldığı veya azaldığı gözlemlenmiştir. Ancak bu azalma sınıf bazında en çok 0.1 ile sınırlı kalmıştır. Dolayısıyla, azalma yaşanan sınıflarda da çok fazla bir kaybın olmadığı söylenebilir.

Tablo 6.2’de ICD kodlarının kestirimi için önerilen ve Bölüm 2.’de detayları aktarılan C Veri Kümesi ile gerçekleştirilmiş literatürdeki çalışmaların 50 ICD kodu için Mikro F1 skoru sonuçları yer almaktadır. Tabloda ayrıca bu tez çalışmasındaki en başarılı sonuçların elde edildiği yöntemlerin F1 skorları ve bu yöntemlerde kullanılan veri kümeleri de bulunmaktadır. Koyu renkle ifade edilmiş satırlar bu çalışmadan elde edilmiş sonuçlara aittir, diğer satırlardaki sonuçlar ise çalışmaların kendisinden alınmıştır. Diğer çalışmalarda kullanılan veri kümeleri bu çalışmadaki veri kümesinden farklı olduğu için adil bir kıyaslama ortamı yaratılamasa da, önerilen birleştirilmiş yöntemin test edilen her iki deneyde de çalışmaların başarısını artırdığını söylemek mümkündür. Dolayısıyla, test edilen her bir metin bazlı model için sayısal veriler eklendiğinde başarının arttığı sonucuna ulaşılmıştır. Ayrıca, söz konusu bu yöntem Bölüm 5.3.2.’de aktarılan, Yang ve arkadaşlarının önerdiği KEPT yöntemi ile kullanıldığında bu çalışmadaki ve literatürdeki en başarılı sonuç elde edilmiştir.

Çalışma	Mikro F-1 Skoru	Veri Kümesi	Veri Tipi
Bu Çalışma (KEPT + Sayısal Sınıflandırıcı)	0.751	B Veri Kümesi	Metin + Sayısal
Bu Çalışma (KEPT)	0.733	B Veri Kümesi	Metin
Zhichao Yang (KEPT) [15]	0.728	C Veri Kümesi	Metin
Zheng Yuan [14]	0.725	C Veri Kümesi	Metin
Thanh Vu [13]	0.716	C Veri Kümesi	Metin
Yang Liu [27]	0.717	Tüm MIMIC Veri Kümesi	Metin
Bu Çalışma (Longformer + Sayısal Sınıflandırıcı)	0.691	A Veri Kümesi	Metin + Sayısal
Xiancheng Xie [11]	0.684	C Veri Kümesi	Metin
Fei Li [46]	0.670	Tüm MIMIC Veri Kümesi	Metin
Bu Çalışma (Longformer)	0.640	A Veri Kümesi	Metin
James Mullenbach [12]	0.633	C Veri Kümesi	Metin

Tablo 6.2 Sonuçların Literatürdeki Diğer Çalışmalarla Karşılaştırılması

KAYNAKLAR

- [1] Rnn, lstm & gru. <http://dprogrammer.org/rnn-lstm-gru>. Accessed: 2022-12-12.
- [2] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9:1735–80, **1997**. doi:10.1162/neco.1997.9.8.1735.
- [3] Kyunghyun Cho, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using RNN encoder–decoder for statistical machine translation. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pages 1724–1734. Association for Computational Linguistics, Doha, Qatar, **2014**. doi:10.3115/v1/D14-1179.
- [4] Liying Liu and Yain-Whar Si. 1d convolutional neural networks for chart pattern classification in financial time series. *J. Supercomput.*, 78(12):14191–14214, **2022**. ISSN 0920-8542. doi:10.1007/s11227-022-04431-5.
- [5] Xin Rong. word2vec parameter learning explained. *CoRR*, abs/1411.2738, **2014**.
- [6] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, editors, *Advances in Neural Information Processing Systems*, volume 30. Curran Associates, Inc., **2017**.
- [7] Tushaar Gangavarapu, Aditya Jayasimha, Gokul S. Krishnan, and Sowmya Kamath S. Predicting icd-9 code groups with fuzzy similarity based supervised multi-label classification of unstructured clinical nursing notes. *Knowledge-Based Systems*, 190:105321, **2020**. ISSN 0950-7051. doi:https://doi.org/10.1016/j.knosys.2019.105321.

