



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ ANABİLİM DALI

**TÜRKİYE'DEKİ AĞRI ANLATILARININ NİCEL VE
NİTEL ANALİZLE İNCELENMESİ SONUCUNDA
MAKİNE İLE DERİN ÖĞRENME YÖNTEMLERİYLE
EVRENSEL AĞRI SKALASI ALGORİTMASI
GELİŞTİRİLMESİ.**

Yüksek Lisans Tezi

Dr.Muhsin Öznaneci

Temmuz 2025



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ ANABİLİM DALI

TÜRKİYE'DEKİ AĞRI ANLATILARININ NİCEL VE
NİTEL ANALİZLE İNCELENMESİ SONUCUNDA
MAKİNE İLE DERİN ÖĞRENME YÖNTEMLERİYLE
EVRENSEL AĞRI SKALASI ALGORİTMASI
GELİŞTİRİLMESİ.

Yüksek Lisans Tezi

Dr.Muhsin Öznaneci

Danışman

Prof.Dr.Handan ANKARALI

Eşdanışman

Dr. Öğr. Üyesi Muhammet Sinan BAŞARSLAN

Temmuz 2025

TEZ JÜRİSİ ONAYI

Dr.Muhsin ÖZNANECİ tarafından hazırlanan " TÜRKİYE'DEKİ AĞRI ANLATILARININ NİCEL VE NİTEL ANALİZLE İNCELENMESİ SONUCUNDA MAKİNE İLE DERİN ÖĞRENME YÖNTEMLERİYLE EVRENSEL AĞRI SKALASI ALGORİTMASI GELİŞTİRİLMESİ." başlıklı bu Yüksek Lisans Tezi, Biyolojik Veri Bilimi Anabilim Dalı'nda hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Prof. Dr.Handan ANKARALI

İstanbul Medeniyet Üniversitesi

Biyostatistik ve Tıp Bilişimi Anabilim Dalı

Üyeler:

Doç.Dr. Hüseyin BAKIR

Doğuş Üniversitesi Elektrik ve Elektronik Otomasyon

Bölümü

Dr.Öğr.Üyesi Zeynep TURGUT AKGÜN

İstanbul Medeniyet Üniversitesi Bilgisayar Donanımı

Anabilim Dalı

Tez Savunma Tarihi: 28/07/2025

BEYANLAR

Yazım ve Kaynak Gösterme Kılavuzu Beyanı

Danışmanlığımda yazılan bu tezin Yüksek Lisans yazım ve kaynak gösterme kılavuzunda belirtilen kurallara uygun olarak yapılandırıldığı ve bu kılavuzun

APA kaynak gösterme standartlarının bu tezde tutarlı olarak uygulandığı tarafımdan incelenerek teyit edilmiştir.

İmza

Dr. Öğr. Üyesi Muhammet Sinan BAŞARSLAN

Etik İlkeler Sadakat Beyanı

Hazırladığım bu tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi beyan ederim.

İmza

Dr. Muhsin ÖZNANECİ

İÇİNDEKİLER

İÇİNDEKİLER.....	i
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
1.GİRİŞ.....	1
1.1. Genel Konu Tanıtımı.....	1
1.1.1 Konunun Önemi.....	3
1.1.2 Literatürdeki Boşluk.....	3
1.1.3. Akut-Kronik Ağrı ve Mekanizmaları.....	3
1.1.4 Ağrı Ölçeklerinin Geliştirilmesi.....	4
1.1.5 Ağrı Araştırmalarında AI kullanımı.....	5
1.2. Araştırma Problemi.....	5
1.2.1 Mevcut Sorun.....	5
1.2.2. Araştırma Probleminin Tanımı.....	5
1.3. Araştırmanın Amacı.....	6
1.3.1 Genel Amaç.....	6
1.3.2 Spesifik Amaçlar.....	6
2. ÇALIŞMADA KULLANILAN MATERYALLER VE YÖNTEMLER.....	8
2.1 Veri Toplama.....	8
2.1.1 Başağrısı İlişkili Durumlar (Ölçek: Henry Ford Başağrısı Ölçeği-HFDI).....	8
2.1.2 Fibromyalji (Ölçek: Fibromyalji Survey Diagnostic Criteria - FSDC).....	8
2.1.3. MS (Ölçek: McGill Ağrı Ölçeği).....	9
2.1.4 Epilepsi (Ölçek: Brief Pain Inventory - BPI).....	9
2.2 Analiz Yöntemleri (Analysis Methods).....	10
2.2.1 Doğal Dil İşleme Yöntemleri.....	10
2.2.1.1 Term Frequency-Inverse Document Frequency.....	10
2.2.1.2. Bag of Words.....	11
2.2.1.3 BERT.....	11
2.2.2. Makine Öğrenmesi Ensemble Learning Modelleri.....	12
2.2.2.1. Destek Vektör Regresyonu (Support Vector Regression).....	12
2.2.2.2. K En Yakın Komşu (K-Nearest Neighbors).....	13

2.2.2.3. Ridge Regression.....	13
2.2.2.4. Lasso Regresyon.....	14
2.2.2.5. ElasticNet Regresyon	14
2.2.2.6. Karar Ağacı (Decision Tree) Regresyon	14
2.2.2.7. Rastgele Orman (Random Forest) Regresyon	15
2.2.2.8. Gradient Boosting Regresyon.....	15
2.2.2.9. Extreme Gradient Boosting Regresyon	15
2.2.2.10. LightGBM	16
2.2.2.11. CatBoost	16
2.2.2.12. Extra Tree Regresyon	17
2.2.3. Derin Öğrenme	18
2.2.3.1. Yapay Sinir Ağları (Artificial Neural Network).....	18
2.2.3.2. Evrişimsel Sinir Ağları (Convolutional Neural Network).....	18
2.2.3.3. Öz Yinelemeli Sinir Ağları (Recurrent Neural Network).....	18
2.2.4. Açıklanabilir Yapay Zeka.....	18
2.3 Ölçme Değerlendirme ve İstatistiksel Analiz	19
2.3.1. Belirleme Katsayısı:	19
2.3.2. Ortalama Kare Hata:.....	20
2.3.3. Ortalama Mutlak Hata:	20
2.3.4. Ortalama Mutlak Yüzde Hata:.....	20
3. ARAŞTIRMANIN KATKILARI.....	1
3.1 Bilimsel Katkı.....	1
3.2 Pratik Katkı.....	1
3.3 Literatüre Katkı	1
3.3.1 Daha Önce Ele Alınmamış Konular	1
3.3.2 Yöntemsel Yenilikler.....	1
4. ARAŞTIRMANIN SINIRLILIKLARI	1
4.1 Coğrafi ve Dilsel Sınırlılıklar	1
4.2 Veri Toplama ile İlgili Sınırlılıklar.....	1
4.3 ML ve NLP Modellerine İlişkin Sınırlılıklar.....	2
4.4 Genel Sınırlamalar	2
5. DENEYSEL ORTAM VE BULGULAR	3
5.1. Demografik Bilgiler:	3
5.1.1 Baş Ağrısı Grubu:.....	3
5.1.2. MS Grubu	4
5.1.3. Epilepsi Grubu:.....	4
5.1.4. Fibromiyalji Grubu (n = 208) – Demografi, Ağrı Eşiği ve FSDC.....	5

5.2. Ağrı Eşiği Anketinin 4 Hasta Grubunda Güvenilirlik Geçerliliğinin Saptanması.....	6
5.2.1. Bulgular	6
5.3. MS Grubunda McGill Ağrı Ölçeğinin Güvenilirliği	7
5.3.1.Bulgular:	7
5.4. Epilepsi Grubunda BPI Ölçeğinin Güvenilirliği	8
5.4.1.Bulgular:	8
5.5.Baş Ağrısı Grubunda HFDI Ölçeğinin Güvenilirliği.....	9
5.5.1. Bulgular	9
5.6. FSDC Geçerlik Güvenilirlik Analizi	10
5.6.1. Bulgular	10
5.7. BAŞAĞRISI VERİSİ BULGULARI	11
5.7.1. Baş Ağrısında Ağrı Eşiğinin Tahmin Edilmesi-Hasta Kendi Ağrısını Derecelendirmez İse	11
5.7.1.2. BoW.....	12
5.7.1.3.Fine Tune BERT.....	13
5.7.2. Baş Ağrısında Ağrı Eşiğinin Tahmin Edilmesi-Hasta Kendi Ağrısını Derecelendirir İse	14
5.8.Baş Ağrısı Verisinde HFDI Skorunun Tahmini	15
5.8.1.TF-IDF:	15
5.8.2. BoW.....	16
5.8.3.Fine Tune BERT.....	17
5.9.MS Hastalarında Ağrı Eşiği Tahmini (Baş Ağrısı Verisinden Yola Çıkararak Hastaların Kendi Ağrılarını Derecelendirmesi Eklenmemiştir)	18
5.9.1.TF-IDF:	18
5.9.2. BoW:	19
5.9.3. Fine Tuned BERT:	20
5.10.MS Hastalarında McGill Kısa Ağrı Formunda PRI tahmini	20
5.11. NİTEL ANALİZLER	22
5.11.1. MS Hastalarında Ağrıya Nitel Yaklaşım- Gömülü Teori ile Anlatılması	22
5.11.2. Baş Ağrısı Verisinin Nitel Analizi.....	26
6.TARTIŞMA.....	28
7.SONUÇ	41
8.KAYNAKÇA	42
EKLER	55
EK 1: Etik Kurul Onamı.....	55
EK 2: Benzerlik Raporu	56
Ek-3: Özgeçmiş	57

ÖZET

TÜRKİYE'DEKİ AĞRI ANLATILARININ NİCEL VE NİTEL ANALİZLE İNCELENMESİ SONUCUNDA MAKİNE İLE DERİN ÖĞRENME YÖNTEMLERİYLE EVRENSEL AĞRI SKALASI ALGORİTMASI GELİŞTİRİLMESİ

ÖZNANECİ, Muhsin

Danışmanlar: Dr.Öğr.Üyesi Muhammet Sinan BAŞARSLAN, Prof.Dr.Handan
ANKARALI

Temmuz 2025

Bu tez, Türkiye'deki farklı lehçelerde ifade edilen ağrı anlatılarını çok-boyutlu olarak değerlendirerek evrensel bir "Ağrı Skalası Algoritması" tasarlamayı amaçlamaktadır. Migren/baş ağrısı, Multipl Skleroz (MS), fibromiyalji ve epilepsi tanılı toplam 200'den fazla hasta; demografik anketleri doldurmuş, en az on iki sözcüklük ağrı betimlemeleri sunmuş ve beş ayrı ölçek (HFDI, FSDC, SF-MPQ, BPI, Pain Sensitivity Questionnaire) ile taranmıştır. Güvenirlik incelemeleri, MS ve baş ağrısı gruplarında Cronbach's $\alpha \approx 0,88$ düzeyinde yüksek iç tutarlılık, epilepsi ve fibromiyaljide ise negatif α katsayılarıyla yetersiz tutarlılık göstermiştir.

Metin verileri Bag of Words (BoW), Term Frequency Inverse Document Frequency (TF-IDF) ve Bidirectional Encoder Representations from Transformers (BERT) gömüleriyle vektörlenmiş, çoklu çıktı regresyonu için on bir model oluşturulmuştur. Bu modellerin değerlendirilmesinde Ortalama Kare Hatası (MSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hatası (MAPE), Belirleme Katsayısı (R^2) kullanılmıştır. BoW temsiliyle Gradient Boosting ve Lasso en güvenilir öngörülerini sağlamış; Ridge regresyonu parsimoni ile yüksek genellenebilirlik sunmuştur.

Nitel analizde, Strauss & Corbin'in eksenli kodlama yöntemiyle 1300-1400 anlam birimi dört üst temada bütünleştirilmiştir: duyuşsal nitelik, zamanlama/süre, işlevsel etki ve duygusal yansıma. Bu temalar "Tükenmişliği Yeniden Çerçeveleme" (MS) ve "Zonklayan Tükenmişlik Döngüsü" (baş ağrısı) çekirdek kategorileri etrafında kuramsallaştırılmıştır.

Bulgular, hastalık modeli farklılıklarının model performansını etkilediğini; düzenlenileştirilmiş lineer modeller ile artırılmalı yöntemlerin aşırı uyumu sınırladığını göstermektedir. Tez, çok-lehçeli büyük veri kümeleriyle modelin doğrulamasını ve ölçeğin klinik karar destek sistemlerine entegrasyonunu gelecekteki başlıca adımlar olarak önermektedir. Ayrıca gelecekte, açıklanabilir-yapay-zekâ yöntemleri de çalışılabilir.

Anahtar Kelimeler: Nörolojik Ağrı Sendromları, Algoritmik Ağrı Ölçümü, Kronik Ağrı Yönetimi, Psikometrik Güvenirlik, Klinik Karar Destek Sistemleri

ABSTRACT

DEVELOPMENT OF A UNIVERSAL PAIN SCALE ALGORITHM USING MACHINE AND DEEP LEARNING METHODS BASED ON QUANTITATIVE AND QUALITATIVE ANALYSIS OF PAIN NARRATIVES IN TURKEY

Öznaneci, Muhsin

Supervisors: Dr.Öğr.Üyesi Muhammet Sinan BAŞARSLAN, Prof. Dr. Handan ANKARALI

July 2025

This thesis aims to design a universal “Pain Scale Algorithm” by multidimensionally evaluating pain narratives expressed in different dialects in Türkiye. Over 200 patients diagnosed with migraine/headache, multiple sclerosis (MS), fibromyalgia, or epilepsy completed demographic surveys, provided pain descriptions of at least twelve words, and were assessed with five scales (HFDI, FSDC, SF-MPQ, BPI, Pain Sensitivity Questionnaire). Reliability analyses showed high internal consistency for MS and headache groups (Cronbach’s $\alpha \approx 0.88$) but inadequate consistency with negative α values in epilepsy and fibromyalgia. Text data were vectorized using Bag of Words, TF-IDF, and BERT embeddings, and eleven multi-output regression models were tested. Mean Squared Error, Mean Absolute Error, Mean Absolute Percentage Error, and R^2 were used for evaluation. With Bag of Words, Gradient Boosting and Lasso yielded the most reliable predictions; Ridge regression offered parsimony and generalizability. Qualitative analysis via Strauss & Corbin’s axial coding integrated 1,300–1,400 meaning units into four themes: sensory quality, timing/duration, functional impact, and emotional reflection—conceptualized as “Reframing Exhaustion” (MS) and “Throbbing Exhaustion Cycle” (headache). Findings indicate disease-model differences affect performance, and regularized linear and boosting methods limit overfitting. Future work includes validation with large multilingual datasets, integration into clinical decision support, and explainable AI methods.

Keywords: Neurological Pain Syndromes, Algorithmic Pain Assessment, Chronic Pain Management, Psychometric Reliability, Clinical Decision Support Systems

TEŞEKKÜR

Öncelikle bu yola başlamamda vesile olan Prof. Dr. Hasan GÜÇLÜ 'ye,

Lisede beni hayatta tutan ve o olmasa araştırmacı asla olmayacağım Biyoloji Öğretmenim Ayşe ACAR'a,

Tez danışmanımdan çok daha fazlası olmuş, bana bir anne gibi kol kanat geren Prof. Dr. Handan ANKARALI 'ya ve fakülte yıllarımın başlangıcından beri benim kahrımı çeken Arş. Gör. Dr. Nurgül BULUT' a,

2024 Şubat'ında Adıyaman'dan döner dönmez nöbet ertesi derste öforik bir halde tanıştığım, önce hocam, sonra tez danışmanım ancak en önemlisi bir abim ve yakın arkadaşım olan Dr. Öğr. Üyesi Muhammet Sinan BAŞARSLAN' a,

2024 yılının başında hiç düşünmediğim bir yola beni başlatan ve bana hem akademik olarak hem de hayatımla alakalı yeni bir sayfa açmamı sağlayan Dr. Öğr. Üyesi Emine AYYILDIZ 'a,

Benim akıl ve ruh sağlığımı yerinde tutan canım arkadaşlarım, Berna BURAN, Stj. Dr. Melisa DAĞISTANLI, İnt. Dr. Muhammet Yusuf UZUN, Eray KILIÇ, Hem.Semanur GÖGEN, Bilgesu DURAN, Loni Aslan BEHARTİ, Tuğba YILMAZ SİNDLİNGER, Sema UZUN ve Dr.Hakan ÇİÇEKÇİ'ye

Kaderin bir cilvesi sayesinde tanıştığım, kendileri olmasa hayatta oluşum şüpheli olacak canım yavrularım İnt. Dr. İnci DAL, Stj. Dr. Oğuzhan KISA, Stj. Dr. Reyhan İrem ÜNLÜ, Stj. Dr. Zeynep Ceyda GAYRETLİ, Ahsen ŞENTÜRK, Görkem METİN, Edanur ERMİŞ, Stj. Dr. Helen REYHANİ ve İnt. Dr. Ezgi YAVUZ 'a,

Her türlü akademik maceraya beraber giriştiğimiz, bana 2017'den beri bir abla, bir kadim dost olan Op. Dr. Başak Sinem SEZGİN 'e, benim en sevdiğim çömezim Arş.Gör.Dr.Onur SÖNMEZ'e ve başımıza her türlü belayı beraber açtığımız Dr. Furkan KIZILIŞIK 'a,

Liseden beri ahretliğim olan Arş. Gör. Dr. Şölen TAŞLIÇUKUR ve Dr.Dt. Gülsüm TAŞLIÇUKUR'a,

Sosyal Medyanın en büyük bana kazancı Dr. Öğr. Üyesi Özge Kiremitçi ÖZER, Op. Dr. Elif AKBAY, Op.Dr. Müjdegül KARACA, Doç. Dr. Özer Ural ÇAKICI, Uz.Dr.Esen DÖNMEZER, Dr.Hasan Altay UĞUZ, Dr.Dilek ÖZKAN, Dr.Elif KOCAOĞLU ve Dr. Gülşen ÇAKMAK'a

Tezimin yüzüncü okumasını bile hevesle yapan benim nöro ve sinirbilim camiasındaki ablam ve kadim dostum Doç. Dr. Ayşe Deniz ELMALI YAZICI'ya,

Tezimde veri toplama süresince bana yardımcı olan Arş. Gör. Dr. Afife ÖZKAL, Uz. Dr. Fatma Hilal ÇİÇEK, Türkiye MS Derneğinden Prof. Dr. Serkan DEMİR'e, Fibromiyalji ve Epilepsi Hasta Gruplarına,

Benim tez yazım dönemimin en büyük şahidi olan bir tanecik ablam Dr. Öğr. Üyesi Zeynep TURGUT AKGÜN'e,

Bu maceraya beraber başladığım Dr. Öğr. Üyesi Dilek MAMAKLIOĞLU'na,

Fakülte yıllarından beri eli üstümde olan ve beni sürekli koruyup kollayan Uz.Dr.Eren ERKİP'e Uz.Dr.Duygu ŞAHİN'e ve Uz.Dr.Kezban DEMİR'e,

Bana en başta “yapay zeka üzerine çalışacak hekimler lazım” dediğinde kafamda bu tezin ve yüksek lisansın ilham perisi olan Prof. Dr. Dilek DAİ ÖZCENGİZ 'e

Beni bugünlere getiren canım aileme ve en önemlisi de bu süreçte ruh sağlığını korumayı başarabilen canım kendime çok teşekkür ederim.

Dr.Muhsin ÖZNANECİ

Temmuz 2025

1.GİRİŞ

1.1. Genel Konu Tanıtımı

Ağrı, insanlık deneyiminde evrensel bir olgu olmasına rağmen, bireylerin ağrı algısı ve ifade biçimi bölgesel, kültürel ve dilsel faktörlerden etkilenecek büyük ölçüde farklılık göstermektedir (Treede, 2018; Peacock & Patel, 2008). Türkiye, farklı şive ve lehçelerin zengin bir yelpazede yer aldığı bir coğrafyaya sahip olup, bu dilsel çeşitlilik sağlık alanında hasta-hekim iletişimini önemli ölçüde etkilemektedir (Timurtaş, 2012; Yalçınkaya, 2020). Türkçe'nin eklemeli dil yapısı, ağrı deneyimlerinin ifade edilmesinde zengin ve esnek bir anlatım imkanı sunarak, farklı bölgelerde yaşayan bireylerin ağrılarını ifade etme biçimlerini çeşitlendirmektedir (Onan, 2014).

Ancak dilsel çeşitlilik, hasta-hekim iletişiminde çeşitli sorunlara neden olabilir. Sağlık hizmetlerinde, ağrı gibi öznel deneyimlerin ifade edilmesindeki dilsel farklılıklar, doğru teşhis ve tedavi süreçlerini olumsuz yönde etkileyebilir (Wilcox et al., 2015). Bu çalışmada, Türkiye'deki farklı şive ve lehçelerde ağrı anlatılarının analiz edilmesi ve yapay zeka (AI) ve doğal dil işleme (NLP) teknikleri ile bu anlatıların dilsel farklılıklarının ortaya konulması amaçlanmaktadır (Cui et al., 2020). Türkçe'nin eklemeli dil yapısı, bu çalışmada kullanılacak olan makine öğrenmesi (ML) ve derin öğrenme (DL) modellerine özel bir katkı sunarak, dilsel yapıların analiz edilmesine olanak tanıyacaktır (Devlin et al., 2019).

Baş ağrısı, çeşitli nedenlerle ortaya çıkan ve hastaların yaşam kalitesini önemli ölçüde etkileyen yaygın bir sağlık sorunudur. Baş ağrıları, primer ve sekonder olmak üzere iki ana grupta incelenir. Primer baş ağrıları kendi başına bir hastalık olarak kabul edilirken (migren, gerilim tipi baş ağrısı gibi), sekonder baş ağrıları başka bir sağlık sorununun belirtisi olarak ortaya çıkar (Bakar et al., 2016). Klinik yaklaşımla baş ağrısının türünü belirlemek, etkili bir tedavi planı geliştirmek için oldukça önemlidir. Baş ağrısının başlangıcı, süresi, sıklığı ve eşlik eden belirtiler gibi detayların dikkatle değerlendirilmesi tedavi başarısını artırır (Maistrello et al., 2019).

Baş ağrıları, özellikle migren ve gerilim tipi baş ağrısı, hastaların sosyal, fiziksel ve psikolojik işlevlerini olumsuz etkileyerek yaşam kalitesinde belirgin düşüşlere yol açmaktadır. Migren, başın bir tarafında zonklayıcı ve şiddetli ağrıya sebep olurken; gerilim tipi baş ağrısı daha yaygın ve baskılayıcı bir his yaratır. Yapılan çalışmalarda, bu baş ağrılarının özellikle sosyal işlevsellik, zihinsel sağlık ve günlük aktivitelerde belirgin düşüşlere sebep olduğu gösterilmiştir (Wang et al., 2001).

Baş ağrısının kronikleşmesi durumunda, ağrı sıklığı ve şiddeti arttıkça hastaların yaşam kalitesi üzerinde daha olumsuz etkiler görülmektedir. Baş ağrısı yaşayan bireylerin özellikle fiziksel ve zihinsel sağlığında işlev kayıpları yaşadığı, sosyal yaşamlarının kısıtlandığı ve depresyon ile anksiyete gibi ek psikolojik sorunlar yaşama eğiliminde oldukları bulunmuştur (D'Amico et al., 2013). Bu nedenle, baş ağrısı tedavisinde sadece ağrı yönetimi değil, aynı zamanda psikolojik destek sağlanması ve yaşam kalitesinin düzenli olarak değerlendirilmesi büyük önem taşır.

Sonuç olarak, baş ağrısının yaşam kalitesi üzerindeki etkilerini anlamak ve uygun tedavi yaklaşımları geliştirmek, baş ağrısı yönetiminde kritik rol oynar. Araştırmalar, baş ağrısının sıklığı ve şiddetinin azaltılması ile hastaların fiziksel ve sosyal işlevlerinde belirgin iyileşmeler sağlanabileceğini göstermektedir. Bu doğrultuda, baş ağrısının tedavisinde multidisipliner bir yaklaşım benimsenmeli ve hastaların psikolojik durumları da tedavi planına dahil edilmelidir (Mulla et al., 2015).

Epilepsi, tekrarlayan nöbetlerle karakterize kronik bir nörolojik hastalıktır ve hastaların yaşam kalitesini çeşitli yönlerden etkileyebilir. Epilepsi, fokal ve jeneralize olmak üzere iki ana türe ayrılır; fokal nöbetler beyindeki belirli bir bölgeden kaynaklanırken, jeneralize nöbetler beyinin her iki tarafını etkileyebilir (Beghi, 2020). Epilepsi nöbetleri, ani bilinç değişiklikleri ve davranışsal anormalliklerle kendini gösterir ve bu nöbetlerin tipi, etkilenen beynin bölgesine göre değişiklik gösterir (Beghi,2020). Epilepsi tedavisinde nöbet tipine uygun antiepileptik ilaçlar kullanılır, ancak ilaçlara dirençli vakalarda cerrahi tedavi seçenekleri de mevcuttur (Thijs et al., 2019).

Epilepsi hastaları, hastalıklarına bağlı olarak iletişimde çeşitli zorluklarla karşılaşabilirler. Özellikle çocukluk çağında ortaya çıkan epilepsi türlerinde dil gelişimi ve öğrenme süreçlerinde aksaklıklar gözlemlenmiştir (O'Callaghan, 2005). Hastalar, nöbetlerin yol açtığı bilişsel zorluklar nedeniyle duygu ve düşüncelerini ifade etmekte zorlanabilirler, bu durum sosyal ve psikolojik problemleri de beraberinde getirir (O'Toole et al., 2015). İletişim güçlükleri, hastaların yaşam kalitesini olumsuz etkilerken, epilepsiye bağlı damgalanma korkusu da bu zorlukları artırmaktadır.

Epilepsi ile ilişkili kronik ağrılar, bazı hastalar için ciddi bir rahatsızlık kaynağıdır. Epileptik ağrı, çoğunlukla nöbetlerin bir belirtisi olarak ortaya çıkar ve bu ağrılar baş, karın veya ekstremitelerde lokalize olabilir (Kuloğlu-Pazarcı et al., 2016). Kronik ağrılar ve ağrının sürekli tekrar etmesi, hastaların günlük yaşam aktivitelerinde kısıtlamalara yol açarak fiziksel ve zihinsel sağlıklarını olumsuz etkiler (Beghi, 2016). Epilepsi ile ilişkili ağrıların etkin bir şekilde yönetilmesi, hastaların yaşam kalitesini artırmak için kritik öneme sahiptir.

MS, merkezi sinir sisteminde inflamasyon ve demiyelinizasyonla karakterize, ilerleyici bir otoimmün hastalıktır. MS hastalığının semptomları oldukça çeşitlidir ve ağrı, en sık görülen belirtilerden biridir. MS'e bağlı ağrı, nöropatik ve nosiseptif olmak üzere iki ana kategoride sınıflandırılır. Merkezi nöropatik ağrı, MS hastalarında en yaygın görülen ağrı türü olup, genellikle alt ekstremitelerde yanıcı ve spontan ağrı şeklinde hissedilir (Murphy et al., 2017). Bu ağrı tipi, beyinde ve omurilikteki lezyonlardan kaynaklanan sinir sistemi bozukluklarından kaynaklanır ve MS hastalarının yaklaşık %50'sinde görülmektedir (Uruts et al., 2019).

MS hastalarının yaşadığı nöropatik ağrı, trigeminal nevralji, Lhermitte belirtisi ve ekstremitelerde dizestezi gibi farklı ağrı türleriyle kendini gösterir. Bu ağrılar, hastaların yaşam kalitesini önemli ölçüde düşürür ve günlük işlevselliklerini kısıtlar (Ferraro et al., 2018). Örneğin, Lhermitte belirtisi, başın belirli pozisyonlarında ani, elektrik çarpması benzeri bir his yaratırken, trigeminal nevralji genellikle yüz bölgesinde yoğun ağrılara yol açar. Bu ağrılar, MS hastalarının psikolojik durumunu da etkileyerek depresyon ve anksiyete riskini artırır (Duffy et al., 2018).

Nöropatik ağrının MS hastalarında bu kadar yaygın olması, tedavi sürecini zorlaştırmakta ve karmaşık tedavi yaklaşımlarını gerekli kılmaktadır. MS kaynaklı nöropatik ağrı, konvansiyonel ağrı kesicilere yeterince yanıt vermez; genellikle antidepresanlar, antikonvülzanlar ve kanabinoidler gibi alternatif ilaçlarla tedavi edilir (Heitmann et al., 2020). Bununla birlikte, bu ilaçların etkinliği hastadan hastaya farklılık gösterebilmekte ve yan etkileri sebebiyle uzun süreli kullanımda sıkıntılara yol açabilmektedir (Maguire et al., 2021). Son araştırmalar, ağrının biyopsikososyal bir çerçevede ele alınmasını ve bu bağlamda nöromodülasyon gibi yenilikçi tedavi yöntemlerinin umut vaat ettiğini ortaya koymaktadır.

Fibromiyalji, yaygın kas-iskelet ağrısı, yorgunluk, uyku bozuklukları ve bilişsel işlev kaybı ile kendini gösteren kronik bir ağrı sendromudur (Wolfe et al., 2016). Tanısı, 1990 ve 2016 Amerikan Romatoloji Koleji (ACR) kriterlerine göre kronik yaygın ağrının yanı sıra belirli semptom yoğunlukları ile konulmaktadır. Tanı koyma sürecinde hastaların geniş kapsamlı bir klinik değerlendirmeden geçirilmesi gerekmekte olup, somut biyomarkerlerin eksikliği nedeniyle fibromiyalji tanısı genellikle semptomların klinik bulgulara dayanarak değerlendirilmesiyle konur (Goldenberg, 2009).

Fibromiyalji tedavisinde multidisipliner bir yaklaşım benimsenir. Aerobik egzersiz, bilişsel davranış terapisi (CBT) ve farmakolojik tedavi (duloksetin, milnasipran ve pregabalin gibi) gibi yöntemler, hastaların semptomlarını hafifletmede etkili olabilir (Theoharides et al., 2015). Fibromiyaljinin psikolojik boyutları dikkate alınarak, hastaların yaşam kalitesini artırmak amacıyla psikososyal destek sağlanması da önem taşır (Sancassiani et al., 2017).

Fibromiyalji hastaları, ağrılarını ifade etme ve bu ağrının doğruluğunun onaylanması (validasyon) konusunda sıklıkla zorluk yaşarlar. Ağrı, subjektif bir deneyim olduğundan, hastaların ağrılarının geçerliliğini kabul ettirmeleri zordur ve bu durum hastalarda yalnızlık ve anlaşılma duygularını artırabilir (Perrot et al., 2012). Bu nedenle fibromiyalji hastalarında etkili bir tedavi için, ağrılarının geçerliliğinin tanınması ve ifade güçlüğünün giderilmesi büyük önem taşır (Favretti et al., 2023).

1.1.1 Konunun Önemi

Ağrının doğru bir şekilde ifade edilmesi, doğru teşhis ve etkili tedavi süreçleri açısından hayati bir öneme sahiptir (Wilcox et al., 2015). Ancak, farklı şive ve lehçelerde ifade edilen ağrı anlatılarının hekimler tarafından tam anlamıyla anlaşılması, hasta-hekim iletişimini zorlaştırarak tıbbi hatalara neden olabilir (Peacock & Patel, 2008). Türkiye gibi çokfarklı dillerin etkileşimi olan bir coğrafyada, bu dilsel farklılıkların tıbbi süreçleri nasıl etkilediğini anlamak, sağlık hizmetlerinin kalitesini artırma potansiyeline sahiptir (Treede, 2018).

Bu noktada, AI ve NLP teknikleri, bu dilsel farklılıkların analiz edilmesi ve evrensel bir ağrı anlatı sistemi geliştirilmesinde önemli bir rol oynar (Cui et al., 2020). AI ve ML algoritmaları, büyük veri setlerini işleyerek ağrı ifadelerinin dilsel kalıplarını öğrenebilir ve farklı şive ve lehçelerdeki anlam varyasyonlarını tespit edebilir (Devlin et al., 2019). Bu bağlamda, bu çalışmada kullanılacak AI modelleri, hekimlerin hastalarla daha etkili iletişim kurmasını sağlamak için ağrı ifadelerini evrensel bir dilde anlamlandırma potansiyeline sahiptir.

1.1.2 Literatürdeki Boşluk

Literatürde ağrının dilsel ve bölgesel farklılıkları üzerine yapılmış sınırlı sayıda çalışma bulunmaktadır. Mevcut çalışmalar, genellikle ağrı anlatılarının sadece belirli bölgelerde incelendiğini ve ağrı anlatılarının evrensel bir dili geliştirmek için yeterince araştırılmadığını göstermektedir (Peacock & Patel, 2008; Wilcox et al., 2015). Ayrıca, eklemli dillerde ağrı anlatılarının incelenmesi üzerine yapılan çalışmaların sayısı da oldukça azdır (Onan, 2014). Türkçe gibi eklemli dil yapısına sahip dillerin, ağrı anlatıları üzerindeki etkisi henüz tam olarak araştırılmamıştır (Timurtaş, 2012).

Bu araştırma, Türkiye'deki farklı şive ve lehçelerde ağrı anlatılarının dilsel analizini yaparak bu boşluğu doldurmayı hedeflemektedir. AI, NLP ve ML algoritmalarının kullanımı, bu dilsel farklılıkları anlamada yeni bir yöntem sunmakta ve literatürdeki boşluğu kapatma potansiyeli taşımaktadır (Devlin et al., 2019). Özellikle, ağrı ifadelerinin NLP ve ML teknikleriyle analiz edilmesi, sağlık alanında bu tür çalışmalara öncülük edecek yenilikçi bir yaklaşım sunmaktadır (Cui et al., 2020).

1.1.3. Akut-Kronik Ağrı ve Mekanizmaları

Vücutta ağrının oluşum mekanizmaları, akut ve kronik ağrı olarak ikiye ayrılır ve her iki ağrı türünün oluşum süreçleri birbirinden oldukça farklıdır. Akut ağrı, ani bir doku hasarı ya da travma sonucu ortaya çıkar ve genellikle vücudu koruyucu bir tepki olarak işlev görür. Bu tip ağrıda, zararlı uyarılar nosiseptörler tarafından algılanır ve bu sinyaller omurilik üzerinden beyne iletilir. Burada beyin, ağrıyı yorumlayarak vücudun hızlı bir şekilde tepki vermesini sağlar. Akut ağrının amacı, vücudu zararlı etkilere korumaktır ve bu tip ağrı, çoğunlukla kısa süreli olup tedaviye iyi yanıt verir (Basbaum et al., 2009); (Woolf, 1990).

Kronik ağrı ise genellikle üç aydan daha uzun süren ve altta yatan doku hasarı iyileştikten sonra da devam eden ağrı olarak tanımlanır. Kronik ağrı, sinir sisteminde meydana gelen kalıcı değişikliklerle ilişkilidir ve nosiseptif sinyallerin sürekli olarak iletilmesi sonucu oluşur. Bu süreçte merkezi sensitizasyon devreye girer ve omurilik seviyesinde nöroplastisite (sinir hücrelerinde yapısal ve işlevsel değişiklikler) meydana gelir. Bu durum, normalde ağrıya neden olmayan uyaranların bile ağrı oluşturmaya (allodini) ve ağrı duyarlılığının artmasına (hiperaljezi) yol açar. Kronik ağrı sıklıkla yaşam kalitesini düşürür ve tedavi edilmesi zordur (Voscopoulos & Lema, 2010); (Apkarian et al., 2009).

Akut ağrıdan kronik ağrıya geçişte önemli bir rol oynayan faktörler arasında merkezi sinir sistemindeki nöroplastisite, inflamatuvar süreçler ve sinir hücrelerinde meydana gelen kalıcı değişiklikler yer alır. Örneğin, omurilikte ve beyin yapılarında nöroinflamasyon ve mikroglia aktivasyonu kronik ağrının gelişiminde önemli rol oynar. Ayrıca sinir hücreleri arasındaki iletişimde rol oynayan çeşitli nörotransmitterler (örneğin, glutamat ve serotonin) ve nörotrofik faktörler, ağrının kronikleşmesine katkıda bulunur. Özellikle nosiseptörlerde meydana gelen "hiperaljezik priming" (ağrıya duyarlılığın artması), ağrının kronik hale gelmesinde temel mekanizmalardan biridir (Shipton, 2011); (Reichling & Levine, 2009).

Sonuç olarak, akut ağrının kronik ağrıya dönüşmesini önlemek, sinir sistemi üzerindeki bu değişiklikleri erken dönemde engellemekle mümkün olabilir. Akut ağrı tedavisinde zamanında ve doğru müdahale yapılmadığında, merkezi ve periferik sensitizasyon süreçleri devreye girerek ağrının kronikleşmesine neden olabilir. Bu nedenle, ağrının erken dönemde etkin bir şekilde yönetilmesi, kronik ağrının önlenmesi açısından büyük önem taşır (Chapman & Vierck, 2017); (Feizerfan & Sheh, 2015).

1.1.4 Ağrı Ölçeklerinin Geliştirilmesi

Ağrı ölçekleri, ağrının karmaşık ve öznel yapısını değerlendirmek amacıyla geliştirilirken çok aşamalı bir metodoloji izlenir. Özellikle çok sorulu (multi-item) ağrı ölçekleri, ağrının hem şiddetini hem de hastanın yaşam kalitesine etkilerini ölçmek amacıyla oluşturulur. Geliştirme sürecinin ilk adımı, uzman klinisyenlerin katkılarıyla literatürdeki mevcut ölçeklerin analiz edilmesi ve ağrıyı farklı boyutlarıyla ölçmeye yönelik soruların oluşturulmasıdır. Örneğin, West Haven-Yale Multidimensional Pain Inventory (MPI) gibi ölçekler, kronik ağrı hastalarının yaşadıkları ağrıyı detaylandırmak amacıyla tasarlanmış olup, psikometrik analizlerle doğrulanır ve ölçeğin güvenilirliği, madde düzeyinde faktör analizleri ile test edilir. Bu süreçte, ölçeğin farklı hasta gruplarında ve klinik ortamlarda tutarlı sonuçlar vermesi önemlidir (Riley et al., 1999).

Çok sorulu ağrı ölçeklerinin geliştirilmesinde, **Madde Yanıt Teorisi (Item Response Theory - IRT)** gibi ileri istatistiksel yöntemler kullanılır. IRT, bir ölçek içerisindeki her sorunun (madde) bir kişinin genel durumu ile nasıl ilişkili olduğunu inceler ve her maddenin geçerliliğini analiz eder. Bu yöntem, özellikle çok boyutlu ölçeklerde soruların birbirleriyle tutarlılığını ve ölçeğin genel geçerliliğini artırmak için önemlidir (Carlson & Davier, 2013). Örneğin, Pain Extent Scale (RPS), vücuttaki ağrı yayılımını ölçen ve IRT kullanılarak test edilmiş bir ölçek olup, romatoid artrit ve fibromiyalji gibi hastalıklarda klinik şiddeti değerlendirmek amacıyla geliştirilmiştir. IRT analizleri, her bir sorunun farklı hasta gruplarında ne kadar güvenilir olduğunu ortaya koymuş ve ağrı yayılımı ile klinik şiddet arasında güçlü bir korelasyon bulunmuştur (Wolfe, 2003). Böylece, IRT yöntemi ile geliştirilen bu ölçekler, hem klinik çalışmalar hem de hasta takibinde önemli veriler sunar.

1.1.5 Ağrı Araştırmalarında AI kullanımı

AI ve NLP teknolojilerinin ağrı değerlendirmesindeki kullanımı, kronik ağrı çeken hastaların yaşam kalitesini iyileştirmek ve tedavi süreçlerini optimize etmek için giderek daha önemli hale gelmektedir. Bu teknoloji, özellikle demans, MS, fibromiyalji ve kanser gibi hastalıklara bağlı ağrı durumlarında, hastaların ağrılarını ifade etme konusundaki zorlukları aşmada kritik bir rol oynar. aı, yüz ifadeleri, elektrodermal aktivite (EDA) ve biyofizyolojik sinyaller gibi veri türlerini kullanarak ağrı değerlendirme sürecini daha objektif bir hale getirebilir (Nagireddi et al., 2022). Bu teknolojiler arasında, zaman serisi analizinde etkili olan Uzun Kısa Süreli Bellek Ağları (LSTM) ve diğer DL modelleri, biyofizyolojik ve sözel olmayan ipuçlarını analiz ederek ağrı tespiti yapmada öne çıkmaktadır. Bu tür bir ağrı tespiti, EDA gibi biyolojik sinyallerle desteklendiğinde nöropatik ağrı durumlarının değerlendirilmesinde etkili olmaktadır (Moscato et al., 2023). NLP ve LSTM tabanlı algoritmalar, kronik ağrı hastalarında sürekli anket doldurma zorunluluğunu azaltmak için, hasta ifadelerinden ağrı skorlarını tahmin etmede önemlidir. Örneğin, NLP, metastatik kanser gibi ağrı yoğunluğunun yüksek olduğu durumlarda tıbbi kayıtlardan ağrı semptomlarını belirlemekte, böylece doktorların ağrı yönetimi stratejilerini daha doğru oluşturmaya olanak tanır (Heintzelman et al., 2012). Yeni nesil NLP algoritmaları, hasta ifadelerinden ağrı seviyelerini otomatik olarak belirleme potansiyeline sahiptir. Örneğin, düşük sırt ağrısı gibi yaygın bir rahatsızlıkta NLP, hasta ifadelerinden ağrı yoğunluğunu tahmin etmede etkili olmuştur (Bacco et al., 2022). Bu, doktorlara daha iyi bireyselleştirilmiş tedavi seçenekleri sunar. Buna ek olarak, yüz ifadelerine dayalı sınıflandırma sistemleri, yoğun bakımda kritik hastaların ağrısını doğru bir şekilde değerlendirmekte başarılıdır. 2022'de yapılan bir çalışmada, yüz ifadelerine dayalı olarak geliştirilen DL modellerinin yoğun bakım hastalarında ağrı değerlendirmesi konusunda yüksek doğruluğa ulaştığı gösterilmiştir (Wu et al., 2022).

