



**T.C. İSTANBUL T CARET
 NİVERSİTESİ**

FEN B LİMLERİ ENSTİT S 

**HEK ME TANI KOYMADA YARDIMCI, YAPAY ZEKA DESTEKL 
HASTALIK TESP T UZMANI**

Ethem KARAL

**Dan şman
Dr.  ğr.  yesi Metin TURAN**

**Y KSEK L SANS TEZİ
B LGİSAYAR M HENDİSLİĐİ ANAB LİM DALI
İSTANBUL - 2021**

KABUL VE ONAY SAYFASI

Ethem KARAL tarafından hazırlanan "**Hekime Tanı Koymada Yardımcı, Yapay Zeka Destekli Hastalık Tespit Uzmanı**" adlı tez çalışması 05/07/2021 tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman	Dr. Öğr. Üyesi Metin TURAN İstanbul Ticaret Üniversitesi
Jüri Üyesi	Dr. Öğr. Üyesi Arzu KAKIŞIM İstanbul Ticaret Üniversitesi
Jüri Üyesi	Dr. Öğr. Üyesi Zeynep TURGUT AKGÜN İstanbul Medeniyet Üniversitesi

Onay Tarihi : 29.07.2021

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsünün 29.07.2021 tarih ve 2021/317 numaralı Yönetim Kurulu Kararının 2. maddesi gereğince, ders yüklerini ve tez yükümlülüğünü yerine getirdiği belirlenen "Ethem KARAL" adlı öğrencinin mezun olmasına oy birliği ile karar verilmiştir.

Prof. Dr. Necip ŞİMŞEK
Enstitü Müdürü

AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

29.07.2021

Ethem KARAL

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER.....	i
ÖZET	ii
ABSTRACT	iv
TEŞEKKÜR.....	vi
ŞEKİLLER LİSTESİ	vii
ÇİZELGE LİSTESİ.....	ix
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ.....	3
3. YAPAY ZEKA YÖNTEMİ KULLANARAK ÖYKÜ (ANAMNEZ) ALMA	3
3.1. Öykü (Anamnez) Alma.....	3
3.2. Öykü (Anamnez) Almanın Önemi.....	3
3.3. Ökü (Anamnez) Alma Anket Sonuçları	9
3.4. Vücut Kitle İndeksinin Bu Araştırma İçin Önemi	13
3.5. Anamnez ile Alınan Verilerin Anlamlandırılmasında Metin Temizleme	14
3.5.1. Ön İşleme	14
3.5.1.1. Stem.....	15
3.5.1.2. Root	15
3.5.1.3. Stemming (Kök Bulma).....	15
3.5.1.4. Lemmatization	16
3.5.1.5. Tokenizing	16
3.6. Anamnez ile Alınan Sonuçların Kategorik Hale Getirilip Eğitilmesi .	16
4. ANAMNEZ SIRASINDA ALINAN VERİLERİN EĞİTİM AŞAMASI	19
4.1. Öğrenme Süreci	19
4.2. Karar Ağaçları	19
4.2.1. Bilgi Kazanımı	20
4.2.2. Gini	21
4.3. Ensemble Yöntemler (Topluluk Öğrenme)	23
4.3.1. Torbalama (Bagging)	24
4.3.2. Artırma (Boosting)	28
4.4. Yapay Sinir Ağları	33
4.5. Siyam Ağı (Siamese Network) Kullanılarak Öğrenme	37
4.5.1. RNN çalışması	37
4.5.2. LSTM	38
4.5.3. BLSTM (Çift Yönlü Kısa Süreli Bellek)	39
4.5.4. Siyam Ağı (Siamese Network)	43
4.5.5. BLSTM ve Siyam Ağı (Siamese Network) kullanılarak öğrenme	44
5. SONUÇ VE ÖNERİLER	51
KAYNAKLAR	52
ÖZGEÇMİŞ.....	55

ÖZET

Yüksek Lisans Tezi

HEKİME TANI KOYMADA YARDIMCI, YAPAY ZEKA DESTEKLİ HASTALIK TESPİT UZMANI

Ethem KARAL

İstanbul Ticaret Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Metin TURAN

2021, 55 sayfa

Bu çalışma, makine öğrenmesi, veri madenciliği ve yapay zeka teknolojileri kullanılarak, hastaya tanı konulmasını kolaylaştırmayı hedeflemektedir. Doğal dil işleme süreçleri ile hasta anamnezleri değerlendirilerek, tanı koymada yardımcı bir sistem oluşturulmuştur. Oluşturulan sistem ile hastadan anamnez alınırken her bir hastalık belirtisi içeren konu başlığı önce anlamlandırılır, sonra kategorize edilerek eğitim yapılır.

Karar Ağaçları, Torbalama, Arttırma, CNN ve Siyam Ağı kullanılarak öğrenme işlemleri gerçekleştirilmiştir. Hastalıkların belirtileri öykü alma sırasında değerlendirilmiştir. Covid-19 gibi pandemi dönemlerinde ya da belirtileri/tedavi yöntemleri/hasta sayısı konularında az veriye sahip olunan dönemlerde, sağlık çalışanlarına ve sağlık sistemine yardımcı bir sistem geliştirilmesi hedeflenmiştir.

Pandemi gibi dönemlerde, sağlık çalışanlarına hızlı çözüm önerileri sunarak yardımcı olabilen ve sağlık sistemine destekleyici olabilecek yöntem ve metotların geliştirilmesi üzerinde durulmuştur. Bu çalışmada alınan veriler ile belirlenmiş olan yöntemler sayesinde büyük doğruluk oranı ile hastalık tanısı koyulması sağlanmıştır.

Hastanın anamnez verilerini değerlendiren sistem, hekime olası sonuçların listesini sunarak hekimin işini kolaylaştırmıştır. Yapay zekanın sonuçlarını değerlendirerek sonuçlara katılmak ya da katılmamak ise tamamen doktorun tercihinin bırakılmıştır.

Anahtar Kelimeler: Doğal dil işleme, hastalık tespit sistemi, makine öğrenmesi, yapay sinir Ağı, yapay zeka.

ABSTRACT

M.Sc. Thesis

ASSISTANT IN DIAGNOSIS FOR DOCTOR, ARTIFICIAL INTELLIGENCE SUPPORTED DISEASE DETECTION SPECIALIST

Ethem KARAL

**İstanbul Commerce University
Graduate School of Applied and Natural Sciences
Department of Computer Engineering**

Supervisor: Assist. Prof. Dr. Metin TURAN

2021, 55 pages

This article aims to facilitate the diagnosis of the patient by using machine learning, data mining and artificial intelligence technologies. With natural language processing processes, patient anamnesis was evaluated and an auxiliary system was created for diagnosis. While taking anamnesis from the patient with the system created, each topic containing the symptoms of the disease is first evaluated, then categorized and trained.

Learning operations were carried out using Decision Tree, Bagging, Boosting, CNN and Siamese Network. Symptoms of the diseases were evaluated during history taking. It is aimed to develop a system that assists health workers and the health system in pandemic periods such as Covid-19 or in periods when there is little data on symptoms / treatment methods / number of patients. This system created; helped doctors diagnose patients' ailments with higher accuracy and efficiency.

In line with all the information obtained in this study; By using machine learning methods, Neural Network and Siamese Network, it is aimed to diagnose the correct disease and to create an auxiliary system for the health system.

The system, which evaluates the patient's anamnesis data, has facilitated the physician's work by presenting a list of possible results to the physician. Evaluating the results of artificial intelligence, whether or not to agree with the results is entirely up to the doctor's choice.

Keywords: Artificial intelligence, artificial neural network, disease detection system, machine learning, natural language processing.

TEŞEKKÜR

Bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan değerli Danışman Hocam Dr. Öğr. Üyesi Metin TURAN'a teşekkürlerimi sunarım.

Tezimin anket aşamasında Tuzla Marmara Üniversitesi Pendik E. A. H. Eğitim Aile Sağlığı Merkezinde görevli olan doktorlara desteklerinden dolayı teşekkür ederim.

Tezimin her aşamasında beni yalnız bırakmayan değerli eşim Şebnem KARAL ve sevgili kızım Lena KARAL'a sonsuz sevgi ve saygılarımı sunarım.

Ethem KARAL
İSTANBUL, 2021

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1: Hastalık isimleri	10
Şekil 2.2: Ağrının yerleşim yeri ve şiddeti	11
Şekil 2.3: Ağrıyı artıran ve azaltan nedenler	11
Şekil 2.4: Ağrıya eşlik eden belirtiler	11
Şekil 2.5: Geçmiş geçirilen hastalıklar ve alınan tedavi yöntemleri	11
Şekil 2.6: Hastaneye yatış ve ameliyat geçirilme durumu	12
Şekil 2.7: Yaş aralığı ve aile bireylerindeki genetik hastalıklar	12
Şekil 2.8: Meslek grupları ve kullanılan bağımlılık yapan madde çeşitleri ..	12
Şekil 2.9: Günlük tüketilen sigara paketi sayısı	12
Şekil 2.10: Gastrointestinal, KBB ve Kardiyovasküler Sistemler	13
Şekil 2.11: Solunum ve Genel Sistemler	13
Şekil 2.12: Stemming kök bulunması	15
Şekil 2.13: Ön işleme şekli	16
Şekil 3.1: Karar Ağacı görseli	20
Şekil 3.2: Karar Ağacı Sınıflandırma Raporu	21
Şekil 3.3: Karar Ağacı Hata Matrisi	22
Şekil 3.4: Karar Ağacı Normalleştirilmiş Hata Matrisi	22
Şekil 3.5: Torbalama (Bagging)	24
Şekil 3.6: Torbalama (Bagging)	25
Şekil 3.7: Random Forest ve Entropi Ölçütü ile Sınıflandırma Raporu	26
Şekil 3.8: Random Forest ve Entropi Ölçütü ile Hata Matrisi	26
Şekil 3.9: Random Forest ve Entropi Ölçütü ile Normalleştirilmiş Hata Matrisi	27
Şekil 3.10: Random Forest ve Entropi Ölçütü ile Sınıflandırma Raporu	27
Şekil 3.11: Random Forest ve Gini Ölçütü ile Hata Matrisi	28
Şekil 3.12: Random Forest ve Gini Ölçütü ile Normalleştirilmiş Hata Matrisi	28
Şekil 3.13: Artırma (Boosting)	29
Şekil 3.14: Adaboost Algoritması ve Öğrenme Sabiti "1.0" ile Sınıflandırma Raporu	30
Şekil 3.15: Adaboost Algoritması ve Öğrenme Sabiti "1.0" ile Hata Matrisi	31
Şekil 3.16: Adaboost Algoritması ve Öğrenme Sabiti "1.0" ile Normalleştirilmiş Hata Matrisi	31
Şekil 3.17: Adaboost Algoritması ve Öğrenme Sabiti "0.5" ile Sınıflandırma Raporu	32
Şekil 3.18: Adaboost Algoritması ve Öğrenme Sabiti "0.5" ile Hata Matrisi	32
Şekil 3.19: Adaboost Algoritması ve Öğrenme Sabiti "0.5" ile Normalleştirilmiş Hata Matrisi	33
Şekil 3.20: Sinir Ağı Modelinin Yapısı	34
Şekil 3.21: Sinir Ağı Modelinin Yapısı	34
Şekil 3.22: Sınıflandırma Yapısı	35
Şekil 3.23: Sınıflandırma Doğruluk Grafiği	35
Şekil 3.24: Sınıflandırma Raporu	36
Şekil 3.25: Sınıflandırma Hata Grafiği	36
Şekil 3.26: Sınıflandırma Raporu (Covid-19)	37
Şekil 3.27: RNN şekli	38

Şekil 3.28: LSTM şekli	39
Şekil 3.29: BLSTM şekli	40
Şekil 3.30: BLSTM Yapısı	42
Şekil 3.31: Geriye dönük hücrelerin bağlanması	43
Şekil 3.32: Siyam Ağı	45
Şekil 3.33: Siyam Ağı (Siamese Network) için farklı ve benzer çift örneği ...	46
Şekil 3.34: Siyam Ağı (Siamese Network) doğruluk grafiği (Covid-19)	47
Şekil 3.35: Siyam Ağı (Siamese Network) hata grafiği	48
Şekil 3.36: Siyam Ağı (Siamese Network) sınıflandırma raporu	48
Şekil 3.37: Siyam Ağı ile benzer ve farklı çiftlerin doğruluk tablosu	49
Şekil 3.38. Siyam Ağı ile mevsimsel grip ve diğer hastalıkların doğruluk grafiği	50
Şekil 3.39: Doğruluk tablosu	50

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1: Hasta özgeçmişi	5
Çizelge 2.2: Hasta ağrı öyküsü	6
Çizelge 2.3: Hasta aile öyküsü	6
Çizelge 2.4: Hasta kişisel ve sosyal öykü	6
Çizelge 2.5: Hasta genel öyküsü	7
Çizelge 2.6: Hasta Kardiyovasküler sistem öyküsü	7
Çizelge 2.7: Hasta Gastrointestinal öykü	8
Çizelge 2.8: Hasta solunum öyküsü	9
Çizelge 2.9: Anketten alınan öykü ile verilerin kategorik hale getirilmesi örneği	17
Çizelge 2.10: Anketten alınan öykü ile verilerin kategorik hale getirilmesi örneği	18
Çizelge 4.1: Doğruluk çizelgesi	51

1. GİRİŞ

Günümüzde makine öğrenmesi ve yapay zeka; doktorları, hastaları, hastaneleri ve sağlık ile ilgili tüm alanları etkilemeye başlamıştır. Bilgisayarlı tomografiler, diyabetik retinopati analizi, EKG ile kalp krizi riski belirlenmesi gibi alanlarda hali hazırda yapay zeka ve makine öğrenmesi yöntemleri kullanılmaktadır. Bu alanlarda bol miktarda veri olduğu için algoritmalar teşhis koyma konusunda en az uzman doktorlar kadar başarılı olabilmektedirler.