- [8] Yuqi Si, Jingcheng Du, Zhao Li, Xiaoqian Jiang, Timothy Miller, Fei Wang, W. Jim Zheng, and Kirk Roberts. Deep representation learning of patient data from electronic health records (EHR): A systematic review. *Journal of Biomedical Informatics*, 115:103671, **2021**. doi:10.1016/j.jbi.2020.103671.
- [9] Pascal Vincent, Hugo Larochelle, Isabelle Lajoie, Yoshua Bengio, and Pierre-Antoine Manzagol. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(110):3371–3408, **2010**.
- [10] Sanjay Purushotham, Chuizheng Meng, Zhengping Che, and Yan Liu. Benchmarking deep learning models on large healthcare datasets. *Journal of Biomedical Informatics*, 83:112–134, **2018**. ISSN 1532-0464. doi:<https://doi.org/10.1016/j.jbi.2018.04.007>.
- [11] Pengtao Xie and Eric Xing. A neural architecture for automated ICD coding. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*. Association for Computational Linguistics, **2018**. doi:10.18653/v1/p18-1098.
- [12] James Mullenbach, Sarah Wiegrefe, Jon Duke, Jimeng Sun, and Jacob Eisenstein. Explainable prediction of medical codes from clinical text. In *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)*, pages 1101–1111. Association for Computational Linguistics, New Orleans, Louisiana, **2018**. doi:10.18653/v1/N18-1100.
- [13] Thanh Vu, Dat Quoc Nguyen, and Anthony Nguyen. A label attention model for icd coding from clinical text. In *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence, IJCAI-20*, pages 3335–3341. **2020**. doi:10.24963/ijcai.2020/461. Main track.

- [14] Zheng Yuan, Chuanqi Tan, and Songfang Huang. Code synonyms do matter: Multiple synonyms matching network for automatic ICD coding. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*, pages 808–814. Association for Computational Linguistics, Dublin, Ireland, **2022**.
- [15] Zhichao Yang, Shufan Wang, Bhanu Pratap Singh Rawat, Avijit Mitra, and Hong Yu. Knowledge injected prompt based fine-tuning for multi-label few-shot icd coding, **2022**. doi:10.48550/ARXIV.2210.03304.
- [16] J. R. Le Gall. A new simplified acute physiology score (SAPS II) based on a european/north american multicenter study. *JAMA: The Journal of the American Medical Association*, 270(24):2957–2963, **1993**. doi:10.1001/jama.270.24.2957.
- [17] J. L. Vincent, R. Moreno, J. Takala, S. Willatts, A. De Mendonça, H. Bruining, C. K. Reinhart, P. M. Suter, and L. G. Thijs. The SOFA (sepsis-related organ failure assessment) score to describe organ dysfunction/failure. *Intensive Care Medicine*, 22(7):707–710, **1996**. doi:10.1007/bf01709751.
- [18] H. Michael Marsh, Iqbal Krishan, James M. Naessens, Robert A. Strickland, Douglas R. Gracey, Mary E. Champion, Fred T. Nobrega, Peter A. Southorn, John C. McMichan, and Mary P. Kelly. Assessment of prediction of mortality by using the apache ii scoring system in intensive-care units. *Mayo Clinic Proceedings*, 65(12):1549–1557, **1990**. ISSN 0025-6196. doi:https://doi.org/10.1016/S0025-6196(12)62188-0.
- [19] Kexin Huang, Jaan Altosaar, and Rajesh Ranganath. Clinicalbert: Modeling clinical notes and predicting hospital readmission, **2019**. doi:10.48550/ARXIV.1904.05342.
- [20] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: pre-training of deep bidirectional transformers for language understanding. In Jill Burstein, Christy Doran, and Thamar Solorio, editors, *Proceedings of the 2019*

Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL-HLT 2019, Minneapolis, MN, USA, June 2-7, 2019, Volume 1 (Long and Short Papers), pages 4171–4186. Association for Computational Linguistics, **2019**. doi:10.18653/v1/n19-1423.