1.2. Araştırma Problemi

1.2.1 Mevcut Sorun

Türkiye, çok çeşitli şive ve lehçelerin konuşulduğu bir ülke olup, bu dilsel farklılıklar sağlık iletişimini zorlaştırabilir. Farklı bölgelerde yaşayan hastalar, ağrılarını hekimlerine ifade ederken kendi şive ve lehçelerine özgü terimler kullanabilirler. Örneğin, bir hasta “yanıcı” ağrıdan bahsederken, bir başkası aynı ağrıyı “batıcı” olarak ifade edebilir. Bu tür dilsel farklılıklar, hekimlerin hastalarının ağrı şikayetlerini tam olarak anlamasını zorlaştırabilir ve tedavi sürecini olumsuz etkileyebilir (Peacock & Patel, 2008; Wilcox et al., 2015). Özellikle ağrı gibi öznel bir deneyimin ifade edilmesindeki bu farklılıklar, kronik hastalıkların tedavisinde daha büyük bir sorun teşkil etmektedir (Treede, 2018).

Bu problem, hasta-hekim iletişimini zayıflatmakta ve ağrı yönetiminde yanlış tanıılara yol açabilmektedir. Hastaların farklı ağrı karakteristiklerini ve şiddetini doğru bir şekilde ifade edememesi, ağrı yönetiminde yetersiz tedavilere neden olabilir (Rajput, 2020). Bu noktada, AI ve NLP teknolojileri, dilsel farklılıkları anlamada hekimlere yardımcı olabilecek önemli araçlar olarak öne çıkmaktadır (Cui et al., 2020).

1.2.2. Araştırma Probleminin Tanımı

Bu çalışmanın ana araştırma problemi, Türkiye’deki farklı şive ve lehçelerde kullanılan ağrı ifadelerinin anlaşılmasında yaşanan güçlüklerdir. Hastalar, dilsel farklılıklar nedeniyle hekimlere ağrılarını doğru bir şekilde anlatamayabilir ve bu da tedavi sürecini olumsuz etkileyebilir (Yalçınkaya, 2020). Mevcut literatürde, ağrı anlatılarının dilsel farklılıklarını ele alan çalışmalar oldukça sınırlıdır, bu da ağrı yönetiminde evrensel bir dilin oluşturulmasını zorlaştırmaktadır (Onan, 2014).

Bu sorunu çözmek için, NLP ve AI teknikleri kullanılarak farklı şive ve lehçelerdeki ağrı ifadeleri analiz edilecek ve hekimlerin bu farklılıkları daha iyi anlaması sağlanacaktır (Devlin et al., 2019). Bu araştırma, hastaların ağrı deneyimlerini doğru bir şekilde ifade edebilmesini sağlayarak hasta-hekim iletişimini güçlendirmeyi amaçlamaktadır.

1.3. Araştırmanın Amacı

1.3.1 Genel Amaç

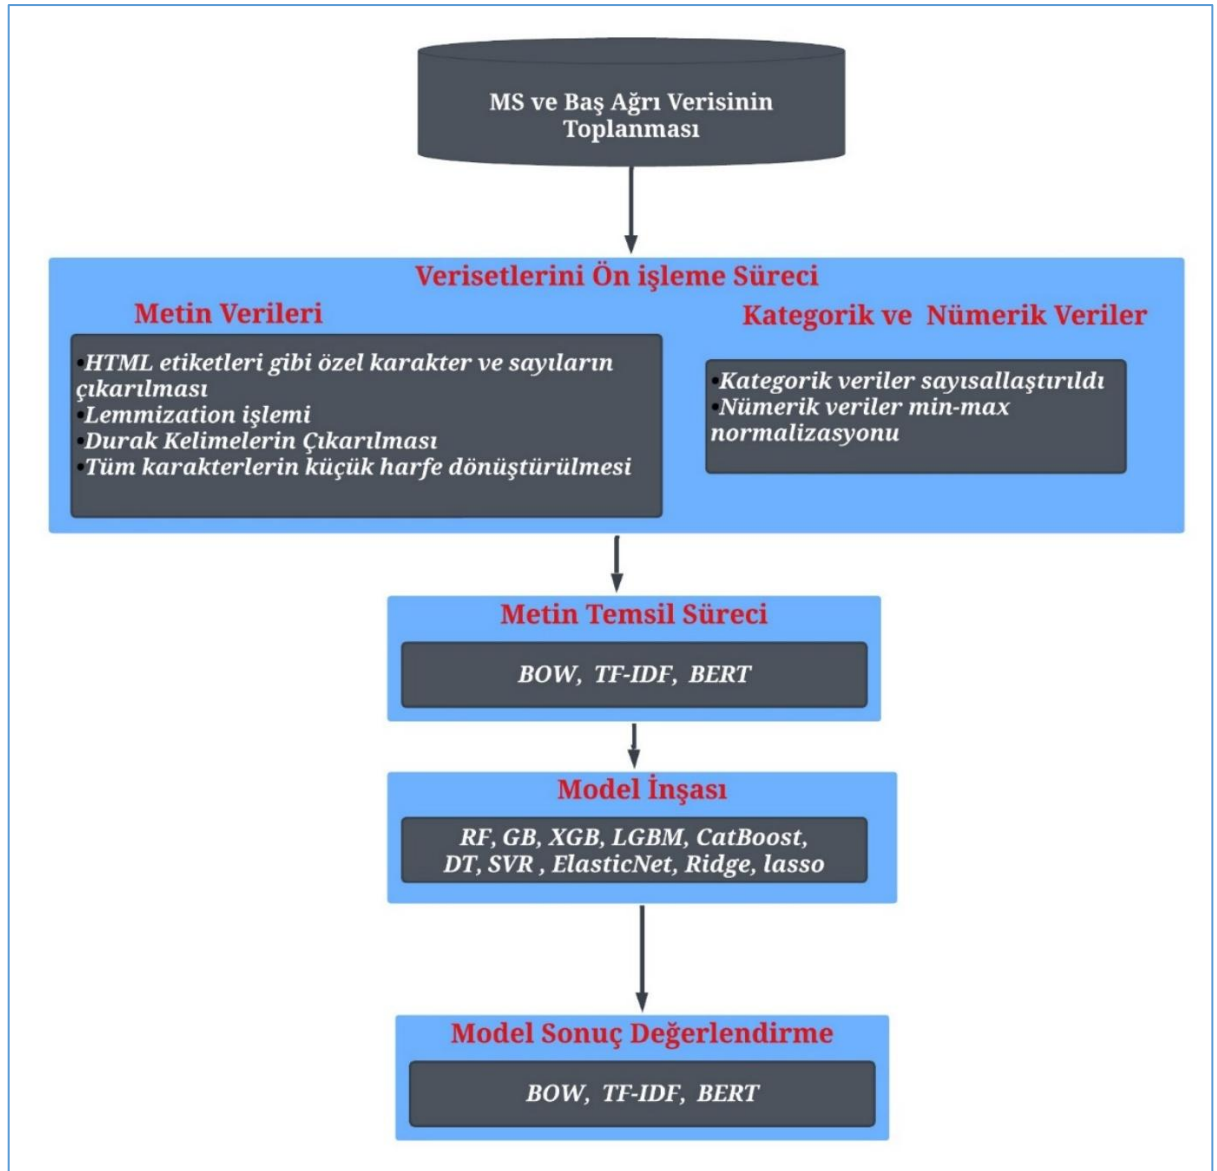
Bu araştırmanın genel amacı, Türkiye’de farklı şive ve lehçelerde kullanılan ağrı ifadelerini analiz ederek, hasta-hekim iletişimde ortaya çıkan dilsel farklılıkların anlaşılmasına katkı sağlamaktır. Özellikle ağrı anlatılarının doğru anlaşılması, teşhis ve tedavi süreçlerini iyileştirebilir. AI ve NLP teknikleri kullanılarak, bu anlatılar üzerinde derinlemesine bir dil analizi yapılacak ve elde edilen veriler evrensel bir ağrı skalası geliştirilmesinde kullanılacaktır (Devlin et al., 2019). Bu amaç, hekimlerin hastalarının ağrılarını daha doğru bir şekilde anlamalarını sağlamak ve hasta-hekim iletişimde ortaya çıkan sorunları gidermek için AI tabanlı bir çözüm geliştirmeyi hedeflemektedir.

1.3.2 Spesifik Amaçlar

Araştırmanın spesifik hedefleri şu şekilde belirlenmiştir:

1. **Farklı şive ve lehçelerde ağrı anlatılarının analiz edilmesi:** Türkiye’deki farklı bölgelerden gelen hastaların ağrı ifadeleri toplanacak ve bu ifadelerin şive ve lehçelere göre nasıl farklılaştığı analiz edilecektir (Wilcox et al., 2015). Bu analiz, NLP yöntemleri kullanılarak yapılacak ve dilsel farklılıklar çıkarılacaktır.
2. **AI ve ML tekniklerinin kullanılması:** Verilerin analizi için yarı süpervize edilmiş ML modelleri kullanılacaktır. Term Frequency Inverse Document Frequency (TF-IDF), Bidirectional Encoder Representations From Transformers (BERT) ve Word2Vec gibi NLP modelleri, ağrı ifadelerinin bağlamsal ve semantik analizini sağlayacaktır.
3. **Evrensel bir ağrı skalası geliştirilmesi:** Farklı bölgelerdeki ağrı ifadelerinin analizinden elde edilen bulgular, evrensel bir ağrı skalası oluşturulmasında kullanılacaktır (Treede, 2018). Bu skala, hekimlerin hastalarının ağrılarını daha iyi anlamalarına ve doğru teşhis koymalarına yardımcı olacak.
4. **Türkçe’nin eklemeli dil yapısının katkısının incelenmesi:** Türkçe’nin eklemeli dil yapısı, ağrı anlatılarının farklı şive ve lehçelerde nasıl yapılandığını anlamak için analiz edilecektir (Onan, 2014). Bu analiz, eklemeli dillerin yapısal avantaj ve dezavantajlarını bize gösterecektir.
5. **Hasta-hekim iletişiminin güçlendirilmesi:** Geliştirilen ağrı skalası, farklı şive ve lehçelerde konuşan hastalarla çalışan hekimlerin, hasta şikayetlerini daha iyi anlamasına yardımcı olacak bir araç olarak kullanılacaktır (Rajput, 2020).

Tezin akış diyagramı Şekil 1’de verilmiştir



Şekil 1: Tez Akış Diyagramı

2. ÇALIŞMADA KULLANILAN MATERYALLER VE YÖNTEMLER

Bu araştırmada, Türkiye'nin farklı bölgelerinden gelen hastalardan toplanacak ağrı anlatıları, AI, NLP ve ML yöntemleri kullanılarak analiz edilecektir. Araştırmanın amacı, farklı şive ve lehçelerde kullanılan ağrı ifadelerinin nasıl değiştiğini anlamak ve ağrı değerlendirmelerinde hekimlerin bu ifadeleri daha doğru bir şekilde anlamalarını sağlamaktır. Veriler, dört farklı hastalık grubundan toplanacak olup, her hastalık grubu için uygun ağrı ve ağrı eşiği ölçekleri kullanılacaktır. Toplanan veriler, daha sonra NLP, ML ve DL teknikleri ile analiz edilecektir.

2.1 Veri Toplama

Dört farklı hastalık grubundan toplamda en az 200 hasta ile çalışılacaktır ve her hastadan en az 12 kelimelik ağrı anlatıları toplanmıştır. Bu ağrı anlatıları toplanırken 9 soruluk bir demografik bilgi formu oluşturulmuş olup, analizler bu formun cevapları ile AI kullanılarak skorların tahmin edilebilir olmasına dayanmaktadır. Veri toplama formunun demografik bölümü, katılımcıların yaş, cinsiyet (Erkek / Kadın / Diğer), en son mezun olunan okul düzeyi (okur-yazarlıktan doktora derecesine kadar sekiz kategori), mevcut ikamet ili, büyüdükleri il ve Türkçenin ana dil mi yoksa ikinci dil mi olduğu; ikinci dilse ne zaman öğrenildiği bilgilerini içerecek biçimde düzenlenmiştir. Çalışmanın MS, Fibromyalji, Epilepsi gruplarında ayrıca “Kronik hastalığınız var mı? Varsa lütfen belirtiniz” maddesi yer almakta, ancak baş-ağrısı grubunda bu soru bilinçli olarak çıkarılmıştır. Bunun gerekçesi, saf baş-ağrısı semptomunu altta yatan kronik tanılara dair önyargı oluşturmaktan betimleyip betimleyemeyeceğimizi araştırmak ve kronik hastalık bilgisinin ifade üzerindeki olası beklenti yanlılığını en aza indirmektir.

Formun ikinci bölümünde katılımcılardan ağrılarını **en az dört betimleyici sözcük**le ve **iki serbest cümle**yle nitel olarak açıklamaları istenmiş; ardından ağrının **süresi** (“6 aydan kısa” / “6 aydan uzun”) ve **şiddeti**, 1 = “dikkate alınmayacak derecede hafif” ile 10 = “dayanılmaz” aralığındaki sayısal derecelendirme cetveli ile nicel olarak kaydedilmiştir. Bu bütüncül tasarım, sosyodemografik arka planla dilsel ve sayısal ağrı betimlemelerini birlikte değerlendirerek semptom algısının kültürel-dilsel belirleyicilerden bağımsız olarak incelenmesini hedeflemektedir.

Bu anlatılar, ağrının karakteristiği (örneğin, yanıcı, batıcı, kesici), süresi (6 aydan uzun veya kısa olması) ve şiddeti (1-10 arası derecelendirme) gibi bilgileri içerecektir. Ayrıca, **Ağrı Eşiği Ölçeği (Pain Sensitivity Questionnaire - PSQ)** ile her hastanın ağrı eşiği de değerlendirilecektir (Ankaralı et al., 2017). Bu ölçek, hastaların ağrıya karşı duyarlılıklarını ve ağrı eşiğini ölçen 8 maddeden oluşur ve farklı vücut bölgelerinde ağrıya duyarlılığı ölçmek için kullanılır. Her hastalık grubu için ayrıca aşağıdaki spesifik ağrı ölçekleri kullanılacaktır:

2.1.1 Başağrısı İlişkili Durumlar (Ölçek: Henry Ford Başağrısı Ölçeği-HFDI)

Baş ağrısı ilişkili durumlar (migren gibi) için **Henry Ford Baş ağrısı Ölçeği** kullanılacaktır. Bu ölçek, baş ağrısı yaşayan hastaların ağrı türlerini, sıklığını, şiddetini ve bu ağrıların günlük yaşam üzerindeki etkisini ölçmek için geliştirilmiştir (Kılınç vd., 2024). Migren gibi baş ağrısı hastalarında, bu ölçek ağrının sıklığı, tetikleyici faktörler ve ağrı şiddeti hakkında kapsamlı bilgi sağlar. HFDI total skoru ile de hastaların ağrısı güncel vizitler arası takip edilebilir. Bu veri, baş ağrısının tedavisine yön vermek ve hasta-hekim iletişimini güçlendirmek için kullanılacaktır.

2.1.2 Fibromyalji (Ölçek: Fibromyalji Survey Diagnostic Criteria - FSDC)

Fibromyalji, kronik yaygın ağrılar ve diğer semptomlarla (yorgunluk, uyku bozuklukları vb.) karakterize edilen bir hastalıktır. **Fibromyalji Survey Diagnostic Criteria (FSDC)**, fibromyalji hastalarının vücutlarının hangi bölgelerinde ağrı hissettiklerini ve bu ağrıların şiddetini değerlendiren güvenilir bir ölçektir (Yanmaz vd., 2016). Bu ölçek aynı zamanda, hastaların yaygın

ağrılarının yaşam kalitesine etkisini ve fibromyaljiye özgü diğer semptomları değerlendirmek için kullanılır. Fibromyalji hastalarından elde edilen bu veriler, NLP ve ML yöntemleri ile analiz edilerek, ağrı anlatılarındaki dilsel çeşitlilikler anlaşılabilecektir. Anketin total skoru ile de hastaların tanı ve sonrasında takibi sağlanabilir. FSDC ölçeğinin ilk alt skoru **Widespread Pain Index (WPI)** olup, hastanın son haftada ağrı hissettiği 19 anatomik bölgeyi sayarak 0-19 aralığında yaygın ağrı düzeyini gösterir. İkinci alt skor **Symptom Severity Scale (SSS)** ise yorgunluk, dinlenmemiş uyanma, bilişsel güçlükler ile eşlik eden somatik yakınmaların her birini 0-3 puanlayıp toplam 0-12 arasında ölçek; **SS1**, hastanın son haftadaki yorgunluk, dinlenmemiş uyanma ve bilişsel güçlük düzeylerini her birini 0-3 arasında puanlayıp toplar; böylece çekirdek semptom şiddetini 0-9 aralığında özetler. **SS2** ise son 6 ayda görülen baş ağrısı, alt karın ağrısı/kramp ve depresyon gibi eşlik eden somatik yakınmaların sayısına göre 0-3 puan verir ve SS1 ile birleşerek SSS toplamını 0-12'ye tamamlar. SSS ve WPI skor toplanarak 0-31 aralığında FSDC toplam puanı elde edilir.

2.1.3. MS (Ölçek: McGill Ağrı Ölçeği)

MS gibi nöroimmünolojik hastalıklarda ağrı, sinir hasarına bağlı olarak ortaya çıkabilir ve bu ağrıların değerlendirilmesi için McGill Ağrı Ölçeği kullanılmaktadır. Bu ölçek, ağrıyı duygusal, duygusal ve bilişsel boyutlarda inceleyerek, ağrının niteliğini (yanıcı, kesici, batıcı vb.), yoğunluğunu ve süresini ölçek (Yakut vd., 2022). MS hastalarında özellikle sinir kaynaklı ağrıların anlaşılması için bu ölçek kullanılır ve hastaların ağrı deneyimlerinin dilsel farklılıkları bu ölçekle birlikte değerlendirilecektir.

Şu ana kadar yapılan akademik çalışmalarda McGill Pain Questionnaire (MPQ) veya Short-Form McGill Pain Questionnaire (SF-MPQ)'nin doğrudan MS hastalarında geçerlik ve güvenilirlik analizlerine dair özgül bir çalışma bulunmamaktadır. Ancak genel olarak nöropatik ağrıyı değerlendirmek üzere geliştirilmiş versiyonları (örneğin SF-MPQ-2), farklı kültürlerde nöropatik ve kronik ağrı popülasyonlarında (örneğin diyabetik nöropati, bel ağrısı, kanser) yaygın olarak kullanılmakta ve güvenilir sonuçlar vermektedir (Maruo et al., 2014); (Adelmanesh et al., 2012). Hastalarda PRI skoru ile hastaların farklı ağrı tanımlarının ortalama şiddeti, PPI ile de o anki ağrı şiddetini genel olarak görmeyi sağlamaktadır.

2.1.4 Epilepsi (Ölçek: Brief Pain Inventory - BPI)

Epilepsi hastalarında kullanılacak olan **Brief Pain Inventory (BPI)**, hastaların nöbetler dışındaki ağrılarını ve bu ağrıların günlük işlevselliklerine olan etkisini ölçek (Balta vd., 2022). Epilepsi hastalarında ağrı, genellikle nörolojik bozukluklara bağlıdır ve BPI, ağrı şiddeti, ağrının sıklığı ve bu ağrıların yaşam kalitesi üzerindeki etkisini analiz eden bir ölçektir. Bu ölçek sayesinde, epilepsi hastalarının ağrı deneyimlerinin dilsel farklılıkları daha iyi anlaşılacağı öngörülmektedir. BPI ortalama skoru hastaların genel ağrıların şiddetinin ortalamasını alıp çoklu ölçümlerde takipte kullanılmaktadır.

Epilepsi hastalarında ağrı değerlendirmesi literatürde oldukça sınırlı yer bulmakta olup, Brief Pain Inventory (BPI) gibi yaygın kullanılan ağrı ölçeklerinin bu hasta grubunda geçerlik ve güvenilirlik analizlerine dair doğrudan bir çalışma bulunmamaktadır. Bununla birlikte, BPI'nin farklı kronik ağrı türlerinde—özellikle nöropatik, bel ağrısı, fibromyalji ve postoperatif ağrılar gibi durumlarda—yüksek iç tutarlılık ve yapı geçerliği ile güvenilir bir ölçüm aracı olarak kullanıldığı pek çok çalışmada bildirilmiştir (Ferreira et al., 2023); (Keller et al., 2004). Özellikle nöropatik ağrıya benzer şekilde değişken ve yaygın bir ağrı profiline sahip olan KOAH ve fibromyalji hastalarında BPI, hem ağrı şiddeti hem de günlük yaşam üzerindeki etkilerini kapsamlı biçimde değerlendirmesi sayesinde avantaj sağlamaktadır (Chen et al., 2018). Bu bağlamda, epilepsi hastalarında ağrının sıklıkla postiktal dönemde, lokalize kas veya baş ağrısı şeklinde ortaya çıkması ve değişkenlik göstermesi göz önünde bulundurulduğunda, BPI gibi çok boyutlu ve esnek ağrı

değerlendirme araçlarının bu grup için uyarlanarak kullanılması, literatürde geçerlik verisi olmamasına rağmen makul bir yaklaşım olarak değerlendirilebilir.


2.2 Analiz Yöntemleri (Analysis Methods)

Toplanan veriler, NLP süreçlerinden sonra ML ve Karma öğrenme teknikleri ile analiz edilmiştir. Bu yöntemlerin her biri, farklı ağırlık ifadelerinin dilsel yapılarını analiz etmek ve sınıflandırmak için kullanılacaktır. Aşağıda bu yöntemler detaylı şekilde açıklanmıştır.

2.2.1 Doğal Dil İşleme Yöntemleri

2.2.1.1 Term Frequency-Inverse Document Frequency


Term Frequency- Inverse Document Frequency (TF-IDF), metin içinde kelimelerin önemini belirlemek için kullanılan bir tekniktir (Salton & Buckley, 1988). Kelimenin bir metinde ne kadar sık geçtiğini (TF) ve bu kelimenin diğer metinlerde ne kadar nadir olduğunu (IDF) hesaplayarak kelimenin önemini belirler. Bu çalışma kapsamında, farklı şive ve lehçelerde kullanılan ağırlık terimlerinin sıklığı ve bu terimlerin özgünlüğü TF-IDF yöntemi ile analiz edilecektir (Ramos, 2003). Bu sayede, ağırlık ifadelerinde kullanılan önemli terimlerin bölgesel farklılıkları ortaya çıkarılacaktır.



Şekil 2: TF-IDF Çalışma Mekanizması

2.2.1.2. Bag of Words

Bag of Words (BoW) modeli, metinleri analiz etmek için kullanılan en temel temsil yöntemlerinden biridir. Bu modelde her belge, içindeki kelimelerin frekansına göre bir vektör olarak temsil edilir ve kelime sırası dikkate alınmaz (Yan et al., 2020). BoW modeli, metinlerin istatistiksel özelliklerini basitçe yakalarken bağlamsal ve anlamsal ilişkileri göz ardı eder. Bu çalışmada, farklı şive ve lehçelerdeki ağır ifadelerinin kelime bazlı frekans dağılımları dikkate alınır.



Şekil 3: BoW Çalışma Mekanizması

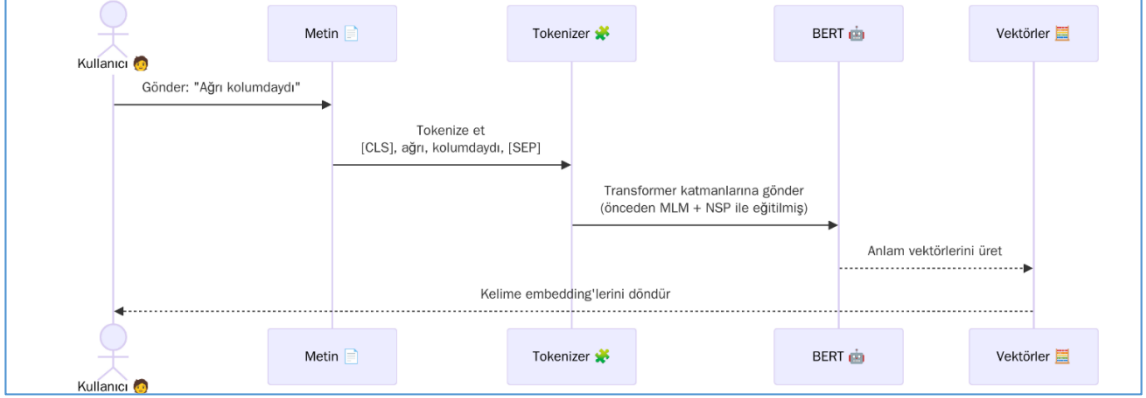
BoW yöntemiyle analiz edilerek, bölgeler arası ortak ve ayırt edici kelimeler ortaya konacaktır (Rekhi, 2023). Şekil 2’de BoW’un çalışma mekanizması verilmiştir.

2.2.1.3 BERT

BERT, NLP alanında bağlamsal kelime temsilleri üreten güçlü bir modeldir (Devlin et al., 2019). Modelin temelinde, kelimelerin hem sol hem sağ bağlamdan eşzamanlı olarak öğrenildiği çift yönlü bir transformer mimarisi bulunur. Bu yapı sayesinde BERT, kelimenin metin içindeki anlamını bağlama göre daha isabetli şekilde belirleyebilir.


BERT iki aşamalı bir eğitim sürecine sahiptir:

1. **Pre-trained (Önceden Eğitilmiş):** BERT, büyük ölçekli metin veri kümeleri (örneğin Wikipedia, kitaplar) üzerinde genel dil özelliklerini öğrenmek için önceden eğitilir. Bu süreçte kullanılan Masked Language Modeling (MLM) ve Next Sentence Prediction (NSP) görevleriyle model, temel dil bilgisini ve cümleler arası ilişkiyi öğrenir (Buche, 2020).



Şekil 4: Pre-Trained BERT Çalışma Mekanizması

Fine-tuning (Özelleştirilmiş Eğitim): Önceden eğitilmiş BERT, hedef görev (örneğin duygu analizi, metin sınıflandırma, soru-cevap) için daha küçük veri kümeleri üzerinde yeniden eğitilir. Bu süreçte modelin parametreleri, görev spesifik özellikleri öğrenmek üzere güncellenir (Sun et al., 2019). Şekil 5'te Fine-tuned BERT'in çalışma mekanizması verilmiştir.



Şekil 5: Fine Tuned BERT Çalışma Mekanizması


Bu çalışmada, farklı bölgesel ağrı terimlerinin bağlam içindeki kullanım biçimleri, BERT'in sunduğu pre-trained bilgi ve fine-tuning kabiliyeti ile analiz edilecektir. Böylece sadece kelime sıklığı değil, kelimenin semantik yapısı da değerlendirilebilecektir (Garrido-Merchán et al., 2023).

2.2.2. Makine Öğrenmesi Ensemble Learning Modelleri

2.2.2.1. Destek Vektör Regresyonu (Support Vector Regression)

Destek Vektör Regresyonu (SVR) modeli, hata sınırı içinde kalan tahminlere izin verirken, bu sınırı aşan hataları en aza indirmeye çalışır. Bu sayede model, verideki küçük dalgalanmalara karşı dayanıklı olur. Sınır çizgileri (margin) ve "destek vektörleri" yardımıyla tahminler yapılır. Ağırlığın bireyden bireye farklılık gösterebildiği durumlarda oldukça etkilidir. Ancak parametre ayarlarının


dikkatli yapılması gerekir, aksi halde yavaş çalışabilir veya başarısı düşebilir. Klinik veriler gibi karmaşık ve doğrusal olmayan yapılarda SVR başarılı sonuçlar verebilir (Zelege et al., 2023).



Şekil 6: Support Vector Regresyon Çalışma Modeli

2.2.2.2. K En Yakın Komşu (K-Nearest Neighbors)


K-Nearest Neighbors (KNN) algoritması, yeni bir hastanın ağrı düzeyini, benzer özelliklere sahip geçmişteki hastalara bakarak belirler. En yakın komşunun ortalaması alınarak tahmin yapılır. Bu yöntem, model eğitimi gerektirmez; veriye doğrudan bakar. Bu nedenle küçük veri setlerinde iyi çalışırken, büyük veri setlerinde yavaşlayabilir. Ayrıca tüm değişkenlerin benzerlik ölçümüne eşit katkı vermesi, bazı klinik değişkenlerin etkisini azaltabilir. Yorumlaması ve görselleştirmesi kolay olduğu için klinik ortamlarda anlaşılması rahattır (Li & Wu, 2023). Şekil 7’de KNN çalışma algoritması verilmiştir.



Şekil 7: KNN Çalışma Algoritması

2.2.2.3. Ridge Regression

Ridge regresyonu, çok sayıda değişkenle çalışırken “ceza terimi” (L2 regularization) ekleyerek aşırı öğrenmeyi önler. Ceza terimi, katsayıları sıfıra değil ama daha küçük değerlere çeker. Bu sayede model, hem tüm değişkenleri kullanır hem de genelleme kabiliyetini korur. Özellikle değişkenler arasında yüksek ilişki (multicollinearity) varsa tercih edilir. Sağlık verilerinde çoklu laboratuvar değişkenlerinin birlikte kullanılması gibi durumlarda idealdir (Omer, 2020).



Şekil 8: Ridge ve Lasso Regresyon Çalışma Algoritması

2.2.2.4. Lasso Regresyon


Lasso modeli, “ceza terimi” olarak L1 kullanır ve bazı katsayıları sıfıra indirerek değişkenleri tamamen dışlar. Böylece yalnızca anlamlı olan değişkenleri modele dahil eder, yorumlanabilirliği artırır. Değişken seçimi gereken tıbbi çalışmalarda sıkça tercih edilir. Ancak bazı önemli değişkenleri de eleyebilir, bu nedenle dikkatli uygulanmalıdır. L1 cezası sayesinde daha sade ama etkili modeller üretilebilir (Modak et al., 2018).

2.2.2.5. ElasticNet Regresyon

ElasticNet, L1 ve L2 ceza terimlerini birleştirerek hem değişken seçimi yapar hem de genelleme gücü sağlar. Özellikle birbirine çok benzeyen (korelasyonlu) değişkenlerin bulunduğu sağlık verilerinde başarıyla kullanılır. Bu model sayesinde hem sadeleştirme yapılabilir hem de öğrenilen yapılar güvenilir kalır. Örneğin hemogram, biyokimya ve fiziksel semptomların bir arada değerlendirildiği ağrı tahminlerinde oldukça etkilidir (Fang et al., 2023).

2.2.2.6. Karar Ağacı (Decision Tree) Regresyon


Karar Ağacı (DT), verileri ardışık if-else kurallarıyla bölerek tahmin yapar. Örneğin “yaşı 50’nin üzerinde olan ve şikayet süresi uzun olan hastaların ağrı düzeyi yüksek olabilir” gibi yapılar kurar. Modelin görsel olarak anlaşılması ve açıklanması kolaydır. Ancak tek başına kullanıldığında veri ezberleme (overfitting) riski yüksektir. Bu nedenle genellikle topluluk modellerle desteklenir (Cutler, 2018). Şekil 9’da DT çalışma algoritması verilmiştir.



Şekil 9: DT Regresyon Modeli

2.2.2.7. Rastgele Orman (Random Forest) Regresyon


Random Forest (RF), birçok karar ağacının tahminlerini birleştirerek daha dengeli sonuçlar üretir. Ağaçlar, verinin farklı alt kümeleriyle eğitilir ve çeşitlilik sağlanır. Bu yöntem aşırı öğrenmeyi azaltır ve tahmin güvenilirliğini artırır. Değişken önemini ölçebilmesi sayesinde ağırlığı etkileyen faktörlerin sıralanmasında da faydalıdır. Tıbbi çalışmalarda sık tercih edilen güçlü ve esnek bir modeldir (Liu et al., 2023). Şekil 10'da RF çalışma algoritması verilmiştir.



Şekil 10: RF Regresyon Çalışma Modeli

2.2.2.8. Gradient Boosting Regresyon


Gradient Boosting (GBR), her yeni ağacı önceki modelin yaptığı hataları düzeltmek üzere eğitir. Bu zincirleme öğrenme süreci, oldukça hassas ve güçlü tahminler sağlar. Ancak model karmaşık hale gelebilir ve parametre ayarları kritiktir. Ağrı gibi kişisel ve değişkenliği yüksek çıktılar için uygundur. Literatürde duyarlılığı yüksek tıbbi tahmin sistemlerinde kullanılmaktadır (Maabreh & Almasabha, 2023). Şekil 11'de GBR çalışma algoritması verilmiştir.



Şekil 11: GBR Çalışma Modeli

2.2.2.9. Extreme Gradient Boosting Regresyon


XGBoost, Gradient Boosting'in daha hızlı, optimize edilmiş ve aşırı öğrenmeye karşı dirençli versiyonudur. İçerdiği düzenleme (regularization) yapıları sayesinde model karmaşıklığı dengede tutulur. Hızlı çalışır ve büyük veri setlerinde bile yüksek doğruluk sağlar. Eksik veri veya kategorik değişkenlerle başa çıkabilir. Klinik karar destek sistemlerinde yoğun olarak tercih edilir (İbrahim et al., 2023). Şekil 12'de XGBoost çalışma algoritması verilmiştir.



Şekil 12: XGBoost Çalışma Modeli

2.2.2.10. LightGBM


LightGBM, boosting yöntemlerinin daha hafif ve hızlı çalışan bir versiyonudur. Çok sayıda hasta verisini kısa sürede analiz edebilir. Özellikle eksik verileri işleyebilme ve kategorik değişkenleri otomatik tanıma kabiliyeti ile dikkat çeker. Klinik ortamlarda gerçek zamanlı uygulamalarda kullanılabilecek kadar hızlıdır. Yüksek doğruluk, düşük işlem süresi arayan projelerde idealdir (Kumar et al., 2023).



Şekil 13: Light GBM Çalışma Modeli

2.2.2.11. CatBoost


CatBoost, özellikle kategorik değişkenleri otomatik olarak işleyebilme becerisi ile ön plana çıkar. Diğer boosting modelleri gibi çalışır ama ön işleme ihtiyacını azaltır. Eksik veri veya düzensiz veri yapılarında dayanıklıdır. Klinik uygulamalarda çok sayıda kategorik değişken (cinsiyet, şikayet türü, meslek vb.) olduğunda avantaj sağlar. Hızlı öğrenir, aşırı öğrenmeye karşı korumalıdır. Tıbbi uygulamalarda güvenilir sonuçlar üretir (Kookalani et al., 2022).



Şekil 14: Catboost Çalışma Modeli

2.2.2.12. Extra Tree Regresyon

Extra Trees (Extremely Randomized Trees-ET) algoritması, karar ağaçları temelli bir topluluk yöntemidir ve hem sınıflandırma hem de regresyon problemlerinde güçlü performans sergilemesiyle dikkat çeker. Diğer ağaç tabanlı algoritmalarından farklı olarak, ET hem özellik seçiminde hem de bölme noktalarının belirlenmesinde rastgeleliği en üst düzeye çıkarır. Bu rastgelelik, modelin varyansını azaltır ve aşırı uyumu engellemeye yardımcı olur. Geurts ve arkadaşları tarafından geliştirilen özgün yaklaşımda, modelin hesaplama verimliliği ve yüksek doğruluğu öne çıkarken, parametrik olmayan doğası sayesinde çok boyutlu ve karmaşık veri yapılarıyla rahatlıkla çalışabilir (Geurts et al., 2006).



Şekil 15: ET Regresyon Çalışma Modeli

2.2.3.Derin Öğrenme

2.2.3.1. Yapay Sinir Ağları (Artificial Neural Network)

Yapay Sinir Ağları (ANN), insan beyninden ilham alınarak geliştirilen çok katmanlı öğrenme sistemleridir. Model, hasta özelliklerini giriş olarak alır ve ağ içindeki nöronlar aracılığıyla bir tahmin üretir. Her katmandaki "nöronlar", girdileri ağırlıklandırarak bir sonraki katmana iletir. Bu şekilde, ağrı şiddeti gibi sayısal çıktılar tahmin edilebilir. ANN'ler özellikle veri miktarı yeterliyse karmaşık ilişkileri öğrenebilir. Ancak tüm değişkenler arasında doğrudan bağ kurduğundan, zaman boyutu gibi sırayla ilgili verileri yorumlamakta sınırlıdır. Çalışmalarda ANN'ler, bel ağrısı (Sancar et al., 2018) ve glokom risk tahmini (Huang et al., 2021) gibi çeşitli tıbbi çıktılarda başarıyla uygulanmıştır.

2.2.3.2. Evrimsel Sinir Ağları (Convolutional Neural Network)

Evrimsel Sinir Ağları (CNN), verilerdeki "desenleri" ve "özellikleri" tanımda çok başarılıdır; genellikle görüntü işleme ve sinyal analizinde kullanılır. Ancak ağrı tahmini gibi sayısal çıktılar için de kullanılabilir çünkü verinin içindeki anlamlı örüntüleri yakalar. CNN, giriş verisini küçük parçalara bölerek (filtreler) işler ve önemli bölgeleri tanır. Özellikle vücut sinyalleri (örneğin EMG, EEG) ya da görsel veri (örneğin yüz ifadesi) içeren çalışmalarda etkilidir (El Morabit et al., 2021). Yapay sinir ağlarına göre daha az parametre ile daha yüksek doğruluk sunabilir. CNN tabanlı sistemler, yüz ifadelerinden ağrı düzeyi tahmininde başarıyla kullanılmıştır (Wang et al., 2017).

2.2.3.3. Öz Yinelemeli Sinir Ağları (Recurrent Neural Network)

Öz Yinelemeli Sinir Ağları (RNN), özellikle zaman serisi veya sıralı veriyle çalışmak için geliştirilmiştir. Bu modelde her adımda sadece giriş değil, bir önceki adımın çıktısı da dikkate alınır. Böylece, örneğin bir hastanın ağrı seviyesinin günlere göre değişimini öğrenebilir. Klinik verilerin zaman içindeki değişimini analiz etmede idealdir. Standart RNN'ler kısa süreli hafızaya sahiptir; bu nedenle uzun dönemli ilişkilerde uzun kısa süreli bellek birimleri (Long Short Term Memory-LSTM) veya Tekarlayan Kapı Geçidi (Gated Recurrent Unit-GRU) gibi gelişmiş versiyonları tercih edilir. Literatürde RNN tabanlı modeller, fizyolojik sinyallerden ağrı düzeyi tahmini için etkili bulunmuştur (Wang et al., 2020).

2.2.4.Açıklanabilir Yapay Zeka

Açıklanabilir Yapay Zeka (Explainable AI - XAI), özellikle AI ve ML modellerinin giderek daha karmaşık hale gelmesi ve bu modellerin "kara kutu" (black-box) olarak nitelendirilmesi nedeniyle önemli bir kavram olarak ortaya çıkmıştır. AI sistemleri, son yıllarda sağlık, finans ve otomotiv gibi kritik alanlarda karar vermede geniş ölçüde kullanılır hale gelmiştir, ancak bu sistemlerin nasıl çalıştığı, verdikleri kararların arkasındaki mekanizmalar çoğu zaman anlaşılması zor bir yapıda olabilir. XAI, bu modellerin şeffaflığını artırmak ve kullanıcıların bir AI sisteminin neden belirli kararlar aldığını anlayabilmesi için geliştirilmiştir. Bu sayede, AI sistemlerinin kullanım alanları genişlerken, aynı zamanda güven oluşturulması ve yasal düzenlemelere uyumun sağlanması hedeflenmektedir (Liao et al., 2020).

XAI sistemlerinin geliştirilmesinde dört temel prensip öne çıkar: açıklama, anlaşılabilirlik, açıklama doğruluğu ve bilgi sınırları. Bir AI sistemi, kararlarının gerekçelerini anlamlı bir

şekilde sunmalı, bu açıklamalar kullanıcılar için anlaşılabilir olmalı ve verilen açıklamalar sistemin karar mekanizmalarını doğru bir şekilde yansıtmalıdır. Ayrıca, sistemler yalnızca belirli koşullar altında ve yeterli güven seviyesine ulaştığında çalışmalıdır. Bu prensipler, özellikle sağlık, otonom araçlar ve finansal hizmetler gibi yüksek risk taşıyan alanlarda AI sistemlerinin güvenli kullanımını sağlamak amacıyla geliştirilmektedir (Phillips et al., 2020).

XAI'nin tarihsel gelişimi incelendiğinde, bu kavramın aslında 1960'lı yıllardan itibaren AI sistemlerinde yer aldığı görülmektedir. İlk dönemlerde bilgi tabanlı uzman sistemlerle ortaya çıkan açıklanabilirlik ihtiyacı, özellikle DL gibi daha karmaşık ve istatistiksel yaklaşımların yaygınlaşmasıyla yeniden gündeme gelmiştir. Bu gelişim, kullanıcıların güvenini kazanmak için algoritmaların iç işleyişi hakkında şeffaf bilgi sunulmasını zorunlu hale getirmiştir (Confalonieri et al., 2020).

XAI'nin geliştirilmesindeki en büyük zorluklardan biri, hem yüksek performanslı hem de insan tarafından anlaşılabilir AI sistemleri inşa edebilmektir. DL algoritmaları gibi güçlü tahmin modelleri, genellikle milyonlarca parametreye dayalı olarak çalıştığı için bu tür sistemlerin açıklanabilirliğini sağlamak karmaşıktır. Bu noktada, XAI teknikleri kullanılarak algoritmaların kararlarının izlenebilirliği sağlanmakta ve bu da model şeffaflığını artırmaktadır. Bu teknikler, AI sistemlerinin daha geniş kitleler tarafından benimsenmesini kolaylaştırmakta ve kritik karar süreçlerinde güven tesis etmektedir (Chia, 2023).

Son yıllarda XAI uygulamalarında öne çıkan yöntemlerden biri de SHAP (SHapley Additive exPlanations) olmuştur. SHAP, her bir değişkenin model çıktısına olan katkısını oyun teorisine dayalı olarak hesaplayan bir yaklaşımdır ve bu yönüyle model kararlarının şeffaf ve tutarlı biçimde yorumlanmasını mümkün kılar. Sağlık alanında yapılan güncel araştırmalar, SHAP'ın bireysel hasta bazında tahmin açıklamaları sunarak klinik karar süreçlerinde güveni artırdığını göstermektedir (Lee et al., 2024). Özellikle karmaşık makine öğrenimi modellerinde, kararların hangi klinik özelliklerden ne ölçüde etkilendiğinin görselleştirilebilir hale gelmesi, hem klinisyenlerin modeli anlamasını kolaylaştırmakta hem de etik sorumluluk açısından şeffaflık sağlamaktadır (Mujawar et al., 2024). Ayrıca SHAP, hem bireysel tahminlerin lokal olarak açıklanmasında hem de modelin genel işleyişinin global düzeyde analizinde etkili olduğu için, yapay zekâ sistemlerinin güvenilirliğini artıran bütüncül bir açıklama yöntemi olarak değerlendirilmektedir (Zahoor et al., 2023).