Hasta ve doktor ilişkisinin ön planda olduğu ve hasta mahremiyetinin sağlanması gereken anamnez alma(hasta öyküsü) gibi alanlarda ise yapay zeka çalışmaları devam etmektedir. Anamnez alma, hastalığın teşhisi için en önemli adımlardan biridir. Anamnez sayesinde gereksiz tetkik ve araştırmalar engellenir ve bu sayede zaman ve para kaybı önlenmiş olur. Doktorlar veri girişi ve masa başı işlere, hastalara ayırdıklarından daha fazla zaman ayırmaktadırlar. Dünya nüfusunun giderek yaşlandığı ve doktor ihtiyacının sürekli arttığı düşünülürse, kazanılan her saniye, çok sayıda insanın sağlığına kavuşmasına yardımcı olacaktır.

Anamnez alma sürecinde; veri girişi ve sonuçların analizinde, yapay zeka yöntemleri kullanılması durumunda potansiyel sorunlar önceden tespit edilerek hekim bilgilendirilebilir. Bu sayede tanı koymada hekime yardımcı olunarak fayda sağlanırken, hekimlerin hastalar ile daha verimli zaman geçirmeleri sağlanabilir. Aynı zamanda yapay zeka yöntemleri, hekimlere zaman kazandırmanın yanında; atlanan ve boşa giden verileri de derleyerek analiz edebilirler. Yapılan bir araştırmaya göre; bir hastane her sene 50 petabyte veri üretmektedir. Ancak bu verilerin %97'si hiç kullanılmamaktadır (Kellner, 2017). Yapay zeka; bu verileri de analiz ederek teşhis ve tedavi için yeni yöntemler ortaya çıkarma potansiyeline sahiptir.

Bu çalışmada; hekime yardımcı olarak geliştirilen yapay zeka platformu, hekimin hastadan alacağı bilgileri baz alarak çalışmaktadır. Önce aldığı tüm verileri ayıklayıp anlamlandırarak kategorilendirecektir. Eğitim yapıldıktan

sonra hastalığın teşhisine yönelik sonuçlar hekime sunulacaktır. Bu süreç sayesinde hem doktorun iş yükü azalarak hasta ile daha verimli zaman geçirebilecek, hem de pandemi gibi bulaşıcı hastalık dönemlerinde hasta ve hekimin izolasyonu sağlanacaktır.

Üzerinde çalışılan hekime tanı koymada yardımcı olması hedeflenen bu sistem, otomasyon sistemlerinin tersine, varyasyon ve esneklik sağlamaktadır. Teşhis koyma, yasal sorumluluğu hekime ait olan bir süreçtir. Bu sistem ile doktora sadece; alınan verilerin değerlendirilmesi ile elde edilen sonuçlar sunulacaktır. Sistemin koyduğu teşhis hekime bir öneri ve yönlendirme niteliği taşımaktadır. Bu noktada doktor; yapay zekanın teşhisini onaylayabilir ve kendi koyduğu teşhisin doğruluğunu pekiştirebilir. Bir diğer seçenek olarak; yapay zekanın koyduğu teşhisi yetersiz ya da geçersiz bulabilir. Bu durumda kendisi ek tetkikleri yaparak tanı hakkındaki son kararı kendisi verecektir.

2. LİTERATÜR ÖZETİ

Anamnez soruları rastgele değil, belirli bir düzen ve sıra ile sorulur. Hasta ve doktor ilişkisinin güven içermesi, sağlıklı bir iletişim kurulması ve doğru sonuçlara/tedavi yöntemlerine ulaşılması doğru ve yeterli bir anamnez alınmasına bağlı olduğunu öngören çalışma yapılmıştır (Alçelik, 2016).

Hasta anamnezi; biyografik bilgiler, esas şikayet ve onun öyküsü, sosyal hikaye, aile hikayesi, davranış ve duygusal hikaye, tıbbi hikaye ve sistemlerin incelenmesi (geçmişteki ve şu andaki) hikayelerini içerir (Nalçacı, 2015).

Hekim ya da sağlık çalışanlarının hasta adayına teşhis koymak veya mevcut hastalığının durumunu tesbit etmek için sorular sorarak bilgi almasına yönelik anamnez almayı açıklar (Tarhan, 2015).

Karar ağacı, veri madenciliğinde veri setlerinin sınıflandırılmasında kullanılan temel bir yöntemdir. Karar ağacının amacı, farklı girdi değişkenleri kullanarak bir hedef değişkenin değerini tahmin eden bir model oluşturmaktır. Karar ağacı modeli ile yapılmış çalışmayı içermektedir (Kılınç, 2016).

İki metin dizisi temel bir ayrıştırma katmanı ve bir LSTM biriminden oluşan ortak bir ağ üzerinden beslenir. Yapılan çalışma ile ortak ağdan öznitelik vektörleri elde edildikten sonra, bir dizi benzerlik ölçüsü (Kosünüs) hesaplanır ve sonunda özellik vektörleri birleştirilir ve ardından verilen metinlerin benzer olup olmadığını sınıflandırmayı amaçlamaktadır (Koch vd., 2015).

3. YAPAY ZEKA YÖNTEMİ KULLANARAK ÖYKÜ (ANAMNEZ)

ALMA

3.1. Öykü (Anamnez) Alma

Hekim ya da sağlık çalışanlarının hasta adayına teşhis koymak veya mevcut hastalığının durumunu tesbit etmek için sorular sorarak bilgi almasına anamnez almak denir. Anamnez soruları belirli bir sıra ve düzen ile hastaya yönlendirilir. İyi bir anamnez tanısı, fizik muayeneden daha fazla ipucu barındırır. Anamnez alındıktan sonra, fizik muayene ve laboratuvar (kan, görüntüleme vb) sonuçları ile teşhis için gerekli bilgiler elde edilir (Tarhan, 2015). Hekimin hastayı görsel olarak muayene etmesinden sonra sıra sesli iletişim kurmaya geçmektedir. Hekimler, anamnez sürecinin ikinci kısmında hastaya belirli kategoriler altında sorular yöneltir. Bu kategoriler kendi içinde ikiye ayrılır: Genel Durum Öyküleri ve Belirli Sistemlere Yönelik Öyküler. Sorulan sorular hastalığın tanısını koymada büyük önem taşır.

3.2. Öykü (Anamnez) Almanın Önemi

Anamnez, hastalara tanı koyulmasında çok önemli rol oynar, özel önlem gereken sistemik hastalıklar öğrenilir, kullandığı ilaçlar, bazı sistemik hastalıklar gibi birçok bilgiye ulaşılır. Doktorlar hastayı görmeden önce, hastanın daha önce oluşturulmuş tıbbi bilgiler içeren kartı hastanın önceden geçirdiği rahatsızlıklar ve hastalıklarının seyri hakkında bilgi verir.

Hastanın adı, cinsiyeti, yaşı, ana-baba adı, doğum yeri-ve ailenin geldiği yer, öykünün alınış tarihi, saati gibi içerikler olmalıdır. Cinsiyet özel işaretlerle veya yazılı ifadelerle belirtilir. Hastanın doğum yeri ya da yaşadığı yer önemli ipuçları verebilir. Pediatrik öykü (anamnez) şu ana bölümlerden oluşur : Yakınma, öykü ve sistem soruları, özgeçmiş – soygeçmiş (Akdeniz Üniversitesi, 2016).

Teşhis konulurken ilk aşama olarak hastalık için gerekli bilgiler toplanır. Hastanın şikayetini anlatırken kullandığı terimler, doktorun muayenelerden

sonraki tesbitleri ve laboratuvar test sonuçları bir araya getirilir. İkinci aşamada, elde edilen tüm bilgiler yorumlanarak bu bilgilerin klinik önemi değerlendirilir. Anamnez alınırken; hasta anamnezi, aile anamnezi, sosyal anamnez birlikte alınır ve değerlendirilir. Böylece olası bir sistemik hastalık belirtisi farkedilmeye çalışılır. Hasta anamnezi; biyografik bilgiler, esas şikayet ve onun öyküsü, sosyal hikaye, aile hikayesi, davranış ve duygusal hikaye, tıbbi hikaye ve sistemlerin incelenmesi (geçmişteki ve şu andaki) ve dental hikayeyi içerir (Nalçacı, 2015). Hasta özgeçmişine ait anamnez bilgileri Çizelge 2.1’de yer almaktadır. Esas şikayetin tesbit edilmesi için sorulacak anamnez bilgileri Çizelge 2.2’de verilmiştir. Hasta aile öyküsü bilgileri Çizelge 2.3’te, hastanın kişisel ve sosyal öyküsü Çizelge 2.4’te görülmektedir.

Çizelge 2.1: Hasta özgeçmişi (Nalçacı, 2015)

Hastanın Özgeçmişi

Yaş?

Boy?

Kilo? (kg)

Yaşamını sürdürdüğü ortam?

Kaza – travma

Alerji, pika, parazit

Aşılama

Cinsiyet? (Erkek)

Cinsiyet? (Kadın)

Gebelik var? yok?

Gebelik öyküsü (Alkol, sigara vb.)

Gebelik süresi, doğum şekli

Gebelikte geçirilen hastalıklar

Gebelik olunan aşılar

Doğum sonrası sorunlar

Psikomotor gelişim

Beslenme (anne sütü, ek gıda vb.)

Çizelge 2.2: Hasta ağrı öyküsü

Ağrı olduğu durumda: Ağrı öyküsü

Yeri
Başlangıcı
Özellik
Yayılım
İlişkileri
Zamanlaması

Çizelge 2.3: Hasta aile öyküsü

Aile öyküsü

Akraba Evliliği
Anne – baba sağlığı / ölüm nedeni
Kalp, Tansiyon, astım vb. genetik olarak gelen hastalıklar

Çizelge 2.4: Hasta kişisel ve sosyal öykü

Kişisel ve Sosyal öykü

Alkol, sigara, uyuşturucu kullanımı
HIV var mı? AIDS var mı?
Riskli bir mesleğe sahip mi?
Evcil hayvan var mı?
Vücut kitle endeksi nedir?
Yaşamını sürdürdüğü ortam nasıl?

Anamnez alınırken sorular rastgele değil, belirli bir düzen ve sıra ile sorulur. Hasta ve doktor ilişkisinin güven içermesi, sağlıklı bir iletişim kurulması ve doğru sonuçlara/tedavi yöntemlerine ulaşılması doğru ve yeterli bir anamnez alınmasına bağlıdır. Anamnez sırasında Genel Durum Öyküleri kategorisi altında sorulan sorular ve kendi içindeki kategoriler çizelgelerle belirtilmiştir (Alçelik, 2016).

