



ÇOK DEĞİŞKENLİ ZAMAN SERİLERİNDE DİLSEL ÖZETLEME

Ümran KAYA

DOKTORA TEZİ

ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TEMMUZ 2025

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Ümran KAYA

04/07/2025

ÇOK DEĞİŞKENLİ ZAMAN SERİLERİNDE DİLSEL ÖZETLEME

(Doktora Tezi)

Ümran KAYA

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2025

ÖZET

Son yıllarda şirketler, bilinçaltı tercihleri ve duyguları geleneksel yöntemlerle yakalayamadıkları için nöropazarlama tekniklerine yönelmiştir. Nöropazarlamada ise en yaygın olarak Elektroensefalografi (EEG) sinyalleri kullanılır. Ancak, EEG sinyalleri büyük veri yığını oluşturur ve ayrıntılı analiz için uzman müdahalesine ihtiyaç duyar. Bu çalışmada, sorunu çözmek amacıyla, bulanık dilsel özetleme yaklaşımı kullanılmıştır. Bu yöntem, büyük veri yığınlarını belirsiz ifadeler içeren günlük kullanılan dil formatında otomatik olarak özetleyebilmektedir. Çalışma, iki bölümden oluşmaktadır. Birinci bölümde, bir otelin üç farklı reklamını (ses, video ve web sayfası) katılımcılar incelerken EEG sinyalleri kaydedilmiştir. Bu sinyaller, bulanık kümeler ile güncellenmiş Russell'ın sirkumpleks modeliyle bulanık duygu etiketlerine dönüştürülmüştür. Elde edilen bulanık duygu etiketleri, dilsel özetlemede kullanılmıştır. Çalışmada EEG verileri, tek değişkenli, çok değişkenli ve granül tespitli çok boyutlu zaman serileri olmak üzere üç farklı perspektiften analiz edilmiştir. Bu analizlerde, hem reklamlar bir bütün olarak incelenmiş, hem de demografik özellikler (örneğin, cinsiyet ve yaş) temelinde ayrıntılı karşılaştırmalar yapılmasına olanak sağlamıştır. Ayrıca, reklamların tüketici duyguları üzerindeki eş zamanlı etkilerini analiz etmek için güncellenmiş bir granüler trend algılama algoritması geliştirilmiştir. Bu yöntem, genellikle göz ardı edilen eş zamanlı bilgileri ortaya çıkarmaktadır. Çalışmanın ikinci bölümünde, önerilen yaklaşımlar, kapsamlı biçimde genişletilerek etkinlik ve verimlilik açısından değerlendirmek için en yaygın kullanılan SEED veri setinde uygulanmıştır. İlk bölümde yalnızca tek bir frontal formül kullanılmışken, bu bölümde dört farklı frontal formül uygulanmıştır. Ayrıca, Russell'ın sirkumpleks modelinde sadece üçgen değil, yamuk ve Gauss bulanık kümeler de entegre edilmiştir. Tüm alternatiflerden elde edilen sonuçlar, literatürde mevcut makine öğrenimi (ML) ve derin öğrenme (DL) yöntemlerinin çıktılarıyla karşılaştırılmış ve böylece önerilen yaklaşımların performans ve verimliliği ampirik olarak ortaya konmuştur. Bu tez çalışması, gelecekteki çalışmalara üç yenilikle ilham verebilecektir: nöropazarlamada bulanık dilsel özetleme tekniği, duygu tanınmanın bulanıklaştırılması ve eş zamanlı kümelenmeyi tespit eden geliştirilmiş çok granüllü trend tespit algoritması.

Bilim Kodu : 90601

Anahtar Kelimeler : Bulanık dilsel özetleme, nöropazarlama, çok granüllü trend tespiti

Sayfa Adedi : 159

Danışman : Prof. Dr. Diyar AKAY

LINGUISTIC SUMMARIZATION IN MULTIVARIATE TIME SERIES

(Ph. D. Thesis)

Ümran KAYA

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2025

ABSTRACT

In recent years, companies have increasingly turned to neuromarketing techniques because traditional methods fail to capture subconscious preferences and emotions. Within neuromarketing, electroencephalography (EEG) signals are most commonly employed; however, EEG signals generate a large volume of data and require expert intervention for detailed analysis. In this study, a fuzzy linguistic summarization approach has been utilized to address this challenge. This method can automatically summarize large datasets in the daily language format contains vague expression The study is structured in two parts. In the first part, EEG signals were recorded while participants viewed three different advertisements of a hotel (audio, video and web page). These signals were converted into fuzzy emotion labels with Russell's circumplex model updated with fuzzy sets, and thus the emotion recognition became more sensitive. The obtained fuzzy emotion labels were used in linguistic summarization. In the study, EEG data were analyzed from three different perspectives: univariate, multivariate and granular detected multidimensional time series. In these analyses, all ads were examined as a whole and detailed comparisons were made based on demographic characteristics (e.g. gender and age). In addition, an updated granular trend detection algorithm was developed to analyze the simultaneous effects of ads on consumer emotions. This method reveals simultaneous information that is often overlooked. In the second part of the study, the proposed approaches were extensively expanded and applied to the widely used SEED dataset to evaluate their effectiveness and efficiency. Whereas the first part employed only a single frontal formula, this section utilized four. Furthermore, in Russell's circumplex model, not only triangular but also trapezoidal and Gaussian fuzzy sets were integrated. The results obtained from all alternatives were compared with the outputs of existing machine learning (ML) and deep learning (DL) methods in the literature, thereby empirically demonstrating the performance and efficiency of the proposed approaches. This thesis study can inspire future studies with three innovations: fuzzy linguistic summarization application in neuromarketing, fuzzification of emotion recognition and modified multi-granular trend detection algorithm that detects simultaneous clustering.

Science Code : 90601

Key Words : Fuzzy linguistic summarization, neuromarketing, multi-granular trend detection

Page Number : 159

Supervisor : Prof. Dr. Diyar AKAY

TEŞEKKÜR

Tez çalışmamın her aşamasında değerli bilgi ve katkılarıyla bana yol gösteren danışman hocam Sayın Prof. Dr. Diyar AKAY'a sabrı ve samimiyeti için teşekkürlerimi sunarım.

Tez süreci boyunca değerli bilgi ve önerileriyle teze kıymet katan hocalarım Doç. Dr. Sevgi Şengül AYAN'a ve Prof. Dr. Selçuk Kürşat İŞLEYEN'e çok teşekkür ederim.

Bu tezi, hayatıma enerji ve değer katan, en büyük motivasyon kaynaklarım olan eşim Derya ve kızım Hüma Asel'e ithaf ediyorum.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	xi
ŞEKİLLERİN LİSTESİ.....	xv
SİMGELER VE KISALTMALAR.....	xvii
1. GİRİŞ.....	1
2. DİLSEL ÖZETLEME.....	11
2.1. Bulanık Kümeler	11
2.1.1. Bulanık kümelerde kesişim	15
2.1.2. Bulanık kümelerde birleşim	17
2.1.3. Kardinalite kavramı.....	18
2.1.4. Bulanık kardinalite kavramı.....	18
2.2. Bulanık Dilsel Özetleme	19
2.3. Bulanık Dilsel Özetleme Protoform Yapıları.....	20
2.3.1. Tip-1 niceleyici cümle yapısı	21
2.3.2. Tip-2 niceleyici cümle yapısı	22
2.3.3. Tip-1 ve tip-2 tabanlı protoform yapıları	23
2.3.4. Sabit kalıplı protoformlar	24
2.3.5. Eğer-Öyleyse kural tabanlı protoform.....	25
2.3.6. Ağaç şeklindeki protoformlar	26
2.4. Dilsel Özetleri Değerlendirme Yöntemleri	31
2.4.1. Tip-1 niceleyici cümle için skaler kardinalite tabanlı yöntemler.....	31
2.4.2. Tip-2 niceleyici cümle için skaler kardinalite tabanlı yöntemler.....	32

Sayfa

2.4.3. Tip-1 niceleyici cümle için bulanık kardinalite tabanlı yöntemler	32
2.4.4. Tip-2 niceleyici cümle için bulanık kardinalite tabanlı yöntemler.....	34
2.4.5. Bulanık kardinalite tabanlı diğer yöntemler.....	35
2.4.6. Tip-1 niceleyici cümle için kardinalite tabanlı olmayan yöntemler.....	37
2.4.7. Tip-2 niceleyici cümle için kardinalite tabanlı olmayan yöntemler	38
2.4.8. Kalite göstergeleri.....	40
2.5. Dilsel Özetleri Değerlendirme Yöntemleri	46
3. NÖROPAZARLAMA	49
3.1. EEG	50
4. LİTERATÜR ARAŞTIRMASI	53
4.1. Tek Değişkenli Zaman Serilerinde Segmentasyon Temelli Yöntemler.....	55
4.2. Tek Değişkenli Zaman Serilerinde Segmentasyonu Olmayan Yöntemler.....	57
4.3. Çok Değişkenli Zaman Serilerinde Segmentasyon Temelli Yöntemler	59
4.4. Çok Değişkenli Zaman Serilerinde Segmentasyonu Olmayan Yöntemler	60
4.5. Zaman Serilerinde Doğruluk Derecesi Ölçümü	60
4.6. Zaman Serilerinde Diğer Değerlendirme Yöntemleri.....	63
4.7. Zaman Serilerinde Dilsel Özetleme Kullanım Alanları	63
5. YÖNTEM.....	65
5.1. EEG İle Duygu Durum Tespiti.....	65
5.2. Russell'in Çemberinde Dilsel Etiketlerin Tespiti.....	66
5.3. Nöropazarlama İndeksi	69
6. DİLSEL ÖZETLEME PROTOFORM YAPILARI.....	71
6.1. Tek Boyutlu Zaman Serisi Özet Yapıları.....	72
6.2. Çok Boyutlu Zaman Serisi Özet Yapıları	76
6.3. Granül Tespitli Zaman Serisi Özet Yapıları.....	81
6.3.1. Çok parçalı trend algılama algoritması	82

	Sayfa
6.3.2. Geliştirilen çok parçalı trend algılama algoritması	84
6.3.3. Dilsel özet yapıları	87
7. UYGULAMA.....	91
7.1. Veri Toplama.....	91
7.2. Veri Ön İşleme	92
7.3. Özellik Çıkarma	93
8. SONUÇ VE ÖNERİLER.....	95
8.1. Tek Boyutlu Zaman Serisi Özet Sonuçları.....	95
8.2. Çok Boyutlu Zaman Serisi Özet Sonuçları	98
8.3. Granüler Trend Tespitli Zaman Serisi Özet Sonuçları.....	103
8.4. Özetler için Kalite Doğrulaması.....	106
8.5. Tartışma ve Öneri.....	107
9. BULANIK DİLSEL ÖZETLEME İLE EEG TABANLI DUYGU SINIFLANDIRMA: SEED VERİ SETİ ÜZERİNDE BİR ÇALIŞMA.	111
9.1. Giriş.....	111
9.2. Literatür Araştırması	112
9.2.1. Duygu tanıma için ML yaklaşımları	112
9.2.2. Duygu tanıma için DL yaklaşımları.....	113
9.2.3. Hesaplamalı boyutlu duygu modelleri	114
9.3. Metodoloji	115
9.3.1. SEED veri seti	116
9.3.2. Veri ön işleme	117
9.3.3. Özellik çıkarımı.....	117
9.3.4. Bulanık kümelerle değiştirilmiş Russell'ın sirkumpleks modeli.....	119
9.3.5. Bulanık dilsel özetleme yapıları.....	120
9.4. Sonuçlar.....	122

	Sayfa
9.4.1. Deney sonuçları.....	122
9.4.2. Diğer yaklaşımlarla karşılaştırma	125
9.5. Tartışma.....	126
9.6. Sonuç.....	130
KAYNAKLAR	133
ÖZGEÇMİŞ	159