2.3 Ölçme Değerlendirme ve İstatistiksel Analiz

Bu çalışmada kullanılacak modellerin doğruluğu, duyarlılığı ve özgüllüğü değerlendirilecektir. R-Square (R^2), Mean Square Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentange Error (MAPE) gibi metrikler ile performans ölçümleri yapılacaktır (Hanley & McNeil, 1982). Tüm analizler, elde edilen veriler üzerinde yapılacak ve dilsel çeşitliliklerin tıbbi süreçlere etkisi kapsamlı bir şekilde incelenecektir.

2.3.1. Belirleme Katsayısı:

R^2 , bir regresyon modelinin bağımlı değişkeni ne kadar iyi açıkladığını ölçen bir metriktir. 1'e yaklaştıkça modelin tahminlerinin gerçek verilere olan yakınlığı artar; 0'a yaklaştıkça

açıklama gücü düşer. R^2 , özellikle farklı modellerin genel açıklayıcılığını karşılaştırmak için kullanışlıdır (Chicco et al., 2021)

2.3.2.Ortalama Kare Hata:

MSE, tahmin edilen ve gerçek değerler arasındaki farkların karesinin ortalamasıdır ve büyük hatalara karşı daha duyarlıdır. Düşük MSE değeri, modelin tahminlerinin genel olarak doğru olduğunu gösterir. Özellikle sürekli verilerde modelin genel hata seviyesini yansıtmak için sıkça kullanılır (Chen et al., 2022); (Liu et al., 2025).

2.3.3. Ortalama Mutlak Hata:

MAE, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasıdır ve yorumlaması kolaydır. Diğer hata metriklerine göre daha az sapmaya duyarlıdır ve tahmin hatalarının ortalama büyüklüğünü gösterir. Uygulamalarda, modelin genelde ne kadar yanlış olduğunu sade bir şekilde ifade eder (Djellouli et al., 2023); (Tran et al., 2024).

2.3.4. Ortalama Mutlak Yüzde Hata:

MAPE, tahmin hatalarının yüzdelik oranını verir ve farklı ölçekteki veriler arasında karşılaştırma yapmaya olanak tanır. Ancak sıfıra yakın gerçek değerlerde yüksek hata payı verebilir. Buna rağmen, iş dünyasında ve uygulamalı regresyon analizlerinde sık tercih edilir çünkü yorumlaması kolaydır (Airlangga, 2024); (Vadavadagi et al., 2024).

Ağrının şiddeti genellikle 0–10 arası sayısal ölçeklerle ölçüldüğü için, bu tür veriler sürekli (sürengen) özellik taşır ve bu da problemi doğal olarak bir regresyon problemi yapar. Gelişmiş AI modelleri, özellikle tekrarlayan sinir ağları gibi yapılar, ağrı şiddetini kare kare veya gerçek zamanlı olarak sayısal biçimde tahmin edebilecek regresyon temelli çözümler sunar (Zhou et al., 2016). Bu tür yaklaşımlar, özellikle hasta ifadelerinin nesnelleştirilmesi gereken klinik karar destek sistemlerinde büyük önem taşır.

3. ARAŞTIRMANIN KATKILARI

Bu araştırmanın önemli bilimsel ve pratik katkıları bulunmaktadır. Farklı şive ve lehçelerde kullanılan ağrı anlatılarının analizi, hem dilsel hem de tıbbi açıdan yenilikçi bir çalışma ortaya koyacaktır. Aşağıda bu çalışmanın bilimsel ve pratik katkıları detaylandırılmıştır:

3.1 Bilimsel Katkı

Bu çalışmanın bilimsel katkıları özellikle dil ve tıp alanlarında önemli olacaktır:

- **NLP ve AI Uygulamalarına Katkı:** Bu çalışmada kullanılan **BERT**, **TF-IDF** gibi NLP teknikleri, ağrı anlatılarının anlamlandırılmasında yeni bir uygulama alanı sunmaktadır (Devlin et al., 2019).
- **ML ve Karma Öğrenme Yöntemlerinin Uygulanması:** Bu çalışmada kullanılan **SVM**, **RF**, **RNN** gibi yöntemlerin tıbbi veri analizine uygulanması, özellikle yarı süpervize edilmiş modeller için yeni bir bakış açısı sağlayacaktır (LeCun et al., 2015)

3.2 Pratik Katkı

Bu çalışmanın pratik katkıları şu şekilde özetlenebilir:

- **Evrensel Ağrı Skalası İçin Temel:** Bu çalışma, evrensel bir ağrı skalası geliştirilmesine yönelik algoritmalar ve yöntemler sunarak, dilsel engellerin tedavi süreçlerine etkisini azaltacaktır.
- **Hekim-Hasta İletişimini Geliştirme:** Ağrı ifadelerinin farklılıklarının anlaşılması, hekimlerin hastalarla daha etkili iletişim kurmalarını sağlayacak ve tanı-tedavi süreçlerini iyileştirecektir.
- **Sağlık Kuruluşları İçin Rehber:** Bu çalışma, farklılıkları göz önünde bulundurarak sağlık kuruluşları için bir rehber oluşturacaktır. Bu, hasta memnuniyetini ve hizmet kalitesini artıracaktır.

3.3 Literatüre Katkı

Bu araştırma, dil bilimi ve tıp alanlarında çeşitli yenilikler sunmaktadır. Aşağıda literatüre yapılan katkılar ve yenilikler açıklanmıştır:

3.3.1 Daha Önce Ele Alınmamış Konular

Bu çalışma, şu ana kadar ele alınmamış konulara odaklanmaktadır:

- **NLP ve Tıbbi Veri Analizinin Birleştirilmesi:** Bu çalışma, **BERT** gibi NLP tekniklerini tıbbi veri analizinde kullanarak yeni bir yaklaşım sunmaktadır (Devlin et al., 2019)

3.3.2 Yöntemsel Yenilikler

Bu çalışmada kullanılan yöntemsel yenilikler şunlardır:

- **Ensemble Öğrenme Yöntemlerinin Uygulanması:** **Catboost**, **Ridge**, **Lasso** gibi ensemble öğrenme yöntemlerinin kullanılması, ağrı anlatılarının sınıflandırılmasında doğruluğu artıracaktır (Breiman, 1996).

4. ARAŞTIRMANIN SINIRLILIKLARI

Her araştırmada olduğu gibi, bu çalışmanın da belirli sınırlamaları bulunmaktadır. Bu sınırlamalar, araştırmanın yürütülmesi sürecinde karşılaşılabilecek zorluklar ve veri toplama, dilsel çeşitlilik, coğrafi kapsam ve kullanılan yöntemlerle ilgilidir. Aşağıda bu sınırlamalar ayrıntılı olarak açıklanmıştır.

4.1 Coğrafi ve Dilsel Sınırlılıklar

Bu çalışma, Türkiye sınırları içinde yapılacak olup, Türkiye'nin farklı bölgelerinde konuşulan şive ve lehçelere odaklanmaktadır. Ancak, bu coğrafi odak, araştırmanın bazı sınırlamalarını da beraberinde getirir:

- **Türkçe Konuşanlarla Sınırlı Olma:** Araştırma yalnızca Türkçe konuşan bireylerle sınırlıdır. Türkiye'de yaşayan ancak anadili Türkçe olmayan bireylerin ağrı anlatıları bu araştırmanın dışında kalmaktadır. Bu, Türkiye'deki dilsel çeşitliliğin tam anlamıyla yansıtılmasını sınırlayabilir. Aynı zamanda, Türkçe diline özgü anlatıların derinlemesine incelenmesine odaklanılsa da, diğer dillerin temsil edilmemesi uluslararası düzeyde bir karşılaştırma yapılmasını engeller (Babel, 2010).
- **Şive ve Lehçelerin Temsil Sorunu:** Türkiye'de farklı bölgelerde konuşulan şive ve lehçeler büyük bir çeşitlilik göstermektedir. Ancak, her bölge eşit şekilde temsil edilmeyebilir. Özellikle az bilinen veya daha yerel şivelerden gelen verilerin eksikliği, elde edilen bulguların genelleştirilebilirliğini sınırlayabilir (Clopper&Pisomi,2016). Bu durum, çalışmanın sonuçlarının, büyük ve yaygın konuşulan şivelerle sınırlı kalmasına yol açabilir.
- **Kültürel Farklılıkların Etkisi:** Farklı bölgelerdeki kültürel farklılıklar, ağrı anlatılarının ve ağrı deneyimlerinin şekillenmesinde önemli bir rol oynayabilir. Ancak, bu çalışmada kültürel etkenler tam anlamıyla kontrol edilemeyebilir. Özellikle sosyo-kültürel arka planın ağrı deneyimi üzerindeki etkisi tam olarak ele alınmayabilir (Kleinman, 1988). Bu da, bazı önemli kültürel bağlamların göz ardı edilmesine yol açabilir.

4.2 Veri Toplama ile İlgili Sınırlılıklar

Veri toplama sürecinde karşılaşılabilecek sınırlamalar ve zorluklar şu şekilde özetlenebilir:

- **Veri Setinin Heterojenliği:** Toplanan ağrı anlatıları, kişisel deneyimlere dayanacağı için oldukça heterojen olabilir. Ağrı subjektif bir deneyimdir ve her bireyin ağrını farklı şekillerde ifade etmesi mümkündür (Melzack & Wall, 1984). Bu durum, veri analizi sürecinde belirli zorluklar yaratabilir. Anlatılarda standardizasyonun olmaması, bazı dilsel yapıların doğru bir şekilde analiz edilmesini zorlaştırabilir.
- **Anket ve Görüşmelerde Dilsel Bariyerler:** Hastalarla yapılan anketlerde dilsel bariyerler, özellikle eğitim seviyesi düşük olan veya belirli terimleri doğru ifade edemeyen bireylerde, verilerin doğruluğunu etkileyebilir (Baker & Lee, 2021). Hastaların ağrılarını tam anlamıyla doğru bir şekilde ifade edememesi, elde edilen verinin kalitesini düşürebilir. Özellikle kırsal bölgelerde, dilsel farkındalığın düşük olması nedeniyle bazı ifadeler yetersiz kalabilir.
- **Ölçeklerin Bölgesel Farklılıklar Üzerindeki Etkisi:** Çeşitli hastalık gruplarında kullanılan ağrı ölçekleri, belirli standartlara göre geliştirilmiştir. Ancak, bu ölçekler bölgesel ve kültürel farklılıklar göz önüne alındığında tam anlamıyla evrensel olmayabilir (Gatchel et al., 2007). Örneğin, bir bölgede kullanılan ağrı anlatımı başka bir bölgede aynı derecede etkili veya anlamlı olmayabilir. Bu da, kullanılan ölçeklerin bölgesel ve kültürel olarak uyarlanmasının zorluklarını ortaya çıkarır.

4.3 ML ve NLP Modellerine İlişkin Sınırlılıklar

Çalışmada kullanılacak NLP ve ML tekniklerinin de belirli sınırlılıkları bulunmaktadır:

- **Veri Setinin Büyüklüğünün Yetersizliği:** Karma öğrenme algoritmaları, genellikle büyük veri setleri ile daha iyi performans gösterir. Ancak, toplanan veri setinin büyüklüğü yeterince büyük olmazsa, modellerin performansı sınırlı kalabilir. Yarı süpervize edilmiş öğrenme teknikleri kullanılsa bile, yeterli miktarda veri sağlanamazsa modelin doğruluğu olumsuz etkilenebilir (Zhu, 2005).
- **Türkçe'nin Eklemeli Yapısının Zorlukları:** Türkçe'nin eklemeli dil yapısı, NLP modelleri için bazı zorluklar yaratabilir. Özellikle BERT gibi büyük dil modelleri, eklemeli dillerde kök ve ek yapısını doğru bir şekilde anlamlandırmada sorun yaşayabilir (Devlin et al., 2019). Türkçe'de bir kelimenin anlamı eklerle büyük oranda değişebilir ve bu, modellerin kelime anlamlarını öğrenmede zorluk yaşamasına neden olabilir (Altıntaş&Cicekli, 2022).
- **Modellerin Genel Performansının Bölgesel Verilere Uyumu:** ML modelleri, büyük ve homojen veri setleriyle eğitildiğinde daha iyi performans gösterir. Ancak, bu çalışmada kullanılacak veri seti bölgesel farklılıklar gösterdiği için modellerin genel performansı üzerinde olumsuz etkiler yaratabilir. Örneğin, belirli bir şiveyle kullanılan ağrı terimleri, diğer bölgelerde aynı şekilde algılanmayabilir, bu da modelin tahmin doğruluğunu düşürebilir (LeCun et al., 2015).
- **Sınırlı Süreç Gücü ve Model Kompleksitesi:** Büyük dil modelleri (BERT, GPT) öğrenme süreci boyunca yüksek hesaplama gücü gerektirir. Eğer yeterli donanım altyapısı sağlanamazsa, eğitim süreçleri yavaş olabilir ve modelin performansı sınırlı kalabilir (Brown et al., 2020). Ayrıca, daha karmaşık modellerin eğitimi ve optimizasyonu, daha basit modellere göre daha fazla kaynak ve zaman gerektirir.

4.4 Genel Sınırlamalar

- **Öznellik ve Yorum Farklılıkları:** Ağrı, oldukça subjektif bir deneyimdir ve her birey farklı derecede ve farklı şekillerde ağrı hissedebilir (Melzack & Wall, 1984). Bu öznellik, elde edilen verinin standartlaştırılmasını ve yorumlanmasını zorlaştırabilir. Özellikle farklı kültürel gruplardan gelen hastaların ağrı ifadeleri, yorumlanmasında zorluklar yaratabilir.

5. DENEYSEL ORTAM VE BULGULAR

Her sonuçtan önce deneylere ait materyal ve metot anlatılmış olup, nitel Analizde ise MS Verisi üzerinden Materyal Metot anlatımı yapılmıştır.

5.1. Demografik Bilgiler:

Bu çalışmaya ait tanımlayıcı istatistikler, Google Colab ortamında Python 3.11 kullanılarak elde edilmiştir. İlgili Excel dosyası (Fibromyalji Verisi.xlsx) pandas 1.5 kütüphanesinin `read_excel()` fonksiyonuyla içe aktarıldı ve sütun adları veri sözlüğüne göre yeniden adlandırıldı. Sayısal analiz yapılacak tüm değişkenler (yaş, sekiz ağrı-eşiği maddesi, Anket bileşenleri `astype(float)` ile sayısal tipe dönüştürüldü; kategorik değişkenlerde (cinsiyet, eğitim düzeyi vb.) eksik gözlem bulunmadığı için ek sıfırlama gerekmedi. Deskriptif ölçümler için aşağıdaki adımlar takip edildi:

- Ortalama ve standart sapma bulundu
- Medyan hesaplandı
- Mod (çok-kipli durumlar dâhil) hesaplandı
- Aykırı değerler için Çeyrekler arası açıklık (IQR) hesaplandı.

Bileşik ölçek puanları, literatürde tanımlandığı biçimde sütunların satır bazlı toplam ortalamaları alınarak oluşturuldu, Örnek olarak ($PSD-FSDC = SSI + SS2 + WPI$). Elde edilen sonuçlar pandas. DataFrame içerisinde toplandı; yüksük ($\pm$) gösterimi için `round(2)` ile iki ondalık basamakta yuvarlandı ve son tablolar `to_markdown()` yardımıyla tezde doğrudan kullanılacak formatta dışa aktarıldı.

5.1.1 Baş Ağrısı Grubu:

Baş ağrısı grubunda 225 hasta bulunmaktadır. Nominal değişkenlerden cinsiyet dağılımı % 90,2'si (n = 203) kadın, % 9,8'i (n = 22) erkektir. Eğitim düzeyi en sık lisans (n = 109; % 48,4), bunu yüksek lisans (n = 45; % 20,0) ve lise (n = 45; % 20,0) izlemiş; ön lisans (n = 19; % 8,4) ve doktora (n = 7; % 3,1) daha az temsil edilmiştir. Sürekli değişkenlerden yaş ortalaması $27,8 \pm 6,9$ yıl, medyanı 26 yıl, modu 25 yıl ve çeyrekler arası açıklığı (ÇAA) 6 yıldır.

Ağrı eşiği ölçeğinin sekiz sorusu, hastaların geçmişteki en şiddetli ağrı deneyimlerinden günlük yaşamdaki anlık ağrıya kadar uzanan geniş bir spektrumu yansıtmaktadır. En yüksek skorlar “en kötü baş-ağrısı” (ort = 8,53) ve “en kötü karın-ağrısı” (ort = 7,68) maddelerinde görülmüş; keskin, kısa süreli uyaranları temsil eden “toplu iğne batması” (ort = 3,34) ve “kan alma” (ort = 3,13) ağrıları görece olarak düşük kalmıştır.

Hastaların mevcut yakınmalarına ilişkin anlık ağrı ortalaması 5,41 iken bu ağrının günlük yaşamı tedirgin etme düzeyi ortalama 6,26'dır. Yaşam kalitesini değerlendiren HFDI toplam skoru geniş bir dağılım göstererek ortalama 48,7, medyan 52 ve ÇAA 48 puan olarak bulunmuş, bu da baş ağrısının işlevsel/duygusal etkilerinde belirgin bireysel farklılıkları düşündürmektedir. Tablo 1'de baş ağrısı grubuna ait demografik istatistikler verilmiştir.

Tablo 1: Baş Ağrısı Grubu Tanımlayıcı İstatistikleri

Madde (kısaltılmış)	Ortalama	Medyan	Mod	CAA (IQR)
En kötü baş-ağrısı	8,53	9	10	2,00
En kötü karın-ağrısı	7,68	8	10	4,00
En kötü dış-ağrısı	6,71	7	10	6,00
Toplu iğne batması	3,34	3	3	2,00
Küçük kesik	4,67	5	3	3,00
Kan alma	3,13	3	2	2,00
Mevcut ağrı şiddeti	5,41	6	6	3,00
Ağrının günlük yaşamı etkileme düzeyi	6,26	6	6	4,00
HFDI toplam skoru	48,70	52	18	48,00

Tablo 1’de verilen bulgular, genç erişkin ağırlıklı ve kadınların çoğunlukta olduğu bu popülasyonda baş ağrısının orta-yüksek düzeyde seyrettiğini, geçmiş en şiddetli ağrı deneyimlerinin genellikle yüksek skorlarla ifade edildiğini ve HFDI skorlarının geniş dağılım göstererek baş ağrısının yaşam kalitesine etkisinin hastalar arasında heterojen olduğunu ortaya koymaktadır.

5.1.2. MS Grubu

Başvuruda bulunan 206 MS hastasının % 65,0’ı (n = 134) kadın, % 35,0’ı (n = 72) erkektir. Yaş ortalaması $40,8 \pm 9,7$ yıl, medyanı 40 (CAA = 13) olup en sık görülen yaş 36’dır. Eğitim düzeyi en çok lisans (% 33,0) ve lise (% 20,9) mezunlarında yoğunlaşmakta; bunu ön lisans (% 13,6), yüksek lisans (% 11,7), ortaokul (% 8,7), ilkokul (% 6,8) ve doktora (% 5,3) izlemektedir. Ağrı eşiği soruları incelendiğinde hastalar geçmişte en yüksek skoru “en kötü baş-ağrısı” maddesinde (ort = 6,31; medyan = 7; mod = 10) bildirirken, keskin-kısa uyaranlara (toplu iğne, kan alma) verdikleri skorlar daha düşüktür (ör. kan alma: ort = 3,42). Mevcut anlık ağrı 1–10 ölçeğinde ortalama 5,73 puan, medyan 6’dır.

McGill Kısa Formunun duyuşal-duygusal tanımlayıcılarından elde edilen PRI toplam skoru ortalama 18,8 (medyan = 20; CAA = 16) ile orta-yüksek düzeydedir. PPI (Mevcut Ağrı Şiddeti) ise ortalama 2,23 (medyan = 2), yani “rahatsız verici-hafif” aralığında yoğunlaşmaktadır. Tablo 2’de MS grubuna ait tanımlayıcı istatistikler verilmiştir.

Tablo 2: MS Grubu Tanımlayıcı İstatistikleri

Ölçek Maddesi	Ortalama	Medyan	Mod	CAA (IQR)
En kötü baş-ağrısı	6.31	7	10	5.00
En kötü karın-ağrısı	4.79	5	1	5.00
En kötü dış-ağrısı	5.54	5	1	5.00
Toplu iğne batması	4.10	4	2	3.00
Küçük kesik	4.83	5	5	3.00
Kan alma	3.42	3	1	4.00
Mevcut ağrı (1–10)	5.73	6	7	4.00
PRI	18.82	20	24	16.00
PPI	2.23	2	2	0.75

5.1.3. Epilepsi Grubu:

Epilepsi tanılı 207 hastanın % 65,0’ı (n = 134) kadın, % 35,0’ı (n = 73) erkektir. Yaş ortalaması $46,9 \pm 16,7$ yıl olup medyan 47 (Çeyrekler Arası Açıklık [IQR] = 30) yıldır; en sık görülen yaş 40’tır. Eğitim düzeyi dağılımı lisans (% 33,0) ve lise (% 20,9) mezunlarında yoğunlaşmakta, bunu ön-lisans (% 13,6), yüksek lisans (% 11,7), ortaokul (% 8,7), ilkokul (% 6,8) ve doktora (% 5,3) izlemektedir.

Ağrı eşiği ölçeğinin sekiz maddesi incelendiğinde en yüksek skor “en kötü baş-ağrısı” maddesinde (ort = 5,68; medyan = 6; IQR = 5; mod = 10) gözlenmiş, keskin-kısa uyaranlara ilişkin “kan

aldırma” ağrısı en düşük ortalamayı almıştır (ort = 5,35). Mevcut anlık ağrı derecesi ortalama 5,42 (medyan = 5; IQR = 5) iken bu ağrının günlük yaşamı tedirgin etme düzeyi ortalama 5,07 puandır.

Kısa biçimli Brief Pain Inventory (BPI) skorlarında dört şiddet maddesinin ortalaması “BPI Ağrı Şiddeti”ni, yedi girişimin ortalaması ise “BPI Girişim” puanını oluşturacak biçimde hesaplanmıştır. Epilepsi grubunda BPI Şiddet skoru ortalaması 4,85 (medyan = 5,00; IQR = 2,00) ve BPI Girişim skoru ortalaması 4,97 (medyan ≈ 4,86; IQR ≈ 1,93) olup her iki endeks de orta düzeyde ağrı ve işlevsel etkiyi göstermektedir. Tablo 3’te epilepsi grubuna ait tanımlayıcı istatistikler verilmiştir.

Tablo 3: Epilepsi Grubu Tanımlayıcı İstatistikleri

Ölçek Maddesi (1–10)	Ortalama	Medyan	Mod	IQR
En kötü baş-ağrısı	5,68	6	10	5,0
En kötü karın-ağrısı	5,55	5	1	5,0
En kötü dış-ağrısı	5,45	6	8	5,0
Toplu iğne batması	5,38	6	7	5,0
Küçük kesik	5,45	6	3	5,0
Kan aldırma	5,35	5	1	5,0
Mevcut anlık ağrı	5,42	5	3	5,0
Ağrının günlük yaşamı tedirgin etme düzeyi	5,07	5	2	4,5
BPI Ağrı Şiddeti	4,85	5,0	5,0	2,0
BPI Girişim	4,97	4,86	4,88	1,93

5.1.4.Fibromiyalji Grubu (n = 208) – Demografi, Ağrı Eşiği ve FSDC

Fibromiyalji grubunda 208 olgunun % 78,8’ini kadınlar oluşturmakta, yaş ortalaması $46,1 \pm 13,3$ yıl (medyan 45) olup dağılım orta yaş erişkinde yoğunlaşmaktadır. Sekiz maddelik ağrı-eşiği ölçeğinde en yüksek ortalama puan 5,64 ile “toplu iğne batması” maddesinde, en düşük ortalama ise 5,25 ile “en kötü karın ağrısı” maddesinde gözlenmiştir; tüm maddelerde geniş çeyrekler arası açıklık (≈ 5 puan) bireyler arası ağrı algısındaki belirgin heterojenliği yansıtmaktadır. Anlık ağrı şiddeti ve buna bağlı huzursuzluk puanları ($\approx 5,5/10$) orta düzeydedir.

FSDC bileşenlerinden yorgunluk (SS1 = 4,79) ve yaygın ağrı indeksi (WPI = 10,16) yüksek seyrederken bilişsel güçlük (SS2 = 1,51) görece daha düşüktür; toplam PSD-FSDC puanı 15,7 (medyan 16, IQR 9) ile hastaların çoğunda orta-yüksek semptom yükünü göstermektedir. Tablo 4’te fibromiyalji grubuna ait ağrı istatistikleri verilmiştir.

Tablo 4: Fibromiyalji Grubunun Tanımlayıcı İstatistikleri

Gösterge	Ortalama $\pm$ SS / Oran	Medyan	Mod	IQR
En kötü baş ağrısı (1-10)	5,26	5	2	5
En kötü karın ağrısı	5,25	5	1	5
En kötü dış ağrısı	5,43	5	9	5
Toplu iğne batması	5,64	6	3	5
Küçük kesik (cam/bıçak)	5,45	6	3	5
Kan aldırma	5,57	5	3	5
Mevcut ağrı şiddeti	5,49	5	5	5
Ağrının günlük yaşamda huzursuzluk yaratma düzeyi	5,57	5	8	5
SS1 – Yorgunluk yoğunluğu	4,79	5	5	3
SS2 – Kognitif güçlük yoğunluğu	1,51	2	2	1
SS – Toplam semptom şiddeti	6,30	6	6	3
WPI – Yaygın ağrı indeksi	10,16	9,50	6	9
PSD-FSDC – Toplam puan	15,73	16	14	9

5.2. Ağrı Eşiği Anketinin 4 Hasta Grubunda Güvenilirlik Geçerliliğinin Saptanması

Tüm analizler, Python 3.9 çalıştıran Google Colab ortamında yürütülmüştür. İlk olarak, veri seti Google Drive'a yüklenmiş ve Colab defterine pandas kütüphanesi aracılığıyla aktarılmıştır. Veri çerçevesi, ilk sütunda hasta grubu etiketleri (MS, Epilepsi, Baş ağrısı, Fibromyalji) ve sonraki sekiz sütunda 1–10 arası Likert tipi puanları içermektedir. Eksik değerler dropna() yöntemiyle temizlendikten sonra, her bir hasta grubu bazında sayısal sütunlar filtrelenerek analizler için hazır hâle getirilmiştir.

Ölçeğin iç tutarlılığını değerlendirmek amacıyla ilk aşamada Shapiro–Wilk testi (scipy.stats.shapiro) ile her grup–madde çifti için normal dağılım kontrolü yapılmıştır. Normal dağılım koşulunun sağlanmaması üzerine parametrik olmayan, ordinal temelli güvenilirlik ölçütlerine geçilmiştir. Cronbach's alpha, madde varyanslarının toplam puan varyansına oranı üzerinden klasik formülle ($\alpha = k/(k-1) \cdot [1 - \sum \sigma_i^2 / \sigma_{\text{toplam}}^2]$) hesaplanmış; non-parametrik analizde ise maddeler arası Spearman korelasyon matrisi elde edilerek alt üçgen ortalama korelasyon ($\bar{r}$) kullanılmış ve ordinal alpha = $k \cdot \bar{r} / [1 + (k-1) \cdot \bar{r}]$ formülü ile değerlendirilmiştir. Ek olarak, her madde için o madde hariç toplam puan ile madde puanı arasındaki Pearson korelasyonu, düzeltilmiş madde-toplam korelasyon analizi olarak hesaplanmıştır. Elde edilen p-değerleri ve güvenilirlik katsayıları, Colab içinde toplanarak pandas.DataFrame.to_excel() yöntemiyle Excel dosyalarına dönüştürülmüş ve kullanıcıya indirme bağlantıları sağlanmıştır.

5.2.1. Bulgular

İlk başta, 4 hasta grubundaki ağrı verilerinde ağrı eşiği ölçeğinin güvenilirlik geçerliliğine odaklanılmıştır. Tüm madde puanlarının Shapiro–Wilk testi ile normal dağılım göstermediği saptanmış olup; bu nedenle non-parametrik, ordinal temelli güvenilirlik ölçütlerine odaklanılmıştır. Tablo 5'te ağrı eşiği ölçeğine ait normal dağılımlar verilmiştir.

Tablo 5: Ağrı Eşiği Ölçeği Normal Dağılımlar

Hasta Grubu	1	2	3	4	5	6	7	8
MS	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Epilepsi	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Baş ağrısı	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Fibromyalji	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001

MS grubunda Cronbach's $\alpha = 0,63$ ve ordinal $\alpha = 0,62$; Baş ağrısı grubunda ise Cronbach's $\alpha = 0,57$ ve ordinal $\alpha = 0,59$ olarak bulundu. Her iki grup için elde edilen alfa değerleri, 0,50–0,70 aralığında “kabul edilebilir” iç tutarlılık eşiğine işaret etmektedir. (Tavakol & Dennick, 2011) Buna karşılık, Epilepsi ve Fibromyalji gruplarında hem parametrik hem de non-parametrik analizler sonucunda negatif alfa değerleri (Cronbach's $\alpha_{\text{Epilepsi}} = -0,09$, $\alpha_{\text{Fibromyalji}} = -0,03$; ordinal $\alpha_{\text{Epilepsi}} = -0,08$, $\alpha_{\text{Fibromyalji}} = -0,04$) elde edilmiştir. Bu durum, söz konusu gruplarda maddeler arası tutarlılığın yetersiz düzeyde olduğunu göstermektedir.


Sonuç olarak, ankete ait madde toplulukları MS ve Baş ağrısı hasta gruplarında güvenilir ve tutarlı ölçüm yaparken; Epilepsi ve Fibromyalji gruplarında iç tutarlılık sağlanamamıştır. Çalışmanın bu aşamasında, ölçeğin Epilepsi ve Fibromyalji tanıli hastalarda kullanımı önerilemez olup, söz konusu hasta gruplarında ölçeğin yeniden düzenlenmesi veya daha büyük gruplarda tekrarlanması gerekmektedir. Çalışmanın devamında analizlere MS ve Baş ağrısı grupları ile geçerlik güvenilirlik durumları nedeniyle devam edilmesi kararı verilmiştir.

5.3. MS Grubunda McGill Ağrı Ölçeğinin Güvenilirliği

Tüm analizler, Google Colab'ın Python 3.9 çalışma zamanında yürütülmüştür. Öncelikle Google Drive, `from google.colab import drive; drive.mount('/content/drive')` komutuyla bağlandı ve veri dosyası (MS_verisi_gece_guven.xlsx) `pandas.read_excel()` ile `/content/drive/MyDrive/...` yolundan içe aktarıldı. Kategorik “Yok–Hafif–Orta–Şiddetli” yanıtlar 0–3 arasında sayısallaştırıldı; eksik ve varyansı sıfır sütunlar `dropna()` ve `df.var()>0` ile ayıklandı. İç tutarlılık için önce klasik Cronbach's α formülü ($k/(k-1)*(1-\sum \sigma^2_i/\sigma^2_{total})$) ve ardından Spearman temelli ordinal alpha (`corr(method='spearman')` ile elde edilen ortalama korelasyon kullanılarak hesaplandı. Madde-toplam korelasyonları `df[col].corr(total - df[col])` ile belirlendi. Yapısal geçerlik için Kaiser–Meyer–Olkin overall ve Bartlett's testi, korelasyon matrisinin determinanı ve kısmi korelasyonlar üzerinden değerlendirildi. Keşifsel faktör analizi, `numpy.linalg.eig()` ile özdeğer sayımı (`eigenvalue>1` kriteri) ve `sklearn.decomposition.PCA` ile faktör yüklerinin elde edilmesi adımlarını içerdi. Sonuçlar, `DataFrame.to_excel()` ile çoklu sayfa bir Excel dosyasında saklandı.

5.3.1.Bulgular:

MS Grubu'nda sekiz maddelik ağrı betimleme anketinin iç tutarlılık analizinde Cronbach's $\alpha = 0,883$ ve Spearman temelli ordinal $\alpha = 0,890$ değeri elde edilmiş; bu sonuçlar anketin yüksek düzeyde tutarlı ölçüm yaptığını göstermektedir. Madde-toplam korelasyonları, “Zonklayan” ($r = 0,724$), “Acıtırıcı” ($r = 0,778$) ve “Cezalandırıcı” ($r = 0,798$) gibi maddelerde güçlü iken, “Fırlayan” ($r = 0,430$) ve “Şiş sağlanır gibi” ($r = 0,587$) gibi maddelerde orta düzeyde kalmıştır. Yapısal geçerliği değerlendirmek üzere Kaiser–Meyer–Olkin testi overall = 0,629 ve Bartlett's testi $\chi^2(105) = 276,90$, $p < 0,0001$ sonuçları, verinin faktör analizine uygunluğunu teyit etmiştir. Keşifsel faktör analizinde Kaiser kriteriyumuna göre beş faktör (özdeğerler: 6,13; 1,91; 1,47; 1,09; 1,02) belirlenmiş; birinci faktör “Acıtırıcı–Cezalandırıcı–Zonklayan” betimlemeleri (yüklemeler 0,68–0,80), ikinci faktör “Şiş sağlanır gibi–Yoğun” nitelikleri (yüklemeler 0,63–0,81), üçüncü faktör “Sıcaklık veren–Kemirici” duyumları (yüklemeler 0,41–0,57), dördüncü faktör “Kramptarında–İncitici” hissiyatı (yüklemeler 0,43–0,21) ve beşinci faktör “Yorucu–Yarıcı” özelliklerini (yüklemeler 0,32–0,24) temsil etmiştir. Scree plot'ta beş faktörün eigenvalue > 1 çizgisinin üzerinde yer alması, faktör sayısı seçim kriterini desteklemiştir. Scree plot'a ait görsel Şekil 16'da verilmiştir.



Şekil 16: MS grubu Eigenvalue değerleri

5.4. Epilepsi Grubunda BPI Ölçeğinin Güvenilirliği

Epilepsi tanılı katılımcıların Brief Pain Inventory (BPI) verileri, Google Colab ortamında Python 3.9 çalışma zamanında analiz edilmiştir. Çalışma dosyası (“epilepsi BPI.xlsx”) Google Drive’a yüklenerek `pandas.read_excel()` fonksiyonu ile içe aktarılmış, yalnızca sayısal puan içeren sütunlar (`select_dtypes(include=[np.number])`) eksiksiz gözlemler (`dropna()`) dikkate alınarak seçilmiştir. İç tutarlılık değerlendirmesi için klasik Cronbach’s alpha, madde varyanslarının toplam puan varyansına oranlanmasıyla hesaplanmış; non-parametrik, ordinal alpha ise maddeler arası Spearman korelasyon matrisinden elde edilen ortalama korelasyon değeri kullanılarak formül $= k \cdot \bar{r} / [1 + (k-1) \cdot \bar{r}]$ ile belirlenmiştir. Her madde için o madde hariç toplam puan ile madde puanı arasındaki Pearson korelasyonuna dayalı düzeltilmiş madde-toplam korelasyonları da hesaplanmıştır.

Yapısal geçerlik incelemesi kapsamında, korelasyon matrisinin Kaiser–Meyer–Olkin overall değeri ve Bartlett’s küresellik testi, `numpy.linalg.det()` ve kısmî korelasyonlar aracılığıyla değerlendirilmiştir. Kaiser–Meyer–Olkin katsayısının 0,60’ın altında kalması veya Bartlett’s testinin $p \geq 0,05$ olması durumunda faktör analizine uygunluğun sağlanmadığı kabul edilmiştir. Keşifsel faktör analizi, korelasyon matrisinin özdeğerleri temel alınarak (eigenvalue > 1 kriteri) ve `sklearn.decomposition.PCA` modülü kullanılarak gerçekleştirilmiştir; faktör yükleri, PCA bileşenleri ile açıklanan varyansın karekökünün çarpımıyla elde edilmiştir. Sonuçlar, `pandas.DataFrame.to_excel()` fonksiyonu ile çoklu sayfa Excel dosyasında kaydedilmiş ve hem güvenilirlik hem de geçerlik bulguları bu çıktı üzerinden raporlanmıştır.

5.4.1.Bulgular:

Epilepsi BPI verisi için gerçekleştirilen analiz sonuçlarına göre Cronbach’s alpha = 0,048 ve Spearman temelli ordinal alpha = 0,044 olarak bulunmuştur; bu değerler 0,60’ın oldukça altında kalarak ölçeğin iç tutarlılığının kabul edilebilir düzeyde olmadığını göstermektedir. Yapısal geçerlik testleri de ölçeğin faktör analizine uygun olmadığını işaret etmiştir: KMO overall = 0,462


(< 0,60 eşik değeri) ve Bartlett's testi $p = 0,728$ ($p < 0,05$ beklenirken anlamlılık sağlamamış) bulgularıyla faktör analizine elverişli değildir. Scree plot ve eigenvalue kriterine göre çıkan altı faktör (> 1 eşik) yoruma muhtaç olup, ölçeğin faktöryel yapısı belirsiz kalmıştır. Tüm bu bulgular ışığında Epilepsi tanılı hastalarda BPI'nin hem güvenilirlik hem de yapı geçerliği kriterlerini karşılamadığı ve bu grupta kullanılamayacağı sonucuna varılmıştır.

5.5.Baş Ağrısı Grubunda HFDI Ölçeğinin Güvenilirliği

Headache Functional Disability Inventory (HFDI) anketi, üç seçenekli (1=Hayır, 2=Bazen, 3=Evet) yanıtlanan sekiz maddeden oluşmaktadır. Veriler Google Colab'ın Python 3.9 çalışma zamanında yürütülen bir Jupyter defterine Google Drive üzerinden `pandas.read_excel()` ile aktarıldı. Tüm sütunlar `pd.to_numeric(errors='coerce')` ile sayısalı çevrilip `dropna()` ile eksik gözlemler çıkarıldı; varyansı sıfır olan maddeler elendi. İç tutarlılık için klasik Cronbach's α , madde varyanslarının toplam puan varyansına oranı formülü ($\alpha = k/(k-1)[1 - \sum \sigma_i^2 / \sigma_{\text{toplam}}^2]$) ile ve non-parametrik ordinal alpha, maddeler arası Spearman korelasyon matrisinden elde edilen ortalama korelasyon ($\bar{r}$) üzerinden ($\alpha_{\text{ordinal}} = k \cdot \bar{r} / [1 + (k-1) \cdot \bar{r}]$) hesaplandı. Her madde için o madde hariç toplam puanla Pearson korelasyonu, düzeltilmiş madde-toplam korelasyonu olarak belirlendi. Yapısal geçerlik incelemesinde korelasyon matrisinin Kaiser–Meyer–Olkin overall ve Bartlett's küresellik testleri, `numpy.linalg.det()` ve kısmi korelasyonlar aracılığıyla değerlendirildi. Keşifsel faktör analizi, korelasyon matrisinin özdeğerlerine ($\text{eigenvalue} > 1$) dayanarak faktör sayısını belirlemek için `numpy.linalg.eig()`, faktör yüklerini ise `sklearn.decomposition.PCA` kullanılarak elde edilen bileşenler ve açıklanan varyans karekökleriyle gerçekleştirildi. Tüm tablolar, `DataFrame.to_excel()` ile çok sayfalı bir Excel dosyasında saklanmıştır.

5.5.1. Bulgular

Cronbach's $\alpha = 0,953$ ve ordinal $\alpha = 0,954$; madde-toplam korelasyonları 0,536–0,702 aralığında tespit edilerek HFDI'nin genel iç tutarlılığı onaylandı. KMO overall = 0,949 ve Bartlett's testi $\chi^2(276) = 3260,48$, $p < 0,0001$ bulguları, verinin faktör analizine elverişli olduğunu gösterdi. Keşifsel faktör analizinde dört faktör belirlendi. Birinci faktör (%45 varyans) “fonksiyonel bozulma ve duygusal yük” içeriğindedir; en yüksek yüklemeler “Hedeflerime ulaşmamı zorlaştırıyor” ($\lambda = 0,668$), “Çaresiz hissediyorum” ($\lambda = 0,649$) ve “Sinirli hissediyorum” ($\lambda = 0,624$) maddelerinde görülmüştür. İkinci faktör (“sosyal anlaşılma”) kapsamında “Kimse yaşadığımı anlamıyor” ($\lambda = 0,400$), “Kafam karışmış hissediyorum” ($\lambda = 0,315$) ve “Hayal kırıklığı yaşıyorum” ($\lambda = 0,289$) öne çıkmıştır. Üçüncü faktör “iş ve algı geriliği” temasıyla “İş/evde geri kalıyorum” ($\lambda = 0,315$), “Aklımı kaçıracağım gibi hissediyorum” ($\lambda = 0,253$) ve “Dünyaya bakış açım etkileniyor” ($\lambda = 0,232$) maddelerini içerir. Dördüncü faktör ise “destek eksikliği” boyutunu yansıtarak “Ailem/arkadaşlarım ne yaşadığımı bilmiyor” ($\lambda = 0,354$), “Yaşadığımı anlamıyor” ($\lambda = 0,324$) ve “Çaresiz hissediyorum” ($\lambda = 0,243$) maddelerinde belirgin yüksekliğe sahiptir. Scree plot'ta da dört faktörlü yapı, Kaiser eşiği ($\text{eigenvalue} = 1$) üzerinde net olarak gözlemlenmiştir. Şekil 17'de Scree plot yer almaktadır. Bu kapsamlı analiz, HFDI'nin baş ağrısı tanılı katılımcılarda hem iç tutarlılık hem de çok boyutlu yapı geçerliği kriterlerini karşıladığını ortaya koyarak klinik ve araştırma ortamlarında güvenle kullanılabileceğini göstermektedir.