Çizelge 2.1, Çizelge 2.2, Çizelge 2.3 ve Çizelge 2.4'te bulunan anamnez sorularının sorulmasından sonra, hastaya Çizelge 2.5'te bulunan Genel Durum Öyküleri anamnez soruları yöneltilir.

Çizelge 2.5: Hasta genel öyküsü

Genel öykü

Yorgunluk / Kırıklık
Ateş
Titreme
İştah artışı
Kilo Kaybı
Ciltte kızarma / morarma
Uyku bozukluğu
Hayattan zevk alamama
Sinirlilik
Baş dönmesi
Bacaklarda ödem
Kas veya eklem ağrısı
Gözlerde ciltte sararma
Gözlerde yanma ve sulanma hissi
El ve ayak parmaklarında renk değişikliği

Kardiyovasküler değerlendirmeye yönelik elde edilecek veriler; göğüs ağrısı, nefes darlığı, çarpıntı, ritim bozukluğu, solgunluk ve ödem, özgeçmiş, soygeçmiş ve kişisel alışkanlıklardır. Hastada varolan tüm belirtiler belli bir düzen içinde sorgulanmalı, belirtinin ne zaman başladığı, nasıl yayıldığı ve diğer belirtiler, tedavisi için neler yapıldığı gibi bilgiler hastadan ya da yakınından alınmalıdır (Sevinç, 2006). Kardiyovasküler sistem öyküsü basamakları Tabla 2.6'da verilmiştir.

Çizelge 2.6: Hasta Kardiyovasküler sistem öyküsü

Kardiyovasküler Sistem Öyküsü

Göğüs ağrısı
Boğazda ağrı / yanma
Kulaklarda dolgunluk
Burunda tıkanıklık / akıntı
Tat veya koku kaybı
Hapşıрма
Ağız kuruluğu
Baş/Göğüs ağrısı
Kalp ritim bozukluğu
Çarpıntı
Aile Öyküsü
Sosyal Öykü
Alerjiler

Gastrointestinal sistem (GİS) hastalıkları oldukça geniş bir hastalık grubundan oluşmaktadır. Hekimlerin vakalar karşısında doğru teşhis koyabilmeleri için; gastroenterolojinin temel bilgilerini ve hastalık semptomlarını yakından tanımaları ve bu alanda yeterli tecrübeye sahip olmaları gerekir. Semptom; hasta tarafından hissedilen (sübjektif) baş ağrısı, baş dönmesi, bulantı, halsizlik gibi belirtilerdir. Hekimin muayene sırasında saptadığı ödem, sarılık ve siyanoz gibi objektif bulgulara ise sign denmektedir (GATA, 2009). Hasta Gastrointestinal Öyküsüne ait bölümler Çizelge 2.7’de verilmiştir.

Çizelge 2.7: Hasta Gastrointestinal öykü

Gastrointestinal öykü

İştah kaybı

Normal/Kanlı kusma

Karın ağrısı

İshal

Hazım (Sindirim) zorluğu

Mide bulantısı

Göğüs Hastalıkları alanında anamnez alınırken; diğer tüm sistemlerde olduğu gibi hastanın kimlik bilgileri (ad, soyad, doğum tarihi, doğum yeri, cinsiyet, medeni durum, meslek) ile sorulara başlanır. Sonrasında hastanın başlıca yakınması/yakınmaları, bu yakınmaların ne zaman başladığı, yakınmaların süreç boyunca nasıl ilerlediği, yakınmaları nelerin tetiklediği sorulur. Hastanın daha önce geçirdiği rahatsızlıklar sorularak anamnez sürecine devam edilir.

Solunum sisteminin başlıca semptomları:

- Öksürük
- Balgam çıkarma
- Nefes darlığı
- Göğüs ağrısı

Her semptom tek tek sorgulanmalıdır. Göğüs ağrısından yakınan hastaya çeşitli sorular sorularak özellikle kardiyak-plöretik ağrı ayırt edilmelidir. Ağrının ne zaman başladığı, yeri, yayılımı, niteliği, nelerle tetiklenip hafiflediği ve eşlik eden semptomlar sorulmalıdır (Ankara Üniversitesi, 2018). Hasta Solunum Yolu Öyküsüne Çizelge 2.8’de yer verilmiştir.

Çizelge 2.8: Hasta Solunum Öyküsü

Solunum Yolu Öyküsü

Öksürük

Balgam

Ağır solunum yetmezliği

Nefes darlığı

Hırıltı solunum

Göğüs ağrısı

Alerjiler

Hızlı soluk alıp verme

Genel Semptomlar

Sosyal Öykü

Sorulan sorulara karşılık verilen cevaplar içerisinde toplam 130 kişiden veri toplanarak işlemler yapılmıştır. Her bir hastalık çeşidine göre alınan veriler anlamlandırılmaya çalışılır. Her sorunun cevabı tek cevap yerine çoklu cevaplar olması durumunda alınan veri çoklu bölümler halinde ön işleme yapmak üzere algoritmaya gönderilir. Yukarıda belirtilen hasta öykü bilgilerinin anket yardımı ile alınan sonuçları aşağıda yer almaktadır.

Bu Çalışma için oluşturulmuş olan "Hekime Tanı Koymada Yardımcı, Yapay Zeka Destekli Hastalık Tespit Uzmanı" isimli çalışmamız için önerdiğimiz anket soruları İstanbul Ticaret Üniversitesi Rektörlüğü Etik Kurul onayı "9.4.2021" tarihli ve "E-65836846-044-207508" sayılı ile onaylanmıştır.

Tuzla Marmara Üniversitesi Pendik E. A. H. Eğitim Aile Sağlığı Merkezinde görevli olan doktorlar ile çalışma süresi boyunca görüşerek bilgi alındı. Ancak araştırma hastanesine bağlı olduğu için çalışan doktorların belirli zaman aralıklarında sürekli değişmesi söz konusuydu. Bu durum söz konusu olduğundan görüşmeler sırasında görüşülen doktorlarda buna bağlı olarak değişim gösterdi.

3.3. Öykü (Anamnez) Alma Anket Sonuçları


Hastanın özgeçmişinde genel bilgi alınırken diğer bölümlerdeki sorular ile hastalık ile ilişkili vücut kısımlarına ait özel sorular yöneltilmiştir. Özgeçmişte,

kısa şekilde geçmiş tıbbi ve cerrahi bilgi alınır. Bu sayede kişinin şuanki hastalık ile ilişkili herhangi bir hastalık geçirip geçirmediği kontrol edilir. Cinsiyete bağlı olarak farklı sorular yönlendirilir. Böylece; kadınlar için doğum yapmış olma, gebelik sırasında geçirilen hastalıklar ve olunan aşılar gibi bilgilerin yanı sıra erkekler için anamnez sırasında sorulan sigara, alkol ve uyuşturucu kullanımı, beden kitle endeksi gibi bilgiler de alınır. Aile öyküsü ile genetik hastalıkların tespiti yapılması amaçlanmıştır. Belirlenen hastalıklar ile ilgili vücut sistemleri için tek tek bölümler oluşturulmuş, bu bölümlerde belirtilere yönelik sorular sorulmuştur. Sonrasında bu sistemlerin birbirleri ile ilişkileri incelenerek anamnez alma süreci tamamlanır. Anamnezde yer alan hastalıklardan, öyküsü alınan kişilerin hastalığının tanısı konulması hedeflenmiştir (Üstündağ, Turhan, Topbaş, & Beyhun, 2020).

Anamnez (Öykü) aldığımız anket sonuçlarından bazı bilgiler Şekil 2.1’de yer almaktadır. Anamnez sırasında 130 denek kişi ile çalışma yapılmış olup toplamda 7 hastalık çeşidine gör bilgilerin doldurulması istenmiştir.


Aşağıdaki hastalıklardan geçirmiş olduğunuzu işaretleyiniz? (Birden fazlasını geçirdiyseniz en son geçirmiş olduğunuz hastalığı işaretleyiniz.)

130 yanıt




Şekil 2.1: Hastalık isimleri

Yapılan anket sonucunda; 65 mevsimsel grip, 21 Covid-19, 18 Astım, 16 Akut Bronşit, 8 Zatürre, 2 Koah ve 0 Hepatit A-B-C kişi belirtilen hastalıkları işaretlemiştir. Çalışmada belirtilen hastalıklar ile verilen cevaplara göre kişinin hangi tip hastalığa yakın olabileceği tespiti yapılmaktadır.



Şekil 2.2: Ağrının yerleşim yeri ve şiddeti




Şekil 2.3: Ağrıyı artıran ve azaltan nedenler




Şekil 2.4: Ağrıya eşlik eden belirtiler

Şekil 2.2, Şekil 2.3 ve Şekil 2.4'te alınan cevaplar ile hastalığı etkileyen sebepler ve eşlik eden herhangi bir belirti olup olmadığı araştırılmıştır.


Ayrıca Şekil 2.5, Şekil 2.6 ve Şekil 2.7'de verildiği üzere geçmişte hastalık ile ilgili geçirilen ameliyat olup olmadığı ve kişinin hastane geçmişi hakkında bilgi edinilmeye çalışılmıştır.



Şekil 2.5: Geçmişte geçirilen hastalıklar ve alınan tedavi yöntemleri



Şekil 2.6: Hastaneye yatış ve ameliyat geçirilme durumu



Şekil 2.7: Yaş aralığı ve aile bireylerindeki genetik hastalıklar

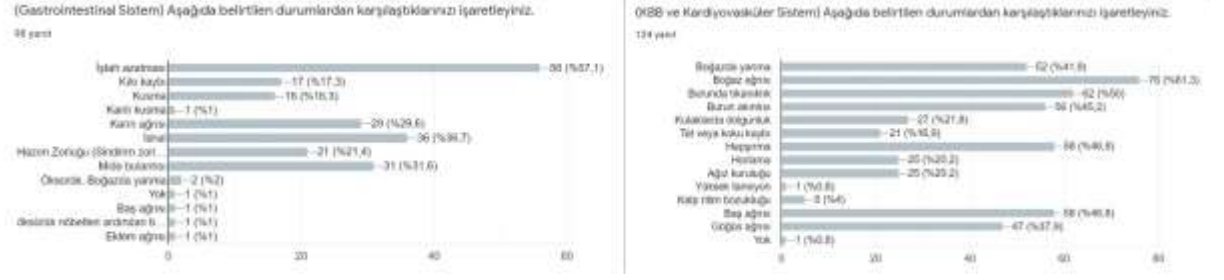
Şekil 2.8, Şekil 2.9, Şekil 2.10 ve Şekil 2.11’de meslek hastalığı veya bağımlılık yapıcı maddeler ile hastalık çeşitleri arasında herhangi bir bağ olup olmadığı değerlendirmek amaçlanmıştır.




Şekil 2.8: Meslek grupları ve kullanılan bağımlılık yapan madde çeşitleri



Şekil 2.9: Günlük tüketilen sigara paketi sayısı



Şekil 2.10: Gastrointestinal, KBB ve Kardiyovasküler Sistemler



Şekil 2.11: Solunum ve Genel Sistemler

3.4. Vücut Kitle İndeksinin Bu Araştırma İçin Önemi

Obezite kilo ve boy değerleri alınarak hesaplanır. Hesaplama için kilonun boy değerinin karesine bölünmesiyle (kg/m^2) hesaplanır. Vücut kitle indeksi sonuçlarına göre 30'un üzeri obez, 40'un üzeri morbid obez, 50'nin üzeri süper obez olarak adlandırılır (Acıbadem, 2021). Obezlik ya da aşırı zayıflık gibi durumların hangi hastalıklarda ne derece etkisi olduğu değerlendirilmiştir.

Vücut kitle indeksi(VKİ) hesaplaması, obeziteyi hesaplamak için tüm dünyada standart olarak kullanılmaktadır. VKİ hesaplanırken; kişinin kilogram cinsinden ağırlığının ölçüsü, kişinin metre cinsinden boy uzunluğunun karesine bölünür (kg/m^2) ulaşılır.