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Dilsel özetlemede kullanılan semboller ve açıklamaları	20
Çizelge 2.2. Trendlerdeki üç özelliğin dilsel etikete dönüşümü (Süre={kısa, orta, uzun}, Dinamiklik={azalan, sabit, artan}, Değişkenlik={düşük, orta, yüksek}).....	48
Çizelge 3.1. EEG sinyalinin frekansa göre sınıflandırılması	51
Çizelge 4.1. Tek değişkenli zaman serilerinde segmentasyon temelli çalışmalar	56
Çizelge 4.2. Tek değişkenli zaman serilerinde segmentasyonu olmayan çalışmalar.....	58
Çizelge 4.3. Zaman serilerinde doğruluk derecesi için yapılan çalışmalar.....	62
Çizelge 4.4. Zaman serilerinde yapılan özetler için diğer değerlendirme ölçütleri	63
Çizelge 5.1. Uyarılma ve değerlik değerleri hesaplama yöntemleri	66
Çizelge 5.2. Bölgelere göre θ açısının hesaplanması	63
Çizelge 6.1. Algoritmanın özet kodu	84
Çizelge 8.1. Tek boyutlu zaman serileri için protoform-1 sonuçları	95
Çizelge 8.2. Tek boyutlu zaman serileri için protoform-2 sonuçları	96
Çizelge 8.3. Tek boyutlu zaman serileri için protoform-3 sonuçları	96
Çizelge 8.4. Tek boyutlu zaman serileri için protoform-4 sonuçları	96
Çizelge 8.5. Tek boyutlu zaman serileri için protoform-5 sonuçları	97
Çizelge 8.6. Tek boyutlu zaman serileri için protoform-6 sonuçları	97
Çizelge 8.7. Tek boyutlu zaman serileri için protoform-7 sonuçları	97
Çizelge 8.8. Tek boyutlu zaman serileri için protoform-8 sonuçları	98
Çizelge 8.9. Çok boyutlu zaman serileri için protoform-1 sonuçları.....	99
Çizelge 8.10. Çok boyutlu zaman serileri için protoform-2 sonuçları.....	99
Çizelge 8.11. Çok boyutlu zaman serileri için protoform-3 sonuçları.....	99
Çizelge 8.12. Çok boyutlu zaman serileri için protoform-4 sonuçları.....	100

Çizelge	Sayfa
Çizelge 8.13. Çok boyutlu zaman serileri için protoform-5 sonuçları.....	100
Çizelge 8.14. Çok boyutlu zaman serileri için protoform-6 sonuçları.....	101
Çizelge 8.15. Çok boyutlu zaman serileri için protoform-7 sonuçları.....	101
Çizelge 8.16. Çok boyutlu zaman serileri için protoform-8 sonuçları.....	101
Çizelge 8.17. Çok boyutlu zaman serileri için protoform-9 sonuçları.....	102
Çizelge 8.18. Çok boyutlu zaman serileri için protoform-10 sonuçları.....	102
Çizelge 8.19. Çok boyutlu zaman serileri için protoform-11 sonuçları.....	102
Çizelge 8.20. Çok boyutlu zaman serileri için protoform-12 sonuçları.....	103
Çizelge 8.21. Çok boyutlu zaman serileri için protoform-13 sonuçları.....	103
Çizelge 8.22. Çok boyutlu zaman serileri için protoform-14 sonuçları.....	103
Çizelge 8.23. Granül tespitli zaman serileri için protoform-1 sonuçları.....	104
Çizelge 8.24. Granül tespitli zaman serileri için protoform-2 sonuçları.....	104
Çizelge 8.25. Granül tespitli zaman serileri için protoform-3 sonuçları.....	105
Çizelge 8.26. Granül tespitli zaman serileri için protoform-4 sonuçları.....	105
Çizelge 8.27. Granül tespitli zaman serileri için protoform-5 sonuçları.....	106
Çizelge 8.27. Doğrulama anket puanı	107
Çizelge 9.1. Literatürdeki uyarılma ve değerlik formülleri	118
Çizelge 9.2. SEED'in üç etiketine atanmış on altı duygu	118
Çizelge 9.3. Dilsel özetleme ile sınıflandırma gösterimi	122
Çizelge 9.4. Tüm EEG noktaları için formüllere göre üyelik fonksiyonlarının doğrulukları	122
Çizelge 9.5. GTD noktaları için formüllere göre bulanık üyelik fonksiyonlarının doğrulukları.....	123
Çizelge 9.6. Her formül için etiket sınıflandırma doğruluğu (her iki veri türünün ortalaması alınarak elde edilmiştir)	124

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Veri yapıları.....	3
Şekil 1.2. Tezin birinci bölümünün içeriği	9
Şekil 2.1. Farklı tipteki BK'ler: (a) Kesikli BK (b) Sürekli BK.....	12
Şekil 2.2. Bulanık kümelerde öz, destek, sınır, geçiş noktaları ve yükseklik.....	13
Şekil 2.3. Üçgensel BS.....	14
Şekil 2.4. Dilsel değişken örneği	15
Şekil 2.5. Dilsel özetleme yapıları	21
Şekil 2.6. (a) "Yaklaşık 3" kesin niceleyicisi, (b) "En az yarısı" göreceli niceleyici	23
Şekil 2.7. GLMP yapısı.....	27
Şekil 2.8. Petri ağ yapısı	28
Şekil 2.9. Tectogramatical tree protoform yapısı.....	29
Şekil 2.10. Syntactic özet yapısı	30
Şekil 2.11. Bi-gram dil modeli.....	30
Şekil 2.12. Dilsel özetleri değerlendirme yöntemleri	31
Şekil 2.13. Trendlerine ayrılmış bir zaman serisi	47
Şekil 2.14. Trend segmentasyonu ve trendlerin özellikleri (dinamiklik, süre, değişkenlik)	48
Şekil 3.1. EEG elektrot yerleşimi	51
Şekil 4.1. Literatür çalışmasının genel akışı	54
Şekil 4.2. Çalışmalara göre doğruluk derecesi hesaplama yöntemleri	61
Şekil 4.3. Zaman serilerinde dilsel özetleme kullanım alanları	64
Şekil 5.1. Russell'ın duygu sınıflandırma modeli (sağ: temel duygular sol: detaylı duygular	65
Şekil 5.2. Koordinat düzlemindeki tüm bölgelerin bulanık küme ile dilsel etikete dönüşümü	68

Şekil	Sayfa
Şekil 6.1. Özetlemede kullanılan veri tipleri gösterimi	71
Şekil 6.2. Θ açısı ve AW indeksi zaman serisi ve bulanık kümeler	72
Şekil 6.3. Niceleyici çeşitleri ve onların bulanık küme tanımları.....	73
Şekil 6.4. “daha” niceleyicisinin bulanık küme tanımı.....	74
Şekil 6.5. Θ açıları ve AW indeksinden oluşan çok boyutlu zaman serisi ve bulanık kümeler.....	77
Şekil 6.6. Destek, süre, aralık ve dağılım parametreleri	83
Şekil 6.7. Serilerin farklı durumları; a) tepe durumu, b) kesişim durumu, c) ayrılma durumu.....	85
Şekil 6.8. Çok parçalı trend algılama yönteminin en temel hali.....	85
Şekil 6.9. Kayan pencere yöntemine dayalı bir örnek gösterimi	86
Şekil 6.10. Geliştirilmiş algoritma ile elde edilen sonuçlar	86
Şekil 6.11. Granüler trendleri tespit edilen Θ açıları ve AW indeksinden oluşan çok boyutlu zaman serisi ve bulanık kümeler.....	87
Şekil 7.1. MUSE 2 cihazı ve sinyal alınan kanal konumları [301].....	92
Şekil 7.2. Veri ön işleme adımları	93
Şekil 9.1. SEED veri seti.....	116
Şekil 9.2. A. İki boyutlu Russell modeli için 45° dönüş hipotezi [325], B. On altı duygu noktasıyla Russell'in sirkumpleks modeli [260], C. On altı duygunun atandığı Russell'in sirkumpleks modeli (duyguların üç kategoriye atanması için A ve B birleşmiştir)	119
Şekil 9.3. Üç bulanık üyelik fonksiyonuna (üçgensel, yamuksal ve Gauss) dayalı dilsel etiketlerin üyelik derecelerinin hesaplanması.....	120
Şekil 9.4. Önerilen EEG tabanlı duygu tanıma metodolojisinin adımları	121
Şekil 9.5. EEG ve GTD verilerinin ortalama doğruluk değeri karşılaştırmaları	123
Şekil 9.6. Tüm EEG noktaları veri türü için formüllere göre karışıklık matrisi.....	124
Şekil 9.7. GTD noktaları veri türü için formüllere göre karışıklık matrisi.....	124
Şekil 9.8. SEED veri setinde FLS, ML ve DL yöntemlerinin karşılaştırılması.....	126

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklamalar
$\tilde{A}$	Bulanık küme
$\mu_{\tilde{A}}(x)$	Eleman x'in, $\tilde{A}$ bulanık kümesine üyelik derecesi
α	Alfa kesmesi
α^+	Güçlü alfa kesmesi
$ET(x)$	x değişkeninin etiket kümesini
M	Anlamsal kural
G	Sözdizimsel kuraldır
$\otimes$	t-norm operatörü
$\oplus$	t-konorm operatörü
E	E tipi bulanık kardinalite
ED	ED tipi bulanık kardinalite
$\mathbb{D}$	Veritabanı
Y	Veritabanındaki tüm nesnelerin kümesi
y_M	Veritabanındaki m. nesne
v_k	k. özellik
X_k	v_k 'in tanım kümesi
$v_k(y_m)$	m. kayıtın k. özelliğine ait değeri
d_m	m. nesnenin tüm özelliklerini kapsayan kayıt
S_k	Özetleyici
Q	Niceleyici
$W_g(S_g)$	Niteleyici
T_1	Doğruluk derecesi
W_y	Doğruluk derecesi vektörü
$g()$	Toplama fonksiyonu
NP	İsim tamlaması
G_Q	E tipi bulanık kardinalite temelli yöntem

Simgeler**Açıklamalar**

GD_Q	ED tipi bulanık kardinalite temelli yöntem
ZS_Q	ES tipi bulanık kardinalite temelli yöntem
ER	ER tipi bulanık kardinalite
$\wedge$	Ve operatörü
$\vee$	Veya operatörü
$\neg$	Değil operatörü
$\cap$	Kesişim operatörü
$/$	Fark operatörü
$\forall$	Evrensel niceleyici
$\exists$	Varoluşsal niceleyici
$\wp(Y)$	Y'nin kuvvet kümesi
$\tilde{\wp}(Y)$	Bulanık küme olan Y'nin kuvvet kümesi
F^M	M niceleyici bulanıklaştırma mekanizması
Q_{Y,a,tip}^{FN}	Yarı bulanık niceleyici
Fn	Fonksiyon
len(s)	s özetinin uzunluğu
b (s)	s özetinin kısalığı
Sp(A)	A özetinin özgüllük derecesi
U	Özetin fayda derecesi
S_{im}	Özetin sadelik derecesi
d_a	Özetin uygunluk derecesi
sim	Benzerlik derecesi
R	Güvenilirlik derecesi
h_A^D	A'nın D'deki değeri hakkındaki tereddüt derecesi
m	Grup içerisindeki minimum üye sayısı
ϵ	Ardışık iki üyenin arasındaki maksimum uzaklık
δ	Minimum süre aralığı
Θ	Teta açısı
AW	Yakınlaşma- Çekilme
BBA	Beyin-bilgisayar ara yüzleri
BK	Bulanık kümeler

Kısaltmalar**Açıklamalar**

BS	Bulanık sayı
C	Merkezi
DL	Derin öğrenme
EEG	Elektroansefalografi
F	Frontal
Fp	Frontopolar
GLMP	Granular linguistic model of phenomenon
KARD	Kardinalite
MAKS	Maksimum
MİN	Minimum
ML	Makine öğrenimi
O	Oksipital
OWA	Sıralı Ağırlıklı Ortalama
P	Parietal
T	Temporal
TFM	Temporal fuzzy model

1. GİRİŞ

Bilimin gelişmesinde en önemli kaynaklardan biri olan veri, hem hacim hem de karmaşıklık açısından ciddi derecede artmıştır. İnternet ve sosyal medya gibi veri üzerine kurulan oluşumlar, beraberinde “büyük veri” olgusunu da getirmiştir [1]. Fakat bu ham veri, bizleri bilgiden uzak, sadece veri zengini yapar [2]. Hızla büyüyen, yaygın olarak bulunan ve devasa boyutlarda olan bu veri yığını, “bilgi çağında yaşıyoruz” cümlesi yerine sadece “veri çağında yaşıyoruz” dedirtiyor. Bu büyük veriden anlamlı bilgileri otomatik olarak ortaya çıkarmak ve verileri organize bilgiye dönüştürmek için güçlü ve çok yönlü araçlara şiddetle ihtiyaç vardır. Bu zorunluluk, veri madenciliğinin doğmasına neden olmuştur [3].