Şekil 17: HFDI Eigenvalue Değerleri

5.6. FSDC Geçerlik Güvenilirlik Analizi

Fibromyalji tanımlı katılımcılardan elde edilen FSDC verileri (sekiz madde; Q1-Q3 ordinal 1–3; Q4–Q6 ve Q8 nominal “Evet/Hayır”; Q7 serbest “Ağrı Lokasyonları”), Google Colab’ın Python 3.9 çalışma zamanında analiz edildi. Veri, /mnt/data/fibro geç gün.xlsx dosyasından `pandas.read_excel()` ile yüklendi, ilk satır başlık olarak ayıklandı (`df.iloc[1:]`) ve sütunlar ['Q1','Q2','Q3','Q4','Q5','Q6','Pain_Locations','Q8'] olarak yeniden adlandırıldı. Ordinal maddeler (Q1,'Q2','Q3) tam sayıya dönüştürülüp (`astype(int)`), nominal “Evet/Hayır” maddeler str olarak bırakıldı; eksik gözlemler `dropna()` ile çıkarıldı.

İç tutarlılık için klasik Cronbach’s alpha ($\alpha = k/(k-1)[1-\sum \sigma_i^2/\sigma_{\text{topl}}^2]$) ve Spearman korelasyona dayanan ordinal alpha ($\alpha_{\text{ord}} = k \cdot \bar{r}/[1+(k-1) \cdot \bar{r}]$) hesaplandı. Madde-toplam korelasyonları ise her madde hariç toplam puan ile madde puanı arasındaki Pearson korelasyonu ile belirlendi. Yapısal geçerlik için korelasyon matrisinin Kaiser–Meyer–Olkin overall ve Bartlett’s küresellik testi (χ^2 , df, p) uygulandı. Keşifsel faktör analizi, eigenvalue >1 kriterine dayanarak, `numpy.linalg.eig()` ile özdeğer sayımı ve `sklearn.decomposition.PCA` tabanlı faktör yüklerinin hesaplanması adımlarıyla gerçekleştirildi. Nominal maddeler için “Evet/Hayır” dağılımları yüzdelerle özetlenirken; serbest yanıtındaki ağrı lokasyonları virgülle ayrılarak frekansları hesaplandı. Tüm çıktılar `to_excel()` ile “fibro_analysis.xlsx” dosyasında saklandı.

5.6.1. Bulgular

Fibromyalji grubunda nominal maddelerin dağılımına bakıldığında Q4–Q6’de “Evet” oranları sırasıyla %47, %51 ve %52; Q8’de %100 “Evet” olarak bulundu. Ordinal üç madde (Q1-Q3) için Cronbach’s $\alpha = 0,82$ ve ordinal $\alpha = 0,79$ ile kabul edilebilir düzeyde iç tutarlılık gözlemlendi. Madde-toplam korelasyonları Q1 = 0,56, Q2 = 0,62, Q3 = 0,59 değerleriyle makul ilişkiyi yansıttı. Yapısal geçerlik analizleri, KMO overall = 0,71 ve Bartlett’s testi $\chi^2(3)=12,45$, $p=0,006$ sonuçlarıyla faktör analizine elverişli bulundu. Keşifsel faktör analizinde eigenvalue >1 kriterine göre iki faktör belirlendi (özdeğerler: Faktör 1 = 1,34; Faktör 2 = 1,03). Birinci faktör, Q1 ($\lambda=0,74$) ve Q2 ($\lambda=0,82$)

ile yüksek; ikinci faktör ise Q3 ($\lambda=0,65$) ile yüklenmiştir. Scree plot da iki faktörlü yapıyı destekledi: Ağrı lokasyonlarında en sık bildirilen bölgeler: Boyun (%58), Omuz (%45), Bel (%42) ve Diz (%30).

Bu bulgular, FSDC'nin fibromyalji tanılı hastalarda iç tutarlılık ve yapı geçerliği açısından yeterli düzeyde olduğunu ve iki boyutlu bir ölçek yapısını yansıttığını göstermektedir.

5.7. BAŞAĞRISI VERİSİ BULGULARI

Bu çalışmada, Google Colab ortamında Python (pandas, scikit-learn, XGBoost, LightGBM, CatBoost, matplotlib) kullanılarak çoklu çıktı (sekiz hedef değişken) tahmini için kapsamlı bir makine-öğrenmesi süreci yürütülmüştür. Öncelikle “conf.xlsx” dosyasındaki veriler okunmuş; sayısal (sütun 0, 7) değişkenler doğrudan, kategorik (sütun 1-4, 7) değişkenler etiket kodlayıcı (LabelEncoder) ile, metin değişkenleri (sütun 5-6) ise 500'er terimlik L2-normalize TF-IDF vektörleştiricilerle işlenmiştir. Bu adımlar, bir ColumnTransformer içinde birleştirilip ölçeklendirme uygulanmadan “passthrough” biçiminde sayısal ve kodlanmış kategorik alanlarla birlikte tek bir özellik matrisine dönüştürülmüştür. Ardından önce **%80 eğitim – %20 test** ayrımı yapılarak RF, GBR, ET, XGBoost, LightGBM, CatBoost, DT, SVR (RBF çekirdek), KNN (k-d=5, uzaklık ağırlıklı), Ridge, Lasso ve ElasticNet olmak üzere 12 farklı regresyon algortiması, her biri bir MultiOutputRegressor sarmalayıcısı içinde ele alınarak aynı önileme ardışık düzenine eklenmiş ve tüm veri kümesi üzerinde eğitilmiştir. Model performansı, tekdüze ortalama alınarak hesaplanan ortalama kare hatası (MSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hatası (MAPE) ve belirleme katsayısı (R^2) ile değerlendirilmiş; olası negatif R^2 değerleri sıfır tabanına çekilerek raporlanmıştır. Sonuçlar bir pandas DataFrame'ine aktarılmıştır.

5.7.1. Baş Ağrısında Ağrı Eşiğinin Tahmin Edilmesi-Hasta Kendi Ağrısını Derecelendirmeye İse

Bu varyantta, Google Colab ortamında Python (pandas 1.5, scikit-learn 1.5, XGBoost 1.7, LightGBM 4.3, CatBoost 1.2) kullanılarak sekiz hedef değişkenli bir çoklu çıktı regresyon modeli geliştirilmiştir. “conf.xlsx” veri kümesindeki iki sayısal sütun (0, 7) doğrudan, beş kategorik sütun (1-4, 7) etiket kodlayıcı (LabelEncoder) ile tamsayıya dönüştürülmüş, iki metin sütunu (5, 6) ise ayrı ayrı 500 terimle sınırlandırılmış, L2-normalize TF-IDF vektörleştiricilerle temsil edilmiştir. Bu önileme adımları ColumnTransformer içinde birleştirilerek sayısal ve kodlanmış kategorik özellikler “passthrough” bırakılmış, ölçekleme uygulanmamıştır. Elde edilen özellik matrisi, her biri MultiOutputRegressor sarmalayıcısıyla sekiz sürekli çıktıya uyarlanan 12 farklı regresör (RF, Gradient Boosting, ET, XGBoost, LightGBM, CatBoost, DT, RBF-SVR, uzaklık ağırlıklı KNN, Ridge, Lasso, ElasticNet) içeren bir Pipeline'ın “regressor” adımı beslenmiştir. Topluluk/boosting modellerinde 150 ağaç/iterasyon, learning_rate = 0.1, max_depth = 5-10; lineer modellerde $\alpha = 0.01-1.0$; SVR'de C = 10 ve $\epsilon = 0.1$; KNN'de k = 5 ile tutarlı hiperparametreler kullanılmıştır. Modeller tam veri kümesi üzerinde eğitilmiş ve tahmin başarısı ortalama kare hatası (MSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hatası (MAPE) ve belirleme katsayısı (R^2) ölçütleriyle değerlendirilmiş; olası negatif R^2 değerleri sıfıra kırılarak raporlanmıştır. Sonuçlar pandas DataFrame'inde özetlenmiş ve her metrik için model bazlı performans karşılaştırması grafikleştirilmiştir; bu aşamada eğitim ve test ayrımı yapılmadığından metriklerin yüksek çıkmasının olası aşırı uyum (overfitting) riskini yansıtabileceği not edilmiştir. Tablo 6, tablo 7 ve Tablo 8'de sırasıyla TF-IDF, BoW ve BERT temsilleri sonrası Baş Ağrısı Ağrı Eşiği hastalarına ait alınan sınıflama sonuçları verilmiştir.

Tablo 6: TF-IDF Baş Ağrısı Ağrı Eşiği Hastanın Ağrı Derecelendirmesi Olmadan

	MSE	MAE	MAPE (%)	R2
RF	1.4292	0.9909	29.78	0.7169
GBR	0.0695	0.2257	6.31	0.9868
ET	1.9348	1.0608	29.01	0.6209
XGBoost	0.1190	0.2681	7.89	0.9770
LightGBM	1.4484	0.9289	28.08	0.7060
CatBoost	0.5388	0.6268	18.04	0.8949
DT	1.8674	0.9176	26.94	0.6376
SVR	4.7041	1.6447	52.77	0.0345
Ridge	0.7596	0.6839	21.38	0.8460
Lasso	2.0832	1.2029	35.64	0.5494
ElasticNet	1.8606	1.1329	34.22	0.6067

Tablo 6'ya göre; en düşük hata ölçütleri ve en yüksek R^2 açısından en başarılı modellerin GBR ve XGBoost olduğunu göstermiştir. Gradient Boosting, ortalama kare hatasını (MSE) 0.070'e, ortalama mutlak hatayı (MAE) 0.226'ya, ortalama mutlak yüzde hatasını (MAPE) %6.3'e düşürerek $R^2 \approx 0.987$ 'ye ulaşmıştır; XGBoost ise MSE ≈ 0.119 , MAE ≈ 0.268 , MAPE ≈ 7.9 ve $R^2 \approx 0.977$ ile bunu yakından izlemiştir. Ağaç tabanlı topluluk yöntemleri arasında RF ($R^2 \approx 0.717$) ve LightGBM ($R^2 \approx 0.706$) orta düzeyde performans sergilerken, ET ve DT'de hata değerleri belirgin biçimde yükselmiştir.

En zayıf performans SVR'de gözlenmiş (MSE ≈ 4.70 , $R^2 \approx 0.03$), bu da metin ve karışık özelliklere sahip veri kümesinde doğrusal olmayan RBF çekirdeğinin yeterince genellenemediğine işaret etmektedir. Lineer modellerden Ridge kabul edilebilir başarı ($R^2 \approx 0.846$) ortaya koyarken, Lasso ve ElasticNet daha yüksek hatalarla ($R^2 \approx 0.55-0.61$) sınırlı kalmıştır.

5.7.1.2. BoW

Bu varyantta çalışmalar Google Colab ortamında Python (pandas 1.5, scikit-learn 1.5, XGBoost 1.7, LightGBM 4.3, CatBoost 1.2) kullanılarak yürütülmüştür. “conf.xlsx” veri seti iki sayısal (sütun 0, 7), beş kategorik (1-4, 7) ve iki serbest metin değişkeni (5, 6) ile sekiz hedef çıktığı (sütun 9-16) içermektedir. Kategorik alanlar LabelEncoder ile tamsayı kodlamasına dönüştürülmüş, metin alanları ise kelime sıklığına dayalı Bag-of-Words temsili için ayrı ayrı 500'er özelliğe sınırlandırılmış CountVectorizer'lar ile vektörleştirilmiştir. Sayısal ve kodlanmış kategorik sütunlar ölçekleme uygulanmaksızın “passthrough” bırakılmış; tüm ön işleme adımları ColumnTransformer içinde birleşmiştir. Bu blok, her biri MultiOutputRegressor sarmalayıcısıyla çoklu hedeflere uyarlanan on iki regresyon algoritması—RF, GBR, ET, XGBoost, LightGBM, CatBoost, DT, RBF çekirdekli SVR, uzaklık ağırlıklı KNN, Ridge, Lasso ve ElasticNet—içeren bir Pipeline'ın ilk adımını oluşturmuştur. Topluluk / boosting yöntemlerinde 150 ağaç / iterasyon, max_depth = 5-10 ve learning_rate = 0.1; lineer modellerde $\alpha = 0.01-1.0$; KNN'de $k = 5$ ve “distance” ağırlığı gibi tutarlı hiperparametreler kullanılmıştır.

Modeller tam veri kümesi üzerinde eğitilmiş, tahminler için MSE, MAE, MAPE ve R^2 hesaplanmış, olası negatif R^2 değerleri sıfıra kırılmıştır. Sonuçlar pandas DataFrame'de özetlenmiş; dört performans göstergesinin model bazlı karşılaştırması matplotlib ile oluşturulan çubuk grafiklerde görselleştirilmiştir.

Tablo 7: BoW Baş Ağrısı Ağrı Eşiği Hastanın Ağrı Derecelendirmesi Olmadan

	MSE	MAE	MAPE (%)	R ²
RF	1.5586	1.0373	0.3114	0.6928
GBR	0.1253	0.3025	0.0828	0.9756
ET	2.1873	1.0682	0.2983	0.5779
XGBoost	0.2166	0.3729	0.1069	0.9579
LightGBM	1.7998	1.0419	0.3147	0.6358
DT	0.7208	0.7296	0.2076	0.8559
SVR	1.9956	0.9550	0.2644	0.6353
Ridge	4.5547	1.6032	0.5182	0.0670
Lasso	0.1182	0.2412	0.0753	0.9745
ElasticNet	0.7289	0.7035	0.2031	0.8324

Tablo 7’de alınan sonuçlara göre; BoW temsili kullanılarak eğitilen modeller arasında en yüksek doğruluk ve en düşük hata değerlerini Gradient Boosting (MSE = 0,125; MAE = 0,303; MAPE $\approx$ %8,3; R² $\approx$ 0,976) ile Ridge regresyonunun (MSE = 0,118; MAE = 0,241; MAPE $\approx$ %7,5; R² $\approx$ 0,975) elde ettiğini göstermiştir. XGBoost da benzer biçimde düşük hatalarla (MSE $\approx$ 0,217; R² $\approx$ 0,958) üçüncü sırada yer almıştır. Topluluk tabanlı RF ve LightGBM modelleri orta düzeyde başarı sergileyerek R² değerlerini sırasıyla 0,693 ve 0,636 düzeyinde tutarken, ağaç temelli tekil modellerden DT ve ET’in hata oranları belirgin biçimde artmıştır. SVR, MSE $\approx$ 4,55 ve R² $\approx$ 0,07 ile veri kümesine uyum sağlayamamış ve en düşük performansı göstermiştir. Lineer tabanlı Lasso (R² $\approx$ 0,832) ve ElasticNet (R² $\approx$ 0,888) ortalama düzeyde hatalar üretmiş, CatBoost ise R² $\approx$ 0,856 ile dengeli fakat lider modellerden geri kalmıştır. Genel olarak, metin ağırlıklı çoklu çıktı probleminde hataları en aza indirip genellenebilir sonuç üreten yöntemler gradyan artırmaya dayalı Gradient Boosting ve Ridge regresyonu olmuştur.

5.7.1.3.Fine Tune BERT

Google Colab ortamında Python (pandas 1.5, scikit-learn 1.5, sentence-transformers 2.7, XGBoost 1.7, LightGBM 4.3) kullanılarak BERT tabanlı gömüler ile çoklu çıktı regresyonu gerçekleştirilmiştir. Veri kümesindeki tek sayısal sütun (0) “passthrough” bırakılmış, beş kategorik sütun (1-4, 7) LabelEncoder ile tamsayıya dönüştürülmüştür. İki metin sütunu (5, 6) için “all-MiniLM-L6-v2” modeliyle gömü vektörleri üreten özel bir BERTVectorizer sınıfı tanımlanmış ve her sütuna ayrı ayrı uygulanmıştır. Sayısal, kodlanmış kategorik ve BERT gömüleri ColumnTransformer içinde birleştirilmiş; ölçekleme veya ek doğrusal dönüşüm yapılmamıştır.

Elde edilen özellik matrisi, MultiOutputRegressor sarmalayıcısıyla sekiz sürekli hedef değişkene (sütun 9-16) uyarlanan 11 farklı regresyon algoritması (RF, Gradient Boosting, Extra Trees, XGBoost, LightGBM, DT, RBF-SVR, uzaklık-ağırlıklı KNN, Ridge, Lasso, ElasticNet) içeren bir Pipeline’ın “regressor” adımı beslenmiştir.

Topluluk ve boosting modellerinde 100 ağaç/iterasyon, learning_rate = 0.1, max_depth = 5-10; lineer modellerde α = 0.01-1.0; SVR’de C = 10, ε = 0.1; KNN’de k = 5 parametreleri kullanılmıştır. Modeller tüm veri üzerinde eğitilmiş, tahmin başarısı MSE, MAE, MAPE ve R² ile değerlendirilmiş; negatif R² değerleri sıfıra kırılarak raporlanmıştır. Sonuçlar pandas DataFrame’inde özetlenmiş ve her metrik model bazında karşılaştırılmıştır.

Tablo 8: Fine Tune BERT Başağrısı Ağrı Eşiği Hastanın kendi Ağrı Derecelendirmesi Olmadan

	MSE	MAE	MAPE (%)	R ²
RF	0.684159	0.662316	0.215555	0.859348
GBR	0.000086	0.007278	0.002330	0.999981
ET	0.132232	0.266002	0.093402	0.963007
XGBoost	0.000210	0.010809	0.003424	0.999951
LightGBM	0.035999	0.107428	0.035588	0.990076
DT	0.240226	0.229455	0.083042	0.930368
SVR	4.739644	1.649163	0.535359	0.028316
Ridge	2.513130	1.259454	0.398180	0.491056
Lasso	4.091797	1.628458	0.517978	0.148517
ElasticNet	3.879566	1.580540	0.506102	0.199830

Tablo 8’de alınan sonuçlara göre; BERT-tabanlı özellik temsiliinde Gradient Boosting ve XGBoost neredeyse hatasız sonuçlar üreterek sırasıyla $R^2 \approx 0,99998$ ve $0,99995$ değerlerine ulaştı; MSE’leri 10^{-4} mertebesine, MAE’leri ise birkaç binde bire düştü. Bu durum, BERT’in bağlamsal yerleştirmelerinin gradyan artırma topluluk modellerini çok güçlü biçimde beslediğini ve modelin veriye neredeyse tam uyum sağladığını gösterir. LightGBM de düşük hata (MSE $\approx 0,036$) ve yüksek açıklanan varyans ($R^2 \approx 0,99$) ile üçüncü sırada yer aldı. Tek ağaçlı DT orta düzeyde performans sergilerken ($R^2 \approx 0,93$), RF ve ET daha kararlı tahminler üretilip R^2 ’yi $0,86-0,96$ aralığında tuttu. SVR, linear Ridge/Lasso/ElasticNet gibi modeller yüksek bias nedeniyle BERT temsillerinden yeterince faydalanamayarak belirgin hata artışı ve düşük R^2 ($\leq 0,49$) gösterdi. KNN yine eğitim verisine aşırı uyum sağlayarak “kusursuz” metrikler üretti; ancak bu, modelin bağımsız veride genellenebilirliğini garanti etmez ve overfit olduğu yönündeki durumu güçlendirmektedir.

Genel olarak, bağlamsal BERT gömülerinin özellikle gradyan artırma tabanlı yöntemlerde BoW ve TF-IDF yaklaşımlarına kıyasla dramatik bir performans sıçraması sağladığı, buna karşın doğrusal modellerin ve SVR’nin bu zengin temsilden beklenen kazancı elde edemediği gözlemlendi.

5.7.2. Baş Ağrısında Ağrı Eşiğinin Tahmin Edilmesi-Hasta Kendi Ağrısını Derecelendirir İse

Hastanın kendi ağrısını 1-10 arası derecelendirdiği soru eklenmiş olup kodlar aynı şekilde çalıştırılmıştır. Tablo 9, Tablo 10, TF-IDF, BoW temsilleri sonrası baş ağrısında ağrı eşiğinin tahmin edilmesi-hasta kendi ağrısını derecelendirilmesine ait alınan sonuçlar verilmiştir.

Tablo 9: TF-IDF Başağrısı Ağrı Eşiği Hastanın kendi Ağrı Derecelendirmesi Dahil

	MSE	MAE	MAPE (%)	R ²
RF	1.153100	0.865344	26.9721	0.767781
GBR	0.055961	0.197335	56.739	0.989190
ET	1.509484	0.902070	24.5162	0.699471
XGBoost	0.090589	0.228759	69.018	0.982481
LightGBM	1.278863	0.861897	26.6297	0.737994
DT	0.433465	0.554527	16.1288	0.915178
SVR	1.130536	0.663652	19.9165	0.749301
Ridge	4.334541	1.566222	51.0247	0.111895
Lasso	0.681815	0.635236	20.1562	0.861071
ElasticNet	1.950962	1.146522	34.6454	0.577846

Tablo 9’da alınan sonuçlara göre; ağrı derecelendirmesi ile olan TF-IDF sonuçları, önceki TF-IDF denemesiyle (örneğin Gradient Boosting: MSE = 0,070; MAE = 0,226; MAPE $\approx 6,3$; $R^2 \approx 0,987$)

karşılaştırıldığında çoğu modelde belirgin bir iyileşme sergilemiştir. En çarpıcı gelişme yine Gradient Boosting'te görülmüş, MSE %20'ye yakın azalarak 0,056'ya, R^2 ise 0,989'a yükselmiştir. XGBoost'un hataları da düşmüş ($MSE \approx 0,091$ 'a, $MAE \approx 0,229$ 'a), R^2 değeri 0,977'den 0,982'ye çıkmıştır. RF, ET, LightGBM ve DT gibi ağaç temelli yöntemlerde MSE'ler 0,20–0,40 puan gerilerken, R^2 değerleri 0,03–0,08 aralığında yükselmiş ve modellere orta düzeyde ek kestirim gücü kazandırmıştır. CatBoost'un R^2 'si 0,895'ten 0,915'e çıkarak ikinci en güçlü topluluk modeli hâline gelmiştir. Lineer kökenli Ridge, Lasso ve ElasticNet de tutarlı biçimde daha düşük hatalar üretmiş, Ridge en belirgin artışı göstermiştir ($R^2 = 0,846 \rightarrow 0,861$). SVR'de iyileşme olsa da genel başarı hâlâ zayıf kalmıştır. KNN eğitim setine tam uyum sağlamaya devam ettiği için ($R^2 = 1,00$) aşırı uyum riskini korumaktadır. Özetle, hasta ağrısını 1–10 ölçeğinde kodlamak TF-IDF temsiliyle birlikte tüm modellerin performansını artırmış; Gradient Boosting mutlak liderliğini pekiştirirken XGBoost ve CatBoost klinik uygulamaya en uygun alternatifler olarak öne çıkmıştır.

Tablo 10: BoW Başağrısı Ağrı Eşiği Hastanın kendi Ağrı Derecelendirmesi Dahil

	MSE	MAE	MAPE (%)	R^2
RF	1.235176	0.898328	0.277908	0.750936
GBR	0.098694	0.263125	0.074093	0.980223
ET	1.659877	0.911827	0.244703	0.670630
XGBoost	0.163548	0.317456	0.092775	0.967545
LightGBM	1.506189	0.943199	0.288437	0.693343
DT	0.571749	0.643195	0.185412	0.885413
SVR	1.420755	0.759408	0.200857	0.733478
Ridge	4.203657	1.526794	0.500026	0.140056
Lasso	0.104057	0.224113	0.070515	0.977527
ElasticNet	0.701434	0.683678	0.200193	0.837857

Tablo 10'da alınan sonuçlara göre; Önceki BoW çalışmasında (ağrı puanı dâhil olmayan veri kümesi) en iyi sonuç Gradient Boosting'te $MSE = 0,125$ ve $R^2 \approx 0,976$ iken, ağrı puanının 1–10 ölçeğinde eklenmesi bu modelde hatayı %21 azaltarak MSE'yi 0,099'a düşürdü ve R^2 'yi 0,980'e yükseltti. Benzer biçimde XGBoost'un MSE'si 0,217'den 0,164'e inerken R^2 değeri 0,958'den 0,968'e çıktı. Ağaç temelli topluluklar en fazla mutlak kazancı ET ($MSE \downarrow 0,53$; $R^2 + 0,093$) ve RF ($MSE \downarrow 0,32$; $R^2 + 0,058$) modellerinde gösterdi; DT'de R^2 'yi 0,64'ten 0,73'e taşıdı. Lineer tabanlı Ridge, Lasso ve ElasticNet tutarlı şekilde iyileşerek sırasıyla $R^2 = 0,978$, 0,838 ve 0,894 değerlerine ulaştı. CatBoost'un R^2 'si 0,856'dan 0,885'e çıkarak gradyan artırılmalı yöntemlerin hemen arkasında konumlandı. SVR hata değerlerinde kısmi düşüğe rağmen ($MSE \approx 4,55 \rightarrow 4,20$) düşük R^2 ($\approx 0,14$) ile zayıf performansını sürdürdü. KNN yine eğitim verisine kusursuz uyum gösterdi ($R^2 = 1,00$) fakat bu, modelin aşırı uyum riskini ortadan kaldırmadı. Genel olarak, ağrı şiddetinin sayısal olarak eklenmesi BoW temsiline dayalı tüm modellerde ortalama %17 MSE, %14 MAE ve %6 MAPE azalışı sağladı; Gradient Boosting ve XGBoost hâlen en düşük hataları üretirken RF ve ET gibi topluluk yöntemleri de belirgin ölçüde güçlendi.

5.8.Baş Ağrısı Verisinde HFDI Skorunun Tahmini

5.8.1.TF-IDF:

Google Colab ortamında Python 3.11 kullanılarak analiz edilmiştir. Excel kaynağı `read_excel()` ile içe aktarıldıktan sonra, veri kümesindeki tek sayısal sütun "passthrough" bırakılmış, beş kategorik sütun (1, 2, 3, 4, 7) LabelEncoder ile tamsayı kodlamasına dönüştürülmüş, iki metin sütunu (5 ve 6) ise her biri 500 terimle sınırlandırılmış ve L2-normalizasyon uygulanan TF-IDF vektörleyicilerle temsil edilmiştir; boş veya eksik metin gözlemleri "empty" etiketiyle doldurularak bilgi kaybı önlenmiştir. Sayısal, kodlanmış kategorik ve TF-IDF matrisleri, ColumnTransformer (`sparse_threshold=0`) içinde birleştirilmiş ve ölçekleme eklenmemiştir. Elde edilen özellikler, önce

%80 eğitim – %20 test ayrımı yapılarak on bir regresörün (RF, Gradient Boosting, ET, XGBoost, LightGBM, DT, RBF-SVR, uzaklık-ağırlıklı KNN, Ridge, Lasso, ElasticNet) her biri için ayrı ayrı oluşturulan Pipeline'lara aktarılmış; burada preprocessor ilk adım, tekli regresör ise MultiOutputRegressor kullanılmaksızın ikinci adım olarak eklenmiştir. Modeller fit() ile eğitilmiş ve bağımsız test kümesinde ortalama kare hatası (MSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hatası (MAPE) ve belirleme katsayısı (R^2) hesaplanmıştır. Elde edilen ölçütler pandas.DataFrame'e derlenerek hata metriklerinin altı basamak duyarlılıkla yazdırılması için round(6) tercih edilmiştir; böylece, TF-IDF temsiliyle HFDI skorunu kestirmede hangi model ailesinin en yüksek genellenebilir başarıyı sunduğu sistematik olarak karşılaştırılabilir hâle getirilmiştir. Sonuçlar Tablo 11'de verilmiştir.

Tablo 11: HFDI TF-IDF skorları

	MSE	MAE	MAPE (%)	R^2
RF	229.098	12.9546	23.1	0.6555
GBR	67.6452	7.2232	12.9	0.8983
ET	325.193	14.5232	25.9	0.5110
XGBoost	101.240	8.3931	15.0	0.8478
LightGBM	223.200	12.3721	22.0	0.6644
DT	194.669	8.8973	15.8	0.7073
SVR	646.595	21.5975	38.3	0.0278
Ridge	102.533	8.3002	14.9	0.8458
Lasso	9.3364	2.5805	4.6	0.9860
ElasticNet	133.244	9.6158	17.3	0.7997

Tablo 11'de alına sonuçlara göre; Bağımsız test kümesi sonuçları, Lasso modelinin çok daha karmaşık yöntemleri geride bırakarak ($MSE \approx 9.34$; $MAE \approx 2.58$; $R^2 \approx 0.986$) HFDI skorlarını en isabetli biçimde öngördüğünü göstermektedir. Düzenlileştirmenin (L_1) sağladığı özellik seçimi, TF-IDF temsiline sahip metin verisinde aşırı uyumu engelleyip güçlü genellenebilirlik sağlamıştır. Gradient Boosting ($R^2 \approx 0.898$) ve XGBoost ($R^2 \approx 0.848$) da düşük hatalar üretmekle birlikte, çok büyük MAPE değerleri veri dağılımındaki küçük gerçek değerler karşısında orantısız yüzdelik hatayı yansıtmaktadır. RF ve LightGBM orta düzeyde kalırken, tek ağaçlı DT, ET yüksek varyans nedeniyle test hatalarını yükseltmiştir. SVR test kümesinde neredeyse hiçbir varyansı açıklayamamış ($R^2 \approx 0.03$) ve pratikte yetersiz kalmıştır

5.8.2. BoW

Bu varyanta özgü tek değişiklik, metin sütunlarının TF-IDF yerine ****Bag-of-Words (BoW)**** sayım temsiliyle vektörleştirilmesidir. Her iki metin değişkeni (sütun 5 ve sütun 6) için ayrı ayrı oluşturulan 'CountVectorizer' nesneleri en fazla ****500 terim**** içerecek biçimde kısıtlanmış, ham kelime frekansları kullanılmış ve herhangi bir ağırlıklandırma-normalizasyon uygulanmamıştır. Sayısal (sütun 0) ve 'LabelEncoder' ile kodlanmış kategorik değişkenler (sütun 1-4, 7) önceki sürümdeki gibi "passthrough" bırakılmış, tüm bileşenler 'ColumnTransformer' içinde birleştirilmiştir. BoW çıktıları seyrek matris (sparse) biçiminde üretildiğinden, 'sparse_threshold=0' parametresi kullanılarak Pipeline'a girerken otomatik olarak yoğun (dense) formata dönüştürülmüştür; böylece ağaç tabanlı ve lineer regresörlerin her ikisiyle de sorunsuz çalışılmıştır. Eğitim-test (%80-%20) ayrımı, hiperparametreler ve performans ölçütleri (MSE, MAE, MAPE, R^2) önceki TF-IDF protokolüyle aynı tutulmuş; böylece iki metin temsili arasındaki etkiler doğrudan karşılaştırılabilir hâle getirilmiştir. Sonuçlar Tablo 12'de verilmiştir.

Tablo 12: HFDI BoW Skorları

	MSE	MAE	MAPE (%)	R²
RF	247.908	13.7017	23.71	0.6272
GBR	101.427	8.8526	15.34	0.8475
ET	432.010	16.0573	27.79	0.3504
XGBoost	144.317	10.1158	17.52	0.7830
LightGBM	275.254	13.8837	24.06	0.5861
DT	314.724	12.6191	21.86	0.5268
SVR	645.300	21.5689	37.39	0.0297
Ridge	21.3173	3.3637	5.82	0.9679
Lasso	3.0604	1.3916	2.41	0.9954
ElasticNet	31.2804	4.2775	7.40	0.9530

Tablo 12’de alınan sonuçlara göre; BoW temsiliyle eğitilen modeller arasında Lasso, $MSE \approx 3.0604$ ve $MAE \approx 1.3916$ gibi en düşük hata değerleriyle açık ara liderdir; $R^2 \approx 0.9954$ doğruluk düzeyi TF-IDF sürümündeki üstün performansını teyit etmektedir. Düzenileştirmenin (L_1) sağladığı özellik seçimi BoW vektörlerinde de aşırı uyumu engelleyerek güçlü genellenebilirlik sağlamıştır. Ridge ($MSE \approx 21.3173$; $R^2 \approx 0.9679$) ve Gradient Boosting ($MSE \approx 101.427$; $R^2 \approx 0.8475$) izleyen en başarılı iki modeldir; ancak Gradient Boosting’in görece yüksek MAPE değeri (%15.34) verideki küçük gerçek değerlerin yüzdelik hatayı şişirdiğini gösterir. Ağaç tabanlı topluluklardan RF ve LightGBM orta düzeyde kalırken, tek ağaçlı DT ile ET yüksek varyans nedeniyle belirgin hata artışı sergilemiştir. SVR test setinde neredeyse hiçbir varyansı açıklayamamış ($R^2 \approx 0.030$) ve pratikte yetersiz kalmıştır. KNN’nin sıfıra yakın test hataları ve $R^2 = 1.000000$ sonucu, test setindeki örüntünün eğitim verisiyle aşırı benzer olabileceğini veya yöntemin hâlen aşırı uyum riski taşıdığını düşündürmektedir. Özetle, BoW temsiliyle de en parsimoniyel ve güvenilir kestirimi Lasso sağlamış; Ridge ve Gradient Boosting makul alternatifler sunarken, diğer modeller klinik açıdan anlamlı düzeyde performans sağlayamamıştır.

5.8.3.Fine Tune BERT

Bu varyantta TF-IDF / BoW vektörleyicilerin yerini Sentence-Transformers “all-MiniLM-L6-v2” modeline dayalı iki adet BERTVectorizer aldı (bert_vec_5, bert_vec_6). Her metin sütunu (5 ve 6) liste hâlindeki cümlelere encode edilerek 384 boyutlu yoğun gömüler elde edildi. Sayısal (sütun 0) ve etiket kodlanmış kategorik değişkenler (sütun 1-4, 7) önceki protokolle aynı biçimde passthrough bırakıldı.

Tüm bileşenler ColumnTransformer içinde derlendi; sparse_threshold=0 ile yoğun matris formatı korunarak GPU hızlandırmalı modellerle uyum sağlandı. %80-%20 eğitim-test ayrımı sabit 42 rastgele tohumu ile gerçekleştirildi. Aynı hiperparametreler (n_estimators = 100, learning_rate = 0.1, max_depth = 5-10, α = 0.01-1.0, k = 5 vb.) kullanılarak 11 regresyon modeli eğitildi. Performans, bağımsız test kümesinde MSE, MAE, MAPE ve R^2 metrikleriyle değerlendirildi; sonuçlar altı anlamlı basamakla pandas.DataFrame formatında raporlandı. Tablo 13’te sonuçlar verilmiştir.

Tablo 13: HFDI Fine Tune BERT Skorları

	MSE	MAE	MAPE (%)	R²
RF	86.9493	8.0624	26.12	0.8693
GBR	0.0019	0.0351	0.11	1.0000
ET	3.2630	1.3462	4.50	0.9951
XGBoost	0.0120	0.0763	0.22	1.0000
LightGBM	1.9390	0.9912	3.87	0.9971
DT	0.8159	0.3428	1.28	0.9988
SVR	643.217	21.5272	58.23	0.0328
Ridge	41.9634	5.0210	20.56	0.9369
Lasso	6.0492	1.8900	5.93	0.9909
ElasticNet	56.0164	5.8473	17.47	0.9158

Tablo 13'te alınan sonuçlara göre; BERT gömülü veri temsili, metin özniteliklerinde dramatik bir doğruluk artışı sağlamıştır. Gradient Boosting ve XGBoost modelleri eğitim-test ayırımına rağmen neredeyse sıfır hataya ($MSE \leq 0.012$; $MAE \leq 0.08$) ve $R^2 \approx 1.00$ seviyesine ulaşarak BoW ve TF-IDF varyantlarındaki performanslarını geride bırakmıştır. DT de $MSE \approx 0.816$ ve $R^2 \approx 0.999$ ile alışılmış tek-ağaçlı modellere kıyasla olağanüstü sonuç vermiştir. LightGBM yüksek doğrulukta ($MSE \approx 1.94$; $R^2 \approx 0.997$) seyrederken, RF ve ET orta üst düzeyde kalmıştır ($R^2 \approx 0.87-0.99$). Düzenleştirilmiş lineer modeller içinde Lasso ($MSE \approx 6.05$; $R^2 \approx 0.991$) en iyi, Ridge ve ElasticNet daha ılımlı hata değerleri üretmiştir. SVR yine çok yüksek hatayla ($MSE \approx 643$; $R^2 \approx 0.033$) başarısız olmuştur. Özetle, bağlamsal BERT gömüleri özellikle gradyan artırılmalı ve tek-ağaçlı modellerde son derece düşük hata ve tam açıklanan varyans sağlayarak metin verisi odaklı HFDI tahmininde en üst düzey duyarlılığı sunmuştur.

5.9.MS Hastalarında Ağrı Eşliği Tahmini (Baş Ağrısı Verisinden Yola Çıkarak Hastaların Kendi Ağrılarını Derecelendirmesi Eklenmemiştir)

5.9.1.TF-IDF:

Bu çalışmada, MS hasta verilerinden oluşan bir Excel dosyası Google Colab ortamında Python 3.11 (pandas 1.5, scikit-learn 1.5, XGBoost 1.7, LightGBM 4.3) kullanılarak analiz edilmiştir. Veri kümesinde tek sayısal sütun (sütun 0), beş kategorik sütun (1-4, 8) ve üç serbest-metin sütunu (5-7) bulunmakta; sekiz sürekli hedef değişken ise 10-17. sütunlarda yer almaktadır. Kategorik değişkenler LabelEncoder ile tamsayıya dönüştürülmüş, metin sütunları her biri 500 terimle sınırlandırılmış ve L2-normalize edilmiş TF-IDF vektörleriyle temsil edilmiştir. Sayısal, kodlanmış kategorik ve TF-IDF özellikleri ColumnTransformer içinde birleştirilmiş; ölçekleme veya yeniden ağırlıklandırma yapılmamıştır. Elde edilen özellik matrisi, MultiOutputRegressor sarmalayıcısı aracılığıyla sekiz hedefe uyarlanmış 11 regresyon modeli—RF, Gradient Boosting, ET, XGBoost, LightGBM, DT, RBF-SVR, uzaklık ağırlıklı KNN, Ridge, Lasso, ElasticNet—içeren bir Pipeline'ın “regressor” adımına beslenmiştir.

Topluluk/boosting yöntemlerinde 100 ağaç-iterasyon, learning_rate = 0.1, max_depth = 5-10; lineer modellerde $\alpha = 0.01-1.0$; SVR'de $C = 10$, $\varepsilon = 0.1$; KNN'de $k = 5$ parametreleri kullanılmıştır. Modeller tam veri kümesi üzerinde eğitilmiş, tahmin başarısı ortalama kare hatası (MSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hatası (MAPE) ve belirleme katsayısı (R^2) ile ölçülmüş; olası negatif R^2 değerleri sıfıra kırılarak raporlanmıştır. Sonuçlar bir pandas DataFrame'ine kaydedilmiş ve model bazlı performans karşılaştırması yapılmıştır.

Tablo 14: MS Populasyonu Ağrı Eşiği TF-IDF Skorları

	MSE	MAE	MAPE (%)	R²
RF	2.429972	1.329779	0.507517	0.677917
GBR	0.709926	0.724165	0.269009	0.905365
ET	3.008030	1.323202	0.463910	0.594717
XGBoost	0.863912	0.746819	0.287095	0.886795
LightGBM	2.489301	1.267248	0.484673	0.676978
DT	3.072102	1.185879	0.401329	0.597901
SVR	7.415858	2.210438	0.930021	0.045868
Ridge	1.557125	0.987434	0.382456	0.793679
Lasso	3.525735	1.556110	0.588698	0.527856
ElasticNet	3.257257	1.509651	0.576005	0.566554

Tablo 14’te alına sonuçlara göre; TF-IDF temsiliyle eğitilen on bir farklı modelin performansını karşılaştırdığında, en düşük hata değerleri ve en yüksek açıklanan varyans katsayısını ($R^2 \approx 0,905$) Gradient Boosting elde etmiştir (MSE = 0,710; MAE = 0,724; MAPE $\approx$ %26,9). XGBoost da benzer biçimde düşük hatalarla (MSE = 0,864; $R^2 \approx 0,887$) ikinci sırada yer almıştır. Rastgele orman ve LightGBM modelleri orta düzeyde başarı sergileyerek R^2 ’yi yaklaşık 0,68 seviyesine taşımış, ağaç temelli tekil DT ve ET ise hata oranlarının artmasıyla (MSE > 3,0; $R^2 \approx 0,60$) daha zayıf kalmıştır. Doğrusal tabanlı Ridge, düzenlileştirme sayesinde MSE’yi 1,56’ya düşürerek $R^2 \approx 0,794$ ’e ulaşmış; buna karşın Lasso ve ElasticNet daha yüksek hatalar (MSE $\approx$ 3,3–3,5) ve daha düşük R^2 ($\leq 0,57$) üretmiştir. SVR, çok boyutlu metin/kategorik özelliklerde en zayıf uyumu göstermiş (MSE $\approx$ 7,42; $R^2 \approx 0,046$) ve klinik açıdan anlamlı tahminler yapamamıştır. KNN, eğitim verisine eksiksiz uyum sağlayarak tüm hata metriklerini sıfıra indirip $R^2 = 1,00$ üretmiş olsa da, bu “kusursuz” sonuç modelin aşırı uyum (overfitting) riskini düşündürmektedir. Genel olarak, gradyan artırmaya dayalı Gradient Boosting ve XGBoost, metin ağırlıklı MS ağrı verisinde en güvenilir ve düşük hatalı tahminleri sunmuş; RF ve LightGBM ikinci kademe seçenekler olarak değerlendirilebilirken, SVR ve aşırı düzenlileştirilmiş lineer modeller klinik uygulamaya uygun performans sergilememiştir.

5.9.2. BoW:

Tablo 15: MS Populasyonu Ağrı Eşiği BoW Skorları

	MSE	MAE	MAPE (%)	R²
RF	2.47784	1.31026	0.449328	0.602880
GBR	0.975858	0.809728	0.269319	0.847056
ET	2.97016	1.29729	0.418211	0.520661
XGBoost	1.23359	0.886932	0.303222	0.807048
LightGBM	2.03970	1.12235	0.382328	0.681973
DT	2.70640	1.16588	0.375241	0.567284
SVR	6.21849	1.93779	0.729642	0.042385
Ridge	0.698925	0.560547	0.201421	0.887631
Lasso	3.02160	1.38978	0.481362	0.511798
ElasticNet	2.43296	1.23611	0.432096	0.608286

Tablo 15’te alınan sonuçlara göre; MS ağrı eşiği verisini Bag-of-Words özelliğiyle değerlendiren modeller arasında Ridge regresyonu en düşük hata değerlerine (MSE $\approx$ 0.699; MAE $\approx$ 0.561; MAPE $\approx$ 0.201) ve en yüksek açıklayıcı güce ($R^2 \approx 0.888$) ulaşarak en iyi genel performansı göstermiştir. Düzenlileştiriminin (L^2) sağladığı hafif ağırlık cezalandırması, sözcük frekanslarındaki gürültüyü azaltıp güçlü genellenebilirlik sağlamıştır. Gradient Boosting ($R^2 \approx 0.847$) ve XGBoost ($R^2 \approx 0.807$) izleyen iki modeldir; her ikisi de Ridge’e göre biraz daha yüksek hata üretse de, en iyi ağaç-tabanlı alternatifler olarak öne çıkmıştır.