18,5 kg/m^2 'den düşük bireyler: Zayıf birey

18,5 – 24,9 kg/m^2 . Arasındaki bireyler: Normal kilolu birey

25 – 29,9 kg/m^2 . Arasındaki bireyler: Fazla kilolu birey

30 – 39,9 kg/m^2 . Arasında bireyler: Obez birey

40 kg/m^2 'nin Üzerinde bireyler: İleri derecede obez birey(morbid obez), olarak tanımlanır.

3.5. Öykü (Anamnez) Alma ile Alınan Verilerin Anlamlandırılmasında Metin Temizleme

Bu çalışmada anamnez ile alınan verilerden eğitim kümeleri oluşturulmuştur. Bu eğitim kümeleri üzerinde ön işleme (kelime ayrıştırma, etkisiz sözcükleri (stop word) eleme, eş anlamlıları bulma, tekrar eden karakterlerin elenmesi, yanlış yazılmış kelime düzeltme, kök bulma) çalışması yapılmıştır. Aşağıda tüm adımlar tek tek verilmiştir.

3.5.1. Ön İşleme

Dil işleme algoritmalarını kullanmadan önce, üzerinde çeşitli ön işleme işlemleri gerçekleştirilir. Bunun nedeni, metinleri arındırmaktır. Ön işleme aşamasında her bir satırdaki hastalığın anamnez sonuçlarına göre metin tek bir bütün olarak değil gruplara ayrılarak aşama aşama ön işleme adımlarına geçilir. Ayrılan gruplarda eğer tekli bir seçim varsa; yalnızca tek bir cevap var/yok olarak değerlendirilerek oluşturulan dosyaya (.csv, .xml) yeni bir veri olarak eklenir. Grup içerisinde birden fazla çoklu seçim olduğu durumda öncelikle çoklu seçim tek bir seçim olacak şekilde indirgenmesi yapılarak her cevap ayrı ayrı oluşturulan dosyaya (.csv, .xml) yeni bir veri olarak eklenir. Cevaplanan kısım diğer kısmı içerisinde yer alıyorsa önce sözcüklere ayırma (“tokenizing”) işlemi uygulanır. Daha sonra metinler küçük harflere dönüştürülür, sayı filtresi ile rakamlar temizlenir. Kelimeler köklerine ayrılır (“stemming”). Cümlelerdeki durdurma kelimeleri (“stop words”) ve terim ağırlıklandırma ile bilgi sağlamayan gereksiz kelimeler temizlenir. Eğer bir anket çalışması yerine yalnızca alınan cevaplara göre öğrenme işlemi gerçekleştirilecek olursa yine aynı ön işleme işlemlerinin gerçekleştirilmesi büyük önem arz ettiği unutulmaması gerekmektedir. Konuyla ilgili hangi dilde kontrol yapılacaksa bir sözlük (“vocabulary”) içerisinde kelimenin o sözlükte yer alıp almadığı kontrol edilir ve karar verilir.

Metin ön işleme aşamasında, metin koleksiyonunun işlemlere hazır hale gelmesi amaçlanır. Bu doğrultuda; işaretleme, sözlük oluşturma, sonuca etki etmeyecek

kelimeleri (stopwords) ayıklama, kelime köklerini bulma gibi işlemler yapılır. İş yükünü azaltmak için özellik seçimi yapılarak doğru sonuca ulaştıracak veriler seçilir (Oğuzlar, 2011).

3.5.1.1. Stem


Stem İngilizce’de kelimenin kökü anlamındadır. Fakat tam olarak Türkçe’deki kelime kökü anlamını karşılamaz. Bir metinde bulunan “yer”, “yemek”, “yeter” sözcükleri için stemming yapıldığında, üç kelimenin de kökü “ye-” olarak kabul edilir.

3.5.1.2. Root

Türkçe’deki anlam taşıyan kelime köküne karşılık gelir.

3.5.1.3. Stemming (Kök Bulma)

Stemming kelimenin “stem”ini yani kökünü bulma işlemidir. Stemming NLP uygulanan dilin yapısına göre değişiklik gösterir. Kök bulunması örneği Şekil 2.12’de gösterilmiştir.



Şekil 2.12: Stemming kök bulunması (Sirsat, 2013)


3.5.1.4. Lemmatization

Lemmatization kelimeleri morfolojik olarak inceler. Örnek olarak “Geliyorlar” kelimesi, gelmek fiilinin üçüncü çoğul şahıs geniş zamanda fiil çekiminden oluşur. Kelimenin fiil çekimi yapılmamış salt haline lemma denmektedir.

“gelmek” bir lemmadır denir. Lemmatization algoritmaları çalışma esnasında bir sözlüğe gereksinim duyarlar.

3.5.1.5. Tokenizing

Sözcüklere ayırma yapılırken bir cümle, anlamlı daha küçük parçalara ayrılır. Sözcüklere örnek olarak semboller, kelimeler, deyimler gösterilebilir. Kullanılan ayrıştırma aracına (“tokenizer”) göre ayrıştırma yöntemleri değişmektedir. Ön işleme aşamaları Şekil 2.13’de gösterilmiştir.



Şekil 2.13: Ön işleme şekli (Dashtipour, 2016)

3.6. Anamnez ile Alınan Sonuçların Kategorik Hale Getirilip Eğitilmesi

Anketten alınan her bir soru değerlendirilir eğer çoklu seçim varsa her bir soruya karşılık gelecek şekilde kategorik hale getirilir. Ön işleme aşamaları uygulanarak kategorik hale getirilen anamnez sonuçları, hastalık ismine göre sınıflandırılıp eğitim için kullanılır. Kategorik hale getirilirken alınan boy ve kilo bilgisinden vücut kitle indeksi hesaplanır. Her bir cevaba göre vücut kitle indeksi sonuçları değerlendirilmeye dahil edilir.

Sistemlerin gözden geçirilmesi altında yer alan tüm veriler çoklu bir kategori haline dönüştürülerek öğrenme metotlarına verilir. Hasta ya da hastalığı geçirmiş olan hastalardan alınan verilerden örnek bir çalışma aşağıda gösterilmiştir.

Ateş, öksürük, nefes darlığı, boğaz ağrısı, baş ağrısı, kas ağrıları, tat ve koku alma kaybı veya ishal belirti ve bulgularından en az biri bulunması durumunda Covid-19 olabileceği düşünülmektedir (Sağlık Bakanlığı, 2020).

Anamnez sırasında hastalara rahatsızlığı sorulduğunda, genelde bir tanı söyleyerek yakınmalarını anlatırlar, fakat hekimin anamnez alırkenki amacı hastanın semptomlarını öğrenmektir. Hekim, semptomların zaman içindeki gelişimini, nelerle tetiklenip nelerle rahatladığını değerlendirir. Böylece hastanın yakınmalarını tek tek belirleyerek ana semptomları ve eşlik eden semptomları sınıflandırır (Uludağ Üniversitesi, 2020). Aşağıda belirtilen kategorik sonuç çizelgeleri hastalardan solunum öyküsü sorusu altındaki cevaplardan alınmıştır. Solunum öyküsü semptomları örnek çizelge olarak Çizelge 2.9 ve Çizelge 2.10'da verilmiştir.

Çizelge 2.9: Anketten alınan öykü ile verilerin kategorik hale getirilmesi örneği

	Kırgınlık	Ateş	Eklem Ağrısı	Öksürük	Nefes Darlığı
Covid – 19	+	+	+	+	+
Mev. Grip	+	+	+	+	
Astım	+		+		+
Koah				+	+
Zatürre				+	
Akut Bronşit	+	+		+	+

Çizelge 2.10: Anketten alınan öykü ile verilerin kategorik hale getirilmesi örneği

	Boğaz Ağrısı	Burun Akıntısı	Baş Ağrısı	İshal
Covid - 19	+	+	+	+
Mev. Grip	+	+	+	
Astım			+	
Koah				
Zatürre	+			+
Akut Bronşit		+	+	

Koah, astım, akut bronşit, zatürre, mevsimsel grip, Hepatit A-B-C ve Covid-19 hastalıklarının kategorik hale getirilip veri seti oluşturulmuştur. Oluşturulan veri setinin %25 oranında test veri seti oluşturularak doğruluk oranı belirlenmeye çalışılmıştır.

4. ANAMNEZ SIRASINDA ALINAN VERİLERİN EĞİTİM AŞAMASI

4.1. Öğrenme Süreci

Alınan verilerden Karar Ağaçları, Topluluk (Ensemble) Öğrenme, CNN Ağı (Sınıflandırma) ve Siyam ağı kullanılarak çeşitli öğrenme yöntemleri uygulanmıştır.

4.2. Karar Ağaçları

Karar ağaçları, regresyon ve sınıflandırma problemleri çözümünde kullanılır. Genelde ise sınıflandırma problemleri için kullanılır. Danışmanlı öğrenme (supervised learning) algoritmasıdır. Bir ağacın oluşturulması için CART (Sınıflandırma ve Regresyon Ağacı algoritması) algoritmasını kullanılır ve metrik olarak Gini indeksini kullanır. ID3 algoritması Entropy ve bilgi kazancını ölçüm olarak kullanır.

Karar ağaçları ağaca benzer bir yapıda olduğu için isimlendirilmesi karar ağacı olarak adlandırılır. Bir karar ağacı basitçe bir soru sorar ve cevaba göre (Evet / Hayır) ağacı alt ağaçlara ayırır. Karar ağaçlarının, diğer sınıflama tekniklerine göre en önemli üstün tarafı, bilgiden çıkarılan kuralın anlaşılır bir şekilde yazılabilesidir (TORAMAN, 2007). Karar Ağacı görseli Şekil 3.1’de gösterilmiştir.



 ekil 3.1: Karar A acı g rseli (Jerzy, 2010)

Karar a acı, veri madenciliğinde veri setlerinin sınıflandırılmasında kullanılan temel bir y ntemdir. Karar a acının amacı, farklı girdi de i kenleri kullanarak bir hedef de i kenin de erini tahmin eden bir model olu turmaktır (Kılın , 2016).

Karar a a larında k k d ğ m ve yaprak d ğ mler i in en iyi  zniteliklerinin se ilmesi amacıyla iki farklı teknik kullanılır. Bunlar Bilgi Kazancı ve Gini İndeksi metrikleridir.

4.2.1. Bilgi Kazanımı

Bir karar a acı algoritması bilgi kazancını maksimum yapmaya  alı ır ve en y ksek bilgi kazancına sahip d ğ mden b l nerek c z m a a  yapısı olu turulur. Bilgi kazancı, beklenmedik olayların ger ekle me olasılı ı ve se ilen her karakter i in belirsizlik kullanılarak hesaplanır. En y ksek bilgi kazancı oranı k k olarak belirlenmi tir (Kılın , 2016).

A a ıdaki form l kullanılarak hesaplanabilir:

$$H(R) = - \sum_{i=1}^n p_i \log_2(p_i) \quad (3.1)$$

Entropi hesaplanırken ikili tabanda hesaplama yapılmalıdır.  rne in;

$$\text{Entropi} = - P(\text{evet}) \log_2 P(\text{evet}) - P(\text{hayır}) \log_2 P(\text{hayır})$$

S = Toplam numune sayısı

P (evet) = evet olasılığı

P (hayır) = hayır olasılığı

H(R) = entropi


4.2.2. Gini

Karar ağacı oluşturulurken gini endeksine sahip özelliğin daha düşük olduğu düğümden dallanma yapılır. Gini indeksi, CART algoritmasında bir karar ağacı oluştururken kullanılan saflığın bir ölçüsüdür.

Gini endeksi aşağıdaki formül kullanılarak hesaplanabilir:


$$Gini = 1 - \sum_{i=1}^c p_i^2 \quad (3.2)$$

Anlaşılması çok kolaydır ve günümüzdeki karar mekanizmalarına benzeyen bir yapıda çalışır. Oluşturulmuş olan bir problemin tüm oluşabilecek sonuçlarını düşünerek karar vermeye yardımcı olur. Karar ağaçları, diğer algoritmalarla oranla veri temizlemeye daha az ihtiyaç duymaktadır. Şekil 3.2'de görüldüğü üzere karar ağacı ile yapılmış sınıflandırma raporu yer almaktadır.




Şekil 3.2: Karar Ağacı Sınıflandırma Raporu

Toplamda 33 test verisi ile sınıflandırma işlemi gerçekleştirilmiştir. Şekil 3.3’de görüldüğü üzere karar ağacı algoritmasından çıkan sonuç olan hata matrisi yer almaktadır.