Veri madenciliği, bir sistem olarak düşünülürse, girdileri ham verilerdir, çıktıları ise kullanıcıya sunulan bilgilerdir. Veri madenciliğinin merkezinde ise veriyi işleyen metot ve algoritmalar vardır. Temel amacı, veriyi faydalı bilgi haline getirmektir. Bu amacı gerçekleştirmek için geliştirilen algoritmalar ve metotlar, genel olarak iki gruba ayrılmıştır; tahmin edici ve tanımlayıcı [3]. Tahmin edici yöntemler, sınıflandırma ve regresyon modelleridir. Sınıflandırma, veri sınıflarını veya kavramları tanımlayan veya ayırt eden bir model bulma sürecidir. Bu modeller, verileri anlamlı bir şekilde ayırt edebilmeyi sağlar. Regresyon ise, hedef değişkenin, farklı girdi değişkenleri tarafından modellenmesidir. Modeller oluşturulduktan sonra, hedef değişken, girdi değişkenler ile tahmin edilir [3].


Fakat tahminleme amaçlı değil; doğrudan verinin karakteri anlaşılacak isteniyorsa, tanımlayıcı metotlar kullanılır. Kısaca, verideki sebep-sonuç ilişkisini, verinin kümelenmesini ve verinin genel özetini yansıtmaktadır. Bu yöntemler, veriyi kendi içerisinde tanımayla ve karakterize etmeyi sağlar [3]. Veri tabanı içerisindeki örüntüleri tespit etmeyi sağlayan tanımlayıcı metotlar; birliktelik kuralları, kümeleme ve özetlemedir [4]. Bir veri seti içerisindeki alt kümelerin birbirleriyle olan benzerlikleri, belli bir kural örüntüsü içerisinde sunulabilmesi, birliktelik kurallarıyla yapılır [3]. Tanımlayıcı bir diğer yöntem, kümelemedir. Bu yöntemler, istenilen özelliklerde benzer örüntüye sahip verileri bir araya getirir.

Verinin içeriğini, özünü tanımlayan bir diğer metot ise, özetlemedir. Özetleme, konu hakkında çalışan bir uzmanın, durumu analiz etmesi için istediği özet sonuçlardır. Bu

sonuçlar, iki farklı yöntemle elde edilmektedir; istatistiksel özetleme ve dilsel özetlemedir. İstatistiksel özetleme, verinin ortalaması, standart sapması, medyanı, modu, simetrisi vb. hesaplamalar ile yapılmaktadır. Bu özetler, veri üzerinde çalışan ve ön bilgisi olan kişiler için gayet anlamlı ve yeterli olabilir. İstatistik temelli bu özetlerin önemli iki eksikliği vardır; ilki, kullanıcıya vereceğiniz özetler çok kısıtlıdır; ortalama, standart sapma vb. Bunlar, veriyi özetlemek için her zaman yeterli olmayabilir [2]. İkinci yetersizliği ise, veri hakkında önceden bilgisi olmayan kullanıcıya sunduğunuz özetin anlaşılabilirliği. Örneğin, bir sınavda öğrencilerin not ortalaması, istatistiksel olarak anlamlı olsa da, sınavın içeriği veya zorluğu hakkında bilgisi olmayan kişiler için anlaşılır değildir.

Günlük yaşamda istatistik temelli cümleler yerine, doğal dil ile ifade daha çok tercih edilir [5]. Bir topluluktaki kadınların boy uzunluğu hakkında konuşulurken, ortalaması, varyansı vb. istatistiksel temelli kelimeler yerine uzun, kısa vb. ifadeler kullanılır [6]. Bu sebeple verilerin dilsel olarak özetlenmesi daha anlaşılır. Bir veri özetlenirken, hem sayısal hem de sayısal olmayan özet biçimi sunulabilir. Aylık gelirlerle ilgili bir veri tabanında “çoğu genç ve tecrübesiz çalışanların aylık kazancı düşüktür” gibi bir özet cümle çıkarılabilir. Bu tarz özetleme, doğal dilde olduğu için herkes tarafından kolayca anlaşılabilir [2].

Dilsel özetleme, Yager (1982) tarafından bulanık kümeler (BK) kullanılarak geliştirilmiştir [7]. Bu çalışmada, 2 farklı dilsel özetleme yapısı sunulmuştur. Bunlar, tip-1 ve tip-2 niceleyici cümle kalıplarıdır. Bu çalışmadan sonra, bulanık dilsel özetleme uygulamaları zaman içerisinde artmıştır. Hem özetleme yapıları, hem uygulama alanları, hem de kullanılan veri tipi çeşitliliği artmıştır [7, 8]. Bulanık dilsel özetlemede 3 farklı veri tipi kullanılmıştır; Tablo şeklindeki veriler, zaman serileri ve ağ yapısı verileridir. Zaman serisi verileri ise yer alan değişken sayısına göre 2'ye ayrılmaktadır. Bunlar; tek değişkenli zaman serisi ve çok değişkenli zaman serisidir. Çok değişkenli zaman serisi de aynı birimli ve farklı birimli olmak üzere 2'ye ayrılmaktadır (Şekil 1.1).



Şekil 1.1. Veri yapıları

İlk çalışmalarda, tip-1 ve tip-2 niceleyici protoform yapısında tablo şeklindeki veri ile özetleme yapılırken [9-11] daha sonra zaman serisi verilerine de uygulanmıştır [11]. Aynı zamanda dilsel özetleme protoform yapıları da zenginleşmiştir [12, 13]. Bu yaygınlaşan uygulamalar en çok zaman serisi verilerinde görülmektedir [5, 10, 14-16].

Zaman serisi verilerinde uygulanan ilk dilsel özetleme çalışmasında, veriden daha fazla ve anlamlı bilgi çıkarmak için trend segmentasyon işlemi uygulanmıştır [17]. Bu işlem ile zaman serilerinde üç özellik bulunur; trendlerin dinamikliği, süresi ve değişkenliğidir. Bu 3 özellik, veriyi farklı yönlerden anlamaya yarayan parametrelerdir. Trend segmentasyon için literatürde birçok metot vardır [5, 14, 18-22].

Dilsel özetlemede, üzerinde en çok çalışılan zaman serisi veri tipi, tek değişkenli zaman serisidir. Fakat çalışmalar arttıkça diğer veri tipleriyle olan çalışmalar da görülmektedir [23].

Tek deęişkenli zaman serilerinde trend segmentasyonu ile bilgi üreterek dilsel özetleme yapılması, dięer veri tiplerine göre daha kolaydır. Çünkü tek bir trend segmentasyon uygulaması ile trendler çıkarılır ve dilsel özetlemeye hazır hale gelir. Fakat birden fazla deęişkene tek bir segmentasyon işlemi uygulanamaz, her deęişken için ayrı ayrı uygulanması gerekir. Buradaki problem, her deęişkene farklı segmentasyon işlemi uygulandığında, trendlerin özetlemede nasıl birleştirileceğidir veya ortak bir trend segmentasyon modelinin nasıl uygulanacağıdır. Dilsel özetleme yapılabilmesi için nasıl bir ön çalışma yapılması gerektięi tam bilinmemekle beraber literatürde çok az miktarda çalışma vardır. Literatürde çok boyutlu veya çok deęişkenli zaman serilerinde yapılan çalışmanın yetersizlięi, bu alanda yeni çalışmaların yapılabileceğini göstermektedir.

Veri analizinin en önemli olduęu ve son zamanlarda yoğun ilgi gösterilen alanlardan biri de nörobilimin bir alt alanı olan nöropazarlamadır. Pazar payını artırma isteęi, işletmeleri daha sıkı rekabet etmeye ve pazarlama stratejilerini güncellemeye zorlamaktadır. Bu sıkı rekabet, nöropazarlama alanını zaruri kılmıştır. Pazarlama yöntemleri arasında reklamcılık, en kritik yatırım alanıdır. Çünkü yüksek bütçeli reklam yatırımlarının verimli ve geri dönüşlerinin gerçekçi olması beklenmektedir [24]. Geleneksel pazarlama yöntemlerinde anketler ve görüşmeler kullanılarak tüketici geri bildirimleri alınır, ancak bu yöntemler her zaman gerçeęi yansıtmayabilir. Tüketicilerin gerçek algı, anlama ve duyguları ile geri bildirimleri arasında tutarsızlıklar olduęu gözlemlenmiştir [25].

Bu eksikliklerden ve nörobilimdeki gelişmelerden dolayı, geleneksel yöntemlerin yerini nöropazarlama almıştır. Nöropazarlama, tüketicilerin bilinçaltı davranış ve duygularını tespit ederek daha doğru sonuçlar sunar [26]. Örneğin, bir tüketici bir broşür veya görsel reklamı incelediğinde, beyin aktiviteleri ve bilinçaltı tepkileri EEG kullanılarak ölçülebilir. EEG'nin uygun maliyeti, onu pazarlama uyarıcılarını deęerlendirmek için en popüler nörogörüntüleme teknięi yapmaktadır [25].

Reklamlara yönelik nöropazarlama çalışmalarında, EEG sinyallerinden duyguların tanınması önemli bir unsurdur [27]. Duygu tanıma modelleri genel olarak iki kategoriye ayrılabilir: hesaplamalı modeller ve veri odaklı modeller. Hesaplamalı modeller, duyguları mutluluk, üzüntü, öfke veya korku gibi sabit kategorilere sınıflandıran kategorik (ayrık) modelleri ve etkiyi genellikle deęer ve uyarılma gibi sürekli eksenler boyunca temsil eden boyutlu (sürekli) modelleri içerir [8, 12, 18]. Veri odaklı modeller, Destek Vektör Makineleri

(SVM), k-En Yakın Komşular (kNN), Karar Ağaçları gibi ML tekniklerini ve Evrişimli Sinir Ağları (CNN'ler), Tekrarlayan Sinir Ağları (RNN'ler) ve dikkat tabanlı mimariler gibi DL yaklaşımlarını kapsar. Bu teknikler, EEG sinyalleri de dahil olmak üzere ham verilerden hiyerarşik özellikleri otomatik olarak çıkarma yetenekleri nedeniyle öne çıkmıştır [17, 18].

Ancak, EEG tabanlı duygu tanıma için ML ve DL modelleri önemli zorluklarla karşı karşıyadır [6]: (1) gürültü ve çevresel tutarsızlıklar nedeniyle gerçek dünya senaryolarında genellenemeyen ve laboratuvarla sınırlı küçük veri kümelerinden kaynaklanan aşırı ezberleme; (2) tamamlayıcı mimarileri etkili bir şekilde entegre edememe; bu da genellikle özneye bağlı aşırı uyum ve optimum olmayan özneler arası performansla sonuçlanır; ve (3) bireysel değişkenlikten kaynaklanan sınırlı doğruluğu (<%70 DEAP veri setinde) ve SEED'in nispeten başarılı tek istisna olarak kalması. Bu sorunlar, bu tür modellerin ölçeklenebilirliğini ve gerçek dünya ortamlarında pratik dağıtımını, özellikle de genelleme gerektiğinde modeli kısıtlar [7].

Buna karşılık, ayrık modeller [8] sezgisel ve kolayca yorumlanabilir çıktılar sunar, ancak gerçek duygusal durumlarda bulunan karmaşıklığı, akışkanlığı ve örtüşmeyi yakalamada başarısız olur [11, 21]. Duygular genellikle bir süreklilik boyunca ortaya çıkar ve kategorik etiketler, karışık veya belirsiz duygusal tepkiler için yetersizdir. Russell'ın sirkumpleks modeli gibi boyutlu modeller, duyguları değer ve uyarılma ile tanımlanan sürekli iki boyutlu bir alana eşleyerek bunu ele alır ve böylece duyguların daha ayrıntılı bir şekilde anlaşılmasını sağlar [8, 16]. Ayrıca, boyutlu modeller, ML ve DL yaklaşımlarıyla ilişkili birçok zorluğun üstesinden gelir.