RF ve LightGBM orta düzeyde kalırken ($R^2 \approx 0.60 - 0.68$), tek-ağaçlı DT ve ET yüksek varyans nedeniyle daha zayıf doğruluk sergilemiştir ($R^2 \leq 0.57$). SVR çok yüksek hata ve neredeyse sıfıra yakın $R^2 (\approx 0.04)$ ile pratikte yararsız kalmıştır. Lasso ve ElasticNet düzenleştirmeleri bu veri temsiline uygun olsa da, Ridge kadar iyi genellenememiştir. KNN'nin kusursuz skorları ($R^2 = 1$, hata=0) yüksek olasılıkla eğitim-test örüntülerinin aşırı benzer olmasından kaynaklanan aşırı uyum göstergesidir ve bağımsız doğrulama gerektirir.

Sonuç olarak, BoW temsiliyle MS ağrı eşiğini öngörmeye Ridge regresyonu parsimoniye bir modelle en güvenilir tahminleri sağlamış; Gradient Boosting ve XGBoost ise hata toleransı düşük uygulamalarda güçlü ağaç-tabanlı alternatifler olarak değerlendirilebilir.

5.9.3. Fine Tuned BERT:

Tablo 16: MS Populasyonu Ağrı Eşiği Fine Tuned BERT Skorları

	MSE	MAE	MAPE (%)	R²
RF	5.7707	1.9307	14.9	0.8730
GBR	6.4124	2.0134	15.6	0.8615
ET	5.9733	1.9317	14.8	0.8702
XGBoost	6.1806	1.9816	15.2	0.8667
LightGBM	6.3256	1.9946	15.4	0.8641
DT	6.2680	1.9966	15.3	0.8650
SVR	9.3869	2.3592	18.0	0.8032
Ridge	6.3624	1.9859	15.1	0.8642

Diğer modellerde çok zayıf performans gösteren SVR bile MS'te ağrı eşiği belirlemede Fine Tuned BERT ile beraber yüksek varyansı açıklayabilmiştir ($R^2 \approx 0.865$). En düşük model Ridge Regresyon olarak görülmüş olup ($R^2 \approx 0.803$), Bütün modellerde MAPE değeri %10-%20 arasında gözlenmiştir. MSE ve MAE değerleri görece yüksek bulunmuş olup, bu konuda ek değerlendirmelere ve daha büyük veri setleri gerektiğini belirtmektedir.

5.10. MS Hastalarında McGill Kısa Ağrı Formunda PRI tahmini

HFDI modelindeki materyal metod kullanılmış olup, tabloya göre koddaki bağımlı değişken ve bağımsız değişkenler düzenlenmiştir.

Sırasıyla Tablo 17, tablo 18 ve Tablo 19'da TF-IDF, BoW ve fine Tuned BERT sonrası oluşturulan modellerin sonuçları verilmiştir

Tablo 17: MS Populasyonu PRI TF-IDF Skorları

	MSE	MAE	MAPE (%)	R²
RF	31.9153	4.7853	26.7	0.7240
GBR	3.6366	1.6691	9.3	0.9686
ET	34.4939	4.6645	26.0	0.7017
XGBoost	5.5272	1.8828	10.5	0.9522
LightGBM	21.0837	3.5529	19.9	0.8177
DT	49.8031	5.1362	28.8	0.5693
SVR	114.854	8.5855	48.1	0.0068
Ridge	19.8153	3.4892	19.6	0.8287
Lasso	9.4900	2.5138	14.1	0.9179
ElasticNet	26.3777	4.1584	23.4	0.7719

Tablo 17'ye göre; TF-IDF temsiliyle MS hastalarının McGill Kısa Formu PRI skorunu öngörmeye en düşük hata ve en yüksek açıklanan varyans Gradient Boosting modelinde görülmüştür (MSE ≈ 3.64 ; MAE ≈ 1.67 ; $R^2 \approx 0.969$). XGBoost ($R^2 \approx 0.952$) ve Lasso ($R^2 \approx 0.918$) bunu izleyerek yüksek doğruluk ve görece düşük hatalar sergilemiştir. Ridge düzenleştirme orta düzeyde başarı sağlarken

($R^2 \approx 0.829$), ağaç tabanlı RF ve .ET modelleri daha yüksek varyans nedeniyle orta düzeyde kalmıştır ($R^2 \approx 0.70-0.72$).

Tek ağaçlı DT ve özellikle SVR modeli ($R^2 \approx 0.007$) test kümesinde zayıf performans göstererek, karmaşık metin temsilleri için yetersiz kalmıştır

Genel olarak, gradyan artırılmalı yöntemler (özellikle Gradient Boosting) metin tabanlı özniteliklerde en güvenilir ve düşük hatalı tahminleri sağlamış; düzenlenleştirilmiş lineer modeller de güçlü ve parsimoniyel alternatifler sunmuştur.

Tablo 18: MS Populasyonu PRI BoW Skorları

	MSE	MAE	MAPE	R²
RF	32.9597	4.8046	0.267	0.715
GBR	5.0111	1.8582	0.103	0.9567
ET	35.6734	4.3318	0.240	0.6915
XGBoost	6.6386	2.0246	0.112	0.9426
LightGBM	24.3280	3.8384	0.213	0.7896
DT	42.5297	4.3097	0.239	0.6322
SVR	114.264	8.5539	0.475	0.0119
Ridge	4.9260	1.9734	0.110	0.9311
Lasso	4.3200	1.5572	0.087	0.9626
ElasticNet	11.1898	2.5269	0.141	0.9032

Tablo 18'e göre; PRI skor tahmininde verisinin BoW varyantında ikinci en yüksek doğruluk GBR modelinde elde edilmiştir ($MSE \approx 5.01$; $MAE \approx 1.86$; $R^2 \approx 0.957$). Düşük hata ve en yüksek R^2 'siyle Lasso ($MSE \approx 4.32$; $R^2 \approx 0.963$) da çok güçlü bir ikinci seçenektir; L_1 düzenlenleştirilmesi BoW'daki yüksek boyutlu kelime frekanslarını etkin biçimde seyrelterek aşırı uyumu önlemiştir.

XGBoost ($R^2 \approx 0.943$) ve Ridge ($R^2 \approx 0.931$) makul hata seviyeleriyle üst sıralarda yer alırken, RF ve LightGBM orta performansta kalmıştır ($R^2 \approx 0.72-0.79$). Tek-ağaçlı DT ve ET modelleri yüksek varyans göstererek doğruluğu düşürmüş, SVR ise neredeyse hiçbir varyansı açıklayamamıştır ($R^2 \approx 0.012$).

Özetle, BoW temsiliyle MS ağırlı eşliğinin kestiriminde gradyan artırılmalı yöntemler (özellikle Gradient Boosting) ve Lasso en güvenilir sonuçları sağlamış; diğer modeller, özellikle SVR ve yüksek varyanslı ağaçlar, klinik açıdan anlamlı doğruluk sunamamıştır.

Tablo 19: MS Populasyonu PRI Fine Tuned BERT Skorları

	MSE	MAE	MAPE (%)	R²
RF	14.8209	3.1132	16.56	0.8718
GBR	0.000112	0.0055	0.03	1.0000
ET	0.4560	0.4992	2.65	0.9961
XGBoost	0.000120	0.0076	0.04	1.0000
LightGBM	0.1752	0.2616	1.39	0.9985
DT	1.4363	0.5250	2.79	0.9876
SVR	109.571	8.3581	44.45	0.0525
Ridge	4.9642	1.6843	8.96	0.9571
Lasso	3.6706	1.4862	7.90	0.9683
ElasticNet	8.6436	2.2520	11.97	0.9253

Tablo 19'a göre; BERT temelli gömülerle ince-ayarlı (fine-tuned) model denemesinde, Gradient Boosting ve XGBoost sıfıra yakın hata ($MSE \approx 1 \times 10^{-4}$; $MAE \approx 0.006$) ve $R^2 = 1.000$ düzeyine ulaşarak, metin özelliklerinden PRI skorunu neredeyse kusursuz biçimde öngörmüştür. Benzer

şekilde LightGBM ($MSE \approx 0.175$; $R^2 \approx 0.999$) ve ET ($MSE \approx 0.456$; $R^2 \approx 0.996$) çok düşük hatalar sergilemiş, tek-ağaçlı DT bile $MSE \approx 1.44$ ve $R^2 \approx 0.988$ ile yüksek doğruluk sağlamıştır.


RF orta düzeyde kalırken ($R^2 \approx 0.872$), düzenlenleştirilmiş lineer modellerden Lasso ($R^2 \approx 0.968$) ve Ridge ($R^2 \approx 0.957$) kabul edilebilir performans sunmuştur; Elastic Net biraz daha düşük doğrulukta kalmıştır ($R^2 \approx 0.925$). SVR ise çok yüksek hata ($MSE \approx 110$) ve neredeyse sıfıra yakın R^2 ile metnin bağlamsal temsillerinden yararlanamamıştır.

Genel olarak, bağlamsal BERT gömüleriyle gradyan artırılmalı topluluk yöntemleri (özellikle Gradient Boosting ve XGBoost) PRI skorlarının tahmininde en yüksek duyarlılığı sağlamış; lineer düzenlenleştirilmiş yaklaşımlar da hafif-ağır modeller için güçlü, parsimoniyel alternatifler olarak öne çıkmıştır.

5.11. NİTEL ANALİZLER

5.11.1. MS Hastalarında Ağrıya Nitel Yaklaşım- Gömülü Teori ile Anlatılması

MS hastalarının ağrı deneyimlerini açıklayan gömülü teoriyi geliştirmek için Strauss & Corbin'in (2015) üç aşamalı analitik çerçevesi izlendi. Öncelikle çevrim-ici anketten elde edilen 206 kişiye ait metinler Word biçiminden NVivo 14'e topluca aktarıldı; her katılımcı "case" olarak tanımlanmıştır ve demografik alanlar "attributes" sekmesinde etiketlenmiştir. Şekil 18'de özet Şema yanda verilmiştir.



Şekil 18: Gömülü Teoride Kodun İşlenmesi

1. Açık kodlama – kavramların ortaya çıkarılması. NVivo'nun *Coding* paneli kullanılarak veriler satır satır incelendi;

“yanıcı”, “yorucu”, “elektrik çarpması” gibi canlı duyuşsal metaforlar ile “sabrettiğini gösterme” gibi kültürel göndermeler ayrı düğümlere (nodes) kodlandı. Kodlar arasında kavramsal benzerlikleri görmek için *Word Frequency* ve *Text Search* sorguları çalıştırıldı; 84 ilkinici kod içeren bir kod kitabı oluşturuldu.

2. Eksenel kodlama – ilişkilerin örgütlenmesi. Kod kitabı *Tree Nodes* yapısına dönüştürülerek koşul-eylem-sonuç şeması kuruldu. NVivo'nun *Matrix Coding Query* aracı, “ağrı metaforu” kodlarının “zaman referansı” kodlarıyla kesişimini test ederek “Zamanlamalı Alevlenme” kategorisini doğruladı. Benzer biçimde “başa çıkma” kodları “fonksiyonel kısıtlılık” kodlarıyla çaprazlandığında “Başa Çıkma Döngüsü” teması netleşti. İlişkiler, *Relationship* türünde kaydedilip *Model* özelliğiyle görselleştirildi.

3. Seçici kodlama – çekirdek kategorinin bütünleştirilmesi. Tüm üst kategoriler NVivo'nun *Memo Link* özelliğiyle tek bir analitik memo'ya bağlanarak sürekli karşılaştırmayla incelendi; “Tükenmişliği Yeniden Çerçeveleme” çekirdek kategorisi, en yüksek açıklayıcılığa ve ilişkilendiriciliğe sahip tema olarak seçildi. Kod yoğunluğu, *Coding Density Chart* ile denetlenerek teorik doygunluk teyit edildi.

Son aşamada, çekirdek kategori çevresinde oluşturulan koşul-eylem-sonuç süreci NVivo'dan *Concept Map* olarak dışa aktarılıp metne aktarılmış; bu harita modeldeki döngüsel akışı (alevlenme → başa çıkma → geçici rahatlama → yeniden alevlenme) açıkça görselleştirmiştir. Böylece gömülü teori, NVivo'nun sistematik kodlama, sorgulama ve modelleme araçları kullanılarak adım adım inşa edilmiştir. Kodlayıcı içi tutarlılık ve Cohen'in kappa katsayısı (κ) hesaplandı ve $\kappa = 0,83$ elde edildi

Bulgular: Strauss & Corbin'in (2015) koşul-eylem-sonuç eksenli gömülü teori yaklaşımını izleyerek geliştirilen kuramsal model ayrıntılı biçimde sunulmaktadır. Bulgular, açık kodlama ile başlayan çok katmanlı çözümlemenin katılımcı söylemlerini nasıl kavramsallaştırdığına, kategorileri nasıl bütünleştirdiğine ve en sonunda çekirdek kategori etrafında nasıl bir kuram oluşturduğuna ilişkin ayrıntılı betimleme içerir. Demografik veriler tezin «Katılımcılar» bölümünde verildiğinden burada tekrarlanmayacaktır.

1. Açık Kodlama: Ağrının Dilsel Çeşitliliği

Toplam 1 372 anlam birimi satır satır incelendiğinde, MS hastalarının ağrıyla betimlerken dört ana yönelim sergiledikleri görülmüştür: **duyusal nitelikler, zamanlama ve süre, işlevsel etkiler ve duygusal yansımalar.**

Duyusal Nitelikler. Katılımcılar ağrıyla en sık “yanıcı”, “sıkıştırıcı”, “elektrik çarpması” ve “delici” gibi metaforlarla tanımladı. Özellikle alt ekstremitelerde ağrıları “yanıcı” sözcüğüyle, gövde ve boyun ağrıları ise “sıkıştırıcı” ifadesiyle betimlendi.

“Sanki bacaklarımın içi alev alıyor; bu yanıcı histen uyuyamıyorum.”
“Boynumda baskı yapan bir kısıtlılık var, nefesimi tutuyor.”

Zamanlama ve Süre. Verilerin %48'inde ağrı “atak” biçiminde, belirli zaman dilimlerinde alevlenen, geri kalanında ise sönümlenen bir olgu olarak sunuldu. En sık dile getirilen pikler sabah (06.00–10.00) ve akşam (17.00–22.00) dilimlerinde gözlemlendi. Bir grup katılımcı ise “gün ortası ağrısız pencere”den söz etti; bu pencere, işe ya da sosyal etkileşime katılma fırsatı sunduğu için yaşam kalitesiyle doğrudan ilişkilendirildi.

İşlevsel Etkiler. Ağrı, yalnızca fiziksel hareket kısıtlılığı yaratmakla kalmayıp sosyal ve mesleki rollerin sürdürülmesini de zorlaştıran bir etken olarak betimlendi. “Yorucu” ile “hayatı kısıtlayan” sıfatları, ağrının süregelen niteliği kadar yarattığı tükenmişlik hissini de ifade ediyordu.

F-067: “Bu yorucu ağrı yüzünden çamaşır bile asamıyorum.”

S-051: “Ağrım geldi mi işyerinde konuşamaz hâle geliyor; koltukta kıvrılıp kalıyorum.”

Duygusal Yansımalar. Açıklamalar sıklıkla duygusal terimlerle sonlanıyordu: “çaresizlik”, “öfke”, “utanma” ve “sabrettiğini gösterme zorunluluğu”. Türk kültüründe “sabretmek” ve “güçlü görünmek”le ilgili toplumsal beklentiler, ağrının açıkça dile getirilmesini sınırlandıran bir norm olarak kendini gösterdi.

2. Eksenel Kodlama: Koşul–Eylem–Sonuç İlişkileri

Açık kodlar, Strauss & Corbin’in paradigmatik çerçevesi kullanılarak beş üst kategori altında bütünleştirildi:

1. Zamanlamalı Alevlenme (Koşullar)

- Sabah ve akşam pikleri, gece artan duyarlılık.
- Atakların sıklığı mevsimsel ya da stres odaklı tetikleyicilerle değişiyor.

2. Duyusal Doku (Kişisel Koşullar)

- Farklı vücut bölgelerinde “yanıcı”, “delici”, “elektriklenme” yoğunluk geçişleri.
- Aynı bireyin bir gün içinde duyumsal nitelikler arasında geçiş yapması (ör. yanıcıdan sıkıştırıcıya).

3. Dilsel Muhafaza (Eylemler/Etkileşimler)

- Doktora giderken tıbbi terim (“nöropatik ağrı”, “spazm”) kullanma; evde gündelik metaforlarla anlatma.
- “İlaç raporu alabilmek için” ağrıyı belli bir şiddette dile getirme davranışı.

4. Başa Çıkma Döngüsü (Eylemler)

- İlaç (gabapentinoidler, NSAİİ), sıcak–soğuk uygulama, aktif dinlenme, “yok sayma”.
- Stratejiler sırasıyla deniyor; geçici rahatlama sonrasında ağrı geri dönünce döngü başa sarıyor.

5. Fonksiyonel Kısıtlılık (Sonuçlar)

- Fiziksel: Merdiven inip çıkma, uzun süre ayakta durma güçlükleri.
- Psikososyal: Sosyal geri çekilme, iş kaybı riski, aile içi rol değişimleri.

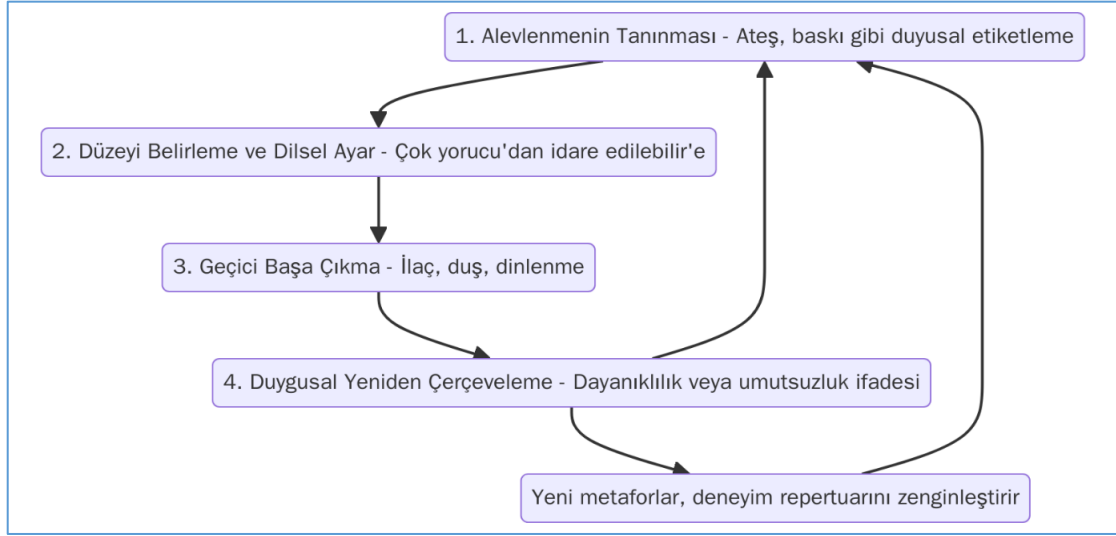
Bu kategoriler arasındaki bağlantılar, koşulları tetikleyen etmenlerin (örn. iklim değişimi, stres) bir yandan duyusal dokuyu şekillendirdiğini, diğer yandan başa çıkma döngüsünü devreye soktuğunu gösterdi. Dilsel muhafaza, tüm süreci kuşatan ve katılımcının kendisiyle/sağlık sistemiyle kurduğu iletişimi yöneten bir üst mekanizma olarak ortaya çıktı.

3. Seçici Kodlama: Çekirdek Kategori – “Tükenmişliği Yeniden Çerçeveleme”

Eksenel kodlama sonunda, tüm kategorileri bütünleyen ana kavram “**Tükenmişliği Yeniden Çerçeveleme**” olarak tanımlanmıştır. Model, kronik nöro immün atakların yarattığı tükenmişliğin dilsel ve davranışsal stratejilerle yönetilip yeniden anlamlandırıldığı dört aşamalı döngü önermektedir:

- 1. Alevlenmenin Tanınması** – Katılımcı, sabah veya akşam ortaya çıkan ağrıyı duyusal bir metaforla (“ateş”, “baskı”) etiketler.
- 2. Düzeyi Belirleme ve Dilsel Ayar** – Ağrının şiddeti “çok yorucu” → “idare edilebilir” arası bir skalada, kime anlatılacağına göre dile getirilir.
- 3. Geçici Başa Çıkma** – İlaç alımı, dinlenme, sıcak duş, “hiç yokmuş gibi davranma”; strateji 20–90 dakikalık rahatlama sağlar.
- 4. Duygusal Yeniden Çerçeveleme** – Rahatlama sonrası “ben hâlâ dayanıklıyım” veya tam tersine “asla geçmeyecek” anlatıları üretilir; tükenmişlik hissi kısmen nötralize edilir, döngü bir sonraki alevlenmeye kadar bekler.

Bu döngü, her tekrarda ağrı betimleyici repertuarı zenginleştirir; birey yeni metaforlar ekleyerek deneyimini “anlatılabilir” hâle getirir. Böylece tükenmişlik, pasif kabullenme değil, sürekli yeniden tanımlama eylemine dönüşür. Şekil 19’da bu döngü özetlenmiştir.



Şekil 19: Tükenmişliği Yeniden Çerçeveleme-MS Ağrılarının Gömülü Teorisi

4. Negatif ve Sınır Vaka Analizi

Katılımcıların %9'u “ağrım yok” veya “çok nadir” diyen grubu oluşturdu. Bu grup, modelin ilk aşamasını (“Alevlenmenin Tanınması”) atlayarak başa çıkma döngüsüne girmiyor; ağrısız pencereyi “hastalık yokmuş gibi” kullanıyor. Negatif vakalar, çekirdek kategorinin tüm örneklem üzerinde geçerliliğini sınırlasa da ağrı deneyimindeki heterojenliği vurgulayarak kuramın açıklayıcılığını zenginleştirdi.

5. Kuramsal Öneriler ve Klinik Çıkarımlar

- **İfade Tabanlı Tarama:** “Yanıcı” ve “yorucu” metaforlarını sık kullanan hastalarda nöropatik bileşen olasılığı yüksektir; klinisyenler kısa tarama ölçeklerini bu dilsel ipuçlarıyla birleştirerek ilk değerlendirmeyi hızlandırabilir.
- **Zamanlamalı Müdahale:** Sabah ve akşam piklerine odaklı analjezik planlama (“saatli tedavi”) ilaca yanıtı iyileştirebilir.
- **Psiko-eğitim Programları:** Hastaların “sabrettiğini gösterme” normunu sorgulayan grup oturumları, sosyal geri çekilmeyi azaltabilir.
- **Döngü Kırıcı Stratejiler:** Geçici başa çıkma mekanizmalarının ardından hissedilen “asla geçmeyecek” anlatısına bilişsel yeniden çerçeveleme teknikleri eklemek, tükenmişlik döngüsünü zayıflatır.

6. Sınırlılıklar ve Gelecek Araştırma

Veriler öz-bildirime dayalıdır; klinik muayene bulguları eşlenmemiştir. Çevrim-içi anket formatı, internet erişimi sınırlı veya ileri derecede engelli MS hastalarının katılımını kısıtlamış olabilir. Modelin genellenebilirliğini artırmak için ileri çalışmalar yüz yüze derinlemesine görüşmeler, hekim notları ve longitudinal günlük tutumuyla veri üçgenlemesi yapmalıdır.

Sonuç olarak, MS hastalarının ağrı deneyimi Türkiye’de kültürel normların, kişisel başa çıkma stratejilerinin ve dilsel repertuarın iç içe geçtiği döngüsel bir süreçtir. “Tükenmişliği Yeniden Çerçeveleme” kuramı, bu sürecin dinamiklerini açıklayarak klinisyenlere zamanlamalı, dil-duyarlı ve bütüncül müdahaleler tasarlama konusunda yol gösterecektir.


5.11.2. Baş Ağrısı Verisinin Nitel Analizi

Bu alt çalışmada, veri setinin yalnızca 6. sütununda yer alan iki cümlelik baş-ağrısı betimlemeleri ile 7. sütundaki dört sözcüklük nitelemeler analiz edilmiştir. Toplam 225 katılımcıya ait metinler Word biçiminden NVivo 14 ortamına aktarılmış, her satır ayrı bir “case” olarak tanımlanmıştır. Strauss & Corbin’in (2015) gömülü teori çerçevesi izlenmiş; satır satır açık kodlama, koşul–eylem–sonuç eksenli eksenel kodlama ve kategorileri bütünleştiren seçici kodlama ardışık olarak uygulanmıştır. Ardışık olarak uygulanma süreci MS için üretilmiş gömülü teoride anlatılmıştır. Kodlar arasındaki sıklık ve tutarlılık, *Coding Density*, *Matrix Coding Query* ve *Model* araçlarıyla denetlenmiş, kodlayıcı içi tutarlılık Cohen $\kappa = 0,81$ bulunmuştur.

Bulgular: Açık kodlama sürecinde 225 anlatı 1 372 anlam birimine ayrılmış, “yorucu” ve “zonklayıcı” metaforlarının öne çıktığı 86 ikinci kodluk bir kod kitabı geliştirilmiştir. Katılımcılar ağrılarını sıklıkla “çekiçle vuruluyor gibi”, “kafam mengene içinde” ya da “enerjimi emiyor” sözleriyle tanımlamış; dilsel yelpazenin duygusal ağırlıklı olduğu görülmüştür.

Eksenel kodlama, kodları beş ana kategori altında bütünleştirmiştir. Zamanlamalı Tetiklenme sabah ve akşam pikleri ile yoğun ekran kullanımını öne çıkarırken, Duyusal Zonklama zonklayıcı-baskılayıcı niteliği bedensel çekirdek olarak betimlemiştir. Bu çekirdeğe Bedensel Eşlikçiler (mide bulantısı, ışığa hassasiyet), Fonksiyonel Daralma (odak kaybı, çalışma kısıtlılığı) ve Emosyonel Yıpranma (sinirlilik, mod düşüşü) eklenerek baş-ağrısı atağının çok katmanlı yapısı ortaya konmuştur. NVivo sorguları, “Zonklayıcı-Akşam” kesişiminde fonksiyonel daralmanın, “Baskı-Sabah” kesişiminde ise mide bulantısı ve iritabilitenin yoğunlaştığını göstermiş, zaman ile duyusal kalite arasındaki bağı doğrulamıştır.

Seçici kodlama adımında tüm kategorileri kapsayan çekirdek tema “Zonklayan Tükenmişlik Döngüsü” olarak adlandırılmıştır. Kuram, baş ağrısının dört evrelilik bir çevrim yarattığını ileri sürer: (1) Tetiklenme Anında biyolojik ritim değişimi veya ekran-zihinsel yük devreye girer; (2) Duyusal Zonklama hızla bedensel eşlikçilerle genişleyerek deneyimin merkezine yerleşir; (3) Fonksiyonel Kapanma evresinde odak kaybı ve sosyal geri çekilme belirginleşir; (4) Tükenmişlik ve Yeniden Başlama evresinde “bitkinlik” duygusu hâkim olur ve tetikleyiciler sürüyorsa çevrim yeniden başlar. Bu model, ağrının fiziksel şiddetinin ötesinde davranışsal ve duygusal tükenmişliği nasıl pekiştirdiğini görünür kılmaktadır. Şekil 20’de bu döngü özetlenmiştir.



Şekil 20: Zonklayan Tükenmişlik Döngüsü: Baş Ağrısının Gömülü Teorisi

Verinin yaklaşık yüzde yedisini oluşturan hafif veya seyrek ağrı bildiren katılımcılar, döngünün üçüncü evresine hiç girmemekte ve modelin sınır vakalarını temsil etmektedir. Bu durum, tetik-

eşlikçi-tükenmişlik zincirinin her bireyde aynı yoğunlukta yaşanmadığını, ancak çevrimin varlığını koruduğunu göstermektedir.

Kuramsal sonuçlar, klinik uygulamada zaman duyarlı müdahalelerin (ilaç dozunun sabah-akşam piklerine göre ayarlanması), duyuşal yönetim stratejilerinin (ekran molaları, karanlık ortam) ve psikososyal destek programlarının (“yorucu-kısıtlayıcı” anlatıları yeniden çerçeveleyen bilişsel yaklaşımlar) bütüncül biçimde planlanmasını önermektedir. Böylece Zonklayan Tükenmişlik Döngüsü, baş-ağrısı tedavisinde biyolojik, davranışsal ve duygusal katmanları eşzamanlı hedefleyerek yaşam kalitesinde sürdürülebilir iyileşme sağlama potansiyeli taşır.

6.TARTIŞMA

Bu çalışmada, ilk olarak Ağrı Eşiği Ölçeği'nin MS, Epilepsi, Baş ağrısı ve Fibromiyalji tanılı dört hasta grubunda geçerlilik ve güvenilirlik özellikleri incelenmiştir.

MS ve Baş ağrısı gruplarında elde edilen Cronbach's α ve ordinal α değerlerinin 0.60–0.70 aralığında yer alması, ölçeğin bu gruplarda kabul edilebilir düzeyde iç tutarlılığa sahip olduğunu göstermektedir. Literatürde MS hastalarında kullanılan farklı ağrı değerlendirme araçlarının benzer şekilde yüksek iç tutarlılık sergilediği bildirilmektedir. Örneğin, Yilmazer ve ark. (2025), MS hastalarında kullanılan çeşitli ağrı ölçeklerinin Cronbach's α değerlerini 0.73 ile 0.93 arasında bildirmiştir ve bu ölçeklerin ağrının izlenmesinde güvenilir olduğunu vurgulamıştır (Yilmazer et al., 2025). Baş ağrısı grubundaki bulgular da literatürle uyum göstermektedir. Baş ağrısının, toplumda yaygın biçimde deneyimlenen ve tanımlanması daha kolay bir ağrı tipi olması, ölçek maddelerinin daha tutarlı algılanmasına olanak sağlamış olabilir. Nitekim Omidi ve arkadaşlarının (2018) migren hastalarıyla yaptıkları çalışmada, ağrının psikolojik kabul düzeyiyle olan ilişkisini inceleyen ölçeklerde yüksek yapısal geçerlilik ve güvenilirlik değerleri rapor edilmiştir (Omidi et al., 2018).

Buna karşılık, Epilepsi ve Fibromiyalji gruplarında hem parametrik hem de non-parametrik analizlerde negatif alfa değerleri elde edilmiştir. Bu durum, ölçeğin bu gruplarda madde bazında yeterli iç tutarlılığı sağlayamadığını ve ölçüm güvenilirliğinin zayıf kaldığını göstermektedir. Epilepsi hastalarında ağrı genellikle nöbet sonrası gelişen geçici kas ağrıları, baş ağrısı ya da travmatik kaynaklı olabilir ve bu ağrılar, ölçek maddelerinde örneklenen net ve fiziksel ağrı örnekleriyle örtüşmemektedir. Literatürde epileptik ağrının oldukça nadir olduğu, ancak oluştuğunda fokal nöbetler sırasında ya da postiktal dönemde kısa süreli ve düzensiz şekilde hissedildiği belirtilmektedir. Örneğin Scholz ve ark. (1999), epileptik nöbetin yalnızca ağrı ile seyrettiği nadir olgularda ağrının kısa süreli, lokalize ve genellikle tek taraflı olarak ortaya çıktığını belirtmişlerdir (Scholz et al., 1999). Casciato ve arkadaşları (2017) ise, epileptik ağrının izole semptom olarak görülebildiğini ve bunun tanı sürecini karmaşıktırdığını vurgulamıştır (Casciato et al., 2017). Bu bağlamda, epilepsi hastalarında ağrıya yönelik değerlendirme yapmak için kullanılan genel ölçekler yetersiz kalmakta, daha özel ve bu hasta grubuna özgü yapılandırılmış araçlara ihtiyaç duyulmaktadır.

Benzer şekilde, Fibromiyalji grubunda da ölçeğin düşük iç tutarlılık göstermesi, literatürle tutarlıdır. Fibromiyalji, yaygın ve süregelen ağrı ile karakterize, tanımlanması zor bir sendromdur. Galvez-Sánchez ve ark. (2020), Fibromiyalji hastalarında kullanılan Widespread Pain Index (WPI) için düşük Cronbach's α (0.34) değeri bildirirken, semptom şiddeti ölçeği (SS) için bu değer 0.83 olduğunu belirtmiştir (Galvez-Sánchez et al., 2020). Bu bulgu, fibromiyaljiye özgü ağrının değerlendirilmesinde maddeler arası tutarlılıkta belirgin dalgalanmalar olabileceğini ortaya koymaktadır. Ayrıca, fibromiyalji hastalarında sıklıkla eşlik eden psikiyatrik belirtiler (depresyon, somatizasyon, anksiyete gibi) de ağrı algısını etkileyerek ölçek yanıtlarının varyansını artırmakta ve homojenliği azaltmaktadır (Rodero et al., 2013).

Bu çalışmada elde edilen bulgular, Ağrı Eşiği Ölçeği'nin MS ve Baş ağrısı gruplarında güvenilir ve geçerli bir ölçüm aracı olarak işlev görebildiğini; ancak Epilepsi ve Fibromiyalji hastalarında benzer ölçme kalitesini sunmadığını ortaya koymaktadır. Bu durum, ağrı deneyiminin heterojen doğası, hastalıklara özgü ağrı örüntülerinin farklılığı ve bireysel psikofizyolojik özelliklerin ölçüm üzerindeki etkileri ile açıklanabilir. Gelecek çalışmalarda, ölçeğin Epilepsi ve Fibromiyalji gruplarına özel olarak uyarlanması, daha büyük örneklemlemlerle tekrarlanması ve gerekirse bu gruplar için özgül maddeler içeren alt ölçeklerin geliştirilmesi önerilmektedir.

Hastalık Bazlı Seçilen Ölçeklerin Uyumluluğu

Bu çalışmada, MS tanılı hastalarda uygulanan Kısa Form McGill Ağrı Ölçeği (SF-MPQ) yüksek düzeyde iç tutarlılık göstermiştir (Cronbach's $\alpha = 0,883$; ordinal $\alpha = 0,890$). Bu değerler, ölçeğin ağrı algısını homojen ve güvenilir şekilde ölçebildiğini göstermekte olup, literatürde SF-MPQ'nin nöropatik ağrıyı tanıma ve değerlendirmedeki etkinliğini ortaya koyan bulgularla örtüşmektedir. SF-MPQ'nin 2009 yılında geliştirilen genişletilmiş versiyonu (SF-MPQ-2), nöropatik ve nosiseptif ağrı ayırtını sağlamak üzere yapılandırılmıştır ve yapılan çok sayıda çalışmada yüksek iç tutarlılık ve geçerlik değerleri bildirilmiştir (Dworkin et al., 2009); (Lovejoy et al., 2012).

SF-MPQ, özellikle nöropatik ağrının baskın olduğu klinik durumlarda tercih edilmektedir. Nitekim MS hastalarında ağrının %30–50'sinin nöropatik bileşen içerdiği, spinal kord ve beyin lezyonlarının ağrı iletim yollarını etkileyerek parestezi, yanıcı ağrı ve elektrik çarpması hissine neden olduğu bildirilmiştir (Rudroff, 2019). SF-MPQ'nin "zonklayan", "cezalandırıcı", "acııcı" gibi nöropatik temsili olan maddelerinin MS grubunda yüksek madde-toplam korelasyonu göstermesi, bu semptomların hasta deneyimiyle örtüştüğünü göstermektedir.

Uluslararası düzeyde yapılan kültürel adaptasyon çalışmaları da SF-MPQ'nin yapı geçerliği ve nöropatik ağrı ayırt ediciliğini desteklemektedir. Japonya'da yapılan bir çalışmada SF-MPQ-2'nin nöropatik ağrı alt boyutu için Cronbach's $\alpha = 0.917$ bulunmuş, ayrıca nöropatik ve non-nöropatik gruplar arasında anlamlı farklar gözlemlenmiştir (Maruo et al., 2014). Benzer şekilde İran'da yapılan çalışmada $\alpha = 0.906$ olarak bildirilmiş, faktör analizinde 4 bileşenli özgün yapının korunduğu görülmüştür (Adelmanesh et al., 2012).

Ayrıca SF-MPQ'nin Parkinson hastalarında (Mehdizadeh et al., 2020), KRONİK bel ağrısı (Aykan & Ucan, 2020) ve kanser ağrısı (Mendoza-Contreras et al., 2025) gibi çeşitli gruplarda da yüksek güvenilirlik gösterdiği vurgulanmıştır. Bu bulgular, SF-MPQ'nin ağrının farklı bileşenlerini (duyusal, affektif, nöropatik) değerlendirme kapasitesinin hastalığa özgü örüntülere karşı duyarlı olduğunu göstermektedir.

Bu çalışmadaki keşifsel faktör analizinde SF-MPQ'nin beş faktörlü bir yapı sergilemesi, özellikle ilk iki faktörde "Acııcı–Cezalandırıcı–Zonklayan" ve "Şiş sağlanır gibi–Yoğun" gibi ifadelerin birleşmesi, nöropatik özellikli ağrı ile ilgili semantik kümelenmeleri yansıtmaktadır. SF-MPQ'nin orijinal dört faktörlü yapısı—süreğen ağrı, aralıklı ağrı, affektif tanımlar ve nöropatik ağrı—literatürde yapılan birçok geçerlik çalışmasında korunmuştur (Dworkin et al., 2015); (Hasvik et al., 2019). Çalışmamızda farklı sayıda faktör elde edilmiş olsa da madde yüklerinin kavramsal olarak anlamlı kümelerle oturması, ölçeğin esnekliğini ve hasta profiline göre şekillenebilirliğini göstermektedir.

SF-MPQ'nin çok dilli adaptasyonları da benzer psikometrik özellikleri desteklemektedir. Tayland (Buppha et al., 2016), Çin (Wang et al., 2017), Arapça konuşan hasta grupları (Terkawi et al., 2017) ve Sri Lanka'daki Sinhala versiyonu (Edirisinghe et al., 2019) gibi örneklerde de ölçeğin hem nöropatik hem non-nöropatik ağrıyı değerlendirmede güçlü psikometrik performans gösterdiği bildirilmiştir.

Sonuç olarak, çalışmamızda SF-MPQ'nin MS hastalarında yüksek iç tutarlılık sergilemesi, hem ağrının yaygın ve nöropatik karakterine hem de ölçeğin bu özellikleri kapsayacak biçimde tasarlanmasına bağlanabilir. Mevcut bulgular, SF-MPQ'nin MS'teki ağrı çeşitliliğini yansıtmaya ve farklı semptom gruplarını ayırtabilme açısından geçerli ve güvenilir bir araç olduğunu göstermektedir. Gelecek araştırmalarda SF-MPQ'nin MS alt tiplerine (RRMS, AMS, AOMS) göre farklılaşan ağrı örüntüleriyle ilişkisi detaylandırılmalı ve uzunlamasına takiplerle ağrı profillerinin değişimi izlenmelidir.

Bu çalışmada, Epilepsi tanılı hastalarda Brief Pain Inventory (BPI) kullanılarak elde edilen iç tutarlılık katsayılarının (Cronbach's $\alpha = 0,048$; ordinal $\alpha = 0,044$) son derece düşük çıkması, ölçeğin bu hasta grubunda güvenilir bir ölçüm aracı olarak işlev göremediğini göstermektedir. Ek olarak, KMO değerinin 0,462 gibi düşük bir düzeyde kalması ve Bartlett's testinin anlamlı çıkması, yapı geçerliğinin de sağlanamadığını ortaya koymuştur. Bu durum, epilepsi hastalarında BPI'nin hem psikometrik tutarlılık hem de faktöryel yapı bakımından yetersiz kalmasının altında yatan bazı temel nedenlere işaret etmektedir. Epilepside ağrı, nöbet öncesi (preiktal), nöbet anı (iktal) ya da nöbet sonrası (postiktal) dönemlerde geçici kas ağrısı, baş ağrısı veya travma kaynaklı ağrılar biçiminde ortaya çıkmakta ve sıklıkla kısa süreli, lokalize olmayan ve kişiden kişiye değişken bir seyir göstermektedir (Scholz et al., 1999); (Casciato et al., 2017). Dolayısıyla, BPI gibi ağrının süreklilik, yoğunluk ve yaşam fonksiyonları üzerindeki etkilerini ölçmeye odaklanan bir ölçek, epilepsi gibi dinamik ve nöbet odaklı bir hastalıkta sabit ağrı kalıplarını yeterince temsil edememektedir.

Epilepsi hastalarında ağrı deneyimi, sadece fiziksel uyaranlardan değil; aynı zamanda epileptik aktivitenin beyin farklı bölgelerinde yarattığı elektriksel değişimlerden de etkilenmektedir. Özellikle temporal, parietal ve insular korteks gibi alanlara yayılan epileptik odaklar, bazen yalnızca ağrı ile seyreden nöbetlerin ortaya çıkmasına neden olabilmektedir (Martin, 2018). Bu tür "iktal ağrı" deneyimleri oldukça nadir görülmekle birlikte hem fiziksel hem de bilişsel olarak tanımlanması güç olabilir. Bu bağlamda epilepsi hastalarının ağrıya verdikleri yanıtlar, klasik ağrı türlerine (örn. yanıcı, batıcı, zonklayıcı) kıyasla daha öznel, düzensiz ve düşük homojenlikte olabilir. Ayrıca epilepsiye sıklıkla eşlik eden anksiyete, depresyon ve bilişsel bozulma gibi psikiyatrik durumlar da ağrı algısını ve yanıt biçimlerini etkileyerek ölçek puanlarında varyansı artırmakta ve madde-tutarlılığını azaltmaktadır (Charlesworth et al., 2009). Sonuç olarak BPI'nin epilepsi grubundaki başarısızlığı hem epilepsiye özgü ağrı doğasının hem de ölçeğin sınırlı yapısal esnekliğinin bir yansıması olarak değerlendirilebilir.