Şekil 3.3: Karar Ağacı Hata Matrisi

Karar ağacı algoritması sonucunda normalize edilmiş hata matrisi elde edilmiştir. Elde edilen sonuçlar Karar Ağacı Normalleştirilmiş Hata Matrisi Şekil 3.4’de verilmiştir.



Şekil 3.4: Karar Ağacı Normalleştirilmiş Hata Matrisi

4.3. Ensemble Yöntemler (Topluluk Öğrenme)

Ensemble yöntemler; birden fazla modelin aynı problemi daha iyi çözebilmesi için eğitildiği ve gerekli sonuçların alındığı makine öğrenimi yöntemidir. Zayıf modellerin doğru şekilde birleştirildiği durumlarda çok daha başarılı sonuçlar alınacağı hipotezine dayanır.


Öğrenmelerdeki hataların temel ve ana nedenleri gürültü ve varyanstan kaynaklanmaktadır. Topluluk öğrenme yöntemleri ile bu faktörlerin en aza indirilmesine yardımcı olur. Topluluk öğrenme yöntemleri algoritmalarındaki doğruluk ve kararlılığı iyileştirmek için geliştirilmiştir. Çoklu sınıflandırma kombinasyonları ile kararsız sınıflandırıcıların varyansı azaltır ve tek bir sınıflandırıcıdan daha güvenli sınıflandırma oluşturulur.

Son yıllarda Ensemble öğrenme modellerinin ortaya çıkması makine öğrenimi ve sınıflandırma alanlarında yapılan en önemli iyileştirmelerden biridir. Ensemble öğrenme yaklaşımının temel amacı, farklı temel sınıflandırıcılar kullanılarak elde edilen sınıflandırma değerlerini bir araya getirerek daha doğru sonuçlar üretmektir. Ensemble sınıflandırma algoritmasını kullanmanın en büyük avantajı, daha doğru değerlere sahip olma olasılığıdır çünkü bu algoritma, diğer yöntemlerin verilerinin bir kombinasyonunu kullanır (Kılınç, 2016).

Genelde karar ağaçlarında düzey sayısı artışında modeller yüksek varyanslara karşı savunmasız hale gelir ve aşırı öğrenme (overfitting) gösterebilir. Düzenlileştirmeyi uygulamak ve aşırı uyumu önlemek için genel kurallara (oldukça özel kurallara) karşı birlikte topluluk teknikleri kullanılmaktadır. Topluluk öğrenme algoritmaları; tahminlerin güvenilirliğini ve modelin kararlılığını sağlamlaştırır ve artırır. Bu avantajlardan yararlanmak için topluluk öğrenme genellikle en çok tercih edilen seçenektir.

4.3.1. Torbalama (Bagging)


Orijinal veri setlerinden elde edilen verilerdeki önyükleme örneklerine göre yeni tahmin modelleri eklenerek bir topluluk oluşturulur. Burada önyükleme uygulaması, iadeli rastgele seçim yapıp alt örneklem oluşturmak için kullanılır örnek model Şekil 3.5’de gösterilmiştir.



Şekil 3.5: Torbalama (Bagging) (Choi, 2020)

Orijinal veri setindeki sayı ile oluşturulmuş alt örneklem aynı olacaktır. Bu sebeple; önyükleme sonucunda oluşturulan örneklerde bazı gözlemlere rastlanmazken, bazı gözlemlere iki veya daha fazla kez rastlanabilir. Tahminler birleştirilirken; regresyon ağaçları için ortalama alınması sırasında, sınıflandırma ağaçlarında sonuçlar oylama ile belirlenir.

Torbalama sırasında, düşük yanlılık miktarına sahip ama yüksek varyanslı olan değişkenler kullanılarak daha elverişli hale getirilir. Böylece tutarsız bir tahminci değişkenin, tahmin geçerliliğini de arttırabilir. Deneysel sonuçlara göre torbalama yöntemi, tekil ağaçlara göre daha etkin sonuçlar vermektedir, torbalama yöntemi görseli Şekil 3.6’da gösterilmiştir.




Şekil 3.6: Torbalama (Bagging) (Saad, 2019)

Orijinal veri setinden çoklu benzer alt kümeler oluşturulur. Alt kümelerde zayıf bir temel model oluşturulur ve her model birbirinden paralel ve bağımsız olarak çalışır. Gerçek tahminlemeler, oluşturulan tüm modellerden gelen tahminlerle birleştirilerek belirlenir. Çok yüksek veri setlerinde başarılı sonuçlar verir. Veri setindeki eksik veri modelin öğrenmedeki performans ve sonuca etki etmez. Sınıflandırma veya regresyon modelinde kesin sonuç vermesi yerine alt kümelerin ortalamasına bakılarak sonuç verir.

Random Forest, farklı ağaç türlerine sahip bir toplu karar ağacı sınıflandırıcısıdır. Bölünmeyi belirlemek için her düğümde rastgele bir özellik dizisi kullanılarak ayrı bir karar ağacı üretilir. Her ağaç, alınan rastgele bir vektörün değerlerine dayanır. Ağaçları yükseltmek için CART yaklaşımı kullanılır. Mümkün olan maksimum boyuta yükseltilebilir ve budanmazlar. Random Forest, girdi özelliklerinden rastgele doğrusal kombinasyonları kullanır. Özelliklerin bir alt kümesini rastgele seçmez, ancak özelliklerin doğrusal bir kombinasyonu olan yeni öz nitelikler oluşturur (Yaman, 2019).


Anamnez ile alınan verilerin kategorik hale getirilmesinden sonra Random Forest algoritması kullanılarak verilerin öğrenme işlemi gerçekleştirilmiştir. Gerçekleştirilen öğrenme işlemi sırasında ölçüt olarak entropi ve gini ölçütleri kullanılarak testler yapılmıştır.

Random Forest algoritması ve entropi ölçütü ile öğrenme işlemi gerçekleştirilmiştir. Yapılan öğrenme işleminde çıkan sonuçların sınıflandırma raporu Şekil 3.7’de yer almaktadır.




Şekil 3.7: Random Forest ve Entropi Ölçütü ile Sınıflandırma Raporu

Random Forest algoritması kullanılıp entropi ölçütü ile yapılan öğrenme işlemi sonuçları, normalleştirilmiş hata matrisi ve hata matrisi şeklinde Şekil 3.8’de ve Şekil 3.9’de yer almaktadır.




Şekil 3.8: Random Forest ve Entropi Ölçütü ile Hata Matrisi




Şekil 3.9: Random Forest ve Entropi Ölçütü ile Normalleştirilmiş Hata Matrisi

Random Forest algoritması kullanılıp Gini ölçütü ile yapılan öğrenme işlemleri gerçekleştirilmiştir. Gini ölçütü ile yapılan öğrenme işleminde çıkan sonuçlara Şekil 3.10'de yer verilmiştir.




Şekil 3.10: Random Forest ve Gini Ölçütü ile Sınıflandırma Raporu

Random Forest algoritması ve Gini ölçütü kullanılarak yapılan öğrenme işlemi sonuçları, normalleştirilmiş hata matrisi ve hata matrisi şeklinde Şekil 3.11 ve Şekil 3.12'te yer almaktadır.



Şekil 3.11: Random Forest ve Gini Ölçütü ile Hata Matrisi



Şekil 3.12: Random Forest ve Gini Ölçütü ile Normalleştirilmiş Hata Matrisi


4.3.2. Artırma (Boosting)

Boosting birbirini tamamlayan modelleri bulmaya çalışarak bu fikirden yararlanmak için birden fazla modeli birleştirmek için kullanılır. Bu, sayısal tahmini tek bir modele göre sınıflandırmak veya ortalamak için oylamadan yararlanması açısından torbalamaya benzer. Diğer bir benzerlik ise, karar ağaçları gibi aynı türden modelleri bir araya getirmesidir. Boosting, yeni

modelleri güçlendirir, böylece öncekiler tarafından yanlış şekilde kontrol edilen durumlar için uzman olurlar (Yaman, 2019).

Boosting (Artırma), birden fazla zayıf modelden güçlü bir sınıflandırıcı oluşturmayı hedefleyen bir topluluk yöntemidir. Zayıf sınıflandırıcıları güçlü sınıflandırıcılara dönüştürmeye odaklanır. AdaBoost , ikili sınıflandırma için geliştirilen ilk başarılı yükseltme algoritmasıdır.

İlk olarak veri setinden bir model oluşturulur. Daha sonra birinci modeldeki hataları düzeltmeye çalışan yeni bir ikinci model oluşturulur. Bu durum modeller eğitim veri setindeki bilgilerin tamamını doğru bir şekilde öğreninceye kadar işlemlere devam edilir veya maksimum model sayısı eklenene kadar yeni model eklenmeye devam edilir. Artırma modelinin örnek görseli Şekil 3.13’de gösterilmektedir.



Şekil 3.13: Artırma (Boosting) (Saad, 2019)


Adaboost Algoritması'nın adımları aşağıda yer almaktadır.

1. Veri kümesini başlat ve her veri noktasına eşit ağırlık ata
2. Bunu modele girdi olarak sağla ve yanlış sınıflandırılmış veri noktalarını tanımla
3. Yanlış sınıflandırılmış veri noktalarının ağırlığını artır
4. (gerekli sonuçlar çıktıysa)
5. adıma git,
- aksi takdirde

2. adıma git


5. Son

Anamnez ile alınan verilerden Adaboost algoritması kullanılarak verilerin öğrenme işlemi gerçekleştirilmiştir. Gerçekleştirilen öğrenme işlemi sırasında ölçüt olarak öğrenme sabiti "1.0" kullanılarak testler yapılmıştır. Öğrenme işleminden sonra çıkan sonuçlar Şekil 3.14'de yer almaktadır.




Şekil 3.14: Adaboost Algoritması ve Öğrenme Sabiti "1.0" ile Sınıflandırma Raporu

Adaboost algoritması kullanılarak yapılan öğrenme işlemi sonuçları, normalleştirilmiş hata matrisi ve hata matrisi şeklinde Şekil 3.15 ve Şekil 3.16'da yer almaktadır.




Şekil 3.15: Adaboost Algoritması ve Öğrenme Sabiti "1.0" ile Hata Matrisi




Şekil 3.16: Adaboost Algoritması ve Öğrenme Sabiti "1.0" ile Normalleştirilmiş Hata Matrisi

Adaboost algoritması ile gerçekleştirilen öğrenme işlemi sırasında ölçüt olarak öğrenme sabiti "0.5" kullanılarak testler yapılmıştır. Öğrenme işleminden sonra çıkan sonuçlara Şekil 3.17'da yer verilmiştir.




Şekil 3.17: Adaboost Algoritması ve Öğrenme Sabiti "0.5" ile Sınıflandırma Raporu

Adaboost algoritması ile gerçekleştirilen öğrenme işlemi sırasında ölçüt olarak öğrenme sabiti "0.5" kullanılarak ile yapılan öğrenme işlemi sonuçları, Normalleştirilmiş hata matrisi ve hata matrisi şeklinde Şekil 3.18 ve Şekil 3.19'de yer almaktadır.



Şekil 3.18: Adaboost Algoritması ve Öğrenme Sabiti "0.5" ile Hata Matrisi




Şekil 3.19: Adaboost ve Öğrenme Sabiti "0.5" ile Normalleştirilmiş Hata Matrisi

4.4. Yapay Sinir Ağları


Danışmanlı öğrenme sırasında ağa verilen giriş değerleri ile birlikte çıktı değerleri de verilir. Ağ, kendi ağırlığını güncelleyerek verilen girdiler için istenen çıkışları oluşturabilir. Ağı yeni ağırlıkları, hata payı bulunarak düzenlenir. Beklenen çıktılar ile ağın çıktıları arasındaki hata miktarı hata payını verir. Sonrasında her hücrenin kendine gelen ağırlıkları güncellenir.