- [21] Mengqi Jin, Mohammad Taha Bahadori, Aaron Colak, Parminder Bhatia, Busra Celikkaya, Ram Bhakta, Selvan Senthivel, Mohammed Khalilia, Daniel Navarro, Borui Zhang, Tiberiu Doman, Arun Ravi, Matthieu Liger, and Taha Kass-hout. Improving hospital mortality prediction with medical named entities and multimodal learning, **2018**. doi:10.48550/ARXIV.1811.12276.
- [22] Minmin Chen. Efficient vector representation for documents through corruption. *5th International Conference on Learning Representations*, **2017**.
- [23] Yanyao Shen, Hyokun Yun, Zachary Lipton, Yakov Kronrod, and Animashree Anandkumar. Deep active learning for named entity recognition. In *Proceedings of the 2nd Workshop on Representation Learning for NLP*, pages 252–256. Association for Computational Linguistics, Vancouver, Canada, **2017**. doi:10.18653/v1/W17-2630.
- [24] Zhouhan Lin, Minwei Feng, Cícero Nogueira dos Santos, Mo Yu, Bing Xiang, Bowen Zhou, and Yoshua Bengio. A structured self-attentive sentence embedding. In *5th International Conference on Learning Representations, ICLR 2017, Toulon, France, April 24-26, 2017, Conference Track Proceedings*. OpenReview.net, **2017**.
- [25] Arthur D. Reys, Danilo Silva, Daniel Severo, Saulo Pedro, Marcia M. de Sousa e Sá , and Guilherme A. C. Salgado. Predicting multiple ICD-10 codes from brazilian-portuguese clinical notes. In *Intelligent Systems*, pages 566–580. Springer International Publishing, **2020**. doi:10.1007/978-3-030-61377-8_39.

- [26] Leopold Franz, Yash Shrestha, and Bibek Paudel. A deep learning pipeline for patient diagnosis prediction using electronic health records. **2020**. doi:10.1145/1122445.1122457.
- [27] Yang Liu, Hua Cheng, Russell Klopfer, Matthew R. Gormley, and Thomas Schaaf. Effective convolutional attention network for multi-label clinical document classification. In *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, pages 5941–5953. Association for Computational Linguistics, Online and Punta Cana, Dominican Republic, **2021**. doi:10.18653/v1/2021.emnlp-main.481.
- [28] Min Chen, Yixue Hao, Kai Hwang, Lu Wang, and Lin Wang. Disease prediction by machine learning over big data from healthcare communities. *Ieee Access*, 5:8869–8879, **2017**.
- [29] Chung-Chian Hsu, Pei-Chi Chang, and Arthur Chang. Multi-label classification of icd coding using deep learning. In *2020 International Symposium on Community-centric Systems (CcS)*, pages 1–6. IEEE, **2020**.
- [30] Dongyang Wang, Junli Su, and Hongbin Yu. Feature extraction and analysis of natural language processing for deep learning english language. *IEEE Access*, PP:1–1, **2020**. doi:10.1109/ACCESS.2020.2974101.
- [31] Tomás Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean. Efficient estimation of word representations in vector space. In Yoshua Bengio and Yann LeCun, editors, *1st International Conference on Learning Representations, ICLR 2013, Scottsdale, Arizona, USA, May 2-4, 2013, Workshop Track Proceedings*. **2013**.
- [32] Quoc Le and Tomas Mikolov. Distributed representations of sentences and documents. In Eric P. Xing and Tony Jebara, editors, *Proceedings of the 31st International Conference on Machine Learning*, volume 32 of *Proceedings of Machine Learning Research*, pages 1188–1196. PMLR, Beijing, China, **2014**.