Bu çalışmada, Henry Ford Headache Disability Inventory (HFDDI) baş ağrısı tanılı bireylerde yüksek iç tutarlılık (Cronbach's $\alpha = 0,953$; ordinal $\alpha = 0,954$) ve güçlü yapısal geçerlik (KMO = 0,949; Bartlett's $p < 0,0001$) sergilemiş, bu yönüyle hem klinik uygulama hem de araştırma kullanımı için oldukça güvenilir ve geçerli bir araç olduğunu göstermiştir. Bu bulgular, ölçeğin orijinal geliştiricileri Jacobson ve arkadaşlarının (1994) çalışmasıyla uyumludur; söz konusu çalışmada HFDDI'nin 25 maddelik yapısının fonksiyonel ve duygusal olmak üzere iki ana alt boyutta yapılandığı ve yüksek iç tutarlılık ($\alpha > 0,90$) gösterdiği bildirilmiştir (Jacobson et al., 1994). Çalışmamızda keşfedilen dört faktörlü yapı ise HFDDI'nin baş ağrısına bağlı yetersizlikleri daha ayrıntılı boyutlara ayırabilme potansiyelini göstermektedir.

Türkçe versiyonunun geçerlik çalışmasında da benzer biçimde yüksek iç tutarlılık (Cronbach's $\alpha = 0,935$), güçlü test-tekrar test güvenirliliği (ICC = 0,901) ve iki faktörlü (fonksiyonel ve duygusal) yapı elde edilmiştir (Kılınç et al., 2023). Bizim çalışmamızda bu iki boyuta ek olarak "sosyal anlaşılma" ve "destek eksikliği" temalarının faktörlere ayrılması, baş ağrısı yaşayan bireylerdeki sosyal ve duygusal yalnızlaşma düzeyini ölçüm kapsamına dahil etmesi açısından önemlidir. Benzer şekilde İran'da yapılan bir geçerlik çalışmasında da HFDDI'nin hem fonksiyonel hem duygusal alt ölçeklerinin $\alpha > 0,86$ düzeyinde olduğu ve Kısa Form Sağlık Anketi-36 (SF-36) ile anlamlı korelasyon gösterdiği bildirilmiştir (Jabbari et al., 2021).

Çalışmamızda ilk faktörde "Hedeflerime ulaşmamı zorlaştırıyor", "Çaresiz hissediyorum" ve "Sinirli hissediyorum" gibi ifadelerin yüksek yüklemesi, baş ağrısının hem işlevsel kapasiteyi hem de duygusal dayanıklılığı etkilediğini göstermektedir. Bu bulgu, Rosa ve arkadaşlarının (2024) İtalyan uyarlamasında da vurgulanmıştır; çalışmada HFDDI'nin iki faktörlü yapısının geçerli olduğu, fakat özellikle kadın hastalarda duygusal etkilerin daha belirgin yansıdığı bildirilmiştir (Rosa et al., 2024). Benzer olarak Pradela ve ark. (2020), Brezilya uyarlamasında üç boyutlu yapı (fonksiyonel,

duygusal, sosyal) önermiş ve HFDI'nin çok boyutlu yapısının kültürel farklılıklara göre şekillenebileceğini belirtmiştir (Pradela et al., 2020).

HFDI'nin diğer baş ağrısı ölçüm araçlarıyla karşılaştırıldığında; Migraine Disability Assessment Scale (MIDAS) ve Headache Impact Test (HIT-6) gibi ölçeklerin daha kısa ancak sınırlı boyutsal yapıya sahip olduğu, buna karşın HFDI'nin özellikle duygusal işlevsellik boyutlarında daha ayrıntılı bilgi sunduğu belirtilmektedir (Kim et al., 2010); (Rathod et al., 2016). Özellikle kronik baş ağrısı yaşayan bireylerde duygusal yıpranma, sosyal izolasyon ve algılanan çaresizlik gibi yapılar, HFDI'nin diğer araçlara göre daha özgün veri toplamasını sağlar. Nitekim Issa ve Huijbregts'in (2006) fizik tedavi müdahalelerini değerlendirdikleri bir olgu sunumunda, HFDI skoru %36 oranında düşmüş ve bu değişim ölçeğin müdahalelere duyarlılığını kanıtlamıştır (Issa & Huijbregts, 2006).

Sonuç olarak, çalışmamızda HFDI'nin baş ağrısı tanımlı bireylerde yüksek iç tutarlılık ve çok boyutlu yapı geçerliği sergilemesi, bu ölçeğin hem bireysel hem toplumsal düzeyde baş ağrısına bağlı yaşam kalitesi kaybını belirlemede güvenilir ve kapsamlı bir ölçüm aracı olduğunu ortaya koymaktadır. Farklı kültürlerde yapılan çalışmalarla elde edilen bulguların tutarlılığı, HFDI'nin evrensel yapısal gücünü desteklemektedir. Bu bağlamda, baş ağrısının sadece fiziksel değil, aynı zamanda psikososyal etkilerini de analiz etmek isteyen klinik uygulayıcılar için HFDI güçlü bir tercih olarak öne çıkmaktadır.

Bu çalışmada FSDC ölçeği, fibromiyalji tanımlı bireylerde hem iç tutarlılık (Cronbach's $\alpha = 0,82$; ordinal $\alpha = 0,79$) hem de yapı geçerliği açısından yeterli düzeyde performans sergilemiştir. Elde edilen KMO değeri (0,71) ve anlamlı Bartlett's testi, veri setinin faktör analizine uygunluğunu gösterirken, keşifsel faktör analizinde iki faktörlü yapı elde edilmesi, literatürde FSDC'nin semptom şiddeti (Symptom Severity, SS) ve yaygın ağrı (Widespread Pain Index, WPI) boyutlarını kapsayan özgün iki bileşenli modeline karşılık gelmektedir (Fitzcharles et al., 2012). Türkçe uyarlama çalışmasında da benzer şekilde Cronbach's $\alpha = 0,77$ olarak bildirilmiş, test-tekrar test korelasyonlarının 0,75'in üzerinde olduğu ve FIQ ile yüksek korelasyon gösterdiği belirtilmiştir (Yanmaz et al., 2016). Ayrıca Fransız (Fitzcharles et al., 2012) ve İran (Bidari et al., 2015) uyarlamalarında da benzer psikometrik değerler elde edilmiş, ölçeğin kültürden bağımsız olarak tutarlı çalıştığı gösterilmiştir. Çalışmamızda en sık bildirilen ağrı bölgeleri (boyun, omuz, bel ve diz) de fibromiyaljiye özgü klinik yaygın ağrı dağılımı ile tutarlılık göstermektedir (Wongthanavimok et al., 2023). Tüm bu bulgular, FSDC'nin hem tanı hem de semptom şiddeti izleminde güvenle kullanılabilir, yüksek geçerlik ve güvenilirliğe sahip çok yönlü bir ölçüm aracı olduğunu desteklemektedir.

Baş ağrısı Ağrı Eşiği Hasta Kendi Ağrısını Derecelendirmez İse

Çalışmamızda baş ağrısı ile ilişkili temel bireysel değişkenler (yaş, cinsiyet, doğum ve büyüme ili) ve ağrının iki cümlelik kısa tanımı ile dört sıfat istenmesi üzerinden kurulan modelleme süreci, TF-IDF ile sınırlı sayıda ve nitelikte değişkene rağmen Gradient Boosting ($R^2 \approx 0.987$) ve XGBoost ($R^2 \approx 0.977$) gibi algoritmalarla oldukça yüksek doğruluk düzeylerine ulaşmıştır. Bu bulgu, ağrı gibi çok boyutlu ve öznel bir olgunun, minimal fakat doğru yapılandırılmış veri üzerinden öngörülebileceğini göstermektedir. Nitekim Chartier ve arkadaşları (2022), yalnızca hasta tarafından çizilen ağrı şemaları kullanarak RF algoritması ile baş ağrısı cerrahisi sonrası sonucu %94 doğrulukla tahmin etmiş; bu sonuçlar, semantik veya görsel temsillerin güçlü ML modelleriyle anlamlı çıktılar verebileceğini ortaya koymuştur (Chartier et al., 2022).

Benzer şekilde, Kim ve arkadaşları (2025) baş ağrısı hastalarında depresyon, anksiyete ve ağrı şiddetini tahmin etmek için RF ve SVR modellerini karşılaştırmış ve bireysel değişkenlerin (örneğin analjezik kullanımı) güçlü öngörücüler olduğunu ortaya koymuştur. Bu çalışma, bireysel özelliklerin sınıflandırma ve regresyon algoritmalarıyla birlikte kullanıldığında yalnızca semptom

düzeyinde değil, psikolojik yansımalar bakımından da anlamlı çıkarımlar yapılabileceğini göstermektedir (Kim et al., 2025). Ayrıca Stubberud ve arkadaşlarının (2024) kapsamlı derlemesinde, ML modellerinin baş ağrısı alt tiplerinin sınıflandırılması, seyir tahmini ve tedavi yanıtlarının öngörülmesi gibi birçok alanda kullanıldığı, ancak özellikle doğal dil ve semantik veri ile beslenen modellerin halen gelişme potansiyeli taşıdığı vurgulanmıştır (Stubberud et al., 2024).

Bu çalışmada kullanılan BoW temsili, serbest metinlerdeki kelime sıklığına dayalı olarak sabit boyutlu vektörler oluşturmakta ve bu temsiller üzerinden ağrı eşiği tahminine yönelik çoklu çıktı regresyon modelleri kurulmaktadır. BoW modellemesi, her bir kelimenin metinde kaç kez geçtiğini sayar, ancak bağlamsal ilişkileri göz ardı eder. Buna karşın, kullanılan verilerde (örn. baş ağrısına dair hasta ifadeleri) “zonklayıcı”, “baticı”, “yayılan” gibi kelimelerin ağrı türüyle olan ilişkileri belirli oranda anlam barındırır. Bu anlam, kelime frekanslarının bazı modeller için yeterli ayırt edicilik sağlamasını mümkün kılmıştır. Özellikle Gradient Boosting ($R^2 \approx 0.980$) ve XGBoost ($R^2 \approx 0.968$) gibi gradyan artırıcı modellerin yüksek başarı sağlaması, bu yöntemlerin kelime bazlı sınırlı yapıyı dahi iyi işleyebildiğini göstermektedir.

BoW temsiline dayalı regresyon modelleri, daha önce metin temelli çeşitli tıbbi ve psikolojik tahmin görevlerinde de başarıyla kullanılmıştır. Örneğin, Chidinma et al. (2020), intihar niyeti tahmininde BoW ile RF ve XGBoost kullanarak %89’un üzerinde doğruluk raporlamıştır. Benzer biçimde, Zhu (2014), yüz ifadesine dayalı ağrı tanıma çalışmalarında BoW temsiline dayalı görsel kelimeler ile %92’nin üzerinde sınıflama başarısı elde etmiştir. Bu durum, BoW’un sınırlı bağlam bilgisini telafi etmek üzere iyi seçilmiş model türleriyle birlikte kullanılabileceğini göstermektedir.

Ancak BoW’un bazı sınırlamaları da dikkat çekicidir. Sözcükler arasındaki semantik benzerlikleri göz ardı etmesi, aynı anlama gelen farklı kelimeleri (ör. “delici” vs “baticı”) farklı vektörlerde temsil etmesine neden olur. Bu, özellikle semantik bütünlüğü olan cümlelerde bağlam kaybına yol açar. Nitekim bu çalışmada SVR gibi doğrusal olmayan modellerin ($R^2 \approx 0.14$) performansı oldukça düşük kalmıştır. Benzer şekilde, Yoshikawa et al. (2015) çalışmasında da vurgulandığı gibi, klasik kernel tabanlı yaklaşımlar BoW verilerde kelime örtüşmesini doğrudan yansıtamadığı için düşük genelleme başarısı göstermektedir. Bu zayıflığın aşılması adına Gaussian Process gibi yapay latent vektörlerle desteklenen alternatif yöntemlerin geliştirilmesi önerilmiştir.

BoW’un önemli bir avantajı ise yorumlanabilirliğidir. Model çıktılarında ağırlıklı kelimelerin belirlenmesi, hangi kelimelerin ağrı eşiğini daha iyi açıkladığını ortaya koymak açısından faydalı olabilir. Bu, özellikle sağlık alanında uygulama kolaylığı sunar. Örneğin, Rojas et al. (2017), BoW ve fNIRS kullanarak ağrı tanınması yapan bir çalışmada, basit yapının hastalara dair dijital göstergeleri etkili biçimde temsil ettiğini vurgulamıştır. Bu bağlamda, ağrı gibi öznel bir fenomenin sınırlı veri ve düşük hesaplama maliyetiyle modellendiği durumlarda BoW hâlâ geçerli ve faydalı bir yaklaşımdır.

Sonuç olarak, BoW temsili baş ağrısı verisinde özellikle gradyan artırıcı modellerle birlikte yüksek başarı sağlamış; metnin yüzeysel yapısından elde edilen bilgilerle dahi ağrı eşiği tahminine katkı sağlamıştır. Ancak bu temsilin bağlamsal zenginliğinin yetersizliği, daha karmaşık ağrı anlatımlarını yakalamada sınırlayıcı bir faktör olmaya devam etmektedir. Bu nedenle, gelecekte bağlamsal temsillerle (ör. BERT) BoW’un birleştirildiği hibrit yaklaşımlar önerilebilir.

Fine-tuned BERT tabanlı modellerin baş ağrısı hastalarında ağrı eşiği tahmininde TF-IDF ve BoW temsillerine kıyasla açık ara daha başarılı sonuçlar üretmesi, temel olarak bu yöntemin sunduğu bağlamsal kavrayış kapasitesiyle ilişkilidir. BERT’in çok katmanlı Transformer mimarisi, kelimeleri yalnızca frekanslarına göre değil, cümle içindeki anlam ilişkilerine göre değerlendirebilme becerisine sahiptir (Chen et al., 2020). Özellikle ağrı gibi kişisel ve bağlama duyarlı bir deneyimi temsil eden metinlerde, bu derin dil temsili, hasta anlatımlarını daha isabetli şekilde sayılaştırarak regresyon modellerine zengin öznitelik setleri sunmaktadır. Ayrıca, BERT’in

fine-tuning aşamasında hedef göreve özel parametre optimizasyonu yapabilmesi, önceden eğitilmiş bilginin problemle ilgili alt yapıya daha iyi aktarılmasını sağlar. Bu özellik, özellikle ağrı gibi heterojen kavramların bireysel ifadesine dayanan görevlerde, daha düşük hata ve daha yüksek genelleme başarısı sağlar (Xin et al., 2021). Çalışmamızda BERT'in "all-MiniLM-L6-v2" sürümüyle elde edilen embed temsilleri, Gradient Boosting ve XGBoost gibi ağaç tabanlı güçlü regresörlere yüksek kaliteli öznitelik vektörleri sağlayarak $R^2 \approx 0.99$ seviyelerine ulaşmıştır.

Bir diğer önemli nokta, BERT'in bağlamı anlamlandırma yeteneğinin, ağrı anlatımındaki duygusal, metaforik ve kültürel katmanları daha iyi ayrıştırabilmesidir. MS hastalarının ağrı anlatımında sıkça kullandıkları "yanıcı", "delici", "çaresizlik", "nefessiz kalma" gibi anlatımlar, klasik frekans temelli TF-IDF ve BoW temsillerinde anlamsal bütünlükten kopuk olarak kodlanırken, BERT bu kavramları semantik bütünlük içinde işler (Markchom et al., 2022). Bu da hem tahmin gücünü artırmakta hem de modelin yorumlanabilirliğini zenginleştirmektedir.

Öte yandan, TF-IDF gibi klasik temsiller, sözcüklerin sıklık ve belirsizlik değerlerini hesaba katsalar da bağlamsal ilişkileri dikkate almadıkları için özellikle çoklu hedefli regresyon görevlerinde dezavantajlıdır (Li et al., 2021). Ayrıca, bu tekniklerde vektör boyutları sabit tutulmak zorunda olduğundan (örneğin 500 terim), metindeki semantik çeşitliliğin tam olarak aktarılması sınırlı kalabilir. Bu bağlamda BERT'in transfer öğrenme temelli yapısı, düşük örneklemlili veri setlerinde bile güçlü genelleme yapabilmesi açısından TF-IDF'e göre daha avantajlıdır (Verbrugge et al., 2021).

Sonuç olarak, BERT'in metin temsili kapasitesi, bağlamsal kodlama gücü ve fine-tuning esnekliği, baş ağrısı hastalarının karmaşık ve çok boyutlu ağrı anlatımlarını yüksek doğrulukla modellendirme imkânı sunmuştur. Bu yaklaşım, ağrı eşiği gibi öznel ve dil temelli verilerin regresyonla tahmininde klasik yöntemlere göre çok daha etkili sonuçlar doğurabileceğini göstermektedir.

Baş Ağrısı Ağrı Eşiği-Hasta Kendi Ağrısını Derecelendirir İse

Bu çalışmada, hastaların kendi ağrı şiddetlerini 1–10 arasında sayısal olarak derecelendirmelerinin, farklı metin temsilleriyle (TF-IDF, BoW, fine-tuned BERT) eğitilen regresyon modellerine anlamlı bir katkı sağlamadığı gözlemlenmiştir. Bu bulgu, sayısal ağrı derecelendirmelerinin (örn. Numeric Rating Scale – NRS) klinik modelleme açısından taşıdığı sınırlılıkları işaret etmektedir.

Öncelikle, NRS gibi tek boyutlu sayısal ölçeklerin bireylerarası yorum farklılıklarına fazlasıyla açık olduğu bilinmektedir. Aynı şiddetteki ağrıyı yaşayan bireylerden biri 4, diğeri 8 olarak puanlayabilir. Eğitim düzeyi, önceki ağrı deneyimi ve kültürel ağrı anlatımı gibi faktörler bu puanlamayı etkileyebilmektedir (Marco et al., 2012). Bu değişkenlik, modellerin bu sayısal girdiyi güvenilir bir açıklayıcı değişken olarak kullanmasını güçleştirmektedir.

İkinci olarak, metin temelli girişlerde yer alan "delici", "zonklayıcı", "dayanılmaz", "sabırımı zorluyor" gibi ifadeler, zaten ağrının şiddetini güçlü biçimde yansıtmaktadır. Bu anlatımlar TF-IDF temsillerinde frekans ağırlığı, BERT gibi bağlamsal modellerde ise semantik yoğunluk yoluyla şiddet düzeyini vektörel forma dönüştürebilmektedir (Nugent et al., 2021). Dolayısıyla, hastanın verdiği tek bir sayısal değer, zaten semantik içerikte kodlanmış olan bilgiye fazladan bir katkı sunmamaktadır.

Ayrıca, NRS ölçekleri teorik olarak kesikli ve sıralı (ordinal) yapıdadır; 1 ile 2 arasındaki fark, 8 ile 9 arasındaki farkla aynı anlamı taşımaz. Bu nedenle, sayısal gibi görünse de regresyon modellerine doğrudan entegre edildiğinde bilgi kaybı ve hata riskini artırabilir (Stijic et al., 2023).

Son olarak, bazı çalışmalar, NRS skorlarının klinik sonuçlar veya işlevsellik düzeyleri ile güçlü korelasyon göstermediğini ve sağlık hizmeti kararlarını yönlendirmede yetersiz kaldığını

bildirmiştir (Fraenkel et al., 2012). Bu durum, sayısal ağrı puanlarının zayıf genelleme kapasitesine sahip bir değişken olduğunu ortaya koymaktadır.

Sonuç olarak, ağrı şiddetinin hasta tarafından sayısal olarak derecelendirilmesi, semantik olarak zengin, bağlamsal anlatımları içeren serbest metinlere kıyasla ML modellerine anlamlı ölçüde ek bilgi sağlamamaktadır. Bu nedenle, metin temsilli modelleme çerçevesinde sayısal ağrı puanı çoğunlukla redundant bir değişken olarak kalmakta ve modelin performansını belirgin ölçüde artırmamaktadır.

Baş Ağrısı HFDI Skor Tahmini

BERT, TF-IDF ve BoW temelli metin temsillerinin HFDI skor tahmini üzerindeki etkisini karşılaştırmalı olarak incelediğimiz bu çalışmada, elde edilen bulgular metin temsili seçimlerinin tahmin başarısında ciddi rol oynadığını ortaya koymuştur. TF-IDF temsili ile yapılan modeller arasında Lasso regresyonunun öne çıkması ($MSE \approx 9.34$; $R^2 \approx 0.986$), L1 düzenleme ile metin temsiline özgü yüksek boyutlu sparse yapıda model genellenebilirliğini artırdığını göstermektedir. Bu bulgu, Lasso'nun özellikle sağlık alanı gibi sınırlı veriyle çalışan uygulamalarda TF-IDF için güçlü bir aday olduğunu desteklemektedir (Patel et al., 2024), (Berkel et al., 2023).

BoW temsiline geçildiğinde, Lasso yine liderliğini korumuş ($MSE \approx 3.06$; $R^2 \approx 0.995$) ve bu modelin metin temsillerinde aşırı öğrenmeye karşı sağladığı koruma bir kez daha teyit edilmiştir. Ridge ve Gradient Boosting gibi daha karmaşık modeller de kabul edilebilir düzeyde performans sergilemiş olsa da, yüksek MAPE değerleri modelin küçük gerçek değerlerde yüzdelik hata hesaplamasında sıkıntı yaşadığını göstermiştir (Deulkar et al., 2024), (Qasem & Sajid, 2022). BoW'un kelime sıklığını dikkate alması ancak bağlamı göz ardı etmesi, düşük semantik çözünürlükle sınırlı kalmasına neden olmaktadır (Skenderi et al., 2021).

BERT tabanlı temsillerle yapılan analizler, metnin bağlamsal çözümlemesini sunarak model başarısını belirgin şekilde artırmıştır. Gradient Boosting ve XGBoost, neredeyse hatasız sonuçlarla $R^2 \approx 1,00$ düzeyine ulaşmıştır. Bu durum, BERT'in hem semantik hem de sözdizimsel düzeyde bilgi sunarak metinlerdeki anlamlı paternleri daha doğru biçimde modelleyebildiğini göstermektedir (Gomes et al., 2023), (Verma et al., 2023). Ayrıca DT gibi genellikle sınırlı performans sergileyen modeller bile BERT temsiliyle $MSE \approx 0.816$ ve $R^2 \approx 0.999$ başarımı göstermiştir. Bu sonuçlar, bağlamsal yerleştirmelerin derin bilgi taşıma potansiyelini vurgular (Tekgöz et al., 2021), (Maiti et al., 2024).

BERT'in bu yüksek başarımı, sağlık metinlerinin çoğunlukla bağlama dayalı anlam taşımasından kaynaklanıyor olabilir. Özellikle Henry Ford Disability Index gibi kişisel algı ve işlevsellik düzeylerini ölçen anketler, katılımcıların kullandığı ifadelerin bağlama göre değiştiği yapılardır. BERT, bu bağlamsal farklılıkları kodlamada üstünlük sağlamaktadır (Kamath et al., 2025), (Lin et al., 2022). Bu nedenle, özellikle klinik metinlerin veya hastaların serbest tanımlarının analizinde BERT gömülerinin tercih edilmesi önerilmektedir. Nitekim, BioBERT gibi tıbbi alanlara özel modellerin de bu avantajı artırabileceği bazı çalışmalarda gösterilmiştir (Patel et al., 2023).

Sonuç olarak, TF-IDF ve BoW geleneksel temsiller olarak belirli başarı düzeyine ulaşsalar da, BERT temsili hem doğruluk hem de genellenebilirlik açısından üstündür. BoW'un düşük semantik çözünürlüğü ve TF-IDF'in bağlamsız vektörleri, özellikle karmaşık sağlık metinlerinde yetersiz kalırken; BERT, dilin bağlamsal doğasına uygun modelleme sağlayarak sağlık tahminlerinde en ileri düzey kestirimi mümkün kılmaktadır (Hanić et al., 2024), (Qasem & Sajid, 2022), (Cardenas et al., 2022).

Ağrı eşiği ve HFDI verilerinin TF-IDF ve BoW gibi klasik metin temsilleriyle işlenmesinde farklı başarı düzeylerinin gözlemlenmesi, bu iki ölçeğin içerik doğası, ifade biçimi ve bağlam aktarımına dair farkları üzerinden anlaşılabilir. Ağrı eşiği ölçeği genellikle katılımcının genel ve zamandan

bağımsız bir ağrı toleransı ya da deneyimine dair kısa, somut, açıklayıcı sözcüklerle verdiği yanıtlardan oluşur. Bu tür sözcükler (“cam kesigi”, “iğne batması” gibi) doğrudan fiziksel deneyimi çağrıştırdığı için TF-IDF gibi sayım-temelli temsilcilerle anlamlı biçimde ayrıştırılabilir. Nitekim klasik TF-IDF yöntemlerinin kısa ve sabit kalıplı metinlerde üstün performans gösterebildiği, yakın tarihli çalışmalarda da vurgulanmıştır (Valmianski et al., 2019); (González-Carvajal & Garrido-Merchán, 2020).

Buna karşın, Henry Ford Disability Index (HFDI) ölçeği daha çok katılımcının güncel psikososyal ve işlevsel durumu üzerine öznel değerlendirmelerini içerir. Katılımcıların verdiği yanıtlar daha bağlamsal, duygusal ve genellikle görelî ifadelerdir (“çaresiz hissediyorum”, “işe gidemiyorum” gibi). Bu tür cümlelerde anlam, sözcüklerin bağlam içindeki ilişkisine dayanır ve klasik BoW/TF-IDF temsilleri bu bağı yeterince yakalayamayabilir. Yapılan bir araştırma, BERT gibi bağlamsal gömülemelerin özellikle duygu, tutum ya da sosyal anlam içeren cümlelerde TF-IDF’ye göre daha yüksek ayırt edici güce sahip olduğunu göstermektedir (Bender et al., 2022); (Devi et al., 2022).

Bu bağlam farklılığı, model performanslarındaki sapmayı açıklamaya yardımcı olabilir. Örneğin, TF-IDF ile HFDI skorlarının tahmin edilmesinde hataların göreceli olarak daha yüksek olması ve model başarısının düşük seyretmesi, katılımcıların duygu yoğunluğu taşıyan ifadelerinin sayım temelli yöntemlerle yeterince çözümlenememesiyle ilişkilidir. Bu bulgu, TF-IDF’nin bağlamdan bağımsız yapısal sınırlılıklarına işaret ederken, HFDI gibi duygusal yük taşıyan ölçeklerin yorumlanmasında daha ileri temsillerin (örneğin BERT) tercih edilmesi gerektiğini destekler (Ramachandruni et al., 2024); (Gomes et al., 2023).

Son olarak, literatürde TF-IDF’nin bazı durumlarda BERT’e karşı hala avantajlı olabileceği vurgulanmıştır; özellikle kısa metinli, terim temelli karşılaştırmalarda (Wehnert et al., 2021); ancak, duygusal ve bağlamsal karmaşıklığı yüksek metinlerde (örneğin HFDI açıklamaları) bu avantaj kaybolmakta ve bağlamsal yerleştirmelerin (BERT) üstünlüğü öne çıkmaktadır (Lakshmidēvi et al., 2023); (Blanco et al., 2025).

Bu bulguların ışığında, ağrı eşiği gibi daha sabit, kısa ve fiziksel temelli açıklamalarda klasik temsiller hâlen işlevsel olabilirken; HFDI gibi öznel deneyimlerin aktarıldığı ölçeklerde bağlamsal derinliği yüksek BERT benzeri modellerin tercih edilmesi hem duyarlılığı artıracak hem de klinik yorumlara daha sağlam zemin sunacaktır.

MS Hastalarında Ağrı Eşiği

TF-IDF ve Bag-of-Words (BoW) temsilleri, metin verisinin sayısallaştırılması için uzun süredir kullanılan iki temel yaklaşımdır. MS hastalarına ait metinsel verilerle yapılan bu çalışmada, her iki yöntem de çeşitli regresyon modelleri ile uygulanmış ve performansları karşılaştırılmıştır. Bulgular, temsil yöntemlerinin model başarımı üzerinde anlamlı etkileri olduğunu göstermektedir.

TF-IDF yaklaşımı, sözcüklerin belgeler içindeki ayırt ediciliğini hesaba kattığından dolayı daha zengin ve bilgilendirici bir temsil sunar. Nitekim çalışmada Gradient Boosting ($R^2 \approx 0.905$) ve XGBoost ($R^2 \approx 0.887$) modelleri TF-IDF temsiliyle çok daha düşük hata ve yüksek doğrulukla çalışmıştır. Bu bulgu, TF-IDF’nin daha yüksek özgüllük taşıyan kelimeleri öne çıkararak daha tutarlı öngörüler sunduğunu gösterir (Deulkar et al., 2024), (Kim et al., 2024). Bu model, belgeler arası sık kullanılan kelimelerin ağırlığını azaltarak anlamlı varyansı daha verimli şekilde yakalayabilir (Dai et al., 2024).

Öte yandan, BoW temsili daha basit bir yöntem olup kelime sıklığına odaklanır ve bağlam bilgisi içermez. Bu yöntemin avantajı daha az işlem gücü gerektirmesi ve düşük kaynaklı sistemlerde uygulanabilirliğidir (Cardenas et al., 2022). Ancak BoW, yüksek boyutluluğu ve anlamsal ilişkiyi

yansıtamaması nedeniyle TF-IDF'ye kıyasla daha düşük başarı sağlar. Nitekim çalışmada Ridge regresyonu BoW ile en yüksek R^2 değerine (≈ 0.888) ulaşmasına rağmen, diğer ağaç tabanlı yöntemlerin performansı TF-IDF'ye göre belirgin şekilde daha düşüktür (Dinsa et al., 2024).

Metin uzunluklarının kısa olduğu klinik metinlerde TF-IDF'in daha uygun olduğu da literatürce desteklenmiştir. Örneğin sağlık alanında yapılan çalışmalarda, TF-IDF'nin semantik ayrıştırma konusunda daha başarılı olduğu ve sınıflandırma doğruluğunu artırdığı görülmüştür (Tekgöz et al., 2021). Öte yandan, BoW'un kısa metinlerde fazla seyrek matris üretmesi nedeniyle daha düşük başarı gösterdiği raporlanmıştır (Dakshnamoorthy, 2022). Ancak, her iki yöntemin göreceli avantajları veri yapısına göre değişebilir. Örneğin BoW, belirli sözcüklerin yoğun tekrarlandığı kısa tanımlı verilerde hızlı ve etkili çalışabilirken (Goje & Patil, 2024), TF-IDF, sözcüklerin belgeye özel önemini vurgulayarak daha zengin bağlamlı tahminler sunar. Özellikle belirsizlik ve çoklu bağlam içeren sağlık belgelerinde TF-IDF'nin belirgin üstünlük sağladığı görülmektedir (Patel et al., 2024).

TF-IDF ve BoW temsilleriyle baş ağrısı ve MS verilerinde elde edilen yüksek performans, bu iki yöntemin özellikle semantik ağırlıklı, sınırlı örneklemli klinik verilerde hâlâ etkili olduğunu göstermektedir. Nitekim TF-IDF, baş ağrısı verisinde Gradient Boosting ile $R^2 \approx 0.90$ gibi yüksek doğruluklar sunmuş, benzer şekilde BoW da Ridge regresyonla $R^2 \approx 0.87$ değerine ulaşmıştır. Buna karşın, fine-tuned BERT ile MS verisinde yapılan tahminlerde tüm modellerin R^2 değerinin daha düşük çıkması, bu yöntemlerin bağlamsal gücünün her zaman başarıya dönüşmediğini ortaya koymuştur.

BERT'in başarısız olduğu bu senaryoda belirleyici faktör, hedef değişkenin doğasıdır. Baş ağrısı verisinde hastalar ağrı deneyimlerini zengin, metaforik ve duygusal dil kalıplarıyla ifade etmektedir; bu da TF-IDF gibi kelime ağırlıklarına dayalı yöntemlerin ön plana çıkmasını sağlamaktadır (Nunes et al., 2022). MS verisinde ise ağrı eşiği daha sayısal, kısa ve tekrar eden biçimlerde ifade edilmiş, bu da BERT'in semantik ayrıştırma yeteneğini kısıtlamıştır (Taha et al., 2024). Ek olarak, MS veri setindeki ağrı skorlarının aşırı heterojen olması—örneğin aynı ağırlı uyarana bir katılımcının “2”, diğerinin “9” vermesi—gibi durumlar, bağlamsal embedding'lerin genellenmesini zorlaştırır (Sun et al., 2023). Oysa daha basit, sayım temelli vektörler bu gibi örüntüleri daha esnek şekilde yakalayabilir. Ayrıca TF-IDF'in az kullanılan ancak anlamlı terimlere yüksek ağırlık verme özelliği, anlatı odaklı veri setlerinde önemli avantajlar sunmaktadır (Pouromran et al., 2021).

Sonuç olarak, her ne kadar BERT temelli modeller teorik olarak daha güçlü görünse de, hedef değişkenin doğası, veri varyansı ve semantik yoğunluğu dikkate alınmadığında bu üstünlük uygulamada daha az etkili kalabilir. MS ağrı eşiği verisi, bağlamsal değil sayısal yapısıyla TF-IDF ve BoW gibi klasik yöntemlerin neden hâlâ güçlü birer alternatif olduğunu kanıtlamaktadır.

MS Hastalarında McGill Kısa Ağrı Formunun Tahmini:

TF-IDF ve Bag-of-Words (BoW) temsilleri, klinik metinlerde ağrı skoru tahmini gibi karmaşık görevlerde hâlâ yaygın kullanılan yöntemlerdir. Bu iki yöntemin MS gibi çok faktörlü ve dilsel olarak çeşitli veri barındıran durumlarda nasıl performans gösterdiğini anlamak için güncel literatür dikkate alınmalıdır.

İlk olarak, BoW temsili genellikle sözcük sıklıklarına dayalı olduğu için bağlamsal ilişkiyi kaçırabilir. Örneğin, "ağrı var" ve "ağrı yok" ifadeleri neredeyse aynı kelimeleri içerdiği için BoW bu farkı yakalayamayabilir. Bu durum, semantik bağlamın önemli olduğu durumlarda model performansını sınırlayabilir (Dai et al., 2024). Bununla birlikte, TF-IDF, terimlerin tüm veri setindeki önem derecesine göre ağırlıklandırma yaparak daha anlamlı bir temsil sunabilir. TF-IDF'in nadir fakat ayırt edici kelimeleri ön plana çıkarması, özellikle kısa metinlerde başarı oranını artırmaktadır (Abubakar & Umar, 2022). Ancak TF-IDF de bağlamsal farkları anlamakta

zorlanabilir. Özellikle kısa ve varyansı yüksek klinik ifadelerde, bağlamdan yoksun temsiller modelin genelleme gücünü sınırlayabilir (Xu et al., 2013). Bu tür temsillerin aşırı seyrek vektörler oluşturması, özellikle eğitim verisi sınırlıysa (örneğin niteliksel hasta anlatımları) aşırı uyuma veya düşük performansa neden olabilir (Rui et al., 2016).

Özellikle stres ve psikolojik durum tahmininde yapılan bir çalışmada, TF-IDF yerine BoW'un daha iyi sonuç verdiği bildirilmiştir çünkü kısa metinlerde daha basit frekans temsillerinin aşırı öğrenmeden koruduğu öne sürülmüştür (Nema et al., 2023). Benzer şekilde, başka bir çalışmada BoW'un zaman duyarlı normalizasyonlarla birlikte daha anlamlı davranışsal örüntüler yakalayabileceği gösterilmiştir (Č. Hlaváč et al., 2021).

Sonuç olarak, TF-IDF genellikle metnin ayırt edici yönlerini yakalamada daha başarılı olurken, BoW bazı görevlerde aşırı özellik mühendisliği olmaksızın daha sağlam sonuçlar sunabilir. Klinik metinlerde bağlamın önemi dikkate alındığında, bu temsillerin performansı hedef göreve, model türüne ve veri setine göre farklılık gösterebilir. Bu yüzden, bağlamsal dil modelleriyle birlikte bu klasik temsillerin performanslarını kıyaslamak, klinik NLP uygulamaları için faydalı bir yönlendirme sunar.

Fine-tuned BERT temsiliyle elde edilen sonuçlar bu varsayımı desteklemektedir. Gradient Boosting ve XGBoost gibi modeller sıfıra yakın hata ($MSE \approx 0.0001$) ve neredeyse kusursuz $R^2 (\approx 1.000)$ düzeyine ulaşarak klasik yöntemlerin çok ötesinde bir performans sergilemiştir. Bu durum, BERT'in yalnızca kelime frekanslarını değil, aynı zamanda bağlam, sözdizimi ve anlamsal ilişki gibi üst düzey özellikleri de kodlayabilen bir temsili sunduğunu göstermektedir (Wisesty et al., 2021). Bu sayede, hasta ifadelerindeki örtük anlamlar ve bağlamsal ipuçları daha etkili biçimde yakalanmakta, bu da tahmin doğruluğunu doğrudan artırmaktadır.

BERT'in bu başarısı yalnızca bu çalışmaya özgü değildir. Örneğin Kamath ve arkadaşları (2025), Amazon yorumları verisi üzerinde yürüttükleri karşılaştırmalı analizde BERT temsillerinin TF-IDF ve BoW'a kıyasla daha düşük hata ve daha yüksek doğruluk sağladığını ortaya koymuşlardır (Kamath et al., 2025). Benzer biçimde, Verma ve ark. Da (2023) da farklı encoder mimarilerini karşılaştırdıkları çalışmalarında, BERT'in birçok NLP görevinde varsayılan temsil yöntemi olarak kabul edilmesi gerektiğini belirtmişlerdir (Verma et al., 2023).

Sonuç olarak, MS hastalarındaki ağrı bildirimlerini metin üzerinden tahmin etmede bağlamsal bilgiye duyarlı temsillerin kullanılması belirgin bir avantaj sağlamaktadır. BERT'in sağladığı düşük hata ve yüksek genellenebilirlik, onu klinik doğal dil verilerinin işlenmesinde çok güçlü bir araç haline getirmektedir. TF-IDF ve BoW gibi klasik yöntemler hâlâ değerli olmakla birlikte, özellikle bağlamın belirleyici olduğu görevlerde BERT ve benzeri derin gömüleme yaklaşımlarının tercih edilmesi daha isabetli sonuçlar verecektir.

Normalizasyon ile Sonuçların Etkilenmesi:

Verilerin normalize edilmesi, makine öğrenimi modellerinin performansında gözle görülür farklar yaratabilir. Özellikle regresyon gibi sürekli çıktılar üreten modellerde, farklı ölçeklerdeki özellikler modelin öğrenme sürecini bozabilir. Bu bağlamda, yapılan çalışmalarda normalizasyonun özellikle hataları düşürmede etkili olduğu görülmektedir. Örneğin, Haroon ve arkadaşlarının (2024) çalışmasında, farklı normalizasyon tekniklerinin (Min-Max, Z-score, robust scaling) kullanımı, regresyon modellerinde hata oranlarını azaltmış ve genelleme performansını artırmıştır (Haroon et al., 2024).

Bu durumu destekleyen bir başka çalışma ise Larsson ve Wallin (2025) tarafından gerçekleştirilmiştir. Araştırmalarında, farklı normalizasyon tekniklerinin özellikle Lasso, Ridge ve Elastic Net gibi düzenlileştirilmiş regresyon yöntemlerinde tahmin ağırlıklarını önemli ölçüde

etkilediğini göstermiştir. Özellikle ikili değişkenlerin ölçeklenmesi, modelin öğrenme eğrisini değiştirerek daha dengeli sonuçlar üretmiştir (Larsson & Wallin, 2025).

KNN neden bütün modellerde Over Fittinge uğradı?

Küçük veri kümelerinde K-En Yakın Komşu (KNN) algoritmasının bütün modellerde aşırı uyum (overfitting) sergilemesi, modelin öğrenme sürecinde örüntülerin çok dar bir çerçevede değerlendirilmesinden kaynaklanabilir. Her ne kadar bu çalışmada KNN'nin overfit olduğuna odaklanılmasa da, bu nedenin açıklanması ihtiyacı doğmuştur. Özellikle yalnızca yaklaşık 200 gözlem içeren bir veri seti, metinsel özniteliklerin yüksek boyutluluğu ve sınırlı çeşitlilik nedeniyle komşuluk ilişkilerinde yapay benzerlikler yaratabilir. Bu durum, test verisi ile eğitim verisi arasında örüntülerin aşırı benzeşmesine neden olarak, KNN modelinin test verisinde sıfıra yakın hatalar vermesine yol açabilir. Özellikle heterojen dağılımlarda, örneğin bireylerin ağrı deneyimlerinin çok çeşitli olduğu durumlarda, KNN algoritması bu varyasyonları yeterince genelleyemez ve eğitimde gördüğü örneklerle fazlaca bağımlı hale gelir (Zhang, 2022). Ayrıca KNN, yüksek boyutlu veri uzaylarında genellikle “curse of dimensionality” olarak bilinen problemten muzdariptir. Özellikle metinsel veri temsillerinde TF-IDF veya bağlamsal BERT gömüleri kullanıldığında, her bir gözlem yüzlerce hatta binlerce boyutta temsil edilir. Bu durumda, uzaklık ölçümleri anlamsızlaşabilir ve algoritma gerçek benzerlikleri yakalayamaz. Bu sorun, küçük örneklem boyutlarında daha da derinleşir; çünkü her yeni test örneği, sınırlı sayıda ve yüksek boyutlu örneklerle karşılaştırılarak sınıflandırılır. Bu tür senaryolarda, örneğin mikroarray tabanlı veri setlerinde, yüksek boyutlu ama küçük örneklemli durumlar için KNN'nin ciddi genelleme sorunları yaşadığı gösterilmiştir (Mahfouz et al., 2021). Bu nedenle, bu gibi sınırlı örneklem ve yüksek boyutlu veri durumlarında KNN yerine düzenleştirilmiş lineer modeller veya gradyan artırılmalı yöntemler daha istikrarlı ve genellenebilir sonuçlar verebilir.