CNN, evrişimli bir işlem ve derin bir yapı içeren ileri beslemeli bir sinir ağı sınıfıdır. Erken geri yayılım (BP) sinir ağı ile karşılaştırıldığında; CNN'nin temel özellikleri yerel algılama ve parametre paylaşımıdır. Uzamsal özellikleri ham girdi verilerinden çıkarabilir ve ham verilerin yüksek boyutlu bir özellik temsilini gerçekleştirebilir. Evrişimli katman, karşılık gelen özellikleri oluşturmak için giriş verilerinin yerel bölgelerini dönüştürmek için evrişimli çekirdekleri kullanır. Bir CNN'nin parametre paylaşımı, sinir ağının hesaplama sürecindeki parametreleri azaltır. Bu; çok fazla parametreye sahip olma olgusunu etkili bir şekilde ortadan kaldırır ve bu da sinir ağına aşırı uyum sağlamasına yol açar. Bu şekilde, sinir ağının aşırı uyumu çözülür. Dahası, sinir ağının eğitim sürecinde kullanılan sistem belleği önemli ölçüde azalır (Yıldırım, 2018). Sinir ağı modelinin yapısı Şekil 3.20'de gösterilmiştir.



Şekil 3.20: Sinir Ağı Modelinin Yapısı (Sultana vd., 2018)


En yaygın olarak kullanılan alanlar bilgisayarla görme, ses tanıma ve doğal dil işlemeyi (NLP) içerir. Yapay sinir ağları veya bazen yapay sinir ağı (YSA) veya ileri beslemeli sinir ağı olarak da adlandırılan sinir ağları, insan beynindeki sinir ağlarından belli belirsiz ilham alan hesaplama ağlarıdır. Sinir ağının sınıflandırılmış modeli Şekil 3.21’de gösterilmiştir.



Şekil 3.21: Sinir Ağı Modelinin Yapısı (Üzen ve Hanbay, 2020)


Özellik vektörlerinde beslenen bir girdi için, nöron katmanına sahip olarak başlanır ve değerler daha sonra gizli bir katmana iletilir. Her bağlantıda, değer bir ağırlıkla çarpılırken ve değere bir önyargı eklenirken, değeri ileri doğru beslemeye devam edilir. Bu her bağlantıda gerçekleşir ve sonunda bir veya daha fazla çıkış düğümü olan bir çıktı katmanına ulaşılır. İkili bir sınıflandırmaya sahip olmak istiyorsak, çıkış katmanında bir düğüm

kullanabiliriz. Belirli hastalık çeşitlerinin sınıflandırılmasından sonraki durumu gösteren görseli Şekil 3.22’de belirtilmiştir.




Şekil 3.22: Sınıflandırma Yapısı

Keras kütüphanesi kullanılarak alınan veriler tek boyutlu vektör olacak şekilde modele verilir ve eğitim işlemi gerçekleştirilir. Eğitim işleminde tüm verinin % 75'i kullanılarak öğrenme aşaması tamamlanır. Öğrenme işlemi sonucunda doğruluk tablosu aşağıda gösterilmiştir. Öğrenme işlemi çok sınıflı (multiclass) belirlendiği durumunda yeterince veri sayısı olmadığı için öğrenme işlemi çok başarılı oluşmamaktadır. Bu yüzden 0-1 şeklinde eğitim yapılarak istenilen sınıfa ait olup olmadığı tespit edilmeye çalışılmıştır. Eğitim sürecinin tamamlanmasından sonra ortaya çıkan Sınıflandırma Doğruluk Grafiği Şekil 3.23'te verilmiştir. Öğrenme sonucunda hastalık sınıflandırma raporu içeriği Şekil 3.24'de gösterilmiştir.




Şekil 3.23: Sınıflandırma Doğruluk Grafiği




Şekil 3.24: Sınıflandırma Raporu

Öğrenme işleminin çok sınıflı olması durumunda yeterince veri sayısı olmadığından dolayı istenilen seviyede başarı oranı elde edilememiştir. Bu yüzden yalnızca Covid-19 verisi ve diğerleri olarak 2 farklı sınıf şeklinde öğrenme işlemi gerçekleştirilmiştir. Gerçekleştirilen işlemler sonucu modelin hatası ve sınıflandırma raporu Şekil 3.25’de ve Şekil 3.26’da yer almaktadır.



Şekil 3.25: Sınıflandırma Hata Grafiği




Şekil 3.26: Sınıflandırma Raporu (Covid-19)

4.5. Siyam Ağı (Siamese Network) kullanılarak öğrenme

4.5.1. RNN çalışması

Recurrent Neural Network (RNN) Türkçe adıyla Tekrarlayan Sinir Ağları, tüm katmanlara aynı ağırlıkları ve önyargıları sağlayarak bağımsız etkinleştirmeleri bağımlı etkinleştirmelere dönüştürür. Bu sayede artan parametrelerin karmaşıklığı azaltılır ve her bir çıktıyı bir sonraki gizli katmana girdi olarak verir. Böylece önceki her çıktıyı ezberler. RNN mimarisi son zamanlarda, özellikle sıralı veriler için oldukça tercih edilen bir mimari olmuştur. Bu mimari; doğal dil işleme, konuşma, tanıma, görüntü tanımlarının oluşturulması ve makine çevirisi gibi birçok soruna başarıyla uygulanmıştır. Geleneksel sinir ağı yapılarının aksine RNN; tüm giriş ve çıkışların birbirine bağlı olduğu bir öğrenme yapısına sahiptir. RNN ile klasik ileri beslemeli nöron yapısı arasındaki temel fark; nöron çıktılarının özyinelemeli olarak kendi girdilerine uygulanmasıdır. RNN'ler, önceki çıktıya bağlı olarak bir dizinin tüm öğeleri için aynı görevleri tekrarladıkları için yinelenen olarak adlandırılır (Yıldırım, 2018). RNN örnek görseli Şekil 3.27'de gösterilmiştir.




Şekil 3.27: RNN şekli

4.5.2. LSTM

Uzun vadeli bağımlılıklarını öğrenebilen özel bir RNN türüdür. LSTM, bilgileri daha iyi depolayarak RNN'in kısa vadeli bellek problemlerini ortadan kaldırmak için tasarlanmıştır. Uzun Kısa Vadeli Hafıza ağları olarak isimlendirilirler. Çok çeşitli sorunların çözümünde iyi derecede çalışmaktadır ve günümüzde yaygın olarak kullanılır. Tekrarlayan tüm sinir ağları, tekrar eden sinir ağ modül zinciri şeklindedir. RNN'ler tanh fonksiyonu kullanırlar. LSTM'ler içerisinde birbiri ardına sıralı yapılar vardır. Tek bir sinir ağı yerine içerisinde dört parça etkileşimli şekilde bulunur. Bunlar Unutma Kapısı (Forget Gate), Giriş Kapısı (Input Gate), Çıkış Kapısı (Output Gate) ve İletişim Hattı (Cell State) 'dir. LSTM'ler, zincir benzeri yapıya sahiptir.

LSTM olarak adlandırılan yöntem uzun vadeli bağımlılıkları öğrenme konusunda daha yetenekli olan özel bir RNN türüdür. Geleneksel RNN'lere göre avantajı LSTM ağlarının, girişler arasındaki bellek süresi bağımlılıklarını daha uzun bir dizi olarak tutabilmesidir. RNN'lerle ilgili temel dezavantajlardan biri, aslında, gradyan üstel bozulma nedeniyle yalnızca yakın geçmişteki bağımlılıkları takip etme yetenekleridir (Cambra, 2018). LSTM'ye özgü şekil aşağıdaki Şekil 3.28'de gösterilmiştir (Cambra, 2018).



Şekil 3.28: LSTM şekli

Yukarıdaki diyagramda, yapının içinde uzun ok işaretiyle gösterilen her zincir (her satır) bir düğümün çıktısından başkalarının girişlerine kadar tüm vektörü taşır. Sarı kutularda sinir ağı katmanları öğrenilirken, pembe daireler vektör eklenmesi gibi noktasal işlemleri temsil eder. Birleştirilen zincirler (satırlar) birleştirme hattını, çatallaştırılan oklar ise kopyalanan içeriğin ve kopyaların farklı çıkışlara gideceğini belirtir. Geçitler, isteğe bağlı olarak bilginin iletilmesini sağlayan bir yoldur. Sigmoid katman, her bileşenin ne kadarının geçeceğini kararlaştırır. Bir LSTM, bu geçitlerden üç tanesine sahiptir. Hücre hangi yeni bilgilerin saklanacağını kararlaştırır.

İlk olarak, hangi değerleri güncelleyeceğimize “giriş kapısı katmanı” olarak adlandırılan bir sigmoid katmanı karar verir. Sonrasında, duruma eklenebilecek yeni aday değerlerinin bir vektörü, tanh fonksiyonu tarafından oluşturulur.

Bir sonraki adımda, Sigmoid katmanı ile çıkış yapılacak olan hücre durumunun hangi bölümlerinin aktarılacağını kararlaştırılır. Son olarak hücre durumu tanh (Değerler -1 ve 1 arasında) ile hesaplanır ve sigmoid ile çarpılır. Bu sayede çıkarılması istenen parçalar çıkarılır.


4.5.3. BLSTM (Çift Yönlü Uzun Kısa Süreli Bellek)

Çift yönlü tekrarlayan sinir ağları (RNN) sadece iki bağımsız RNN'yi bir araya getirmektedir. Bu yapı, ağların her zaman adımında, sıra hakkında hem geri hem de ileri bilgi sahibi olmalarına izin verir. Çift yönlü kullanmak, girdileri, biri geçmişten geleceğe ve diğeri gelecekte geçmiş olmak üzere iki şekilde çalıştıracaktır. Bu yaklaşımı tek yönlü olmaktan ayıran şey, geriye doğru çalışan

LSTM'de gelecekte gelen bilgileri korumak ve bir araya getiren iki gizli durumu kullanmaktır. Böylece; hem geçmiş hem de gelecekte gelen bilgileri zamanın herhangi bir noktasında koruyabilir.

Çift yönlü bir RNN (BRNN), geleneksel RNN'lerden çeşitli kısıtlamaları kaldırmak için önerilen bir modeldir. Bu model, normal RNN nöron durumlarını ileri ve geri olarak böler. Başka bir deyişle, ileri ve geri olmak üzere iki farklı tekrarlayan ağ vardır. Bu iki ağ, çıktı bilgisi oluşturmak için aynı çıktı katmanına bağlanır. Bu yapı ile bir zaman çerçevesindeki sıralı girdilerin hem geçmiş hem de gelecekteki durumları gecikmeden değerlendirilir.

BRNN yapısının LSTM versiyonuna Çift Yönlü LSTM (BLSTM) adı verilir. Bu sürüm, sınıflandırma süreçlerinde LSTM model performansını iyileştirebilir. Standart LSTM yapısının aksine, iki farklı LSTM ağı, BLSTM mimarisinde sıralı girişler için eğitilir (Yıldırım, 2018). BLSTM yapısını içeren görsel Şekil 3.29'da gösterilmiştir.



Şekil 3.29: BLSTM şekli (Yıldırım, 2018)

BLSTM'ler içeriği daha iyi anlayabildikleri için daha iyi sonuçlar elde edilebilir.

Örnek bir soru üzerinden LSTM yapısını anlatmaya çalışırsak:

Tek yönlü bir LSTM'in göreceği bir cümlede, sonraki kelimeyi yüksek düzeyde tahmin etmeye çalışırsak,

Çocuklar... 'e gittiler.

Çocuklar kelimesinden sonraki kelimeyi sadece bu bilgiler ile tahmin etmeye çalıştığımız varsayılmıştır. Çift yönlü LSTM ile bilgilerin ilerisini de görebiliriz.

İleri LSTM:

"Çocuklar ..."

Geri LSTM:

"... ve sonra havuzdan çıktılar"

Gelecekte gelen bilgileri kullanarak ağın bir sonraki kelimenin ne olduğunu anlamasının daha kolay olabileceğini görebilmekteyiz.