- [33] Iz Beltagy, Matthew E. Peters, and Arman Cohan. Longformer: The long-document transformer. *arXiv:2004.05150*, **2020**.
- [34] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, Alban Desmaison, Andreas Kopf, Edward Yang, Zachary DeVito, Martin Raison, Alykhan Tejani, Sasank Chilamkurthy, Benoit Steiner, Lu Fang, Junjie Bai, and Soumith Chintala. Pytorch: An imperative style, high-performance deep learning library. In *Advances in Neural Information Processing Systems 32*, pages 8024–8035. Curran Associates, Inc., **2019**.
- [35] Wes McKinney. Data Structures for Statistical Computing in Python. In Stéfan van der Walt and Jarrod Millman, editors, *Proceedings of the 9th Python in Science Conference*, pages 56 – 61. **2010**. doi:10.25080/Majora-92bf1922-00a.
- [36] Edward Loper and Steven Bird. Nltk: The natural language toolkit. *CoRR*, cs.CL/0205028, **2002**.
- [37] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, **2011**.
- [38] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization, **2014**. Cite arxiv:1412.6980Comment: Published as a conference paper at the 3rd International Conference for Learning Representations, San Diego, 2015.
- [39] Y. Zhu, R. Kiros, R. Zemel, R. Salakhutdinov, R. Urtasun, A. Torralba, and S. Fidler. Aligning books and movies: Towards story-like visual explanations by watching movies and reading books. In *2015 IEEE International Conference on Computer Vision (ICCV)*, pages 19–27. IEEE Computer Society, Los Alamitos, CA, USA, **2015**. ISSN 2380-7504. doi:10.1109/ICCV.2015.11.

- [40] Mahnaz Koupaee and William Yang Wang. Wikihow: A large scale text summarization dataset, **2018**. doi:10.48550/ARXIV.1810.09305.
- [41] Mandar Joshi, Eunsol Choi, Daniel Weld, and Luke Zettlemoyer. TriviaQA: A large scale distantly supervised challenge dataset for reading comprehension. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1601–1611. Association for Computational Linguistics, Vancouver, Canada, **2017**. doi:10.18653/v1/P17-1147.
- [42] Yikuan Li, Ramsey M Wehbe, Faraz S Ahmad, Hanyin Wang, and Yuan Luo. Clinical-longformer and clinical-bigbird: Transformers for long clinical sequences. *arXiv preprint arXiv:2201.11838*, **2022**.
- [43] Biplob Biswas, Thai-Hoang Pham, and Ping Zhang. Transicd: Transformer based code-wise attention model for explainable icd coding. In Allan Tucker, Pedro Henriques Abreu, Jaime Cardoso, Pedro Pereira Rodrigues, and David Riaño, editors, *Artificial Intelligence in Medicine*, pages 469–478. Springer International Publishing, Cham, **2021**. ISBN 978-3-030-77211-6.
- [44] Zachariah Zhang, Jingshu Liu, and Narges Razavian. BERT-XML: Large scale automated ICD coding using BERT pretraining. In *Proceedings of the 3rd Clinical Natural Language Processing Workshop*, pages 24–34. Association for Computational Linguistics, Online, **2020**. doi:10.18653/v1/2020.clinicalnlp-1.3.
- [45] Damian Pascual, Sandro Luck, and Roger Wattenhofer. Towards BERT-based automatic ICD coding: Limitations and opportunities. In *Proceedings of the 20th Workshop on Biomedical Language Processing*, pages 54–63. Association for Computational Linguistics, Online, **2021**. doi:10.18653/v1/2021.bionlp-1.6.
- [46] Fei Li and Hong Yu. Icd coding from clinical text using multi-filter residual convolutional neural network. In *Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence*. **2020**.