Boyutsal model gibi yaklaşımlar, duyguların bir noktada temsil edilmesini ve farklı duygular arasında geçişlerin analiz edilmesini sağlar [28]. Ancak bu duygusal verilerin büyük miktarda olması, tüketici davranışını anlamayı zorlaştırır. Bu veri karmaşasının üstesinden gelmek için zaman serileri tipinde olan EEG verilerini segmente edip işlemek ve daha sonra bulanık dilsel özetleme ile otomatik dilsel özetler oluşturmak, bu tez çalışmasının motivasyon kaynağıdır.

Bu alanda herhangi bir dilsel özetleme çalışması bulunmamaktadır. Bu sebeple nöropazarlama alanında ve hesaplamalı boyutsal duygu tanıma modellerinde ilk olacaktır. Çalışma, iki farklı bölümden oluşmaktadır. İlk bölümde genel odaklanma, çok boyutlu

zaman serilerinde segmentasyon, dilsel özetleme yapısı geliştirme ve hesaplamalı boyutsal duygu modellerinin bulanıklaştırılması üzerine olacaktır. Bu bölümde, bir otelin üç farklı tanıtım reklamı (web sayfası, sesli tanıtım ve video tanıtım reklamı) farklı cinsiyetlerde ve yaşlarda bulunan katılımcılara izletilerek EEG verileri alınmıştır. Bu veriler ön işlemlerden geçirilmiş, duygu durum analizi yapılmaya elverişli hale getirilmiştir. Kişilerin, reklamlarda izlediği, okuduğu veya dinlediği dış etkenlere karşı; kendilerinde oluşan duygular tespit edilmiştir. Zamana göre tespit edilen bu duygular, dilsel özetlemede kullanılmıştır.

Dilsel özetleme, üç farklı veri yapısına göre yapılmıştır. Bunlar, tek boyutlu, çok boyutlu ve granüler trend tespitli zaman serileridir. Farklı tip zaman serilerinde dilsel özetleme yapmanın amacı, hem birey bazında, hem genel olarak, hem de duygu yoğunluğu açısından reklamları analiz edip, dilsel olarak özetlemektir. Tek boyutlu, çok boyutlu ve granüler trend tespitli zaman serilerine uygun olarak üç farklı başlıkta protoform yapıları hazırlanmıştır. Granül tespitli zaman serilerinin protoformlarından önce, çok granüllü trend algılama algoritması ve geliştirilmiş versiyonu sunulmuştur.

Çalışmanın ikinci bölümünde ise ilk bölümde geliştirilen metodoloji, literatürde en çok kullanılan SEED veri setinde test edilmiş ve sonuçları, ML ve DL modelleriyle karşılaştırılarak performans analizleri sunulmuştur. Dahası, daha etkin ve geniş bir perspektif sunabilmek için, metodoloji daha da zenginleştirilmiştir. Literatürdeki uyarılma ve değerlik hesaplayan diğer üç frontal formül eklenmiş ve bu formüller arasındaki hesaplama farklılıkları, sonuçlardaki performanslarına göre yorumlanmıştır. İlk bölümde Russell'ın modelinde sadece üçgen bulanık küme kullanılırken, ikinci bölümde yamuk ve Gauss bulanık küme yapıları da eklenmiştir. Böylelikle bulanık kümelerin, duygu tanımadaki etkinliği gösterilmiştir. İlk bölümde olduğu gibi, bu bölümde de SEED veri seti, granüler trend tespit algoritması ile iki farklı veri yapısı olarak ele alınmıştır. Tüm EEG noktalarının kullanımı ve eş zamanlı verilerin kullanımı arasındaki performans farklılığı da sunulmuştur. Bunlarla beraber, ikinci bölümün en önemli amacı, neredeyse tüm kısıtlamalardan arınmış hesaplamalı boyutlu duygu modellerinin bulanık kümelerle ve dilsel özetlemeyle entegre kullanılması, ML ve DL modelleriyle çok iyi rekabet edebiliyor olmasıdır. Özetle katkılarımızı şu şekilde sıralayabiliriz: (1) Frontal alfa ve beta bantlarından türetilen tüm uyarılma/değerlik formüllerinin performansları SEED veri setinde karşılaştırıldı. (2) Russell'ın modelindeki on altı duygu etiketi, Larsen ve Diener'in 45° teorisine göre ilk defa üç sınıfa atandı. (3) Duygu lokalizasyonunu iyileştirmek ve

performanslarını karşılaştırmak için Russell modeli üç bulanık üyelik fonksiyonu (üçgen, yamuk ve Gauss) ile güçlendirildi. (4) FLS kullanılarak sınıflandırma yapıldı ve geleneksel ML ve DL modelleri ile karşılaştırıldı.

Bu çalışma iki farklı adımda sunulacaktır. Birinci adım tamamen verildikten sonra ikinci bölüm de verilecektir. Çalışmanın ilk bölümünün kapsamı aşağıdaki biçimde yapılandırılmıştır;

- Birinci bölümün ikinci başlığında, dilsel özetleme konusunu ele alınarak, bulanık kümelerin matematiksel temellerine ve işlemlerine yer verilmiştir. Bulanık kümelerde kesişim, birleşim ve kardinalite kavramlarının tanımları verilmiş ve bulanık dilsel özetlemenin temeli anlatılmıştır. Daha sonra bulanık dilsel özetleme protoform yapıları (Tip-1 ve Tip-2 niceleyici cümle yapıları) örneklendirilerek anlatılmıştır. Zaman serilerinde dilsel özetleme tekniklerinin uygulanabilirliği örneklerle anlatılmış ve bu özetlemelerin değerlendirme yöntemleri detaylandırılmıştır.
- Üçüncü başlığında, nöropazarlama ve EEG teknolojisinin kullanımı ele alınmıştır. EEG'nin tüketicilerin duygusal tepkilerini ve bilinçaltı davranışlarını analiz etmedeki rolü vurgulanmış, özellikle nöropazarlamada duyguları doğru yansıtabilmesi açısından önemi üzerinde durulmuştur.
- Dördüncü başlıkta literatür araştırması, zaman serilerinde kullanılan segmentasyon temelli ve temelli olmayan yöntemler olarak iki farklı şekilde incelenmiş ve doğruluk ölçümleri detaylı şekilde verilmiştir. Tek ve çok değişkenli zaman serilerinde kullanılan yaklaşımlar ile dilsel özetleme tekniklerinin uygulama alanları karşılaştırılmıştır. Bu kapsamda, mevcut literatürün güçlü ve zayıf yönleri değerlendirilerek, bu çalışmanın hangi boşlukları doldurmayı hedeflediği ortaya konmuştur.
- Beşinci başlık olan Yöntem'de, EEG verilerinin dilsel özetler haline gelebilmesi için hangi yöntemlerin uygulanacağı ve bu yöntemlerde hangi geliştirmeler yapıldığı sunulmaktadır. Russell'ın çemberinden bulanık duygu etiketi çıkarım yeniliği bu kısımda tüm detaylarıyla verilmektedir. Ayrıca nöropazarlamada kullanılan indeksler, formüller ve bu indekslerin tüketici davranışlarının değerlendirilmesindeki rolü anlatılmıştır.

- Altıncı kısımda, nöropazarlama alanındaki uygulamada, o alana uygun dilsel özetleme yapıları üç farklı zaman serisi yapısına göre oluşturulmuştur. Bu cümle kalıplarına göre EEG sinyalleri özetlenecektir.
- Birinci bölümün uygulama kısmında, verilerin nasıl elde edildiği ve ön işleme süreçleri detaylandırılmıştır. Verilerin özellik çıkarma yöntemleriyle analize uygun hale getirilmesi açıklanmıştır.
- Son kısımda, üç farklı zaman serisine göre dilsel özetleme sonuçları, doğruluk dereceleriyle beraber verilmiştir. Bu özetlere göre reklamlar analiz edilmiş, sonuçlar tartışılmış ve öneriler sunulmuştur.

Birinci bölümün arasındaki bağlantıları göstermek ve daha kolay anlaşılmasını sağlamak için bölümler hakkında bilgi veren içerik Şekil 1.2’de sunulmuştur.

Bölüm 1: Giriş	Araştırma konusu, problemin tanımı ve önemi
Bölüm 2: Dilsel Özetleme	Bulanık küme, Bulanık dilsel özetleme, Temel ve gelişmiş protoform yapıları, Doğruluk derecesi, kalite ölçüm göstergeleri ve zaman serilerinde dilsel özetleme
Bölüm 3: Nöropazarlama	Nöropazarlama ve EEG tanımları
Bölüm 4: Literatür Araştırması	Tek değişkenli ve çok değişkenli zaman serileri hakkında literatür araştırması ve sınıflandırılması
Bölüm 5: Yöntem	EEG ile bulanık duygu tespiti ve Russell'ın çemberinde gösterimi, nöropazarlama indeksleri
Bölüm 6: Dilsel Özetleme Protoformları	Tek boyutlu, çok boyutlu ve granül tespitli veri tiplerine uygun dilsel özetleme protoform yapılarının geliştirilmesi
Bölüm 7: Uygulama	Veri elde edilmesi, veri ön işleme süreci ve özellik çıkarımı
Bölüm 8: Sonuç ve Öneriler	Dilsel özetleme sonuçları, tartışma ve öneriler

Şekil 1.2. Tezin birinci bölümünün içeriği



2. DİLSEL ÖZETLEME

2.1. Bulanık Kümeler

Bulanık kümeler (BK), istatistiksel yönden gösterilemeyen belirsizliklere sahip veri ve bilgileri açıklamak için Zadeh (1965) tarafından oluşturulmuştur [29]. Klasik küme teorisinde, elemanların A kümesine olan aitlik dereceleri 0-1 üyelik fonksiyonlarıyla gösterilmektedir. Herhangi bir eleman, A kümesine ya aittir (1 ile gösterilir) veya değildir (0 ile gösterilir). Klasik kümeler, gerçek dünyadaki belirsizliği veya kesinsizliği ifade etmekte yeterli değildir. Bu yetersizlikten dolayı, karmaşık sistemleri daha iyi ifade edip, belirsizliği gösteren dereceli üyelik fonksiyonlarıyla ifade edilen bulanık kümeler önerilmiştir [30]. BK'ler, insana ait düşünme yeteneklerinin bilgi tabanlı sistemlere uygulanmasını sağlayan bir çıkarım dilbilimi sağlar. Bu teori, düşünme ve akıl yürütme gibi insan bilişsel süreçleriyle ilgili belirsizlikleri yakalamak için matematiksel bir güç sağlar [31].

Bulanık bir küme, evrensel kümedeki her bir elemanın $[0,1]$ aralığındaki bir sayı ile eşlendiği bir üyelik fonksiyonu olarak Eş. 2.1'de şöyle tanımlanır [2];

$$\mu_{\tilde{A}}(x) \rightarrow [0,1], \forall x \in X \quad (2.1)$$

BK'lerde herhangi bir nesne, üyelik derecesi ile tanımlanır. Üyelik derecesi 0 ile 1 arasındaki bir değer olabilir. Burada 0, nesnenin kümenin üyesi olmadığını, 1 ise kümenin tam üyesi olduğunu gösterir. Bulanık küme, nesne, nesnenin ilgili kümeye üyelik derecesi şu sırayla gösterilir (Eş. 2.2);

$$\tilde{A} = (x, \mu_{\tilde{A}}(x)), \forall x \in X \quad (2.2)$$

Evrensel küme kesikli ise $\tilde{A}$ BK'si Eş. 2.3'deki gibi gösterilir.

$$\tilde{A} = \left\{ \frac{\mu_{\tilde{A}}(x_1)}{x_1} + \frac{\mu_{\tilde{A}}(x_2)}{x_2} + \dots + \frac{\mu_{\tilde{A}}(x_n)}{x_n} \right\} = \left\{ \sum_{i=1}^n \frac{\mu_{\tilde{A}}(x_i)}{x_i} \right\} \quad (2.3)$$


Eğer evrensel küme, sürekli ve sonsuz ise $\tilde{A}$ BK'si Eş. 2.4'deki gibi gösterilir.

$$\tilde{A} = \left\{ \int \frac{\mu_{\tilde{A}}(x)}{x} \right\}, \forall x \in X \quad (2.4)$$

Bulanık küme tanımında kullanılan " $\sum, \int, /$ " ve "+" simgeler, herhangi bir cebirsel anlam ifade etmez. Bu simgeler sırasıyla; bulanık tekliklerin kesikli evrende (" $\sum$ "), sürekli evrende (" $\int$ ") olduğunu gösterir. "/" simgesi, $(x, \mu_{\tilde{A}}(x))$ tekliğini, "+" simgesi de bulanık tekliklerin birleşimini ifade etmek için kullanılır [32].