BLSTM, iki bağımsız LSTM sinir ağından oluşmuştur ve iki yönde ileri ve geri yayılma vardır. Hochreiter ve Schmidhuber tarafından önerilen LSTM ağı, benzersiz bir tekrarlayan sinir ağı (RNN) sinir ağıdır. Bir giriş kapısı ve bir çıkış kapısı yapısından oluşan belirli bir ağ yapısına sahiptir. LSTM, kapı yapısı aracılığıyla her seferinde bir RNN'nin durumunu etkiler. Kapılar yalnızca bilgi akışının yönlerini sınırlar. Kapının yapısının aktivasyon işlevi sigmoid'dir. LSTM yapısının özü, uzun süreli belleği etkin bir şekilde koruyabilen unutma kapısı ve giriş kapısıdır. Unutma geçidi, sinir ağının önceki yararsız bilgiyi mevcut girdi x_t ve son anın çıktısı h_t ile terk etmesini sağlar. Ağ, bir geçit yapısı ve bellek hücrelerini içe aktararak eğitim sırasında gradyan kaybolmasının veya gradyan artmasının üstesinden gelir. Şekil 3.30'de gösterildiği üzere giriş kapısı, x_t ve a_{t-1} parametrelerine göre yeni bir C_t durumu oluşturmak için C_{t-1} durumuna eklenecek bilgiyi belirler. Unutma geçidi ve giriş geçidi yapısı sayesinde, LSTM hangi bilgilerin unutulduğunu ve hangi bilgilerin saklandığını etkin bir şekilde belirleyebilir. Bu nedenle, LSTM yararlı bilgiler çıkarır; çıkış kapısından h_t 'nin çıktısını, en son durum C_t ve akım girişi olan x_t anında çıkış h_{t-1} 'e göre belirler.

LSTM'de, sadece C (aday değerler) değil, aktivasyon değerleri de kullanılmaktadır. Ayrıca hücreden 2 çıktı, yeni bir aktivasyon ve yeni bir aday değerimiz vardır. Yeni adayı hesaplamak için aşağıdaki formül kullanılabilir. LSTM yapısını içeren görsel Şekil 3.30'da gösterilmiştir. LSTM'ye özgü formül aşağıdaki gibi tanımlanır: (Zhao vd., 2020)

$$C^{N< t >} = \tanh (W_c [a^{< t - 1 >}, x^{< t >}] + b_c)$$

Burada LSTM'de bellek hücrelerini 3 farklı kapıdan kontrol etmekteyiz.

Update $F_u = \sigma(W_u [a^{< t - 1 >}, x^{< t >}] + b_u)$


$$\text{Unut} \quad F_f = \sigma(W_f [a^{<t-1>}, x^{<t>}] + b_f)$$

$$\text{Çıkış} \quad F_o = \sigma(W_o [a^{<t-1>}, x^{<t>}] + b_o)$$

LSTM'den 2 çıktımız bulunmaktadır; yeni aday ve yeni bir aktivasyon değerleridir. Çıkışlar:

$$C^{<t>} = F_u * C^{N^{<t>}} + F_f * C^{<t-1>}$$

$$a^{<t>} = F_o * C^{<t>}$$




Şekil 3.30: BLSTM Yapısı (Zhao vd., 2020)

BLSTM'de: NLP'de olduğu gibi, bazen bir kelimeyi anlamak için sadece önceki kelimeye değil, aynı zamanda bu örnekte olduğu gibi gelecek olan kelimeye de ihtiyacımız vardır.

Bugün **boğaz** ağrım hafifledi.

Bugün **boğaz** harika görünüyor.

İlk cümledeki boğaz anlamı ile ikinci cümledeki kelimenin anlamları birbirinden farklıdır. İlk cümledeki “boğaz” ile kişinin organı olan boğaz kastedilirken, ikinci cümledeki “boğaz” ile iki kara parçası arasında uzanan geçit kastedilmiştir. Burada boğaz kelimesinden sonraki kelimenin ağrım ya da harika olacağını söyleyemeyiz, cümlelerin içeriğine bağlı olarak karar verebilir. BLSTM, herhangi bir RNN modelini kullanabilen genel bir mimaridir. Geriye dönük verilerin bağlantısına ilişkin görsel Şekil 3.31’de gösterilmiştir.



Şekil 3.31: Geriye dönük hücrelerin bağlanması (Chawla vd., 2019)

$$y^{<t>} = g(W_y [a^{<t>}, a^{<t>}] + b_y)$$

Burada, biri ileri hücelere ve diğeri geri hücelere olmak üzere 2 kez ileri yayılma uygulanmaktadır. Her iki aktivasyon da (ileri, geri) t zamanında y çıktısını hesaplamak için kabul edilmektedir.

4.5.4. Siyam Ağı (Siamese Network)

Modern yapay sinir ağlarının çok iyi performans gösterebilmesi için büyük veriye ihtiyaç duyulmaktadır. Anamnez verilerinden sonuç çıkarmak için hastalardan alınması gereken örneklemin yetersiz olduğu, elimizdeki hasta sayısının ve semptomların yeteri kadar olmadığı durumlarda ya da acil olarak kullanmamız gerektiği zamanlarda (pandemi gibi) problemi çözmek için Siyam Ağları adı verilen yeni bir sinir ağı mimarisini kullanılabilir. Siyam Ağları; çok az veriden yararlanarak daha iyi tahminler üretebilmeyi gerçekleştirir.

Siyam Sinir Ağı, iki veya daha fazla aynı parametre ve ağırlıklara sahip alt sinir ağları içerir. Parametre güncellemeleri, içerideki her iki ağda da yapılır. Bu yapı, girdi verilerin özellik vektörlerini karşılaştırıp aralarındaki benzerliği bulmak için çalışır. Birçok uygulamada Siyam Sinir ağı kullanılır. Siyam Sinir Ağlarının, kategori sayısının fazla olduğu ve kategori başına örnek sayısının az olduğu sınıflandırmada başarılı olduğunu söyleyebiliriz.


İkiz ağlar arasındaki parametreler bağlıdır. Ağ simetriktir, böylece ikiz ağlara iki farklı anamnez (öykü) bilgisi verildiği durumda; sinir ağından iki özellik vektörü elde edilir. Daha sonra elde edilen bu vektörlerin farkı bir fonksiyon yardımıyla

bulunur. Bu fonksiyon herhangi bir uzaklık ölçüm fonksiyonu olabilir. Bu işlemin sonucunda, belirlenen eşik değerlerine göre, anamnez (öykü) verisine sahip hastalıklar benzer veya benzer değil olarak sınıflandırılabilir. Sezgisel olarak veri girdilerinin sınıflandırılması yerine, siyam ağı girdilerin birbirleri arasındaki farklılığı ve benzerliği öğrenir. Bunu yaparken bir tür mesafeye dayalı yöntemler kullanır.

4.5.5. BLSTM ve Siyam Ağı (Siamese Network) kullanılarak öğrenme

Hesaplama verimlilikleri ve doğrulukları nedeniyle, siyam ağı son zamanlarda görsel izleme araştırmalarında büyük ilgi görmüştür. Tıp alanında, Siyam ağ mimarisi, her iki dizdeki benzer konumlardan elde edilen iki boyutlu sagittal orta ağırlıklı turbo spin eko dilimlerinden bilgilerin ikili olarak öğrenilmesi için kullanılmıştır. Siyam ağı, cümle benzerliğini öğrenmede yüksek performans elde eder. Değişken uzunluklu dizilerin çiftlerinden oluşan etiketli veriler için LSTM ağının bir Siyam uyarlamasını sunar ve bu model cümleler arasındaki anlamsal benzerliği değerlendirmek için uygulanır (Mueller & Thyagarajan, 2018). Değişken uzunluklu karakter dizilerinde bir benzerlik ölçüsü öğrenmek için derin bir mimari sunmuştur. Bu model, karakter düzeyinde çift yönlü LSTM'lerin bir yığını bir Siyam mimarisiyle birleştirir. Bu model, değişken uzunluklu dizeleri sabit boyutlu bir gömme boşluğuna yalnızca dizge çiftleri arasındaki benzerlik hakkındaki bilgileri kullanarak yansıtmayı öğrenir. Siyam Ağları kullanılarak bilgisayarla görme ve NLP alanındaki son derece başarılı uygulamalar geliştirilmiştir (Wua, Li, Wub, & Changa, 2020).

Siyam ağında, karşılaştırılmak istenen iki nesne, aynı ağ üzerinden geçirilir. Tam olarak aynı ağ ile her iki varlığın da Şekil 3.32'te gösterildiği gibi aynı ağırlıklara sahip aynı mimariden geçirilmesi kastedilmektedir. Şekil 3.32'te hastalık sınıflandırması için Siyam ağının mimarisi gösterilmiştir (Zhu vd., 2019).



Şekil 3.32: Siyam Ağı (Siamese Network)

Ortak ağı sonunda, daha sonra aralarındaki benzerliği ölçmek için, kullanılabilecek girdinin vektörel bir temsili elde edilir. Siyam ağına amacı, iki girişin benzer veya farklı olup olmadığını öğrenmektir. Elimizde 2 farklı hastalık verisinin olduğu ve iki hastalığın benzer olup olmadığını öğrenmek istediğimiz bir örneklem durumunda; Hata Fonksiyonu (Binary Cross-Entropy) aşağıdaki gibi tanımlıdır.

$$H_p(q) = -\frac{1}{N} + \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (3.3)$$

Hata fonksiyonunda N çıktı boyutunu temsil eder. Burada, $p(y_i)$ model çıktısındaki i'nci skaler değerdir. y_i karşılık gelen ise hedef değerdir ve model çıktısındaki skaler değerlerin sayısıdır.

Tıpkı iki görüntünün benzer olup olmadığını kontrol etmek için Siyam ağını kullandığımız gibi, aynı kavram, iki hastalığın benzer olup olmadığını kontrol etmek için de kullanılabilir. İki metnin benzer veya değil olarak sınıflandırılması için yine Siyam ağı kullanılabilir. Burada, metinleri öne çıkarmak için kullanılan ortak ağ, basit bir ayrıştırma katmanı ve ardından BLSTM kullanımıdır.

Bu ağda, input_1 ve input_2, benzer amaç için karşılaştırılacak olan önceden işlenmiş ve Keras ile belirtilmiş metin dizileridir. Bu iki metin dizisi daha sonra temel bir ayrıştırma katmanı ve bir LSTM biriminden oluşan ortak bir ağ üzerinden beslenir. Bu ortak ağdan öznitelik vektörleri elde edildikten sonra, bir dizi benzerlik ölçüsü (Kosünüs) hesaplanır ve sonunda özellik vektörleri

birleştirilir ve ardından verilen hastalıkların benzer olup olmadığını sınıflandırmaya yardımcı olacak sigmoid fonksiyonu kullanılır. Siyam ağı eğitimi sırasında kullanılacak benzer ve farklı çift örneği Şekil 3.33’de gösterilmiştir (Koch vd., 2015).


Girdi Çiftleri		Label
 Grip Veri 1	 Grip Veri 2	Benzer
 Covid-19 Veri 1	 Grip Veri 1	Farklı
 Covid-19 Veri 1	 Covid-19 Veri 3	Benzer
 Astim Veri 1	 Grip Veri 1	Farklı

Şekil 3.33: Siyam Ağı (Siamese Network) için farklı ve benzer çift örneği

Siyam ağları sadece yüz tanıma için değil, bu çalışmada olduğu gibi çok fazla örnek verinin olmadığı uygulamalarda ve iki girdi arasındaki benzerliği öğrenmemiz gereken görevlerde de yaygın olarak kullanılmaktadır. Siyam ağları

video üzerinde nesne tespiti, yazı tanıma, yüz tanıma, kusur tespiti, endüstri alanında parçanın varlığı, cümle benzerliği, metin sınıflandırma gibi birçok alanda kullanılabilir.


Bu çalışmada Siyam Ağları, hastalıkların arasındaki anlamsal benzerliği değerlendirmek için uygulanmıştır. Siyam Ağı ile sisteme yalnızca öğrenmesini ve tespit etmek istediğimiz hastalık ile ilgili verileri vererek öğrenme işlemi gerçekleştirilmiştir. Öğrenme sonucunda çıkan doğruluk grafiği Şekil 3.34’de gösterilmiştir.