EKLER

EK 1 - Test Veri Kümesinde Yer Alan Örnek Bir Hasta Taburcu Notu ve Sonucu

Admission Date: [**2127-4-25**] Discharge Date: [**2127-4-29**] Date of Birth: [**2074-8-24**] Sex: M Service: CARDIOTHORACIC Allergies: No Known Allergies / Adverse Drug Reactions Attending:[**First Name3 (LF) 165**] Chief Complaint: chest pain Major Surgical or Invasive Procedure: OPERATION: 1. Emergency coronary artery bypass graft x6, left internal mammary artery to left anterior descending artery, saphenous vein sequential grafting to obtuse marginal 1 and 2, saphenous vein sequential grafting to posterior left ventricular branch and posterior descending artery, saphenous vein graft to diagonal. 2. Endoscopic harvesting of the long saphenous vein. History of Present Illness: Mr. [**Known lastname **] is a 52 yo who woke this pm with left sided chest discomfort radiating to jaw. He has no history of similar pain. He was taken by EMS where he was found to have ST elevations in the inferior leads, which resolved with nitroglycerine. He was taken to the cath lab were he was found to have severe, difuse 3 vessel disease not amenable to percutaneous intervention. He is transfered for surgical intervention. Past Medical History: PMHx: Multiple broken bones, s/p spinal fusion "L region" 25 years ago s/p surgical repair/pinning of R clavicle s/p repair of torn R rotator cuff Social History: Lives with:wife and 3 children Occupation:IT analyst Tobacco:denies ETOH:2 beers/week runs 5 miles/day Family History: n/c Physical Exam: Physical Exam Pulse:47 Resp: 14 O2 sat: 100B/P Right: 115/67 Left: Height: Weight: General: Skin: Dry [x] intact [x] HEENT: PERRLA [x] EOMI [x] Neck: Supple [x] Full ROM [x] Chest: Lungs clear bilaterally [x] Heart: RRR [x] Irregular [] Murmur-none Abdomen: Soft [x] non-distended [x] non-tender [x] bowel sounds + [x] Extremities: Warm [x], well-perfused [x] Edema none [x]Varicosities: None [x] Neuro: Grossly intact [x] Pulses: Femoral Right: angioseal-no hematoma Left:2+ DP Right:2+ Left:2+ PT [**Name (NI) 167**]:2+ Left:2+ Radial Right: 2+ Left:2+ Carotid Bruit Right: none Left:none Pertinent

Results: [**2127-4-29**] 06:50AM BLOOD WBC-5.8 RBC-3.11* Hgb-10.3* Hct-28.9*
 MCV-93 MCH-33.3* MCHC-35.8* RDW-14.6 Plt Ct-187# [**2127-4-25**] 04:14AM
 BLOOD WBC-4.8 RBC-4.03* Hgb-13.4* Hct-37.7* MCV-94 MCH-33.2* MCHC-35.5*
 RDW-12.6 Plt Ct-237 [**2127-4-25**] 01:43PM BLOOD PT-14.2* PTT-26.3 INR(PT)-1.2*
 [**2127-4-25**] 04:14AM BLOOD PT-12.6 PTT-46.5* INR(PT)-1.1 [**2127-4-29**]
 06:50AM BLOOD Glucose-96 UreaN-15 Creat-0.9 Na-139 K-4.2 Cl-103 HCO3-27
 AnGap-13 [**2127-4-25**] 04:14AM BLOOD Glucose-107* UreaN-15 Creat-0.7 Na-139
 K-3.7 Cl-105 HCO3-27 AnGap-11 [**Hospital1 18**] ECHOCARDIOGRAPHY REPORT
 [**Known lastname **], [**Known firstname **] [**Hospital1 18**] [**Numeric Identifier
 89931**] (Complete) Done [**2127-4-25**] at 9:34:01 AM FINAL Referring Physician
 [**Name9 (PRE) **] Information [**Name9 (PRE) **], [**First Name3 (LF) **] Division
 of Cardiothoracic [**Doctor First Name **] [**First Name (Titles) **] [**Last Name
 (Titles) **] [**Hospital Unit Name 4081**] [**Location (un) 86**], [**Numeric Identifier
 718**] Status: Inpatient DOB: [**2074-8-24**] Age (years): 52 M Hgt (in): 72 BP (mm
 Hg): 101/56 Wgt (lb): 200 HR (bpm): 40 BSA (m2): 2.13 m2 Indication: Intraop CABG
 acute STEMI ICD-9 Codes: 410.91, 424.0 Test Information Date/Time: [**2127-4-25**]
 at 09:34 Interpret MD: [**First Name8 (NamePattern2) **] [**Last Name (NamePattern1)
], MD Test Type: TEE (Complete) Son[Name (NI) 930**]: [**Initials (NamePattern4)
] [Last Name (NamePattern4) **], MD Doppler: Full Doppler and color Doppler Test
 Location: Anesthesia West OR cardiac Contrast: None Tech Quality: Adequate Tape #:
 2011AW1-: Machine: us 4 Echocardiographic Measurements Results Measurements Normal
 Range Left Ventricle - Septal Wall Thickness: *1.4 cm 0.6 - 1.1 cm Left Ventricle -
 Inferolateral Thickness: *1.2 cm 0.6 - 1.1 cm Left Ventricle - Diastolic Dimension: *5.8 cm
 j= 5.6 cm Left Ventricle - Systolic Dimension: 3.3 cm Left Ventricle - Fractional Shortening:
 0.43 j= 0.29 Left Ventricle - Ejection Fraction: 55 Left Ventricle - Stroke Volume: 76 ml/beat
 Left Ventricle - Cardiac Output: 3.04 L/min Left Ventricle - Cardiac Index: *1.43 j= 2.0
 L/min/M2 Aorta - Sinus Level: 3.3 cm j= 3.6 cm Aorta - Ascending: 3.4 cm j= 3.4 cm
 Aortic Valve - Peak Gradient: 4 mm Hg j 20 mm Hg Aortic Valve - Mean Gradient: 2
 mm Hg Aortic Valve - LVOT VTI: 20 Aortic Valve - LVOT diam: 2.2 cm Aortic Valve -
 Valve Area: 3.3 cm² j= 3.0 cm² Mitral Valve - E Wave: 0.5 m/sec Mitral Valve - A Wave:

0.2 m/sec Mitral Valve - E/A ratio: 2.50 Mitral Valve - E Wave deceleration time: 197 ms
140-250 ms Findings LEFT ATRIUM: Normal LA size. RIGHT ATRIUM/INTERATRIAL
SEPTUM: Normal RA size. LEFT VENTRICLE: Mild symmetric LVH. Mildly dilated LV
cavity. Overall normal LVEF (<55RIGHT VENTRICLE: Normal RV chamber size and free
wall motion. AORTA: Normal aortic diameter at the sinus level. Normal ascending aorta
diameter. No atheroma in ascending aorta. Normal aortic arch diameter. Focal calcifications
in aortic arch. Normal descending aorta diameter. Focal calcifications in descending aorta.
AORTIC VALVE: Normal aortic valve leaflets (3). No AS. No AR. MITRAL VALVE:
Normal mitral valve leaflets with trivial MR. TRICUSPID VALVE: Normal tricuspid valve
leaflets with trivial TR. PULMONIC VALVE/PULMONARY ARTERY: Normal pulmonic
valve leaflets. No PR. PERICARDIUM: No pericardial effusion. GENERAL COMMENTS:
A TEE was performed in the location listed above. I certify I was present in compliance
with HCFA regulations. No TEE related complications. Conclusions Pre bypass: The left
atrium is normal in size. There is mild symmetric LVH with mild LV chamber enlargement.
Overall left ventricular systolic function is normal (LVEF<55ventricular chamber size and
free wall motion are normal. The aortic valve leaflets (3) appear structurally normal with
good leaflet excursion and no aortic regurgitation. The mitral valve appears structurally
normal with trivial mitral regurgitation. Post bypass: Patient is a paced on phenylephrine
infusion. Preserved biventricular function, LVEF <55Aortic contours intact. Remaining exam
is unchanged. All findings discussed with surgeons at the time of the exam. I certify that I
was present for this procedure in compliance with HCFA regulations. Electronically signed
by [**First Name8 (NamePattern2) **] [**Last Name (NamePattern1) **], MD, Interpreting
physician [**Last Name (NamePattern4) **] [**2127-4-25**] 13:51 ?????? [**2119**]
CareGroup IS. All rights reserved. Brief Hospital Course: The patient was brought to the
operating room on [**4-25**] where he underwent CABGX6 (left internal mammary
artery to left anterior descending artery, saphenous vein sequential grafting to obtuse
marginal 1 and 2, saphenous vein sequential grafting to posterior left ventricular branch
and posterior descending artery, saphenous vein graft to diagonal) with Dr.[**First Name
(STitle) **]. Please refer to operative report for further surgical details. He was transferred
to CVICU in stable condition for recovery and invasive monitoring. POD 1 found the patient

extubated, alert and oriented and breathing comfortably. He was neurologically intact and hemodynamically stable, weaned from inotropic and vasopressor support. Beta blocker was initiated and the patient was gently diuresed toward the preoperative weight. Mr.[**Known lastname **] was transferred to the step down unit further recovery. Chest tubes and pacing wires were discontinued without complication. Physical therapy was consulted for evaluation of assistance with strength and mobility. He continued to progress and by the time of discharge on POD #4 he was ambulating freely, the wound was healing and pain was controlled with oral analgesics. Dr.[**First Name (STitle) **] cleared him for discharge to home with VNA services on POD#4. All appropriate follow up instructions were advised.