Üyelik fonksiyonları, kesikli-sürekli, asimetrik-asimetrik olmayan ve parametrik-parametrik olmayan şeklinde sınıflandırılabilir. Üyelik fonksiyonunun belirlenmesi, rassal değişkenlerin olasılık yoğunluk fonksiyonunun belirlenmesine benzetilebileceği için uygulamadaki anlam durumuna göre sezgisel olarak üyelik fonksiyon derecesi atanabilir [33]. Literatürde görülen üyelik fonksiyonları şöyledir; üçgensel, yamuksal, z-şekilli, s-şekilli, sigmoid, çan şekilli, pi (π)-şekilli ve gaussian üyelik fonksiyonlarıdır [34].

Bir BK'ye ait elemanların üyelik fonksiyonlarının kesikli ve sürekli formda gösterimleri Şekil 2.1'de verilmektedir [33].



Şekil 2.1. Farklı tipteki BK'ler: (a) Kesikli BK (b) Sürekli BK

BK'lerde önemli kavramlardan iki tanesi; alfa (α) kesmesi ve güçlü alfa (α^+) kesmesidir. X evrensel kümesinde $\tilde{A}$ bir BK ve $\alpha \in [0,1]$ olmak üzere α kesmesi ve α^+ kesmesi sırasıyla Eş. 2.5 ve Eş. 2.6'da gösterilmiştir [31].

$$\tilde{A}_{\alpha} = \{x \in X | \mu_{\tilde{A}}(x) \geq \alpha\} \quad (2.5)$$

$$\tilde{A}_{\alpha^+} = \{x \in X | \mu_{\tilde{A}}(x) > \alpha\} \quad (2.6)$$

α kesmesiyle $\tilde{A}$ BK'sinin elemanlarının üyelik dereceleri α 'ya eşit ya da büyük olan $\tilde{A}_\alpha$ kesin kümesine; güçlü α^+ kesmesiyle de $\tilde{A}$ BK'sinin elemanlarının üyelik dereceleri α 'dan büyük olan $\tilde{A}_{\alpha^+}$ kesin kümesine dönüşmektedir [35].

X evrensel kümesindeki bir bulanık $\tilde{A}$ kümesinin özü, desteği, sınırı, geçiş noktaları ve yüksekliği Eş. 2.7-2.11 arasındaki eşitliklerde ve Şekil 2.2'de gösterilmiştir [34].


$$\text{Öz}(\tilde{A}) = \{x \in X | \mu_{\tilde{A}}(x) = 1\} \quad (2.7)$$

$$\text{Destek}(\tilde{A}) = \{x \in X | \mu_{\tilde{A}}(x) > 0\} \quad (2.8)$$

$$\text{Sınır}(\tilde{A}) = \{x \in X | 0 < \mu_{\tilde{A}}(x) < 1\} \quad (2.9)$$

$$\text{Geçiş Noktaları}(\tilde{A}) = \{x \in X | \mu_{\tilde{A}}(x) = 0.5\} \quad (2.10)$$

$$\text{Yükseklik}(\tilde{A}) = \sup_{x \in X} \{\mu_{\tilde{A}}(x)\} \quad (2.11)$$



Şekil 2.2. Bulanık kümelerde öz, destek, sınır, geçiş noktaları ve yükseklik


X evrensel kümesinde bir bulanık $\tilde{A}$ kümesinin konveks olması için Eş. 2.12'de verilen şartı sağlaması gerekmektedir [34, 35].

$$\mu_{\tilde{A}}(\lambda x_1 + (1 - \lambda)x_2) \geq \min(\mu_{\tilde{A}}(x_1), \mu_{\tilde{A}}(x_2)) \quad \forall x_1, x_2 \in X, \quad \lambda \in [0,1] \quad (2.12)$$

X evrensel kümesinde bir bulanık $\tilde{A}$ kümesinin normal olması için Eş. 2.13’de verilen şartı sağlaması gerekmektedir [34, 35].

$$\text{Yükseklik}(\tilde{A}) = \sup_{x \in X} \{\mu_{\tilde{A}}(x)\} = 1 \quad (2.13)$$


Z bulanık sayısının (BS), X evrensel kümesinde bir bulanık alt küme olabilmesi için konveks ve normal olması gerekir. Gerçek sayılar kümesinde tanımlanan BS’lar, çeşitli BK tipleri içerisinde özel öneme sahip alt kümelerdir. BS’lar, verilen gerçek sayıya yaklaşık sayıların kümesi olduğu için belirsizliğin olduğu mühendislik uygulamalarında ve karar vermede sıklıkla kullanılmaktadır. BS’lar, üyelik fonksiyonlarının şekillerine göre isimlendirilir. Literatürde çok sayıda üyelik fonksiyonu tanımlanmakla birlikte işlem yükünün az olması nedeniyle en fazla kesikli, üçgen ve yamuk fonksiyonlar kullanılmaktadır. Şekil 2.3’te üçgensel BS’nın gösterimi verilmiştir. Üçgensel BS için üyelik fonksiyonu Eş. 2.14’de tanımlanmıştır [34, 35].



Şekil 2.3. Üçgensel BS

$$\mu_Z(x) = \begin{cases} 0, & x < l \\ \frac{x-l}{m-l}, & l \leq x \leq m \\ \frac{u-x}{u-m}, & m \leq x \leq u \\ 0, & x > u \end{cases} \quad (2.14)$$

Bir dilsel değişken $(x, ET(x), X, G, M)$ fonksiyonuyla tanımlanabilir. Burada x , dilsel değişkenin adını; $ET(x)$, x değişkeninin etiket kümesini ve X evrensel kümeyi göstermektedir. G sözdizimsel kuraldır ve $ET(x)$ kümesinde yer alan etiketleri üretir. M anlamsal kuraldır ve her A etiketinin (BK) anlamını gösterir. $M(A)$ ise X uzayındaki bir BK'yı gösterir. Örneğin Şekil 2.4'de; "süre" değişkeni x ile temsil edilmektedir. Bu değişkenin $ET(x)$ etiket kümesi ise "kısa", "orta" ve "uzun" dilsel etiketlerinden oluşabilir. Dilsel terimler, temel değişken olan süreye göre atanan BS'larla ifade edilirler. Süre için tanımlanan "kısa" "orta" ve "uzun" etiketlerinin gösterimi Şekil 2.4'de verilmiştir [35].



Şekil 2.4. Dilsel değişken örneği

2.1.1. Bulanık kümelerde kesişim

$\tilde{A}_1$ ve $\tilde{A}_2$, X evrensel kümesinde tanımlanmış BK'ler ve bu kümelerin üyelik fonksiyonları $\mu_{\tilde{A}_1}(x)$ ve $\mu_{\tilde{A}_2}(x)$ ile gösterilsin. $\tilde{A}_1$ ve $\tilde{A}_2$, BK'lerinin kesişimi $\tilde{A}_1 \cap \tilde{A}_2$ şeklinde ifade edilirken; üyelik fonksiyonu olan $\mu_{\tilde{A}_1 \cap \tilde{A}_2}(x)$, $\otimes: [0,1] \times [0,1] \rightarrow [0,1]$ ifadesi Eş. 2.15'teki gibi tanımlanır [5].

$$\mu_{\tilde{A}_1 \cap \tilde{A}_2}(x) = \otimes(\mu_{\tilde{A}_1}(x), \mu_{\tilde{A}_2}(x)) \quad \forall x \in X \quad (2.15)$$

BK'lerin kesişim işleminde kullanılan $\otimes$ operatörü t-norm olarak adlandırılır. Bir operatörün t-norm olabilmesi için, $\forall x_1, x_2, y_1, y_2 \in [0,1]$ ifadesi tarafından aşağıdaki şartların sağlanması gerekir [5]:

- Sınır şartı: $\otimes(x_1, 1) = x_1$
- Monotonluk şartı: $y_1 \leq y_2$ olduğu takdirde $\otimes(x_1, y_1) \leq \otimes(x_1, y_2)$
- Simetri şartı: $\otimes(x_1, y_1) = \otimes(y_1, x_1)$
- Birleşme şartı: $\otimes(x_1, \otimes(x_2, y_2)) = \otimes(\otimes(x_1, x_2), y_2)$

Literatürde kullanılan ve Eş. 2.16-2.20 arasında tanımları verilen operatörler, t-normdur [5].

$$\text{Minimum} \rightarrow \otimes_{\min}(x_1, y_1) = \min(x_1, y_1) \quad (2.16)$$

$$\text{Çarpım} \rightarrow \otimes_{\text{car}}(x_1, y_1) = x_1 y_1 \quad (2.17)$$

$$\text{Lukasiewicz} \rightarrow \otimes_{\text{Luk}}(x_1, y_1) = \max(0, x_1 + y_1 - 1) \quad (2.18)$$

$$\text{Drastik} \rightarrow \otimes_{\text{Dra}}(x_1, y_1) = \begin{cases} x_1, & \text{Eğer } y_1 = 1 \\ y_1, & \text{Eğer } x_1 = 1 \\ 0, & \text{d. d.} \end{cases} \quad (2.19)$$

$$\text{Hamacher} \rightarrow \otimes_{\text{Ham}}(x_1, y_1) = \begin{cases} 0, & \text{Eğer } x_1 = y_1 = 0 \\ \frac{x_1 y_1}{x_1 + y_1 - x_1 y_1}, & \text{d. d.} \end{cases} \quad (2.20)$$

Bazı durumlarda, bazı özelliklerle t-normların kısıtlanması istenmektedir. Bu özelliklerden en önemli üç tanesi şöyledir [33].

- Süreklilik: $\otimes \left(\lim_{n \rightarrow \infty} x_n, \lim_{n \rightarrow \infty} y_n \right) = \lim_{n \rightarrow \infty} \otimes(x_n, y_n)$
- Alt eşgüçlülük: $\otimes(x_1, x_1) < x_1$
- Katı monotonluk: $x_1 < x_2$ ve $y_1 < y_2$ olduğu takdirde $\otimes(x_1, y_1) < \otimes(x_2, y_2)$

T-normlar, özelliklerine göre isimlendirilmektedir. Sürekli ve alt eşgüçlülüğe sahip bir t-norm, Archimedean t-norm olarak isimlendirilir. Eğer bir t-norm, hem Archimedean hem de her bir değişkeni katı bir şekilde artırıyor ise katı Archimedean t-norm olarak isimlendirilir [2, 34].

2.1.2. Bulanık kümelerde birleşim

$\tilde{A}_1$ ve $\tilde{A}_2$, X evrensel kümesinde tanımlanmış BK'ler olsun ve bu kümelerin üyelik fonksiyonları $\mu_{\tilde{A}_1}(x)$ ve $\mu_{\tilde{A}_2}(x)$ ile gösterilsin. $\tilde{A}_1$ ve $\tilde{A}_2$, BK'lerinin birleşimi $\tilde{A}_1 \cup \tilde{A}_2$ iken, üyelik fonksiyonu olan $\mu_{\tilde{A}_1 \cup \tilde{A}_2}(x)$, $\oplus : [0,1] \times [0,1] \rightarrow [0,1]$ ifadesi Eş. 2.21'deki gibi tanımlanır [5].

$$\mu_{\tilde{A}_1 \cup \tilde{A}_2}(x) = \oplus(\mu_{\tilde{A}_1}(x), \mu_{\tilde{A}_2}(x)) \quad \forall x \in X \quad (2.21)$$

BK'lerde birleşim işleminde kullanılan $\oplus$ operatörü t-konorm olarak adlandırılır. Bir operatörün t-konorm olabilmesi için, $\forall x_1, x_2, y_1, y_2 \in [0,1]$ ifadesi tarafından aşağıdaki şartların sağlanması gerekir [5].