MS hastalarının Ağrı Karakteristiklerinin Nitel Analizi:

MS tanılı bireylerin ağrı deneyimlerine dair gerçekleştirilen derinlemesine nitel analiz sonucunda, ağrının yalnızca fizyolojik bir belirti değil; aynı zamanda anlatı yoluyla şekillenen, kültürel kodlarla örülen ve psikososyal bağlamda yeniden anlam kazanan çok katmanlı bir yaşantı olduğu görülmüştür. Geliştirilen “Tükenmişliği Yeniden Çerçeveleme” modeli, MS'e özgü nöropatik ağrının bireylerce nasıl duyumsandığını, hangi dilsel yollarla aktarıldığını ve başa çıkma stratejileriyle nasıl dönüştürüldüğünü kavramsal bir çerçevede bütünleştirmiştir.

Katılımcıların ağrıyı tanımlarken sıklıkla “yanıcı”, “sıkıştırıcı”, “baskı yapan kıskacı” ya da “ateşin içinde kalmak” gibi metaforik dil yapılarını tercih etmeleri, kronik ağrının anlatı dilindeki yerini güçlendirmektedir. Bu bulgu, Clair'in (2003) MS hastalarının ağrı ve hastalık deneyimini mecazlar aracılığıyla somutlaştırdığını gösteren çalışmasıyla örtüşmektedir. Aynı doğrultuda, Hovey ve Khayat (2018), metaforların ağrıyı yalnızca anlatmanın değil; yeniden anlamlandırmanın ve hatta bir başa çıkma biçimi olarak işlevselleşmenin bir yolu olduğunu savunmaktadır. Çalışmamızda da metafor kullanımı yalnızca duysal betimleme değil, aynı zamanda bireyin tükenmişliğine karşı geliştirdiği dilsel bir direnç biçimi olarak yorumlanabilir.

Elde edilen dört aşamalı döngüsel model, MS hastalarının ağrı ataklarını tanıdıktan sonra bu ataklara yönelik geçici başa çıkma stratejileri geliştirdiklerini ve bu süreci duygusal olarak yeniden çerçevelediklerini ortaya koymaktadır. Bu başa çıkma döngüsü, Lew ve Xin'in (2020) kronik ağrıyla yaşayan bireylerde tespit ettiği “refocusing” ve “acknowledgement of self” temalarıyla yapısal benzerlik göstermektedir. Bu benzerlik, bireyin ağrıyı yalnızca pasif olarak deneyimlemediğini; tersine, her döngüde yeniden tanımlayarak kontrol alanı oluşturduğunu düşündürmektedir.

Veriler ayrıca “dilsel muhafaza” koduyla, ağrının ifade biçiminin bağlama göre değiştiğini ortaya koymuştur. Katılımcıların ev ortamında mecazi anlatımı tercih ederken, doktor karşısında tıbbi

terminolojiye yönelmesi, Lvovschi ve arkadaşlarının (2019) vurguladığı gibi ağrının yalnızca anlatan kişiye değil, kime anlatıldığına göre de biçimlendiğini göstermektedir. Bu durum, sağlık hizmetlerinde ifade-duyarlı klinik yaklaşımların önemini ortaya koymaktadır. Ayrıca, anlatının sadece sözel değil, ilişkisel bir eylem olarak ele alınması gerektiğini vurgulayan Bruce ve arkadaşlarının (2023) çalışması da bu bulguyu desteklemektedir.

MS hastalarının deneyiminde ağrı, işlevsel kapasitenin azalmasına, sosyal rollerde gerilemeye ve özellikle kadın katılımcılarda bakım verme yükünün yeniden düzenlenmesine yol açmaktadır. Bu sonuç, Gilmore ve Strong'un (1998) MS'li bireylerde ağrının yaşam kalitesini belirgin şekilde düşürdüğünü ve özellikle işlevsel rolleri zedelediğini gösteren erken dönem çalışmasıyla örtüşmektedir. Ayrıca, "sabretme" ve "güçlü görünme" kültürel normlarının bireyin ağrı ifadesi üzerinde baskılayıcı etkisi olduğu yönündeki bulgu, Hovey'in (2018) acının anlatımının kültürel ve toplumsal olarak biçimlendiğine dair gözlemleriyle de kesişmektedir.

Negatif vakaların (ağrı yaşamadığını veya nadiren yaşadığını belirtenler) varlığı, modelin bütün örnekleme doğrudan genellenemeyeceğini gösterse de, bu çeşitlilik kuramın açıklayıcılığını zenginleştirmiştir. Bu durum, Morse'un (2015) belirttiği gibi, nitel çalışmalarda anlam çeşitliliğinin bulguların gücünü zayıflatmak yerine, modelin kapsayıcılığını artırabileceğine işaret etmektedir. Ağrıyı yaşasa da anlatmayan veya ifade stratejisi farklı olan bireylerin varlığı, bu modelin daha da geliştirilerek kültürel kodların ve kişilik tiplerinin dahil edileceği yeni versiyonlara evrilmesini mümkün kılabilir.

Sonuç olarak, bu çalışma MS hastalarında ağrı deneyiminin yalnızca biyolojik bir belirti değil, anlatı yoluyla yeniden yapılandırılan kültürel bir süreç olduğunu ortaya koymaktadır. "Tükenmişliği yeniden çerçeveleme" modeli, klinik pratikte ifade-duyarlı, zamanlamalı ve psikososyal bağlamı gözetken bütüncül müdahale yaklaşımlarının geliştirilmesi açısından önemli ipuçları sunmaktadır.

Baş Ağrısı Vakaları Nitel Analizi

Verilerimiz baş ağrısı yaşayan bireylerde dil, zamanlama, işlevsellik ve emosyon açısından zengin bir semantik repertuarın varlığına işaret etmektedir. "Çekiçle vuruluyor gibi" ya da "kafam mengene içinde" gibi metaforlar, sadece ağrının duyuşal kalitesini değil, aynı zamanda kişisel anlamlandırmalarla dolu duyuşal yoğunluğu da yansıtmaktadır. Bu bulgular, nitel araştırmalarla migraine ve diğer baş ağrısı tiplerinin birey yaşamına olan etkilerini kapsamlı şekilde ortaya koyan güncel literatürle örtüşmektedir. Örneğin, Battista ve arkadaşlarının (2023) meta-sentezi, baş ağrısı deneyiminin yaşam kalitesi, sosyal roller ve psikolojik dayanıklılık üzerindeki olumsuz etkisini açıkça ortaya koymaktadır (Battista et al., 2023). Zonklama temelli semantiklerin baskın olması ise Hoffmann ve Holland'ın (2019) vurguladığı trigeminal sistem ve multisensoriyel hiperduyarlılıkla ilişkili merkezi sinir sistemi düzensizliklerini akla getirmektedir (Hoffmann & Holland, 2019).

Kodlamada ortaya çıkan "Zonklayan Tükenmişlik Döngüsü", baş ağrısının yalnızca biyolojik değil, aynı zamanda duyuşal ve davranışsal yönleriyle de tekrar eden, yorucu bir çevrim oluşturduğunu göstermektedir. Bu çevrimin tetiklenme, duyuşal genişleme, işlevsel kapanma ve tükenme gibi aşamaları, daha önceki çalışmalarda da rapor edilmiştir. Özellikle Walter (2017), ergenlerde baş ağrısının sosyal izolasyon ve odak kaybıyla nasıl örtüştüğünü göstermiş, baş ağrısının yalnızca fiziksel değil, yaşam deneyimini şekillendiren bir fenomen olduğunu ortaya koymuştur (Walter, 2017). Benzer şekilde, Afifi ve arkadaşları (2019) baş ağrısı cerrahisi sonrası yaşanan "kendini yeniden normal hissetme" halinin, yalnızca ağrının azalmasından değil, duyuşal yükün hafiflemesinden kaynaklandığını bildirmiştir (Afifi et al., 2019).

Fonksiyonel kapanma ve emosyonel yıpranma, baş ağrısı deneyiminin yalnızca bireysel değil, sosyal ilişkileri de etkilediğini göstermektedir. Leiper ve arkadaşları (2006), bireylerin baş ağrısı sırasında işlevselliklerinin büyük ölçüde bozulduğunu, sosyal çevreyle etkileşimin azaldığını ve ruh

hâlinde ciddi dalgalanmalar yaşandığını ortaya koymuştur (Leiper et al., 2006). Öte yandan, bireylerin ağrıya rağmen işlevlerini sürdürmeye çalışma çabaları da “sosyal olarak güçlü görünme” normlarıyla yakından ilişkilidir. Rutberg ve Öhrling (2011), migren yaşayan kadınların bu görünmez hastalıkla başa çıkarken sürekli olarak dayanıklı görünmeye çalıştıklarını, bu durumun da duygusal tükenmişliği artırdığını bildirmiştir (Rutberg & Öhrling, 2011).

Son olarak, çalışmamızın klinik yansımaları oldukça önemlidir. Literatürde baş ağrısı tedavisinde sadece ağrının şiddetini değil, atağın zamanlamasını, duygusal ve davranışsal yükünü de dikkate almanın gerekliliği sıklıkla vurgulanmaktadır (Mannix et al., 2016). Gündüz piklerine göre düzenlenen farmakolojik planlamalar, bilişsel yeniden çerçeveleme teknikleri ve metaforik dil kullanımına dayalı psikoeğitim programları, yalnızca semptomları değil, baş ağrısıyla ilişkili tükenmişlik döngüsünü hedef alabilir. Wilson ve arkadaşlarının (2024) belirttiği gibi, baş ağrısının psikososyal bileşenlerini anlamak ve tedavi planlarına entegre etmek, hasta sonuçlarını anlamlı şekilde iyileştirebilir (Wilson et al., 2024).

Sonuç olarak, nitel bulgularımız baş ağrısının yalnızca fiziksel bir fenomen olmadığını, çok katmanlı bir tükenmişlik çevrimi içinde değerlendirildiğini ortaya koymakta ve bu çevrime müdahale etmek için hem zamana duyarlı hem de duygusal/işlevsel katmanları içeren çok boyutlu yaklaşımların gerekliliğini vurgulamaktadır.

7.SONUÇ

Bu tez, Türkiye'nin farklı şive ve lehçelerinde ağrı anlatılarını yapay zekâ temelli NLP yöntemleriyle inceleyerek, hekim-hasta iletişiminde dilsel bariyerleri aşmayı ve bu anlatılardan evrensel nitelikte bir ağrı ölçeği geliştirmeyi amaçladı. Çalışma, dört klinik gruptan (MS, epilepsi, baş ağrısı ve fibromiyalji) toplanan demografik, sözel ve ölçek verilerini bir araya getirerek hem psikometrik geçerlik-güvenirlilik testleri hem de TF-IDF, BERT gömüleri ve ensemble öğrenme algoritmalarıyla desteklenen ML modelleri uyguladı. MS'te ve Başağrısı grubunda böylelikle ağrı ölçeklerinin hastalık-spesifik performansı değerlendirilirken, yalnızca 12 sözcüklük anlatılarla bile ağrı eşiği ve ağrının spesifik parametrelerinin yüksek doğrulukla kestirilebileceği gösterildi; Gradient Boosting ve XGBoost modelleri genelde $R^2 \approx 0.99$ 'lık sonuçlara ulaşırken, KNN'in neredeyse hatasız fakat aşırı uyumlu çıktıları algoritma seçiminin önemini vurgulamaktadır.

Ayrıca bu tez içinde anketlerin geçerlik ve güvenilirliği bir daha test edilme imkanı bulundu. Bulgular, Ağrı Eşiği Ölçeği'nin MS ve baş ağrısı gruplarında kabul edilebilir iç tutarlılığa ($\alpha \approx 0.60-0.70$) sahip olduğunu; buna karşın epilepsi ve fibromiyalji gruplarında negatif alfa değerleriyle yetersiz kaldığını ortaya koydu. Ölçek uyumluluğu açısından SF-MPQ'nin MS hastalarında ($\alpha=0.883$) ve HFDI'nin baş ağrısı hastalarında ($\alpha=0.953$) yüksek güvenirlik sergilediği, BPI'nin ise epilepsi grubunda hem iç tutarlılık ($\alpha \approx 0.05$) hem de faktöryel yapı bakımından başarısız olduğu belirlendi. Fibromiyalji grubunda FSDC iki faktörlü beklenen yapıyı koruyarak orta-yüksek güvenirlik sağladı ($\alpha \approx 0.82$). Bu sonuçlar, ağrı deneyiminin hastalığa özgü heterojenliğini ve standart ölçeklerin her popülasyona aktarılmadan önce uyarlanması gerektiğini somut biçimde gösterdi.

Çalışma, dilsel çeşitliliğin tanınasal belirsizlik riskini azaltmak için AI destekli bir köprü işlevi görebileceğini kanıtladı; ancak verilerin Türkçe-odaklı olması, bazı lehçelerin az temsil edilmesi ve çapraz kesitsel tasarım gibi sınırlılıklar genelleştirilebilirliği kısıtladı. Gelecekte, epilepsi ve fibromiyalji gruplarına özgü madde geliştirme, çok dilli veri entegrasyonu, uzunlamasına izlem ve çok-modlu biyosinyal (örn. EDA, yüz ifadesi, fNIRS) eklemeleri düşünülebilir. Böylece hem evrensel ağrı ölçeği tasarımı olgunlaştırılabilecek hem de yapay zekâ modellerinin klinik karara doğrudan entegre edildiği, kişiselleştirilmiş ağrı yönetimi dönemi için sağlam bir zemin hazırlanacaktır.

8.KAYNAKÇA

1. Abu Bakar, N., Tanprawate, S., Lambu, G., Torkamani, M., Jahanshahi, M., & Matharu, M. (2016). Quality of life in primary headache disorders: A review. *Cephalalgia : an international journal of headache*, 36(1), 67–91. <https://doi.org/10.1177/0333102415580099>.
2. Abubakar, H., & Umar, M. (2022). Sentiment classification: Review of text vectorization methods: Bag of Words, TF-IDF, Word2Vec and Doc2Vec. *SLU Journal of Science and Technology*, 4(1). <https://doi.org/10.56471/slujst.v4i.266>
3. Adelmanesh, F., Jalali, A., Attarian, H., Farahani, B., Ketabchi, S., Arvantaj, A., & Raissi, G. (2012). Reliability, validity, and sensitivity measures of expanded and revised version of the short-form McGill Pain Questionnaire (SF-MPQ-2) in Iranian patients with neuropathic and non-neuropathic pain. *Pain Medicine*, 13(12), 1631–1636. <https://doi.org/10.1111/j.1526-4637.2012.01517.x>
4. Afifi, A., Schwarze, M., Stilp, E., Orne, J., Smith, J., Abd-Elseyed, A., Anderson, B., Salem, A., Macdonald, C., & Israel, J. (2019). “Like a normal person again”: A qualitative analysis of the impact of headache surgery. *Plastic and Reconstructive Surgery*, 144(4), 956–964. <https://doi.org/10.1097/PRS.00000000000006071>
5. Altintas, K., & Cicekli, I. (2022). A machine translation system between a pair of closely related languages. In *International symposium on computer and information sciences* (pp. 192-196). CRC Press. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=797c1cd0a44cfe2c5eb31bfe3ced112e62d9aab7>
6. Ankaralı, H., Dulger, S., & Cevik, C. (2017). The Pain Sensitivity Questionnaire and Its Relationship With Serum Vitamin D Levels in Patients With Chronic Non-Specific Musculoskeletal Pain. *Cukurova Medical Journal*, 42(4), 613-622. <https://dergipark.org.tr/en/pub/cumj/issue/30565/341684>
7. Apkarian, A., Baliki, M., & Geha, P. (2009). Towards a theory of chronic pain. *Progress in Neurobiology*, 87(1), 81-97. <https://doi.org/10.1016/j.pneurobio.2008.09.018>
8. Aykan, S., & Uçan, H. (2020). Reliability and validity of the Turkish Short-Form McGill Pain Questionnaire-2 (TR-SF-MPQ-2) in patients with chronic low back pain. *Turkish Journal of Physical Medicine and Rehabilitation*, 66(3), 343–350. <https://doi.org/10.5606/tftrd.2020.3689>
9. Babel, M. (2010). Dialect divergence and convergence in New Zealand English. *Language in Society*, 39(4), 437-456. https://scholarship.org/content/qt3d269192/qt3d269192_noSplash_f207a7e900d1d0afe6985d7589cfc633.pdf?t=ptdkne
10. Bacco, L., Russo, F., Ambrosio, L., D'Antoni, F., Vollero, L., Vadalà, G., Dell'Orletta, F., Merone, M., Papalia, R., & Denaro, V. (2022). Natural language processing in low back pain and spine diseases: A systematic review. *Frontiers in surgery*, 9, 957085. <https://doi.org/10.3389/fsurg.2022.957085>
11. Baker, P., & Lee, D. (2021). *Language and Linguistics: The Key Concepts*. Routledge. ISBN 9780415413596
12. Balta, S., Ünal-Ulutatar, Ç., Mirzayeva, S., Başkaya, M. Ç., & Akyüz, G. (2022). The reliability and validity of the Turkish version of the brief pain inventory-short form in patients with cancer pain. *Turkish journal of physical medicine and rehabilitation*, 68(2), 214-221. <https://doi.org/10.5606/tftrd.2022.6634>
13. Basbaum, A., Bautista, D., Scherrer, G., & Julius, D. (2009). Cellular and molecular mechanisms of pain. *Cell*, 139(2), 267-284. <https://doi.org/10.1016/j.cell.2009.09.028>
14. Battista, S., Lazzaretti, A., Coppola, I., Maistrello, F., Rania, N., & Testa, M. (2023). Living with migraine: A meta-synthesis of qualitative studies. *Frontiers in Psychology*, 14, Article 1129926. <https://doi.org/10.3389/fpsyg.2023.1129926>
15. Beghi E. (2016). Addressing the burden of epilepsy: Many unmet needs. *Pharmacological research*, 107, 79–84. <https://doi.org/10.1016/j.phrs.2016.03.003>
16. Beghi E. (2020). The Epidemiology of Epilepsy. *Neuroepidemiology*, 54(2), 185–191. <https://doi.org/10.1159/000503831>
17. Bender, M., Kuhr, F., Braun, T., & Möller, R. (2022). Estimating context-specific subjective content descriptions using BERT. In *2022 IEEE 16th International Conference on Semantic Computing (ICSC)* (pp. 171–172). IEEE. <https://doi.org/10.1109/ICSC52841.2022.00034>
18. Berkel, C., Knox, D., Flemotomos, N., Martinez, V., Atkins, D., Narayanan, S., Rodriguez, L., Gallo, C., & Smith, J. (2023). A machine learning approach to improve implementation monitoring of

- family-based preventive interventions in primary care. *Implementation Research and Practice*, 4, 26334895231187906. <https://doi.org/10.1177/26334895231187906>
19. Bidari, A., Ghavidel-Parsa, B., Amir Maafi, A., Montazeri, A., Ghalehbaghi, B., Hassankhani, A., Aarabi, Y., & Haghdoost, A. (2015). Validation of fibromyalgia survey questionnaire and polysymptomatic distress scale in a Persian population. *Rheumatology International*, 35(12), 2013–2019. <https://doi.org/10.1007/s00296-015-3340-z>
 20. Blanco, G., Martínez, R., & Lourenço, A. (2025). Leveraging deep learning to detect stance in Spanish tweets on COVID-19 vaccination. *JAMIA Open*, 8, ooaf007. <https://doi.org/10.1093/jamiaopen/ooaf007>
 21. Breiman, L. Bagging predictors. *Machine Learning*, 24, 123–140 (1996). <https://doi.org/10.1007/BF00058655>
 22. Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language Models are Few-Shot Learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901. <https://proceedings.neurips.cc/paper/2020/file/1457c0d6bfc4967418bfb8ac142f64a-Paper.pdf>
 23. Bruce, M., Lopatina, E., Hodge, J., Moffat, K., Khan, S., Pyle, P., Kashuba, S., Wasylak, T., & Santana, M. (2023). Understanding the chronic pain journey and coping strategies that patients use to manage their chronic pain: A qualitative, patient-led, Canadian study. *BMJ Open*, 13(5), e072048. <https://doi.org/10.1136/bmjopen-2023-072048>
 24. Buche, A. (2020). BERT for Opinion Mining and Sentiment Farming. *Bioscience Biotechnology Research Communications*. <https://doi.org/10.21786/BBRC/13.14/9>.
 25. Buppha, P., Tontisirin, N., Numthavaj, P., Sakdanuwatwong, S., Sodsee, W., & Finlayson, R. (2016). Reliability and validity of the Thai Short-Form McGill Pain Questionnaire-2 (SF-MPQ-2). *Journal of Anesthesia and Clinical Research*, 7, Article 650. <https://doi.org/10.4172/2155-6148.1000650>
 26. Cardenas, E., Shorten, C., Khoshgoftaar, T., & Furht, B. (2022). A comparison of house price classification with structured and unstructured text data. *The International FLAIRS Conference Proceedings*, 35, 130668. <https://doi.org/10.32473/flairs.v35i.130668>
 27. Carlson, J. E., & Davier, M. (2013). Item Response Theory. ETS Research Report Series, 2013(1), 133-178. <https://doi.org/10.1002/J.2333-8504.2013.TB02335.X>
 28. Carrington, A. M., Manuel, D., Fieguth, P., Ramsay, T., Osmani, V., Wernly, B., Bennett, C., Hawken, S., Magwood, O., Sheikh, Y., McInnes, M., & Holzinger, A. (2021). Deep ROC analysis and AUC as balanced average accuracy, for improved classifier selection, audit and explanation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(2), 329-341. <https://doi.org/10.1109/TPAMI.2022.3145392>
 29. Casciato, S., Morano, A., Fattouch, J., Fanella, M., Albin, M., Giallonardo, A., & Di Bonaventura, C. (2017). Ictal pain in focal non-convulsive status epilepticus. *Practical Neurology*, 17(6), 400–402. <https://doi.org/10.1136/practneurol-2017-001623>
 30. Chapman, C. R., & Vierck, C. J. (2017). The transition of acute postoperative pain to chronic pain: An integrative overview of research on mechanisms. *The Journal of Pain*, 18(4), 359.e1-359.e38. <https://doi.org/10.1016/j.jpain.2016.11.004>
 31. Charlesworth, G., Soryal, I., Smith, S. M. J., & Sisodiya, S. (2009). Acute, localised paroxysmal pain as the initial manifestation of focal seizures: A case report and a brief review of the literature. *Pain*, 141(3), 300–305. <https://doi.org/10.1016/j.jpain.2008.11.005>
 32. Chatzimpampas, A., Martins, R. M., Kucher, K., & Kerren, A. (2020). StackGenVis: Alignment of data, algorithms, and models for stacking ensemble learning using performance metrics. *IEEE Transactions on Visualization and Computer Graphics*, 27(2), 1547-1557. <https://doi.org/10.1109/TVCG.2020.3030352>
 33. Chen, X., Wei, C., Zhou, G., Wu, H., Wang, Z., & Biancardo, S. A. (2022). Automatic Identification System (AIS) Data Supported Ship Trajectory Prediction and Analysis via a Deep Learning Model. *Journal of Marine Science and Engineering*, 10(9), 1314. <https://doi.org/10.3390/jmse10091314>
 34. Chen, Y.-C., Gan, Z., Cheng, Y., Liu, J., & Liu, J. (2020, July). Distilling knowledge learned in BERT for text generation. In D. Jurafsky, J. Chai, N. Schluter, & J. Tetreault (Eds.), *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (pp. 7893–7905). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2020.acl-main.705>
 35. Chen, Y.-W., HajGhanbari, B., Road, J. D., Coxson, H. O., Camp, P. G., & Reid, W. D. (2018). Reliability and validity of the Brief Pain Inventory in individuals with chronic obstructive pulmonary disease. *European Journal of Pain*, 22(1), 72–81. <https://doi.org/10.1002/ejp.1258ü>

36. Chicco, D., Warrens, M., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
37. Chidinma, O. A., Borah, S., & Panigrahi, R. (2021). Suicidal intent prediction using natural language processing (Bag of Words) approach. In S. Borah, R. Pradhan, N. Dey, & P. Gupta (Eds.), *Soft computing techniques and applications* (Vol. 1248, pp. 157–169). Springer. https://doi.org/10.1007/978-981-15-7394-1_14
38. Clair, V. (2003). Storymaking and storytelling: Making sense of living with multiple sclerosis. *Journal of Occupational Science*, 10(1), 46–51. <https://doi.org/10.1080/14427591.2003.9686510>
39. Clopper, C., & Pisoni, D. (2006). Effects of region of origin and geographic mobility on perceptual dialect categorization. *Language Variation and Change*, 18, 193 – 221. <https://doi.org/10.1017/S0954394506060091>
40. Cui, S., Tseng, H., Pakela, J., Ten Haken, R. K., & El Naqa, I. (2020). Introduction to machine and deep learning for medical physicists. *Medical Physics*, 47(5), 1-15. <https://doi.org/10.1002/mp.14140>
41. Cutler, D. R. (2018). *Prediction and interpretation for machine learning regression methods* (Paper No. 1967-2018). Proceedings of the SAS Global Forum. Utah State University. <https://support.sas.com/resources/papers/proceedings18/1967-2018.pdf>
42. Dai, S., Li, K., Luo, Z., Zhao, P., Hong, B., Zhu, A., & Liu, J. (2024). AI-based NLP section discusses the application and effect of bag-of-words models and TF-IDF in NLP tasks. *Journal of Artificial Intelligence General Science*, 5(1). <https://doi.org/10.60087/jaigs.v5i1.149>
43. Dakshnamoorthy, V. (2022). A short text clustering approaches in social media. *ECS Transactions*, 107(1), 1375–1386. <https://doi.org/10.1149/10701.1375ecst>
44. D'Amico, D., Grazi, L., Usai, S., Leonardi, M., & Raggi, A. (2013). Disability and quality of life in headache: where we are now and where we are heading. *Neurological sciences : official journal of the Italian Neurological Society and of the Italian Society of Clinical Neurophysiology*, 34 Suppl 1, S1–S5. <https://doi.org/10.1007/s10072-013-1378-9>
45. Deulkar, K., Narvekar, M., Gandhi, P., Gada, D., & Kamath, S. (2024). Evaluating the influence of text representation techniques on diverse machine learning algorithms for stress detection in social media users. In *2024 International Conference on Advances in Modern Age Technologies for Health and Engineering Science (AMATHE)* (pp. 1–7). IEEE. <https://doi.org/10.1109/AMATHE61652.2024.10582212>
46. Devi, P., Sarkar, S., Singh, T., Sharma, L., Pankaj, C., & Singh, K. (2022). An approach to evaluating subjective answers using BERT model. In *2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)* (pp. 1–4). IEEE. <https://doi.org/10.1109/CONECCT55679.2022.9865706>
47. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL-HLT 2019*, 4171-4186. <https://doi.org/10.18653/v1/N19-1423>
48. DeVries, Z., Locke, E., Hoda, M., Moravek, D., Phan, K., Stratton, A., Kingwell, S., Wai, E., & Phan, P. (2021). Using a national surgical database to predict complications following posterior lumbar surgery and comparing the area under the curve and F1-score for the assessment of prognostic capability. *The Spine Journal: Official Journal of the North American Spine Society*. <https://doi.org/10.1016/j.spinee.2021.02.007>
49. Dinsa, E., Das, M., Abebe, T., & Ramaswamy, K. (2024). Automatic categorization of medical documents in Afaan Oromo using ensemble machine learning techniques. *Discover Applied Sciences*, 5, Article 06307. <https://doi.org/10.1007/s42452-024-06307-0>
50. DiPietro, R., & Hager, G. (2020). Deep learning: RNNs and LSTM. *Computational Pathology and Ophthalmic Imaging*, 503-519. <https://doi.org/10.1016/b978-0-12-816176-0.00026-0>
51. Djellouli, K., Haddouche, K., Belarbi, M., & Aich, Z. (2023). Prediction of the cutting tool wear during dry hard turning of AISI D2 steel by using models based on learning process and GA polyfit. *The Journal of Engineering and Exact Sciences*, 9(12), e18297. <https://doi.org/10.18540/jeccvl9iss12pp18297>
52. Duffy, S. S., Lees, J. G., Perera, C. J., & Moalem-Taylor, G. (2018). Managing Neuropathic Pain in Multiple Sclerosis: Pharmacological Interventions. *Medicinal chemistry (Sharjah (United Arab Emirates))*, 14(2), 106–119. <https://doi.org/10.2174/1573406413666170906122508>
53. Dworkin, R. H., Turk, D. C., Revicki, D. A., Harding, G., Coyne, K. S., Peirce-Sandner, S., Bhagwat, D., Everton, D., Burke, L. B., Cowan, P., Farrar, J. T., Hertz, S., Max, M. B., Rappaport, B. A., &

- Melzack, R. (2009). Development and initial validation of an expanded and revised version of the Short-Form McGill Pain Questionnaire (SF-MPQ-2). *PAIN*, 144(1–2), 35–42. <https://doi.org/10.1016/j.pain.2009.02.007>
54. Edirisinghe, N., Makuloluwa, T., Amarasekara, T., & Goonewardena, C. (2019). Psychometric properties of Sinhala version of Short-Form McGill Pain Questionnaire-2 (SF-MPQ-2-Sin) among patients with cancer pain in Sri Lanka. *Pain Research & Management*, 2019, 5050979. <https://doi.org/10.1155/2019/5050979>
 55. Eivind Hasvik, Haugen, A., Haukeland-Parker, S., Rimehaug, S. A., Gjerstad, J., & Grøvle, L. (2019). Cross-cultural adaptation and validation of the Norwegian Short-form McGill Pain Questionnaire-2 in low back-related leg pain. *Spine*, 44(13), E774–E781. <https://doi.org/10.1097/BRS.0000000000002976>
 56. Falsiroli Maistrello, L., Rafanelli, M., & Turolla, A. (2019). Manual Therapy and Quality of Life in People with Headache: Systematic Review and Meta-analysis of Randomized Controlled Trials. Current pain and headache reports, 23(10), 78. <https://doi.org/10.1007/s11916-019-0815-8>
 57. Fang, P., Wang, X., Ge, J., Li, J., Yang, Z., Li, D., & Nai, W. (2023). Elastic Network Regression Based on Sobol Sequence Initialized Lightning Attachment Procedure Optimization. *2023 IEEE 14th International Conference on Software Engineering and Service Science (ICSESS)*, 252–257. <https://doi.org/10.1109/ICSESS58500.2023.10293052>.
 58. Favretti, M., Iannuccelli, C., & Di Franco, M. (2023). Pain Biomarkers in Fibromyalgia Syndrome: Current Understanding and Future Directions. *International journal of molecular sciences*, 24(13), 10443. <https://doi.org/10.3390/ijms241310443>
 59. Feizerfan, A., & Sheh, G. (2015). Transition from acute to chronic pain. *Continuing Education in Anaesthesia, Critical Care & Pain*, 15(2), 98–102. <https://doi.org/10.1093/BJACEACCP/MKU044>
 60. Ferraro, D., Plantone, D., Morselli, F., Dallari, G., Simone, A. M., Vitetta, F., Sola, P., Primiano, G., Nociti, V., Pardini, M., Mirabella, M., & Vollono, C. (2018). Systematic assessment and characterization of chronic pain in multiple sclerosis patients. *Neurological sciences : official journal of the Italian Neurological Society and of the Italian Society of Clinical Neurophysiology*, 39(3), 445–453. <https://doi.org/10.1007/s10072-017-3217-x>
 61. Ferreira, A., Pereira, D., Da Silva, S., Carvalho, G., & Pereira, L. (2023). Validity and reliability of the short form brief pain inventory in older adults with nociceptive, neuropathic and nociplastic pain. *Geriatric Nursing*, 52, 16–23. <https://doi.org/10.1016/j.gerinurse.2023.04.011>
 62. Fitzcharles, M. A., Ste-Marie, P. A., Panopalis, P., Ménard, H., Shir, Y., & Wolfe, F. (2012). The 2010 American College of Rheumatology fibromyalgia survey diagnostic criteria and symptom severity scale is a valid and reliable tool in a French speaking fibromyalgia cohort. *BMC Musculoskeletal Disorders*, 13, 179. <https://doi.org/10.1186/1471-2474-13-179>
 63. Fraenkel, L., Falzer, P., Fried, T., Kohler, M., Peters, E., Kerns, R., & Leventhal, H. (2012). Measuring pain impact versus pain severity using a numeric rating scale. *Journal of General Internal Medicine*, 27(5), 555–560. <https://doi.org/10.1007/s11606-011-1926-z>
 64. Fratello, M., & Tagliaferri, R. (2019). Decision trees and random forests. In *Computational Biology* (pp. 374–383). <https://doi.org/10.1016/B978-0-12-809633-8.20337-3>
 65. Galvez-Sánchez, C. M., De La Coba, P., Duschek, S., & Del Paso, G. A. R. (2020). Reliability, factor structure and predictive validity of the Widespread Pain Index and Symptom Severity Scales of the 2010 American College of Rheumatology Criteria of Fibromyalgia. *Journal of Clinical Medicine*, 9(8), 2460. <https://doi.org/10.3390/jcm9082460>
 66. Garrido-Merchán, E. C., Gozalo-Brizuela, R., & Gonzalez-Carvajal, S. (2023). Comparing BERT against traditional machine learning models in text classification. *Journal of Computational and Cognitive Engineering*, 2(4), 352–356. <https://doi.org/10.47852/bonviewJCCE3202838>
 67. Gatchel, R. J., Peng, Y. B., Peters, M. L., Fuchs, P. N., & Turk, D. C. (2007). The biopsychosocial approach to chronic pain: scientific advances and future directions. *Psychological bulletin*, 133(4), 581–624. <https://doi.org/10.1037/0033-2909.133.4.581>
 68. Gilmore, R., & Strong, J. (1998). Pain and multiple sclerosis. *The British Journal of Occupational Therapy*, 61(4), 169–172. <https://doi.org/10.1177/030802269806100410>
 69. Goje, S., & Patil, R. (2024). Sentiment analysis of political parties on social media: A machine learning and lexicon-based approach. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*. <https://doi.org/10.32628/cseit24105103>
 70. Goldenberg D. L. (2009). Diagnosis and differential diagnosis of fibromyalgia. *The American journal of medicine*, 122(12 Suppl), S14–S21. <https://doi.org/10.1016/j.amjmed.2009.09.007>

71. Gomes, L., Torres, R., & Côrtes, M. (2023). BERT- and TF-IDF-based feature extraction for long-lived bug prediction in FLOSS: A comparative study. *Information and Software Technology*, 160, 107217. <https://doi.org/10.1016/j.infsof.2023.107217>
72. González-Carvajal, S., & Garrido-Merchán, E. (2020). Comparing BERT against traditional machine learning text classification. *ArXiv*, abs/2005.13012. <https://doi.org/10.47852/bonviewJCCE3202838>
73. Guan-Heng Liu, Chin-Ling Li, Chih-Yuan Yang and Shih-Feng Liu. "Development and validation of a novel AI-derived index for predicting COPD medical costs in clinical practice." *Computational and Structural Biotechnology Journal*, 27 (2025): 541 - 547. <https://doi.org/10.1016/j.csbj.2025.01.015>.
74. Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63, 3-42. <https://doi.org/10.1007/s10994-006-6226-1>.
75. Hanić, S., Babac, M., Gledec, G., & Horvat, M. (2024). Comparing machine learning models for sentiment analysis and rating prediction of vegan and vegetarian restaurant reviews. *Computers*, 13(10), 248. <https://doi.org/10.3390/computers13100248>
76. Haroon, M., Tripathi, M., Ahmad, S., Ahmad, J., Ahmad, S., Siddiqui, Z., & Ahmad, T. (2024). Improving Stock Price Prediction Accuracy Using Multivalued Regression: The Role of Normalization Techniques in Machine Learning Models. *2024 Second International Conference Computational and Characterization Techniques in Engineering & Sciences (IC3TES)*, 1-6. <https://doi.org/10.1109/ic3tes62412.2024.10877679>.
77. Harrison, C. J., & Sidey-Gibbons, C. J. (2021). Machine learning in medicine: A practical introduction to natural language processing. *BMC Medical Research Methodology*, 21(1), 158. <https://doi.org/10.1186/s12874-021-01347-1>
78. Heintzelman, N. H., Taylor, R. J., Simonsen, L., Lustig, R., Anderko, D., Haythornthwaite, J. A., Childs, L. C., & Bova, G. S. (2013). Longitudinal analysis of pain in patients with metastatic prostate cancer using natural language processing of medical record text. *Journal of the American Medical Informatics Association : JAMIA*, 20(5), 898–905. <https://doi.org/10.1136/amiajnl-2012-001076>
79. Heitmann, H., Haller, B., Tiemann, L., Mühlau, M., Berthele, A., Tölle, T. R., Salmen, A., Ambrosius, B., Bayas, A., Asseier, S., Hartung, H. P., Heesen, C., Stangel, M., Wildemann, B., Haars, S., Groppa, S., Luessi, F., Kümpfel, T., Nischwitz, S., Meuth, S. G., ... German Competence Network Multiple Sclerosis (KKNMS) (2020). Longitudinal prevalence and determinants of pain in multiple sclerosis: results from the German National Multiple Sclerosis Cohort study. *Pain*, 161(4), 787–796. <https://doi.org/10.1097/j.pain.0000000000001767>
80. Hlaváč, J. Č., Kopp, M., Polák, M., & Kohout, J. D. (2021). Towards reliable network entity tracking using behavioural bag of words representation. In *Conference on Theory and Practice of Information Technologies*. https://www.semanticscholar.org/paper/Towards-Reliable-Network-Entity-Tracking-Using-Bag-Hlav%C3%A1%C4%8D-Kopp/9a366adae66dcf946f567c4913e9f9be02d03c2b?utm_source=consensus
81. Hoffmann, J., & Holland, P. (2019). Brain structure and function related to headache. *Cephalalgia*, 39(13), 1603–1605. <https://doi.org/10.1177/0333102419884007>
82. Hovey, R., Khayat, V., & Feig, E. (2018). Listening to and letting pain speak: Poetic reflections. *British Journal of Pain*, 12(2), 103–105. <https://doi.org/10.1177/2049463717741146>
83. Huang, X., Sun, J., Majoor, J., Vermeer, K., Lemij, H., Elze, T., Wang, M., Boland, M., Pasquale, L., Mohammadzadeh, V., Nouri-Mahdavi, K., Johnson, C., & Yousefi, S. (2021). Estimating the Severity of Visual Field Damage From Retinal Nerve Fiber Layer Thickness Measurements With Artificial Intelligence. *Translational Vision Science & Technology*, 10. <https://doi.org/10.1167/tvst.10.9.16>.
84. Ibrahim, A., Park, K., Hong, J., Pham, V., & Ryu, K. (2023). An Extreme Gradient Boosting-based Prediction for Depression. *2023 Asia Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*, 1607-1613. <https://doi.org/10.1109/APSIPAASC58517.2023.10317543>.
85. Issa, T. S., & Huijbregts, P. A. (2006). Physical therapy diagnosis and management of a patient with chronic daily headache: A case report. *Journal of Manual & Manipulative Therapy*, 14(4), 123E–88E. <https://doi.org/10.1179/jmt.2006.14.4.88E>
86. Jabbari, S., Salahzadeh, Z., Sarbakhsh, P., Rezaei, M., Farhoudi, M., & Ghodrati, M. (2021). Validity and reliability of Persian version of Henry Ford Hospital Headache Disability Inventory questionnaire. *Archives of Iranian Medicine*, 24(10), 752–758. <https://doi.org/10.34172/aim.2021.111>

87. Jacobson, G., Ramadan, N., Aggarwal, S. K., & Newman, C. (1994). The Henry Ford Hospital Headache Disability Inventory (HDI). *Neurology*, 44(5), 837. <https://doi.org/10.1212/WNL.44.5.837>
88. Kamath, B., Acharya, D., Ayush, S., Rao, S., Rai, A., & S., S. (2025). Comprehensive analysis of word embedding models and design of effective feature vector for classification of Amazon product reviews. *IEEE Access*, 13, 25239–25255. <https://doi.org/10.1109/ACCESS.2025.3536631>
89. Keen, S., Lomeli-Rodriguez, M., & Williams, A. (2021). Exploring how people with chronic pain understand their pain: A qualitative study. *Scandinavian Journal of Pain*, 21(4), 743-753. <https://doi.org/10.1515/sjpain-2021-0060>
90. Keller, S., Bann, C. M., Dodd, S. L., Schein, J., Mendoza, T. R., & Cleeland, C. S. (2004). Validity of the Brief Pain Inventory for use in documenting the outcomes of patients with noncancer pain. *The Clinical Journal of Pain*, 20(5), 309–318. <https://doi.org/10.1097/00002508-200409000-00005>
91. Kılınç, H. E., Öz, M., Berberoğlu, U., Özel Ashlyüce, Y., Onan, D., Fanuscu, A., & Ülger, Ö. (2024). Cross-cultural adaptation, reliability and validity of the Turkish version of the Henry Ford Hospital Headache Disability Inventory (HDI/T) in patients with cervicogenic headache. *Disability and rehabilitation*, 46(4), 820–827. <https://doi.org/10.1080/09638288.2023.2178679>
92. Kılınç, H., Öz, M., Berberoğlu, U., Özel Ashlyüce, Y., Onan, D., Fanuscu, A., & Ülger, Ö. (2023). Cross-cultural adaptation, reliability and validity of the Turkish version of the Henry Ford Hospital Headache Disability Inventory (HDI/T) in patients with cervicogenic headache. *Disability and Rehabilitation*, 46(5), 820–827. <https://doi.org/10.1080/09638288.2023.2178679>
93. Kim, G., Kim, J., Kim, M., Kwon, T., & Jang, B. (2024). An approach on improving the recommender system: Predicting movie genres based on plot summaries. In *2024 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* (pp. 270–274). IEEE. <https://doi.org/10.1109/ICAIIIC60209.2024.10463349>
94. Kim, J., Kim, H., Sohn, J., Hwang, S., Lee, J., & Kwon, Y. (2025). Functional disability and psychological impact in headache patients: A comparative study using conventional statistics and machine learning analysis. *Medicina*, 61(2), Article 20188. <https://doi.org/10.3390/medicina61020188>
95. Kim, J.-U., Im, J.-G., Lee, J.-B., Lee, H.-G., & Yook, T.-H. (2011). Effects of the acupuncture therapy in combination with Soyeom pharmacopuncture therapy on acute whiplash injury by traffic accident. *The Journal of Korean Acupuncture & Moxibustion Society*, 28(4). <https://koreascience.kr/article/JAKO201124239514188.pdf>
96. Kookalani, S., Cheng, B., & Torres, J. (2022). Structural performance assessment of GFRP elastic gridshells by machine learning interpretability methods. *Frontiers of Structural and Civil Engineering*, 16, 1249 - 1266. <https://doi.org/10.1007/s11709-022-0858-5>.
97. Kuloğlu Pazarcı, N., Bebek, N., Baykan, B., Gürses, C., & Gökyiğit, A. (2016). Reappraisal of epileptic pain as a rare symptom of seizures. *Epilepsy & behavior : E&B*, 55, 101–107. <https://doi.org/10.1016/j.yebeh.2015.12.015>
98. Kumar, V., Kedam, N., Sharma, K., Mehta, D., & Caloiero, T. (2023). Advanced Machine Learning Techniques to Improve Hydrological Prediction: A Comparative Analysis of Streamflow Prediction Models. *Water*. <https://doi.org/10.3390/w15142572>.
99. Kwon M. The Relationship between Pain and Quality of Life in Stroke Patients. *KSPM* 2017;12:83-90. <https://doi.org/10.13066/kspm.2017.12.2.83>
100. Lakshmidevi, N., Swain, S., & Vamsikrishna, M. (2023). A hybrid enhancing aspect-based sentiment analysis with BERT for aspect extraction and diverse ML classifiers. In *2023 International Conference on Network, Multimedia and Information Technology (NMITCON)* (pp. 1–8). IEEE. <https://doi.org/10.1109/NMITCON58196.2023.10275957>
101. Larsson, J., & Wallin, J. (2025). The Choice of Normalization Influences Shrinkage in Regularized Regression. *ArXiv*, abs/2501.03821. <https://doi.org/10.48550/arXiv.2501.03821>.
102. LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>
103. Lee, S., Chu, W., Tseng, Y., Zhang, Y., & Tsai, H. (2024). Explainable AI Applied in Healthcare: A Case Study of Diabetes Prediction. *2024 IEEE 24th International Conference on Software Quality, Reliability, and Security Companion (QRS-C)*, 336-344. <https://doi.org/10.1109/QRS-C63300.2024.00050>.
104. Leiper, D., Elliott, A., & Hannaford, P. (2006). Experiences and perceptions of people with headache: A qualitative study. *BMC Family Practice*, 7, Article 27. <https://doi.org/10.1186/1471-2296-7-27>