Şekil 3.34: Siyam Ağı (Siamese Network) Doğruluk Grafiği (Covid-19)

Pandemi gibi yeni bir hastalık olduğunda hastalığın ilk başlarında elde yeterli veri bulunmadığından hastalığın tespiti çok zorlaşmaktadır. Bu yüzden günümüzde de Covid-19 hastalığının başlangıcında elde yeterli veri olmadığı için kimin nasıl bir belirti gösterdiği ve hastalığı taşıyan kişiyi tespit edebilmek büyük önem taşımaktadır. Covid-19 ilk geçiren kişilerin gösterdiği belirtiler ile birçok kişinin aynı belirtileri gösterdiği düşünülerek doğru hasta kişileri tespit etmeye çalışılmıştır. Yapılan anket sırasında anamnezi alınan hastalar içerisinde 21 kişi, Covid-19 hastası olduğunu belirtmiştir. Alınan Covid-19 ve diğer hastalık verilerinden yeterli sayıda benzer çiftler oluşturulmuştur. Ayrıca farklı çiftler de oluşturularak benzer ve farklı çiftler ile Siyam Ağı (Siamese Network) ile eğitim süreci gerçekleştirilmiştir. Yapılan eğitim sonucu modelin

hata grafiği ve sınıflandırma başarısı sırasıyla Şekil 3.35 ve Şekil 3.36'da verilmiştir.




Şekil 3.35: Siyam Ağı (Siamese Network) Hata Grafiği



Şekil 3.36: Siyam Ağı (Siamese Network) Sınıflandırma Raporu


Sınıflandırma tablosu içerisinde benzer ve farklı çiftlerin oranları yer almaktadır. Sınıflandırma tablosundan 185 çift içerisinde doğruluk oranı %98 olarak bulunmuştur. Aşağıdaki tabloda benzer çiftler 0 ve farklı çiftler 1 olarak gösterilmiştir.

Doğruluk tablosundan görüleceği üzere, 72 benzer çiftten 69 unun ve 117 farklı çiftin hepsinin siyam ağı ile doğru tespiti gerçekleştirilmiştir. Sonuçlar Şekil 3.37’de görülmektedir.




Şekil 3.37: Siyam Ağı ile Benzer ve Farklı Çiftlerin Doğruluk Tablosu

Bir başka hastalık olan mevsimsel grip ve diğer hastalık verilerinden yeterli sayıda benzer çiftler oluşturularak eğitim gerçekleştirilmiştir. Gerçekleştirilen eğitim sonucu modelin doğruluk grafiği Şekil 3.38’de verilmiştir. Covid-19 için yapılmış testler sonucu 185 benzer ve farklı çift içerisinde Doğruluk Oranı %98 olarak bulunmuştur.



Şekil 3.38: Siyam Ağı ile Mevsimsel Grip ve Diğer Hastalıkların Doğruluk Grafiği

Siyam ağı kullanılarak Mevsimsel Grip ve diğer hastalık çeşitlerinden benzer ve farklı çiftler oluşturulmuştur. Test işlemi için benzer çiftlerden 500 veri ve farklı çiftlerden 1000 veri kullanılarak sonuçlar alınmıştır. Sınıflandırma tablosu Şekil 3.39’de verilmiştir.



Şekil 3.39: Doğruluk Tablosu

5. SONUÇ VE ÖNERİLER

Bu çalışmada Karar Ağaçları, Torbalama, Artırma, Evrişimli Sinir Ağları ve Siyam Ağları gibi teknikler kullanılmıştır. Bu teknolojiler gelecekte belki de herhangi bir doktorun varlığına ya da yardımına ihtiyaç duymadan birçok hastalığın tedavi ve tanı yöntemlerinde kullanılacaktır.

Yapılan çalışmaya göre hasta öyküsü almanın (Anamnez) büyük bir önemi olduğu görülmüştür. Doğru alınan öykü ile birçok hastalığın erken aşamada tanısı gerçekleştirilerek hastalığın erken safhasında tedaviye başlanması sağlanabilir. Hayati önem arz eden birçok hastalık çeşidi (az miktarda veri olduğu durumlarda bile) bu çalışmada uygulanan yöntemler kullanılarak doğru şekilde tanınabilir ve yüksek doğruluk oranına sahip, hekime yardımcı bir tanı koyma sistemi olarak kullanılabilir. Çizelge 4.1’de bu çalışmada kullanılan yöntemlerin doğruluk oranları verilmiştir.

Çizelge 4.1: Doğruluk Tablosu

	Doğruluk Oranları
Karar Ağaçları (Decision Tree)	0.73
Torbalama (Bagging)	0.76
Artırma (Boosting)	0.67
Sinir Ağı ile Sınıflandırma (Classification)	0.70
BLSTM ile Siyam Ağı (Siamese Network)	0.98

Aynı zamanda günümüzdeki pandemi dönemi gibi yeterli sağlık personeline ulaşılmasının zor olduğu durumlarda bu sistem ile gelişmiş bir teknolojik alt yapı oluşturularak belirli hastalıkların ön tespiti yapılabilir. Gelecekte, sağlık sektöründe yapılacak teknolojik alt yapı çalışmaları ile yapay zeka teknolojilerinden yararlanarak, çok daha hızlı ve doğru hastalık tanısı koyarak hastanın en doğru şekilde iyileşme süreci sağlanabilecektir.

KAYNAKLAR

- Acıbadem, 2021. Vücut Kitle İndeksi Hesaplama. Erişim Tarihi: 17.05.2021.
<https://www.acibadem.com.tr/ilgi-alani/vucut-kitle-indeksi-hesaplama/>
- Akdeniz Üniversitesi Tıp Fakültesi, 201. Tıbbi Hikaye ve Fizik Muayene Pratik Soru Örnekleri ve Yanıtları. Erişim Tarihi: 20.04.2021.
<https://docplayer.biz.tr/113441389-Tibbi-hikaye-ve-fizik-muayene-pratik-soru-ornekleri-ve-yanitlari.html>
- Alçelik, A., 2016. Anamnez Hikaye Alma. Erişim Tarihi: 12.05.2021.
<https://pdfslide.net/health-medicine/ic-hastaliklari-anamnez-alma-aytekin-alcelik.html>
- Ankara Üniversitesi Tıp Fakültesi, 2018. Göğüs Hastalıklarında Anamnez ve Fizik Muayene. Erişim Tarihi: 09.05.2021.
<https://acikders.ankara.edu.tr/course/view.php?id=5093>
- Cambra, M. M., 2018. Using Recurrent Neural Networks to predict the time for an event. Universitat De Barcelona, Fundamentals of Data Science, M.Sc. Thesis, 33p, Barcelona.
- Chawla, A., Jacob, P., Lee, B., Fallo, S., 2019. Bidirectional LSTM Autoencoder for Sequence based Anomaly Detection in Cyber Security. International Journal of Simulation, 1473-804, 1473-8031.
- Choi, S. 2020. An Ensemble Learner-Based Bagging Model Using Past Output Data for Photovoltaic Forecasting, energies, 13(6), 1438.
- Dashtipour, K., 2016. Multilingual Sentiment Analysis: State of the Art and Independent Comparison of Techniques, Cogn Comput, 8, 757–771.
- Gülhane Askeri Tıp Akademisi, 2009. Tıbbın Olmazsa Olmazı Fizik Muayeneyi İhmal mi Ediyoruz? Erişim Tarihi: 16.04.2021.
<http://guncel.tgv.org.tr/journal/30/pdf/322.pdf>
- Kellner, T. 2017. AI Healthcare Expert: Doctors And Machines Make A Brilliant Match. Erişim Tarihi: 14.05.2021.
<https://www.ge.com/news/reports/ai-healthcare-expert-doctors-machinesmake-brilliant-match>
- Kılınç, D. 2016. The Effect of Ensemble Learning Models on Turkish Text Classification, CBÜ Fen Bil. Dergi., 12, 2, 215-220.
- Koch, G., 2015. Siamese Neural Networks for One-shot Image Recognition. University of Toronto, Graduate Department of Computer Science, M.Sc. Thesis, 27p, Toronto.

- Mueller, J., Thyagarajan, A., 2018. Siamese Recurrent Architectures for Learning Sentence Similarity, Thirtieth AAAI Conference on Artificial Intelligence, 20,1, 2786-2792.
- Oğuzlar, A., 2011. Temel metin madenciliği. Dora Yayıncılık, 156, Bursa.
- Rana Nalçacı, 2015. Anamnez Formu. Erişim Tarihi: 13.05.2021. <https://acikders.ankara.edu.tr/mod/resource/view.php?id=63988>
- Uludağ Üniversitesi Tıp Fakültesi, 2020. Solunum Sistemi Hastalıklarında Anamnez ve Başlıca Semptomların Değerlendirilmesi. Erişim Tarihi: 01.05.2021. https://uludag.edu.tr/dosyalar/gogushastaliklari/YeniKlasor%201/donem_4_gogus_hastaliklari_staji_anamnez_dersi_pdf_1.pdf
- Üstündağ, M. G., Turhan, S., Topbaş, M., & Beyhun, N. E., 2020. The importance of anamnesis on the fil-iation of COVID-19 patients and the determination of their contacts. Turk J Public Health, 107-111.
- Saad, M., 2019. Stacking vs Bagging vs Boosting. Erişim Tarihi: 24.04.2021 <https://mksaad.wordpress.com/2019/12/21/stacking-vs-bagging-vs-boosting/>
- Sağlık Bakanlığı, 2020. Genel Bilgiler, Epidemiyoloji ve Tanı. Erişim Tarihi: 22.05.2021. <https://covid19.saglik.gov.tr/TR-66337/genel-bilgiler-epidemiyoloji-ve-tani.html>
- Sevinç, S. 2006. Kardiyovasküler Sistemin Değerlendirilmesi, Hemşirelikte Eğitim ve Araştırma Dergisi. 3(1), 12-21.
- Sirsat, S. R., 2013. Strength and Accuracy Analysis of Affix Removal, International Journal of Computer Science and Information Technologies, 4(2), 265-269.
- Stefanowski, J., 2008. Discovering Decision Trees, Poznań University of Technology, Institute of Computing Science, Dr. Thesis, 61p, Catania
- Sultana, F., Sufian, A., Dutta, P., 2018. Advancements in Image Classification using Convolutional Neural Network, IEEE Xplore. 978-1-5386-7638-7/18
- Tarhan, Ö. R. 2015. Anamnez Nedir Nasıl Alınır. Erişim Tarihi: 22.04.2021. <https://www.turkcerrahi.com/makaleler/anamnez/nedir-nasil-alinir/>
- Toraman, İ. T., 2007. Karar Ağaçları ve Fraktal Analiz Kullanarak Histopatolojik İmgelerin Sınıflandırılması, Gazi Üniv. Müh. Mim. Fak. Der, 22, 4, 753-758.

- Türkoğlu, İ., Toraman, S., 2007. Karar Ağaçları ve Fraktal Analiz Kullanarak Histopatolojik İmgelerin Sınıflandırılması, Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 22, 4, 753-758.
- Üzen, H., Hanbay, K., 2020. Yaya Özellik Tanıma için LM Filtre Temelli Derin Evrişimsel Sinir Ağı, Politeknik Dergisi, 23(3), 605-613.
- Wua, Y., Li, J., Wub, J., Changa, J., 2020. Siamese capsule networks with global and local features for text classification, Neurocomputing, 390, 88-98
- Yaman, E., 2019. Comparison of Bagging and Boosting Ensemble Machine Learning Methods for Automated EMG Signal Classification, Hindawi BioMed Research International, 13, 1-13.
- Yıldırım, O., 2018. A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification, Computers in Biology and Medicine, 96, 189-202.
- Zhao, C., Huang, X., Li, Y., 2020. A Double-Channel Hybrid Deep Neural Network Based on CNN and BiLSTM for Remaining Useful Life Prediction, Sensors, 20(24), 7109
- Zhu, R., Gong, X., Hu, S., Wang, Y., 2019. Power Quality Disturbances Classification via Fully-Convolutional Siamese Network and k-Nearest Neighbor, Energies, 12(24), 4732.

ÖZGEÇMİŞ

Adı Soyadı : Ethem KARAL

Eğitim Durumu

Lise : Dündar Uçar Lisesi, 2011

Lisans : Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik
Fakültesi, Bilgisayar Mühendisliği Bölümü

Yüksek Lisans : İstanbul Ticaret Üniversitesi,
Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim
Dalı

Yayımları

Karal, E., Turan, M., 2021. Hekime Tanı Koymada Yardımcı, Yapay Zekâ Destekli
Hastalık Tespit Uzmanı, Avrupa Bilim ve Teknoloji Dergisi, 26, 100-116.