- Sınır şartı: $\oplus(x_1, 1) = x_1$
- Monotonluk şartı: $y_1 \leq y_2$ olduğu takdirde $\oplus(x_1, y_1) \leq \oplus(x_1, y_2)$
- Simetri şartı: $\oplus(x_1, y_1) \leq \oplus(y_1, x_1)$
- Birleşme şartı: $\oplus(x_1, \oplus(x_2, y_2)) \leq \oplus(\oplus(x_1, x_2), y_2)$

Literatürde kullanılan Maksimum ($\oplus_{maks}$), Çarpım ($\oplus_{\text{Çar}}$), Lukasiewicz ($\oplus_{Luk}$), ve Drastik ($\oplus_{Dra}$) operatörleri t-konorm olup, Eş. 2.22-2.25'te gösterildiği şekilde tanımlanmaktadır [30]:

$$Maks \rightarrow \oplus_{maks}(x_1, y_1) = \max(x_1, y_1) \quad (2.22)$$

$$\text{Çarpım} \rightarrow \oplus_{\text{Çar}}(x_1, y_1) = x_1 + y_1 - x_1 y_1 \quad (2.23)$$

$$Lukasiewicz \rightarrow \oplus_{Luk}(x_1, y_1) = \min(1, x_1 + y_1) \quad (2.24)$$

$$Drastik \rightarrow \oplus_{Dra}(x_1, y_1) = \begin{cases} x_1, & \text{Eğer } y_1 = 0 \\ y_1, & \text{Eğer } x_1 = 0 \\ 1, & d.d. \end{cases} \quad (2.25)$$

Bazı durumlarda, bazı özelliklerle t-konormların kısıtlanması istenmektedir. Bu özelliklerden en önemli üç tanesi şöyledir [33].

- Süreklilik: $\oplus$ sürekli bir fonksiyon olması,
- Süper eşgüçlülük: $\oplus(x_1, x_1) > x_1$,
- Katı monotonluk: $x_1 < x_2$ ve $y_1 < y_2$ olduğu takdirde $\oplus(x_1, y_1) < \oplus(x_2, y_2)$

T-konormlar, özelliklerine göre isimlendirilmektedir. Sürekli fonksiyon olan bir t-konorm, alt eşgüçlülüğe sahip ise Archimedean t-konorm olarak isimlendirilir. Eğer bir t-konorm, hem Archimedean hem de her bir değişkeni katı bir şekilde artırıyor ise katı Archimedean t-konorm olarak isimlendirilir [2, 30].

2.1.3. Kardinalite kavramı

X evrensel kümesinde tanımlanmış bir $\tilde{A}$ BK'sinin kardinalitesi Eş. 2.26'da sürekli formda, Eş. 2.27'de kesikli formda tanımlanmıştır [32].

$$kard(\tilde{A}) = \int_x \mu_{\tilde{A}}(x) dx \quad (2.26)$$

$$kard(\tilde{A}) = \sum_x \mu_{\tilde{A}}(x) \quad (2.27)$$

2.1.4. Bulanık kardinalite kavramı

X evrensel kümesinde tanımlanmış bir $\tilde{A}$ BK'sinin bulanık kardinalitesi Eş. 2.28'de tanımlanmıştır. Bulanık kardinalitenin kendisi de bir bulanık kümedir. Bulanık kardinalite, kardinaliteyi negatif olmayan tamsayılar üzerinde bulanık bir küme olarak temsil etmekten oluşur [33]. Literatürde farklı tiplerde bulanık kardinalite tanımları bulunmaktadır. Bunların ilki Zadeh'in tanımıdır (Eş. 2.28) [34];

$$Z(A, k) = \begin{cases} 0, & \text{eğer } (a \mid \tilde{A}_a = k) \text{ değilse} \\ \sup\{a \mid \tilde{A}_a = k\}, & \text{diğer} \end{cases} \quad (2.28)$$

Bir diğer bulanık kardinalite hesaplama yöntemi ise, Delgado ve ark.'nın [36] önerdiği E tipi bulanık kardinalitedir. Bulanık kardinalite yöntemleri, niceleyici hesaplama için kullanılmıştır. Bu hesaplama yöntemleri, Bölüm 2.4'de verilmiştir. E tipi bulanık kardinalite Eş. 2.29'da tanımlanmıştır.

$$E(S, i) = L(S, i) \otimes \overline{L(S, i + 1)} \quad (2.29)$$

$L(S, i)$, X'in en az i elemanının S'ye ait olma olasılığını gösterir (Eş. 2.30).

$$L(S, i) = \begin{cases} 1, & i = 0 \\ 0, & i > M \\ \bigoplus_{(I_1, \dots, I_i) \in I_i} (\mu_S(Y_{I_1}) \otimes \dots \otimes \mu_S(Y_{I_i})), & 1 \leq i \leq M \end{cases} \quad (2.30)$$

I_i , aşağıdaki gibi dizinlerin i-tuples kümesidir (Eş. 2.31);

$$I_i = \{(I_1, \dots, I_i) | I_1 < \dots < I_i, I_j \in (1, \dots, M) \forall j \in (1, \dots, i)\} \quad (2.31)$$

Delgado ve ark'ları [37]. E tipi bulanık kardinalitenin özel bir durumu olan ED bulanık kardinaliteyi Eş. 2.32'deki gibi tanımlamıştır [8].

$$ED(S, i) = \max\{b_i + 1 - b_{i+1} - 1, 0\} = b_i - b_{i+1} \quad (2.32)$$

$\otimes_{min}$ ve $\oplus_{max}$ operatörlerinin kullanılması durumunda $b_i = L(S, i)$ olur [38].

2.2. Bulanık Dilsel Özetleme

Yager, doğal dil yardımıyla her kullanıcı tarafından kolaylıkla anlaşılacak “dilsel özetleme” yöntemini önermiştir [39]. Bu çalışmasında, bulanık küme tabanlı iki tip özet yapısı sunmuştur. Dilsel özetlemenin temel yapısı şu şekildedir;

Y nesne kümesi $Y = \{y_1, y_2, y_3, \dots, y_M\}$, nesnelere ait özelliklerin kümesi $V = \{v_1, v_2, \dots, v_k\}$ ve $X_k = \{k = 1, 2, 3, \dots, K\}$ v_k 'in tanım kümesi olarak tanımlansın. $v_k(y_m) \equiv v_k^m \in X_k$, m. nesnenin k. özelliğine ait değeri göstermektedir. Veritabanı $\mathbb{D}$, Y kümesine ait

nesnelerle ilgili veriden oluşmaktadır (Eş. 2.33). d_m , m. nesnenin tüm özelliklerini gösterir. S_k , k. özellik için özetleyiciler kümesini ifade eder (Çizelge 2.1).

$$\mathbb{D} = \{\langle v_1^1, v_2^1, \dots, v_K^1 \rangle, \langle v_1^2, v_2^2, \dots, v_K^2 \rangle, \dots, \langle v_1^M, v_2^M, \dots, v_K^M \rangle\} = \{d_1, d_2, \dots, d_M\} \quad (2.33)$$

Çizelge 2.1. Dilsel özetlemede kullanılan semboller ve açıklamaları

Sembol	Açıklama	Örnek
$\mathbb{D}$	Veritabanı	İnsan kaynakları veritabanı
Y	Veritabanındaki tüm nesnelerin kümesi	Çalışanlar
y_M	Veritabanındaki m. nesne	Veritabanındaki m. çalışan
v_k	k. özellik	Yaş, aylık kazanç
X_k	v_k 'in tanım kümesi	[35-65] yaş, [5-10] bin TL aylık
$v_k(y_m)$	m. kayıttan k. özelliğine ait değeri	m. çalışanın yaşı
d_m	m. nesnenin tüm özelliklerini kapsayan	<35,5bin TL,...>
S_k	Özetleyici	Genç, orta, vb
Q	Niceleyici	Çoğu, yaklaşık yarısı, tümü, vb
$W_g(S_g)$	Niteleyici	Genç, orta, vb
T_1	Doğruluk derecesi	[0,1] aralığında bir değer

2.3. Bulanık Dilsel Özetleme Protoform Yapıları

Dilsel özetleme, literatürde iki şekilde görülmektedir; tek kelimelik özet yapısı ve protoform cümle yapısı. Tek kelimelik özet yapısı, verinin genel karakterini belirleyip, en basit haliyle sunmak için kullanılmıştır. Mesela bir hareketin tipi, tek kelime (duruyor, hareket halinde vb.) ile özetlenmiştir [8].


Protoform cümle yapıları ise üç farklı şekilde incelenebilir; temel tip-1 ve tip-2 protoform yapıları, çalışmaya özel geliştirilen protoform yapıları ve diğer gelişmiş protoform yapılarıdır. Temel tip-1 ve tip-2 protoform yapıları, Yager (1982) [39]. tarafından geliştirilen en temel protoform yapılarıdır.

Çalışmaya özel geliştirilen protoform yapıları da iki farklı şekilde ele alınabilir; birincisi, tip-1 ve tip-2 protoform tabanlı genişletilmiş özel yapılardır. Bu yapılar, dilsel özetlemede özellikle vurgulanması istenilen özellikleri içerir. Mesela, “*Büyük topların birkaçı ağırdır ve topların birkaçı hem büyük ve hem de ağırdır*” [40]. cümlesi, tip-1 ve tip-2’nin genişletilmiş halidir. Bipolar query dil yapısı ve temporal tip-1 ve tip-2 gibi özet yapıları bu gruptandır. İkincisi ise, tip-1 ve tip-2’ye bağlı olmayan, çalışmaya özel geliştirilen protoform

yapılarıdır. Mesela, “19:59:27 ve 19:59:51 arasındaki çoklu modelde 5 benzer çoklu model var” [41]. gibi bir özet yapısı, sabit bir kalıbın olduğu ve bazı etiketlerin değişeceği özet yapılarıdır.

Son olarak, literatürde kullanılan diğer gelişmiş protoform yapıları; Eğer-Öyleyse kural tabanlı protoformlar, granular linguistic model of phenomenon (GLMP), petri ağları, tectogramatical tree, syntactic structure, bi-gram dil modelidir [42].

Bu protoformlar da yapısal olarak iki gruba ayrılabilir; Eğer-Öyleyse kural tabanlı olan protoform yapıları ve ağaç şeklinde, eklemeli, esnek protoform yapılarıdır. Bulanık dilsel özetlemede kullanılan tüm protoform yapıları Şekil 2.5’de özetlenmiştir.



Şekil 2.5. Dilsel özetleme yapıları

2.3.1. Tip-1 niceleyici cümle yapısı

“Q Y(nesneler) $S=\{S_1, S_2, S_3, \dots, S_K\}$ ’dır. $[T_1]$ ”

Burada Q niceleyici, S_k özetleyici ve T_1 doğruluk derecesi anlamına gelmektedir. “Çoğu çalışan gençtir.” [0,75] gibi bir özet cümlesi oluşturulmaktadır. “Çoğu” niceleyici, “çalışan”

nesne, “*gençtir*” özetleyici ve “0.75” ise özetin doğruluk derecesidir. Doğruluk derecesi, Eş. 2.34-2.35’deki gibi hesaplanır;

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_s(d_m)}{R} \right) \quad (2.34)$$

$$R = \begin{cases} M, & \text{Göreceli niceleyici (çoğu)} \\ 1, & \text{Mutlak niceleyici ("3'den büyük")} \end{cases} \quad (2.35)$$

Q , “3’den büyük” gibi bir mutlak niceleyici ise R , 1 değerini alır. Eğer “çoğu” gibi göreceli niceleyici ise R , toplam nesne sayısının değerini alır. μ_s , S özetinin üyelik derecesini ifade etmektedir. Özetleyiciler, niceleyiciler ve niteleyiciler, bulanık kümeler ile modellenir. Modelleme, ilk önce verinin bulanık kümelerde üyelik fonksiyonuna dönüştürülmesiyle başlar. Bu dönüşüm, bulanık c-ortalama gibi kümeleme metotlarıyla yapılır.

Özet cümle sayısı, niceleyici ve özetleyicilerin kombinasyonu kadardır. Fakat en anlamlı cümleyi, doğruluk derecesi göstermektedir. Genellikle belli bir eşik değerin üzerinde olan cümleler seçilir [43].