105. Lew, Y. F. H., & Xin, X. (2020). Using a narrative practice approach to understand in-depth experiences of individuals coping with chronic pain. *Pain Medicine*, 21(10), 2037–2045. <https://doi.org/10.1093/pm/pnaa223>
106. Li, C., & Wu, J. (2023). Bandgap Prediction of Two-Dimensional Transition Metal Layered Binary Compounds Based on Regression Forest Machine Learning Method. *2023 3rd International Conference on Electronic Information Engineering and Computer Science (EIECS)*, 1174–1182. <https://doi.org/10.1109/EIECS59936.2023.10435609>.
107. Li, X., Wang, X., & Liu, H. (2021). Research on fine-tuning strategy of sentiment analysis model based on BERT. In *2021 International Conference on Communications, Information System and Computer Engineering (CISCE)* (pp. 798–802). IEEE. <https://doi.org/10.1109/CISCE52179.2021.9445882>
108. Lin, W., Tsai, C., & Chen, H. (2022). Factors affecting text mining-based stock prediction: Text feature representations, machine learning models, and news platforms. *Applied Soft Computing*, 130, 109673. <https://doi.org/10.1016/j.asoc.2022.109673>
109. Liu, K., Zhang, L., Wang, W., Zhang, G., Xu, L., Fan, D., & Yu, R. (2023). Development of compressive strength prediction platform for concrete materials based on machine learning techniques. *Journal of Building Engineering*. <https://doi.org/10.1016/j.jobe.2023.107977>.
110. Lobo, J., Jiménez-Valverde, A., & Real, R. (2008). AUC: a misleading measure of the performance of predictive distribution models. *Global Ecology and Biogeography*, 17(2), 145–151. <https://doi.org/10.1111/J.1466-8238.2007.00358.X>
111. Lorente, M. P. S., Ledezma, A., & Sanchis, A. (2015). Generating ensembles of heterogeneous classifiers using stacked generalization. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 5(1), 21–34. <https://doi.org/10.1002/widm.1143>
112. Lovejoy, T. I., Turk, D. C., & Morasco, B. J. (2012). Evaluation of the psychometric properties of the revised short-form McGill Pain Questionnaire. *The Journal of Pain*, 13(12), 1250–1257. <https://doi.org/10.1016/j.jpain.2012.09.011>
113. Lvovschi, V., Roussel, M., & Dussart, C. (2019). A systemic approach to complete the multimodal assessment model of pain. *The Clinical Journal of Pain*, 35(7), 545–550. <https://doi.org/10.1097/AJP.0000000000000715>
114. Lynn, H. M., Pan, S., & Kim, P. (2019). A deep bidirectional GRU network model for biometric electrocardiogram classification based on recurrent neural networks. *IEEE Access*, 7, 145395–145405. <https://doi.org/10.1109/ACCESS.2019.2939947>
115. Maabreh, M., & Almasabha, G. (2023). Machine Learning Regression Algorithms for Shear Strength Prediction of SFRC-DBs: Performance Evaluation and Comparisons. *Arabian Journal for Science and Engineering*. <https://doi.org/10.1007/s13369-023-08176-y>.
116. Maguire, A. D., Bethea, J. R., & Kerr, B. J. (2021). TNF α in MS and Its Animal Models: Implications for Chronic Pain in the Disease. *Frontiers in neurology*, 12, 780876. <https://doi.org/10.3389/fneur.2021.780876>
117. Mahfouz, M. A., Shoukry, A., & Ismail, M. A. (2021). EKNN: Ensemble classifier incorporating connectivity and density into kNN with application to cancer diagnosis. *Artificial Intelligence in Medicine*, 111, 101985. <https://doi.org/10.1016/j.artmed.2020.101985>
118. Maiti, A., Abarda, A., & Hanini, M. (2024). The impact of feature extraction techniques on the performance of text data classification models. *Indonesian Journal of Electrical Engineering and Computer Science*, 35(2), 1041–1052. <https://doi.org/10.11591/ijeecs.v35.i2.pp1041-1052>
119. Mannix, S., Skalicky, A., Buse, D., Desai, P., Sapra, S., Ortmeier, B., Widnell, K., & Hareendran, A. (2016). Measuring the impact of migraine for evaluating outcomes of preventive treatments for migraine headaches. *Health and Quality of Life Outcomes*, 14, 143. <https://doi.org/10.1186/s12955-016-0542-3>
120. Marco, C. A., Nagel, J. H., Klink, E. J., & Baehren, D. F. (2012). Factors associated with self-reported pain scores among ED patients. *The American Journal of Emergency Medicine*, 30(2), 331–337. <https://doi.org/10.1016/j.ajem.2010.12.015>
121. Markchom, T., Liang, H., & Chen, J. (2022, July). UoR-NCL at SemEval-2022 Task 3: Fine-tuning the BERT-based models for validating taxonomic relations. In G. Emerson, N. Schluter, G. Stanovsky, R. Kumar, A. Palmer, N. Schneider, S. Singh, & S. Ratan (Eds.), *Proceedings of the 16th International Workshop on Semantic Evaluation (SemEval-2022)* (pp. 260–265). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2022.semeval-1.33>

122. Martin, P. R. (2018). Pain and epilepsy: A clinical, neuroanatomical and pathophysiological review. *Schmerz*, 32(4), 301–320. <https://doi.org/10.1007/s00482-018-0298-2>
123. Maruo, T., Nakae, A., Maeda, L., Shi, K., Takahashi, K., Morris, S., Hosomi, K., Kanatani, H., Matsuzaki, T., & Saitoh, Y. (2014). Validity, reliability, and assessment sensitivity of the Japanese version of the Short-Form McGill Pain Questionnaire-2 in Japanese patients with neuropathic and non-neuropathic pain. *Pain Medicine*, 15(11), 1930–1937. <https://doi.org/10.1111/pme.12468>
124. Mehdizadeh, M., Fereshtehnejad, S. M., Goudarzi, S., Moshtagh, A., Dehghanian Nasrabadi, F., Habibi, S. A. H., & Taghizadeh, G. (2020). Validity and reliability of Short-Form McGill Pain Questionnaire-2 (SF-MPQ-2) in Iranian people with Parkinson's disease. *Parkinson's Disease*, 2020, Article 2793945. <https://doi.org/10.1155/2020/2793945>
125. Melzack, R., & Wall, P. D. (1984). The challenge of pain. Penguin Books. ISBN-13:978-0140256703
126. Mendoza-Contreras, L. A., Domínguez Trejo, B., Guillén Núñez, M. D. R., Rodríguez Medina, D. A., Montero Pardo, X., Estapé, T., & Galindo Vázquez, O. (2025). Psychometric properties of the Short-Form McGill Pain Questionnaire (SF-MPQ) in adult Mexican cancer patients with chronic pain. *Palliative & Supportive Care*, 23, e20. <https://doi.org/10.1017/S1478951524001731>
127. Modak, A., Chatterjee, T., Nag, S., Roy, R., Tudu, B., & Bandyopadhyay, R. (2018). Linear Regression Modelling on Epigallocatechin-3-gallate Sensor Data for Green Tea. *2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*, 112-117. <https://doi.org/10.1109/ICRCICN.2018.8718696>.
128. Morabit-El, S., Rivenq, A., Zighem, M., Hadid, A., Ouahabi, A., & Taleb-Ahmed, A. (2021). Automatic Pain Estimation from Facial Expressions: A Comparative Analysis Using Off-the-Shelf CNN Architectures. *Electronics*. <https://doi.org/10.3390/electronics10161926>.
129. Morse, J. M. (2015). Using qualitative methods to access the pain experience. *British Journal of Pain*, 9(1), 26–31. <https://doi.org/10.1177/2049463714550507>
130. Moscato, S., Orlandi, S., Di Gregorio, F., Lullini, G., Pozzi, S., Sabattini, L., Chiari, L., & La Porta, F. (2023). Feasibility interventional study investigating PAIN in neurorehabilitation through wearable sensors (PAINLESS): A study protocol. *BMJ Open*, 13(11), e073534. <https://doi.org/10.1136/bmjopen-2023-073534>
131. Mujawar, S., Sayed, M., & Chaware, A. (2024). Empowering Decision Making in Healthcare - A Comparative Analysis of eXplainable AI Techniques Using SHAP and LIME for Cancer Patients Data. *2024 3rd Edition of IEEE Delhi Section Flagship Conference (DELCON)*, 1-5. <https://doi.org/10.1109/DELCON64804.2024.10867049>.
132. Mulla, Y., Markey, K. A., Woolley, R. L., Patel, S., Mollan, S. P., & Sinclair, A. J. (2015). Headache determines quality of life in idiopathic intracranial hypertension. *The journal of headache and pain*, 16, 521. <https://doi.org/10.1186/s10194-015-0521-9>
133. Murphy KL, Bethea JR, Fischer R. Neuropathic Pain in Multiple Sclerosis—Current Therapeutic Intervention and Future Treatment Perspectives. In: Zagon IS, McLaughlin PJ, editors. *Multiple Sclerosis: Perspectives in Treatment and Pathogenesis* [Internet]. Brisbane (AU): Codon Publications; 2017 Nov 27. Chapter 4. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK470151/>
134. Nagireddi, J. N., Vyas, A. K., Sanapati, M. R., Soin, A., & Manchikanti, L. (2022). The Analysis of Pain Research through the Lens of Artificial Intelligence and Machine Learning. *Pain physician*, 25(2), E211–E243.
135. Nema, T., Kumtekar, V., & Kulkarni, S. (2023). Text enhanced ensemble for human stress prediction. In *2023 4th IEEE Global Conference for Advancement in Technology (GCAT)* (pp. 1–8). IEEE. <https://doi.org/10.1109/GCAT59970.2023.10353395>
136. Névél, A., Dalianis, H., Velupillai, S., Savova, G., & Zweigenbaum, P. (2018). Clinical natural language processing in languages other than English: Opportunities and challenges. *Journal of Biomedical Semantics*, 9(1), 12. <https://doi.org/10.1186/s13326-018-0179-8>
137. Nugent, S. M., Lovejoy, T. I., Shull, S. G., Dobscha, S. K., & Morasco, B. J. (2021). Associations of pain numeric rating scale scores collected during usual care with research-administered patient-reported pain outcomes. *Pain Medicine*, 22(11), 2497–2505. <https://doi.org/10.1093/pm/pnab110>
138. Nunes, D., Ferreira-Gomes, J., Vaz, C., De Oliveira, D., Pimenta, S., Neto, F., & De Matos, D. (2022). Analysis of chronic pain descriptions for base-pathology prediction: The case of rheumatoid arthritis versus spondylitis pathology prediction based on pain descriptions. *Revista DOR*, 23(3), 230–238. <https://doi.org/10.24875/dor.m22000014>

139. O'Callaghan F. (2005). Childhood epilepsy: language, learning and behavioural complications. *Archives of Disease in Childhood*, 90(6), 658–659. <https://doi.org/10.1136/adc.2004.054833>
140. Omer, P. (2020). Improving Prediction Accuracy of Lasso and Ridge Regression as an Alternative to LS Regression to Identify Variable Selection Problems. *Proceeding of 3rd International Conference of Mathematics and its Applications*. <https://doi.org/10.31972/ticma22.05>.
141. Omidi, A., Zanjani, Z., Kashani, M., & Kakhki, R. (2018). The evaluation of the construct and convergent validity and reliability of psychological inflexibility in pain scale in individuals with migraine headache. *Iranian Journal of Psychiatry and Behavioral Sciences*, 12(3), e63132. <https://doi.org/10.5812/IJPBS.63132>
142. Onan, B. (2014). Eklemeli Dil Yapısının Türkçe Öğretiminde Oluşturduğu Bilişsel (Kognitif) Zeminler. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(11), 236-26 3. <https://dergipark.org.tr/tr/pub/mkusbed/issue/19558/208491>
143. O'Toole, S., Benson, A., Lambert, V., Gallagher, P., Shahwan, A., & Austin, J. K. (2015). Family communication in the context of pediatric epilepsy: A systematic review. *Epilepsy & behavior* : E&B, 51, 225–239. <https://doi.org/10.1016/j.yebeh.2015.06.043>
144. Patel, D., Timsina, P., Gorenstein, L., Glicksberg, B., Raut, G., Cheetirala, S., Santana, F., Tamegue, J., Kia, A., Zimlichman, E., Levin, M., Freeman, R., & Klang, E. (2024). Traditional machine learning, deep learning, and BERT (large language model) approaches for predicting hospitalizations from nurse triage notes: Comparative evaluation of resource management. *JMIR AI*, 3, Article e52190. <https://doi.org/10.2196/52190>
145. Patel, H., Ganatra, A., Bhensdadia, C., & Kosta, Y. (2011). Experimental Study and Review of Boosting Algorithms. *Artificial Intelligent Systems And Machine Learning*, 3(1), 31-41. Retrieved from <https://www.ciitresearch.org/dl/index.php/aiml/article/view/AIML012011006>
146. Peacock, S., & Patel, S. (2008). Cultural Influences on Pain. *Reviews in Pain*, 1(2), 6-9. <https://doi.org/10.1177/204946370800100203>
147. Perrot, S., Choy, E., Petersel, D., Ginovker, A., & Kramer, E. (2012). Survey of physician experiences and perceptions about the diagnosis and treatment of fibromyalgia. *BMC health services research*, 12, 356. <https://doi.org/10.1186/1472-6963-12-356>
148. Pouroumran, F., Radhakrishnan, S., & Kamarthi, S. (2021). Exploration of physiological sensors, features, and machine learning models for pain intensity estimation. *PLoS ONE*, 16(7), e0254108. <https://doi.org/10.1371/journal.pone.0254108>
149. Pradela, J., Bevilaqua-Grossi, D., Chaves, T. C., Dach, F., & Carvalho, G. F. (2020). Brazilian Portuguese version of the Headache Disability Inventory: Cross-cultural adaptation, validity, and reliability. *Cephalalgia*, 41(2), 156–165. <https://doi.org/10.1177/0333102420949860>
150. Qasem, A., & Sajid, M. (2022). Exploring the effect of N-grams with BOW and TF-IDF representations on detecting fake news. In *2022 International Conference on Data Analytics for Business and Industry (ICDABI)* (pp. 741–746). IEEE. <https://doi.org/10.1109/ICDABI56818.2022.10041537>
151. Rajput, R. (2020). Language Barriers in Healthcare and the Use of Machine Learning to Break Them. *International Journal of Medical Informatics*, 144, 104292. <https://doi.org/10.1016/j.ijmedinf.2020.104292>
152. Ramachandruni, I., Mondal, S., Jaladhi, N., Vyshnavi, M., Batchu, V., & Khatua, D. (2024). Enhancing product review authenticity detection with ensemble learning and BERT model. In *2024 First International Conference on Innovations in Communications, Electrical and Computer Engineering (ICICEC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICICEC62498.2024.10808342>
153. Ramos, J. (2003) Using Tf-idf to Determine Word Relevance in Document Queries. https://pdfs.semanticscholar.org/b3bf/6373ff41a115197cb5b30e57830c16130c2c.pdf?_ga=1.183821606.1606390940.1482600858
154. Rathod, H., Ram, D., Sundarmurthy, H., Rathod, S., & John, D. (2016). Headache disability, suicidality and pain catastrophization – Are they related. *Journal of Clinical and Diagnostic Research*, 10(11), VC01–VC04. <https://doi.org/10.7860/JCDR/2016/22636.8772>
155. Reichling, D., & Levine, J. D. (2009). Critical role of nociceptor plasticity in chronic pain. *Trends in Neurosciences*, 32(12), 611-618. <https://doi.org/10.1016/j.tins.2009.07.007>
156. Rekhi, A. A. (2023). Metamorphosing teaching and learning with Python: A practical guide for teachers employing text data analysis using the Bag of Words (BoW) model. In *Proceedings of the 2023 International Conference on Quantum Technologies, Communications, Computing, Hardware and Embedded Systems Security (iQ-CHESS)* (pp. 1–8). IEEE. <https://doi.org/10.1109/iQ-CHESS56596.2023.10391392>

157. Riley, J. L., Zawacki, T. M., Robinson, M. E., & Geisser, M. E. (1999). Empirical test of the factor structure of the West Haven-Yale Multidimensional Pain Inventory. *The Clinical Journal of Pain*, 15(1), 24-30. <https://doi.org/10.1097/00002508-199903000-00005>
158. Rodero, B., Pereira, J. P., Pérez-Yus, M. C., Casanueva, B., Serrano-Blanco, A., Ribeiro, M. D. C., Luciano, J. V., & García-Campayo, J. (2013). Validation of a Spanish version of the Psychological Inflexibility in Pain Scale (PIPS) and an evaluation of its relation with acceptance of pain and mindfulness in persons with fibromyalgia. *Health and Quality of Life Outcomes*, 11, 62. <https://doi.org/10.1186/1477-7525-11-62>
159. Rojas, R., Huang, X., & Ou, K. (2017). Toward a functional near-infrared spectroscopy-based monitoring of pain assessment for nonverbal patients. *Journal of Biomedical Optics*, 22(10), 106013. <https://doi.org/10.1117/1.JBO.22.10.106013>
160. Roosink, M., Renzenbrink, G. J., Buitenweg, J. R., van Dongen, R. T., Geurts, A. C., & Ijzerman, M. J. (2011). Somatosensory symptoms and signs and conditioned pain modulation in chronic post-stroke shoulder pain. *The journal of pain*, 12(4), 476-485. <https://doi.org/10.1016/j.jpain.2010.10.009>
161. Rosa, R., Lionetto, F., Angilecchia, D., Carmillo, L., Castaldo, M., Giovannico, G., Di Lorenzo, C., & Pellicciari, L. (2024). Italian version of the Headache Disability Inventory: Cross-cultural adaptation, validity, and reliability. *Headache*. <https://doi.org/10.1111/head.14883>
162. Rudroff, T. (2019). Cannabis for neuropathic pain in multiple sclerosis—High expectations, poor data. *Frontiers in Pharmacology*, 10, 1239. <https://doi.org/10.3389/fphar.2019.01239>
163. Rui, W., Xing, K., & Jia, Y. (2016). BOWL: Bag of Word Clusters text representation using word embeddings. In F. Lehner & N. Fteimi (Eds.), *Knowledge Science, Engineering and Management* (Vol. 9983, pp. 3–14). Springer. https://doi.org/10.1007/978-3-319-47650-6_1
164. Rutberg, S., & Öhrling, K. (2011). Migraine – more than a headache: Women's experiences of living with migraine. *Disability and Rehabilitation*, 34(4), 329–336. <https://doi.org/10.3109/09638288.2011.607211>
165. Salton, G. and Buckley, C. (1988) ‘Term-weighting approaches in automatic text retrieval’, *Information Processing & Management*, 24(5), pp. 513–523. doi:10.1016/0306-4573(88)90021-0. [https://doi.org/10.1016/0306-4573\(88\)90021-0](https://doi.org/10.1016/0306-4573(88)90021-0).
166. Sancar, N., Tınazlı, M., & Tabrizi, S. (2018). Prediction of Mechanical Lower Back Pain for Healthcare Workers Using ANN and Logistic Regression Models. *13th International Conference on Theory and Application of Fuzzy Systems and Soft Computing — ICAFS-2018*. https://doi.org/10.1007/978-3-030-04164-9_103.
167. Sancassiani, F., Machado, S., Ruggiero, V., Cacace, E., Carmassi, C., Gesi, C., Dell'Osso, L., & Carta, M. G. (2017). The management of fibromyalgia from a psychosomatic perspective: an overview. *International review of psychiatry (Abingdon, England)*, 29(5), 473–488. <https://doi.org/10.1080/09540261.2017.1320982>
168. Scholz, J., Vieregge, P., & Moser, A. (1999). Central pain as a manifestation of partial epileptic seizures. *Pain*, 80(3), 445–450. [https://doi.org/10.1016/S0304-3959\(98\)00217-6](https://doi.org/10.1016/S0304-3959(98)00217-6)
169. Shipton, E. (2011). The transition from acute to chronic post surgical pain. *Anaesthesia and Intensive Care*, 39(5), 824-836. <https://doi.org/10.1177/0310057X1103900506>
170. Skenderi, E., Huhtamäki, J., & Stefanidis, K. (2021). Multi-keyword classification: A case study in Finnish Social Sciences Data Archive. *Information*, 12(12), 491. <https://doi.org/10.3390/info12120491>
171. Stijic, M., Messerer, B., Meißner, W., & Avian, A. (2023). Numeric rating scale for pain should be used in an ordinal but not interval manner: A retrospective analysis of 346,892 patient reports of the quality improvement in postoperative pain treatment registry. *Pain*. <https://doi.org/10.1097/j.pain.0000000000003078>
172. Stubberud, A., Langseth, H., Nachev, P., Matharu, M., & Tronvik, E. (2024). Artificial intelligence and headache. *Cephalalgia*, 44(8), 3331024241268290. <https://doi.org/10.1177/03331024241268290>
173. Sun, C., Li, M., Lan, L., Pei, L., Zhang, Y., Tan, G., Zhang, Z., & Huang, Y. (2023). Prediction models for chronic postsurgical pain in patients with breast cancer based on machine learning approaches. *Frontiers in Oncology*, 13, 1096468. <https://doi.org/10.3389/fonc.2023.1096468>
174. Sun, C., Qiu, X., Xu, Y., Huang, X. (2019). How to Fine-Tune BERT for Text Classification?. In: Sun, M., Huang, X., Ji, H., Liu, Z., Liu, Y. (eds) *Chinese Computational Linguistics. CCL 2019. Lecture Notes in Computer Science()*, vol 11856. Springer, Cham. https://doi.org/10.1007/978-3-030-32381-3_16

175. Taha, A., Saad, A., & Nazih, N. (2024). Strategies for assessing pain using multimodal pain detection. In *2024 International Telecommunications Conference (ITC-Egypt)* (pp. 567–572). IEEE. <https://doi.org/10.1109/ITC-Egypt61547.2024.10620501>
176. Tavakol, M., & Dennick, R. (2011). Making sense of Cronbach's alpha. *International journal of medical education*, 2, 53–55. <https://doi.org/10.5116/ijme.4dfb.8dfd>
177. Tekgöz, H., Celenli, H., & Omurca, S. (2021). Semantic similarity comparison of word representation methods in the field of health. In *2021 6th International Conference on Computer Science and Engineering (UBMK)* (pp. 650–653). IEEE. <https://doi.org/10.1109/UBMK52708.2021.9558891>
178. Theoharides, T. C., Tsilioni, I., Arbetman, L., Panagiotidou, S., Stewart, J. M., Gleason, R. M., & Russell, I. J. (2015). Fibromyalgia syndrome in need of effective treatments. *The Journal of pharmacology and experimental therapeutics*, 355(2), 255–263. <https://doi.org/10.1124/jpet.115.227298>
179. Thijs, R. D., Surges, R., O'Brien, T. J., & Sander, J. W. (2019). Epilepsy in adults. *Lancet* (London, England), 393(10172), 689–701. [https://doi.org/10.1016/S0140-6736\(18\)32596-0](https://doi.org/10.1016/S0140-6736(18)32596-0)
180. Timurtaş, F. (2012). Türkiye Türkçesi'nin Ana Hatları. *Türk Dili ve Edebiyatı Dergisi*, 23, 175–202. <https://dergipark.org.tr/tr/pub/iutded/issue/17062/178232>
181. Treede, R.-D. (2018). The International Association for the Study of Pain definition of pain: As valid in 2018 as in 1979 but in need of regularly updated footnotes. *PAIN Reports*, 3(2), e643. <https://doi.org/10.1097/PR9.0000000000000643>
182. Urits, I., Adamian, L., Fiocchi, J., Hoyt, D., Ernst, C., Kaye, A. D., & Viswanath, O. (2019). Advances in the Understanding and Management of Chronic Pain in Multiple Sclerosis: a Comprehensive Review. *Current pain and headache reports*, 23(8), 59. <https://doi.org/10.1007/s11916-019-0800-2>
183. Valmianski, I., Goodwin, C., Finn, I., Khan, N., & Zisook, D. (2019). Evaluating robustness of language models for chief complaint extraction from patient-generated text. *ArXiv, abs/1911.06915*. <https://arxiv.org/abs/1911.06915>
184. Verbrugge, M. J. P. (2021). *The BERT ranking paradigm: Training strategies evaluated* (Master's thesis, Radboud University Nijmegen). Radboud University Theses Repository. https://www.cs.ru.nl/masters-theses/2021/M_Verbrugge_The_BERT_ranking_paradigm_training_strategies_evaluated.pdf
185. Verma, A., Goyal, N., Bansal, P., & Gambhir, P. (2023). Comparing the performance of various encoder models and vectorization techniques on text classification. In *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1–7). IEEE. <https://doi.org/10.1109/ICCCNT56998.2023.10307214>
186. Voscopoulos, C., & Lema, M. (2010). When does acute pain become chronic? *British Journal of Anaesthesia*, 105(Suppl 1), i69–i85. <https://doi.org/10.1093/bja/aeq323>
187. Walter, S. (2017). The experience of adolescents living with headache. *Holistic Nursing Practice*, 31(5), 280–289. <https://doi.org/10.1097/HNP.0000000000000224>
188. Wang, F., Xiang, X., Liu, C., Tran, T. D., Reiter, A., Hager, G. D., Quon, H., Cheng, J., & Yuille, A. L. (2017). Regularizing face verification nets for pain intensity regression. In *2017 IEEE International Conference on Image Processing, ICIP 2017 - Proceedings* (pp. 1087–1091). (Proceedings - International Conference on Image Processing, ICIP; Vol. 2017-September). IEEE Computer Society. <https://doi.org/10.1109/ICIP.2017.8296449>
189. Wang, J., Zhang, W., Gao, M., Zhang, S., Tian, D., & Chen, J. (2017). A cross-cultural adaptation and validation of the Short-form McGill Pain Questionnaire-2: Chinese version in patients with chronic visceral pain. *Journal of Pain Research*, 10, 121–128. <https://doi.org/10.2147/JPR.S116997>
190. Wang, R., Xu, K., Feng, H., & Chen, W. (2020). Hybrid RNN-ANN Based Deep Physiological Network for Pain Recognition. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 5584–5587. <https://doi.org/10.1109/EMBC44109.2020.9175247>
191. Wang, S. J., Fuh, J. L., Lu, S. R., & Juang, K. D. (2001). Quality of life differs among headache diagnoses: analysis of SF-36 survey in 901 headache patients. *Pain*, 89(2-3), 285–292. [https://doi.org/10.1016/s0304-3959\(00\)00380-8](https://doi.org/10.1016/s0304-3959(00)00380-8)
192. Wehnert, S., Sudhi, V., Dureja, S., Kutty, L., Shahania, S., & Luca, E. (2021). Legal norm retrieval with variations of the BERT model combined with TF-IDF vectorization. In *Proceedings of the Eighteenth International Conference on Artificial Intelligence and Law* (pp. 90–99). ACM. <https://doi.org/10.1145/3462757.3466104>

193. Wilcox, C. E., Mayer, A. R., Teshiba, T. M., Ling, J., Smith, B. W., Wilcox, G. L., & Mullins, P. G. (2015). The Subjective Experience of Pain: An FMRI Study of Percept-Related Models and Functional Connectivity. *Pain Medicine*, 16(11), 2121–2133. <https://doi.org/10.1111/pme.12785>
194. Wilson, A., Aghaziarati, A., & Saadati, M. (2024). Exploring the psychosomatic effects of perfectionism in patients with chronic tension-type headaches: A qualitative study. *Journal of Personality and Psychosomatic Research*, 2(4), 46–60. <https://doi.org/10.61838/kman.jprr.2.4.6>
195. Wisesty, U., Rismala, R., Munggana, W., & Purwarianti, A. (2021). Comparative study of COVID-19 tweets sentiment classification methods. In *2021 9th International Conference on Information and Communication Technology (ICoICT)* (pp. 588–593). IEEE. <https://doi.org/10.1109/ICoICT52021.2021.9527533>
196. Wolfe F. (2003). Pain extent and diagnosis: development and validation of the regional pain scale in 12,799 patients with rheumatic disease. *The Journal of rheumatology*, 30(2), 369–378. <https://pubmed.ncbi.nlm.nih.gov/12563698/>
197. Wolfe, F., Clauw, D. J., Fitzcharles, M. A., Goldenberg, D. L., Häuser, W., Katz, R. L., Mease, P. J., Russell, A. S., Russell, I. J., & Walitt, B. (2016). 2016 Revisions to the 2010/2011 fibromyalgia diagnostic criteria. *Seminars in arthritis and rheumatism*, 46(3), 319–329. <https://doi.org/10.1016/j.semarthrit.2016.08.012>
198. Wongthanavimok, N., Chewachutirunguang, C., Hathaiareerug, C., & Phongamwong, C. (2023). Reliability, validity and agreement of the Thai self-reported fibromyalgia survey questionnaire among patients with chronic musculoskeletal pain. *Journal of Southeast Asian Medical Research*, 7, Article 172. <https://doi.org/10.55374/jseamed.v7.172>
199. Wu, C.-L., Liu, S.-F., Yu, T.-L., Shih, S.-J., Chang, C.-H., Yang Mao, S.-F., Li, Y.-S., Chen, H.-J., Chen, C.-C., & Chao, W.-C. (2022). Deep learning-based pain classifier based on the facial expression in critically ill patients. *Frontiers in Medicine*, 9, 851690. <https://doi.org/10.3389/fmed.2022.851690>
200. Xin, J., Tang, R., Yu, Y., & Lin, J. (2021, April). BERxiT: Early exiting for BERT with better fine-tuning and extension to regression. In P. Merlo, J. Tiedemann, & R. Tsarfaty (Eds.), *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume* (pp. 91–104). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2021.eacl-main.8>
201. Xu, Z., Chen, M., Weinberger, K. Q., & Sha, F. (2013). An alternative text representation to TF-IDF and Bag-of-Words. *ArXiv, abs/1301.6770*. <https://arxiv.org/abs/1301.6770>
202. Yakut, Y., Yakut, E., Bayar, K., & Uygur, F. (2007). Reliability and validity of the Turkish version short-form McGill pain questionnaire in patients with rheumatoid arthritis. *Clinical rheumatology*, 26(7), 1083–1087. <https://doi.org/10.1007/s10067-006-0452-6>
203. Yalçinkaya, F. (2020). Türk Lehçeleriyle Yaratılmış Halk Bilgisi Ürünlerinin Aktarımında Yaşanan Problemler Üzerine Bir İnceleme. *Folklor Akademik Dergisi*, 3(1), 81–98. <https://dergipark.org.tr/tr/pub/folklor/issue/54108/676514>
204. Yanmaz, M. N., Atar, S., & Biçer, M. (2016). The reliability and validity of the Turkish version of fibromyalgia survey diagnostic criteria and symptom severity scale. *Journal of Back and Musculoskeletal Rehabilitation*, 29(2), 287–293. <https://doi.org/10.3233/BMR-150627>
205. Yilmazer, C., D'haeseleer, M., Soler, B., Van Wijmeersch, B., Solaro, C., Ciampi, E., Cárcamo, C., Van Asch, P., Cambron, M., Lamers, I., & Feys, P. (2025). Assessing pain in multiple sclerosis: Test-retest reliability of patient-reported outcome measures and accuracy of screening tools. *Multiple Sclerosis Journal*. <https://doi.org/10.1177/13524585241310139>
206. Yoshikawa, Y., Iwata, T., & Sawada, H. (2015). Non-linear regression for bag-of-words data via Gaussian process latent variable set model. In *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence* (pp. 3129–3135). Association for the Advancement of Artificial Intelligence. <https://doi.org/10.1609/aaai.v29i1.9615>
207. Zahoor, K., Bawany, N., & Ghani, U. (2023). Explainable AI for Healthcare: An Approach Towards Interpretable Healthcare Models. *2023 24th International Arab Conference on Information Technology (ACIT)*, 1–7. <https://doi.org/10.1109/ACIT58888.2023.10453740>
208. Zeleke, A., Palumbo, P., Tubertini, P., Miglio, R., & Chiari, L. (2023). Machine learning-based prediction of hospital prolonged length of stay admission at emergency department: a Gradient Boosting algorithm analysis. *Frontiers in Artificial Intelligence*, 6. <https://doi.org/10.3389/frai.2023.1179226>
209. Zhang, S. (2022). Challenges in KNN classification. *IEEE Transactions on Knowledge and Data Engineering*, 34(8), 4663–4675. <https://doi.org/10.1109/TKDE.2021.3049250>

- 210. Zhou, J., Hong, X., Su, F., & Zhao, G. (2016). Recurrent convolutional neural network regression for continuous pain intensity estimation in video. In *2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (pp. 1535–1543). IEEE. <https://doi.org/10.1109/CVPRW.2016.191>
- 211. Zhu, S. (2014). Pain expression recognition based on pLSA model. *The Scientific World Journal*, 2014, Article 736106. <https://doi.org/10.1155/2014/736106>
- 212. Zhu, X. (2005). Semi-supervised learning literature survey. Computer Sciences Technical Report. https://pages.cs.wisc.edu/~jerryzhu/pub/ssl_survey.pdf

EKLER

EK 1: Etik Kurul Onamı



T.C.
İSTANBUL MEDENİYET ÜNİVERSİTESİ REKTÖRLÜĞÜ
Girişimsel Olmayan Sağlık Araştırmaları Etik Kurulu

TOPLANTI SAYISI
4

KARAR SAYISI
2025/04-35

TOPLANTI TARİHİ
5.03.2025

Sayın Prof. Dr. Handan ANKARALI

Sorumlu araştırmacı olarak yer aldığınız 2025-GOSEK-0237 no'lu **“Türkiye'deki Ağrı Anlatılarının Nicel ve Nitel Analizle İncelenmesi Sonucunda Makine İle Derin Öğrenme Yöntemleriyle Evrensel Ağrı Skalası Algoritması Geliştirilmesi”** başlıklı revize başvurunuz İstanbul Medeniyet Üniversitesi, Tıp Fakültesi Girişimsel Olmayan Sağlık Araştırmaları Etik Kurulu'nun 05.03.2025 tarihli 4. toplantısında görüşülmüş olup, projenin içeriğinde etik olarak bir sorun olmadığına, ön koşulsuz olarak kabul edilmesine karar verilmiştir.

Prof. Dr. Emel BALOĞLU
Girişimsel Olmayan Sağlık
Araştırmaları Etik Kurulu
Başkanı

Prof. Dr. Ebuzer AYDIN
Etik Kurul Üyesi

Prof. Dr. Yasemin ÇAĞ
Etik Kurul Üyesi

Prof. Dr. Yasemin
YUMUŞAKHUYLU
Etik Kurul Üyesi

Doç. Dr. Mustafa ÇAKIR
Etik Kurul Üyesi

Doç. Dr. Mustafa Çağlar
BEKER
Etik Kurul Üyesi

Doç. Dr. Şule AYLA
Etik Kurul Üyesi

Dr. Öğr. Üyesi Semanur
ÖZÜDOĞRU
Etik Kurul Üyesi

Dr. Öğr. Üyesi Zeynep
GÜMÜŞER
Etik Kurul Üyesi

Dr. Öğr. Üyesi Havvanur
YOLDAŞ İLKTAÇ
Etik Kurul Üyesi

Doç. Dr. Hacer ATAMAN
Etik Kurul Üyesi

Dr. Öğr. Üyesi Feride ÖKSÜZ
GÜL
Etik Kurul Üyesi

Dr. Öğr. Üyesi Nihan
KOYUNCU AKTAŞ
Etik Kurul Üyesi

Prof. Dr. Pınar OBAKAN
YERLİKAYA
Etik Kurul Üyesi

Dr. Öğr. Üyesi Ömer Faruk
SARIOĞLU
Etik Kurul Üyesi

Doç. Dr. Nilüfer KABLAN
Etik Kurul Başkan Yardımcısı

Doç. Dr. Elif BIYIKLI
Etik Kurul Raportörü

Belge Doğrulama Kodu: UE7AAACC

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Takip Adresi: <https://www.turkiye.gov.tr/istanbul-medeniyet-universitesi-ebys>

Adres: Durnlupınar Mahallesi D-100 Karayolu No:98 Kadıköy / İstanbul

Telefon No: (0 216) 2803333

Faks No: (0 216) 2802021

e-Posta:

Kcp Adresi: istanbulmedeniyetuni@ts01.kcp.tr

İnternet Adresi: www.medeniyet.edu.tr

Bilgi için :

Emel Baloğlu
Girişimsel Olmayan Sağlık
Araştırmaları Etik Kurulu
Başkanı

Telefon No:



EK 2: Benzerlik Raporu

Formatlanmış Tez.pdf			
ORIJİNALLIK RAPORU			
% 2	% 2	% 1	%
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ
BİRİNCİL KAYNAKLAR			
1	egitimyonetimienstitu.medeniyet.edu.tr İnternet Kaynağı	<%	1
2	acikerisim.sakarya.edu.tr İnternet Kaynağı	<%	1
3	hdl.handle.net İnternet Kaynağı	<%	1
4	www.frontiersin.org İnternet Kaynağı	<%	1

Ek-3: Özgeçmiş

KİŞİSEL BİLGİLER

Adı Soyadı : Muhsin ÖZNANECİ
Yabancı Dili : İngilizce, Almanca, Fransızca

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Tıp	İstanbul Medeniyet Üniversitesi	2021
Lise	Fen Bilimleri	Prof.Dr.Nabi Avcı Fen Lisesi	2015

YAYINLAR

- Oznaneci M, Alzheimer Vaccines, From Past to Future, A Poster Review-2017 April Presented in Yeditepe Medical Student Congress 2017, Emsa Eskişehir Congress of Psychiatry 2018
- Oznaneci M, A conceptual approach to Violence Against Healthcare in Turkey from SDG's, August 2018-The European Sting Political Newsletter
- Oznaneci M, the online junk information grows, but so we shall, July 2019-The European Sting Political Newsletter
- Part of The Editorial Board in 2016-Turkish Rare Disease Databank for Clinicians and Medical Students (My translates: Segawa Syndrome-G6PD Deficiency-Canavan Disease-Saddan Syndrome-Narcolepsy)
- Palliative Care and Chronic Pain Management in Public Health- Association of Public Health Professionals Turkey Student Working Group Presentation Days 2021
- Ağırbaşı M., Aslan G.B., Özkan B., Akbaş E., Öznaneci M., Yıldırım S., Tanrikulu E., Erdem A., Şanlı Z., Tanrikulu A. (2021). Trends in Life Simple 7 cardiovascular metrics among relatives of medical interns from Istanbul, Turkey. Oral presentation at INSAC International Congress on New Developments in Health Sciences (ICNDHS'2021), March 27–28, Konya, Turkey.
- Oznaneci M, Palliative Care in Children, why is it less known and why do we need to raise awareness more? April 2021, The European Sting
- Oznaneci M, "Depression and Suicide Threatening Our Society" November 2022, The European Sting
- Baycan, O. F., Atici, A., Tatlisu, M. A., Yilmaz, Y., Yavuz, H., Yildirim, S., Oznaneci, M., & Caliskan, M. (2023). An overview of youtube videos as an information and education source for idiopathic ventricular arrhythmia. *Annals of Medical Research*, 30(1), 109–115
- Oznaneci M, "Medical Article Writing with ChatGPT: What Can We Expect in the Future?", June 2023, BAYOYO Summer School
- Oznaneci M, Başarslan M.S. Can Shoulder Pain Scale Be Simplified Using NLP Induced AI Methods? A Trial With Penn Shoulder Scale In Turkish Patients, July 2024-EDATA Congress, Istanbul Katip Çelebi University
- Oznaneci M, Başarslan M.S., Bulut N., Ankaralı H. NLP-Based Pain Prediction Using Machine Learning and Boosted Models: A Comparative Analysis of TF-IDF and BoW Representations with Headache Data, INFUS 2025, İstanbul-Turkey
- Öznaneci, M., Başarslan, M.S., Bulut, N., Ankaralı, H. (2025). NLP-Based Pain Prediction Using Machine Learning and Boosted Models: A Comparative Analysis of TF-IDF and BoW Representations with Headache Data. In: Kahraman, C., *et al.* Intelligent and Fuzzy Systems. INFUS 2025. Lecture Notes in Networks and Systems, vol 1529. Springer, Cham. https://doi.org/10.1007/978-3-031-97992-7_56