Medications on Admission: None Discharge Medications: 1. oxycodone-acetaminophen 5-325 mg Tablet Sig: 1-2 Tablets PO Q4H (every 4 hours) as needed for pain. Disp:*50 Tablet(s)* Refills:*0* 2. ranitidine HCl 150 mg Tablet Sig: One (1) Tablet PO BID (2 times a day). Disp:*60 Tablet(s)* Refills:*2* 3. simvastatin 10 mg Tablet Sig: Two (2) Tablet PO DAILY (Daily). Disp:*60 Tablet(s)* Refills:*2* 4. metoprolol tartrate 25 mg Tablet Sig: 0.5 Tablet PO BID (2 times a day). Disp:*30 Tablet(s)* Refills:*2* 5. docusate sodium 100 mg Capsule Sig: One (1) Capsule PO BID (2 times a day). Disp:*60 Capsule(s)* Refills:*2* 6. furosemide 40 mg Tablet Sig: One (1) Tablet PO once a day for 7 days. Disp:*7 Tablet(s)* Refills:*0* 7. potassium chloride 10 mEq Tablet Extended Release Sig: Two (2) Tablet Extended Release PO once a day for 7 days. Disp:*14 Tablet Extended Release(s)* Refills:*0* 8. aspirin 81 mg Tablet, Delayed Release (E.C.) Sig: One (1) Tablet, Delayed Release (E.C.) PO DAILY (Daily). Disp:*60 Tablet, Delayed Release (E.C.)(s)* Refills:*2* Discharge Disposition: Home With Service Facility: Care Centrix Discharge Diagnosis: CAD Discharge Condition: Alert and oriented x3 nonfocal Ambulating, gait steady Sternal pain managed with oral analgesics Sternal Incision - healing well, no erythema or drainage Discharge Instructions: DISCHARGE INSTRUCTIONS: Please shower daily including washing incisions gently with mild soap, no baths or swimming, and look at your incisions Please NO lotions, cream, powder, or ointments to incisions Each morning you should weigh yourself and then in the evening take your temperature, these should be written down on the chart No driving for approximately one month and while taking narcotics, will be discussed at follow up appointment with surgeon when you will be able

to drive No lifting more than 10 pounds for 10 weeks Please call with any questions or concerns [**Telephone/Fax (1) 170**] **Please call cardiac surgery office with any questions or concerns [**Telephone/Fax (1) 170**]. Answering service will contact on call person during off hours** Females: Please wear bra to reduce pulling on incision, avoid rubbing on lower edge Followup Instructions: You are scheduled for the following appointments: Surgeon Dr.[**Last Name (STitle) 7772**] #[**Telephone/Fax (1) 170**] Date/Time:[**2127-5-26**] at 1:00 Cardiologist Dr.[**Last Name (STitle) 31888**] on [**5-29**] at 1pm Please call to schedule the following: Primary Care Dr. [**Last Name (STitle) **],[**First Name3 (LF) **] in [**5-20**] weeks Address: [**2127**], [**Apartment Address(1) 3745**], [**Location (un) **],[**Numeric Identifier 42001**] Phone: [**Telephone/Fax (1) 76493**] [**Name6 (MD) **] [**Name8 (MD) **] MD [**MD Number(2) 173**] Completed by:[**2127-4-29**]

Etiket:

- Single internal mammary-coronary artery bypass (3615)
- Extracorporeal circulation auxiliary to open heart surgery (3961)
- Coronary Atherosclerosis of native coronary artery (41401)

Tahmin:

- Single internal mammary-coronary artery bypass (3615)
- Extracorporeal circulation auxiliary to open heart surgery (3961)
- Coronary Atherosclerosis of native coronary artery (41401)
- Anemia, unspecified (2859)

EK 2 - Elde Edilen Hata Matrisleri



Şekil 6.1 GRU Modeli için Elde Edilen Hata Matrisi



Şekil 6.2 Longformer Modeli için Elde Edilen Hata Matrisi



Şekil 6.3 Birleştirilmiş Model için Elde Edilen Hata Matrisi