2.3.2. Tip-2 niceleyici cümle yapısı


“ $Q \ w_g(S_g) \ Y(\text{nesneler}) \ S=\{S_1, S_2, S_3, \dots, S_K\}$ ’dır. $[T_1]$ ”

Bu protoform yapısında tip-1’den farklı olarak niteleyici olarak adlandırılan $w_g(S_g)$ öncül özetleyiciler eklenmiştir. Niteleyiciler, nesneyi vasıflandıran sıfatlardır. Mesela, “*çalışkan öğrenci*”, “*yüksek kazançlı işçi*” gibi özetlemeye yardım eder. Niteleyiciler de özetleyici ve niceleyiciler gibi bulanık küme tabanlı modellenir ve etiketlere göre verinin üyelik dereceleri çıkarılır. Tip-2 niceleyici protoform yapısındaki özetlerin doğruluk derecesi Eş. 2.36’deki gibi hesaplanır [42];

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M (\mu_{w_g(S_g)}(v_g^m) \otimes \mu_s(d_m))}{\sum_{m=1}^M \mu_{w_g(S_g)}(v_g^m)} \right) \quad (2.36)$$

“Çoğu çalışkan öğrenciler matematik dersinden düşük almıştır.” [0.85] cümlesi tip-2 protoform yapısına örnektir. Burada, “çoğu” niceleyici, “çalışkan” niteleyici ve “düşük” etiketi ise özetleyicidir. Niteleyici ve özetleyiciler için etiketler kümesi oluşturulur. Mesela, özetleyiciler kümesi {düşük, orta, yüksek} veya {çok düşük, düşük, orta, yüksek, çok yüksek} şeklinde tanımlanabilir. Tanımlanan etiket sayısı üzerinden, bulanık kümeleme algoritmaları yardımıyla verinin etiketlere olan üyelik dereceleri hesaplanarak üyelik fonksiyonu oluşturulur. Üyelik fonksiyonunun belirlenmesi, rassal değişkenlerin olasılık yoğunluk fonksiyonunun belirlenmesine benzetilebileceği için uygulamadaki anlam durumuna göre sezgisel olarak üyelik fonksiyon derecesi atanabilir [44]. Literatürde görülen üyelik fonksiyonları şöyledir; üçgensel, yamuksal, z-şekilli, s-şekilli, sigmoid, çan şekilli, pi (π)-şekilli ve gaussian üyelik fonksiyonlarıdır [2].

Niceleyiciler, literatürde farklı şekillerde tanımlanmışlardır. 2 tip niceleyici vardır; mutlak ve göreceli. Mutlak niceleyiciler, “yaklaşık 3”, “2 ile 4 arasında” gibi niceleyicilerdir (Şekil 2.6 (a)). Göreceli niceleyiciler ise, “hepsi”, “çoğu”, “yarısı” gibi niceleyicilerdir (Şekil 2.6 (b)). Eş. 2.37’de niceleyiciler için örnek bir bulanık küme tanımı verilmiştir [31].



Şekil 2.6. (a) "Yaklaşık 3" kesin niceleyicisi, (b) "En az yarısı" göreceli niceleyici

$$\mu_Q(x) = \begin{cases} 1, & x \geq 0.8 \\ 2x - 6, & 0.3 > x > 0.8 \\ 0, & x \leq 0.3 \end{cases} \quad (2.37)$$

2.3.3. Tip-1 ve tip-2 tabanlı protoform yapıları

Sabit bir yapısı olmayıp, çalışmaya göre değişkenlik gösteren özel protoform yapılarıdır. Bu özetler, temelde tip-1 ve tip-2’den türetilmiştir. Kullanıcıya sunulması istenen ek özellik bu temel yapılara eklenerek özetin yapısı genişletilir. Genişletilmiş tip-1 ve tip-2 yapıları,

çalışmaya göre çok değişkenlik gösterdiği için en yaygın iki özet yapısı sunulacaktır. Bunlar, bipolar query ve temporal tip-1 ve tip-2 yapılarıdır.

Bipolar, kelime olarak “iki kutuplu” anlamına gelmektedir. Doğal dil kullanımında bir anlam ifade edilirken o anlamı desteklemek veya geliştirmek için bazen yan bir anlam veya zıt bir anlam eklenmektedir. Bu doğal ihtiyaçtan dolayı bipolar query geliştirilmiştir [45]. Bu yapının en temel hali şöyledir;

“C ve muhtemelen P”

“C”, özetin en temel halidir, “P” ise özete eklenen yan anlamdır. Tip-1 protoform yapısının bipolar ile genişletilmiş örneği şu şekildedir [46].

“Çoğu çalışan, genç ve muhtemelen bölüm arkadaşlarına göre yüksek maaş alıyor.”

Temporal tip-1 ve tip-2 protoform yapısı, temel özet yapılarının zamansal etiketle genişletilmesiyle elde edilmiştir. Bu özet yapısı ilk kez Kacprzyk ve Wilbik [47] tarafından geliştirilmiştir. Tip-1 olan “Çoğu trend kısadır” veya tip-2 olan “çoğu kısa trend artandır” özetleri, zamansal ifade ile genişletildiğinde “son zamanlarda çoğu trend kısadır” veya “başlangıçta çoğu kısa trendler artandır” haline gelmektedir. Kullanıcıya sunulan bilginin zamansal yönü, özetin içerisine eklenir [47].

2.3.4. Sabit kalıplı protoformlar

Bu başlık, birbirinden bağımsız ve sadece çalışmaya özel geliştirilen protoform yapılarını sınıflandırmak için kullanılmıştır. Bu özetler literatürde bazen kısa bir cümle [42], bazen uzun bir paragraf şeklinde [48] görülmektedir.

Geliştirilen protoform yapılarının sabit bir yapısı vardır. Sadece, istenilen bilgiyi özetleyen etiketler değiştirilir. Bu etiketler ise, bulanık küme temelli olduğu için en yüksek üyelik derecesine göre seçilir. Örnek olarak 2018 yılında Banaee, Schaffernicht ve Loutfi’nin çalışmaları incelendiğinde iki farklı yapı görülmektedir [49]. Yaprak görsellerinin incelendiği bu çalışmada, yaprakların isimleri tahmin edilir ve şekilleri özetlenir.

"Bu yaprak İngiliz Holly'si gibidir, ancak ucu tırtıklı bir kenarla çevrilidir."

"Bu yaprak Oleander gibidir ve ayrıca sivri uçludur."

Sabit kalıplı protoformların avantajı, çalışmaya özel istenilen formda tasarlanabilir olmasıdır. Özellikle raporlama şeklinde istenen özetler için çok uygundur. Fakat her çalışma için ayrı tasarlanması ve özeti sabit olması bu yapıların dezavantajlarındandır. Çünkü doğal dil ihtiyacını sabit formda olduğu için tam karşılayamamaktadır.

2.3.5. Eğer-Öyleyse kural tabanlı protoform

Temel olarak öncüller ve sonuçlardan oluşan ve birbiriyle nedensellik ile bağlı özet yapılarıdır. En temel yapısı şöyledir [50].

Eğer (A_1, S_1 ve ... ve A_m, S_m) ise, (A_{m+1}, S_{m+1} ve ... ve A_{m+n}, S_{m+n})'dir.

Bir veri seti verildiğinde, kuralların öncülleri ve sonuçları belirlenir. Kullanıcının, her bir öncül ve sonuç için kullanılan sözcükleri ve bunlara karşılık gelen bulanık küme modellerini belirtmesi gerekir. Ardından, kuralların tüm olası kombinasyonları oluşturulur [51].

Eğer-Öyleyse protoform kalıplarında doğruluk derecesi ölçümü Eş. 2.38'da skaler kardinalite tabanlı hesaplandığı gibi [52],

$$T = \left(\frac{\sum_{i=1}^l \min(\mu_{S_1}(d_1^i), \dots, \mu_{S_{m+n}}(d_{m+n}^i))}{\sum_{i=1}^l \min(\mu_{S_1}(d_1^i), \dots, \mu_{S_m}(d_m^i))} \right) \quad (2.38)$$

bazı çalışmalarda özel formüller [53], bazılarında ise destek ve güven hesapları, özetlerin doğruluk derecesi için kullanılmıştır (Eş. 2.39-2.40) [50];

$$Destek_{\otimes}(A \Rightarrow B) = \left(\frac{\sum_{o \in D} A(o) \otimes B(o)}{n} \right) \quad (2.39)$$

$$Güven_{\otimes}(A \Rightarrow B) = \left(\frac{\sum_{o \in D} A(o) \otimes B(o)}{\sum_{o \in D} A(o)} \right) \quad (2.40)$$

Bu doğruluk derecesi hesaplamaları, Eğer-Öyleyse kural tabanlı özetlerde kullanılan temel yöntemlerdir.

Eğer-Öyleyse protoform yapısının en büyük avantajı, hem özetleme hem de tahminleme için kullanılabilir olmasıdır. Veri içerisinde birbirine bağlı yapıyı ve nedenselliği özetleyebilen basit fakat etkili bir protoform yapısıdır. Fakat sebep-sonuç ilişkisi harici esnek özetleme yapılamadığı için bu yapı, içerik açısından çok zengin sayılmaz.

2.3.6. Ağaç şeklindeki protoformlar


a. Granular linguistic model of phenomenon (GLMP) protoform yapısı:

Dilsel özetlemede diğer özetlerden bağımsız ve sabit kalıbı olmayan bir yapıdır. Genel yapısı, dallardan ağaç gövdesine uzanan veya detaydan genele giden ağaç gibidir. GLMP, birden fazla verinin özetlenmesi için uygundur. Algılama (PM) ve hesaplama algısı (CP) isimli iki işlem ile oluşturulmaktadır [54].

Veriler, PM modülünde bazı formüller ile hesaplandıktan sonra, CP modülüne dilsel etiket oluşturulması için aktarılır. CP'ler dilsel ifadelerin oluşturulduğu yerdir. Veri, başlangıçta veriye bağlı olan PM'lerde formüllerle hesaplanır. Fakat CP'lere bağlı olan MP'lerin değeri eğer-öyleyse kuralları ile hesaplanır (Şekil 2.7) [55].

GLMP, sadece tek bir yapıda özet sunmaz. Mesela, kişinin günlük sportif aktivitelerine göre, günlük, haftalık ve aylık raporlamalar yapabilir [56]. GLMP'nin birbirine bağlı ve birbirini besleyen yapısı ile bunu gerçekleştirebilmektedir. Özet yapısında sonuç sunulurken, “fakat” kullanılarak özetin zıt anlamlısını ve “çünkü” kullanılarak özetin sebebini verebilmektedir.

Bu özet yapısı, hem eğer-öyleyse kurallarını, hem de ağaç şeklinde özetleme yapılarını (tectogramatical tree, petri ağları vb.) içerdiği için, en zengin dilsel özetleme yapısıdır denilebilir.



Şekil 2.7. GLMP yapısı

GLMP dilsel özetleme protoformunda doğruluk derecesi CP'lerde hesaplanır. Özeti doğruluk derecesi, bulanık mantık toplama fonksiyonuyla (aggregation function) CP'lerdeki etiketlerin üyelik derecesi kullanılarak hesaplanır (Eş. 2.41) [57].

$$W_y = g(W_{u_1}, W_{u_2}, \dots, W_{u_n}) \quad (2.41)$$

W_y : Doğruluk derecesi vektörü,


$g()$: Toplama fonksiyonu,

W_{u_y} : CP'de işlem gören her etiketin için üyelik derecesi.

GLMP, protoformlar arasında en gelişmiş özetleme yapısına sahiptir. Eğer-öyleyse kurallarıyla çıkarılan sonuçların ağaç yapısıyla birbirine eklenmesi, bu yapıdaki hem esnekliği hem de doğal dil izlenimini en yüksek seviyeye çıkarmaktadır. Matematiksel hesaplamalarla desteklenen sonuçların hem sebebini hem de zıt anlamını özetleyebilen bir yapıya sahiptir. Fakat bu yapının tek dezavantajı, protoform yapısının kurulumu ve tasarlanması diğer yapılara göre daha zor olmasıdır.

b. Petri ağıları protoform yapısı:

Petri ağıları, sistemin matematiksel bir modelle modellenenebilmesine izin verir. Bir petri ağı, geçiş (transition) ve yerleşim (place) düğümlerinden oluşan tek yönlü iki parçalı grafik olarak da tanımlanabilir. Geçiş noktaları, hesaplama ve verinin dilsel etikete çevrildiği yerdir. Yerleşim yerleri ise dilsel özetlemedeki protoform kalıplarının oluşturuldukları yerlerdir [56]. Şekil 2.8’de gösterildiği gibi veriler geçiş noktalarında (t-2, t-3 vb.) etiketlere çevrilir, yerleşim yerlerinde (p-2, p-3 vb.) ise protoform kalıplarında özete çevrilir. Özet oluşturulurken, her geçiş noktasında en yüksek üyelik derecesine sahip etiket seçilmektedir [57].




Şekil 2.8. Petri ağı yapısı

Bu özet yapısı, GLMP protoform yapısı ile çok benzerlik göstermektedir. Eklemeli ağaç yapısı tarzında olan bu protoformlar, çalışmaya özel hazırlanır ve sabit bir yapısı yoktur. Fakat bu özelliği, daha esnek bir özet yapısı sunmaktadır. Birden fazla protoform yapılarını birleştirerek anlam zenginliğini sağlasa da sabit cümle yapısından dolayı doğal dil algısını tam sunamamaktadır.

c. Tectogramatical tree:

Bu protoformun karar ağaçları tarzında bir yapısı vardır. Bu yapının iki temel özelliği vardır; ağacın dikeyde birbirine bağlanan dalları özetin içerisinde birbiriyle ilişkili olan öğelerini oluşturur. Dalların yatayda sağa doğru akışı ise, protoform yapısının akış sırasını belirler.

Şekil 2.9'deki yapının özeti şöyledir: “*T döneminde X zaman serisinin eğilimi yavaşça artıyor*” [58].




Şekil 2.9. Tectogramatical tree protoform yapısı

Dikeyde birbirine bağlı dallar, cümle öbeklerini; bu dalların yatayda sırası ise protoform yapısının akışını vermektedir. Doğruluk derecesi, üyelik derecesiyle bulunmaktadır [59, 60].

Ağaç şeklinde olan bu yapılar, esnek özetleme imkânı sunabilmektedir. Fakat diğer ağaç şeklinde olan yapılar gibi bu yapının da dezavantajı, her çalışma için yeniden tasarlanması gerekir.

d. Syntactic model:

Bu yapı, dilbilgisinde kullanılan sözdizimsel yapıdır. Bu yapılar, dilsel ifadelerde cümle akışının yapısını göstermektedir (Şekil 2.10). Bu protoform, sadece bir çalışmada kullanılmıştır [61].




Şekil 2.10. Syntactic özet yapısı

Syntactic özetleme yapısında, S özetlemeyi, NP isim tamlamasını, Det niceleyiciyi, N ismi, VP fiil yapısını göstermektedir. Cümle yapısı, tectogramatical tree yapısıyla çok benzerdir. Bu yapılar genelde doğal bir dilin diziliminden türetilmiştir. Özet cümlelerin doğruluk derecesi, etiketlerin üyelik derecesiyle ölçülmüştür [62]. Bu yapı, tectogramatical tree yapısıyla çok benzer olduğu için avantaj ve dezavantajları aynıdır.

e. Bi-gram dil modeli:

Birbiriyle bağlı etiketlerden oluşan ağ yapısıdır. Ağ yapısında etiketler önceden belirlenmiştir. Başlangıç düğümünden başlanır ve veriye göre etiket tercih edilerek son düğüme gelinir. Ağ yapısındaki bu dizilim, özet akışını oluşturmaktadır [62] (Şekil 2.11). Veriden alınan bilgi ile en yüksek üyelik dereceli etiket kullanılır.




Şekil 2.11. Bi-gram dil modeli

Bu yapının avantajı, diğer gelişmiş protoformlar gibi esnek bir özet sunabilmektedir. Fakat başlangıçta yapının oluşturulması ve bu yapının dışına çıkılamaması, bu protoform yapısının dezavantajıdır. Bu sebeple doğal dil izlenimini tam sağlayamamaktadır.

2.4. Dilsel Özetleri Değerlendirme Yöntemleri

Doğruluk derecesi değerlendirme yöntemleri, çalışmalarda farklılık göstermiştir. Doğruluk derecesi hesaplama yöntemleri genel olarak şöyledir (Şekil 2.12);



Şekil 2.12. Dilsel özetleri değerlendirme yöntemleri

2.4.1. Tip-1 niceleyici cümle için skaler kardinalite tabanlı yöntemler

Skaler kardinalite temelli doğruluk derecesi hesaplama yöntemlerinden en temeli, Zadeh'in önerdiği yöntemlerdir.

i. Yager'in OWA (Sıralı Ağırlıklı Ortalama) yöntemi:

OWA operatörüne dayalıdır ve yalnızca görel ve tutarlı niceleyicileri dikkate alır [63]. OWA operatörü, min ve maks arasında bir sonuç sağlar. Yager'in OWA yöntemine dayanan doğruluk derecesi şöyledir (Eş. 2.42).

$$Y_Q(S) = \sum_{i=1}^M w_i b_i \quad (2.42)$$

Burada b_i , tip-1 bulanık küme olan S 'ye ait en büyük i . değerdir.

w_i de, $w_i = Q\left(\frac{i}{M}\right) - Q\left(\frac{i-1}{M}\right)$, $i \in \{1, 2, \dots, M\}$ ve $Q=0$ [64] şeklinde elde edilir.

ii. *Choquet İntegral tabanlı yöntem:*

b_i , tip-1 bulanık küme olan S 'ye ait en büyük i . değeri olmak üzere doğruluk derecesi Eş. 2.43'deki gibi hesaplanır [65].

$$C_Q(S) = \sum_{i=1}^M b_i x\left(Q\left(\frac{i}{M}\right) - Q\left(\frac{i-1}{M}\right)\right) \quad (2.43)$$

2.4.2. Tip-2 niceleyici cümle için skaler kardinalite tabanlı yöntemler

Tip-2 cümlesi için skaler kardinalite temelli Zadeh'in doğruluk derecesi hesaplama yöntemi, formül (Eş. 2.34) ve (Eş. 2.36)'da verilmiştir.

i. *Yager'in OWA yöntemi:*

Yager'in OWA yöntemine dayanan doğruluk derecesinde w_i 'ler ağırlıklardır. J_i , tip-1 bulanık küme olan S 'ye ait en büyük i . değerdir (Eş. 2.44) [66];

$$Y_Q\left(\left(S|w_Q(S_Q)\right)\right) = \sum_{i=1}^M w_i J_i \quad (2.44)$$

2.4.3. Tip-1 niceleyici cümle için bulanık kardinalite tabanlı yöntemler

i. *G metodu:*

E tipi bulanık kardinalite ve dilsel niceleyicilere göre hesaplanan doğruluk derecesi kesin niceleyiciler için (Eş. 2.45) [67, 68];

$$G_Q(S) = \bigoplus_{i \in \{0, \dots, M\}} (E(S, i) \otimes Q(i)) \quad (2.45)$$

ve göreceli niceleyiciler için şöyle hesaplanmıştır (Eş. 2.46);

$$G_Q(S) = \bigoplus_{i \in \{0, \dots, M\}} (E(S, i) \otimes Q\left(\frac{i}{M}\right)) \quad (2.46)$$

ii. *GD metodu:*

ED tipi bulanık kardinalite ve dilsel niceleyicilere göre hesaplanan doğruluk derecesi kesin niceleyiciler için (Eş. 2.47) [8, 67];

$$GD_Q(S) = \sum_{i=0}^M ED(S, i) \times Q(i) \quad (2.47)$$

ve göreceli niceleyiciler için şöyle hesaplanmıştır (Eş. 2.48);

$$GD_Q(S) = \sum_{i=0}^M ED(S, i) \times Q\left(\frac{i}{M}\right) \quad (2.48)$$

iii. *ZS metodu:*

Z tipi bulanık kardinalite ve dilsel niceleyicilere göre hesaplanan doğruluk derecesi kesin niceleyiciler için (Eş. 2.49) [8, 67];

$$ZS_Q(S) = \max_{i \in \{0, \dots, M\}} \min(Z(S, i), Q(i)) \quad (2.49)$$

ve göreceli niceleyiciler için şöyle hesaplanmıştır (Eş. 2.50);

$$ZS_Q(S) = \max_{i \in \{0, \dots, M\}} \min(Z(S, i), Q(\frac{i}{M})) \quad (2.50)$$

2.4.4. Tip-2 niceleyici cümle için bulanık kardinalite tabanlı yöntemler

i. *GD metodu:*

ER tipi bulanık kardinalite ve dilsel niceleyicilere göre hesaplanan doğruluk derecesi Eş. 2.51'de verilmiştir [8, 67];

$$GD_Q(S|w_g(S_g)) = \sum_{c \in CR(S|w_g(S_g))} ER(S|w_g(S_g), c) \cdot Q(c) \quad (2.51)$$

Burada $ER(S|w_g(S_g), c)$, S'nin göreceli bulanık kardinalitesidir ve şöyle tanımlanır (Eş. 2.52);

$$ER(S|w_g(S_g), c) = \sum_{c \in C(S|w_g(S_g), a_i)} (\alpha_i - \alpha_{i+1}) \quad \forall c \in CR(S|w_g(S_g)) \quad (2.52)$$

Burada c'yi hesaplamak için $C(S|w_g(S_g), a_i)$ ve $CR(S|w_g(S_g))$ 'nin tanımlanması gerekmektedir (Eş. 2.53-2.54);

$$C(S|w_g(S_g), a_i) = \frac{|S \cap w_g(S_g)_{a_i}|}{|w_g(S_g)_{a_i}|} \quad (2.53)$$

$$CR(S|w_g(S_g)) = \left\{ \frac{|S \cap w_g(S_g)_{a_i}|}{|w_g(S_g)_{a_i}|}, \quad a_i \in \Gamma(S|w_g(S_g)) \right\} \quad (2.54)$$

$\Gamma(S|w_g(S_g)) = \{a_1, a_2, \dots, a_m\}$, a seviyelerinin bir birleşimidir.

ii. *ZS metodu:*

ES tipi bulanık kardinalite ve dilsel niceleyicilere göre hesaplanan doğruluk derecesi (Eş. 2.55) [8, 67];

$$ZS_Q(S|w_g(S_g)) = \max_{c = CR(S|w_g(S_g))} \min(ES((S|w_g(S_g)), c), Q(c)) \quad (2.55)$$

Burada $ES(S|w_g(S_g), c)$, S'nin göreceli bulanık kardinalitesidir ve şöyle tanımlanır (Eş. 2.56);

$$ES(S|w_g(S_g), c) = \max \left\{ a \in \Gamma(S|w_g(S_g)) \mid c = \frac{|S \cap w_g(S_g)|}{|w_g(S_g)|} \right\} \quad (2.56)$$

2.4.5. Bulanık kardinalite tabanlı diğer yöntemler

i. Kısıtlama seviyesi temelli yöntem:

Bulanık kardinalite hesaplamaları genelde a kesmesi ile yapılırsa da bazı çalışmalarda [68] kısıtlama seviyesi kullanmıştır. Niceleyici ve kardinalite arasındaki uyumluluğu hesaplayan bir yöntemdir (Eş. 2.57-2.58) [67]. $\Lambda = \{a_1, a_2, \dots, a_m\}$, seviyelerin belirlendiği sonlu küme olsun ve $\rho: \Lambda \rightarrow \wp(Y)$, her kısıtlama seviyesini bu seviyedeki net bir gerçekleştirmeye eşleyen bir fonksiyondur. Kısıtlama seviyesi bir çift bileşenle $\{(a_1, \rho(a_1)), \dots, (a_n, \rho(a_n))\}$ sunulur [68].

$$RL_Q(S|w_g(S_g)) = \sum_{a_i \in \Lambda_S \cup \Lambda_{w_g(S_g)}} (\alpha_i - \alpha_{i+1}) x Q\left(\frac{|\rho_{S \wedge w_g(S_g)}(\alpha_i)|}{|\rho_{w_g(S_g)}(\alpha_i)|}\right) \quad (2.57)$$

$$\rho_{S \wedge w_g(S_g)}(\alpha_i) = \rho_{w_g(S_g)}(\alpha_i) \cap \rho_{w_g(S_g)}(\alpha_i) \quad (2.58)$$

S ve $w_g(S_g)$ tip 1 bulanık küme olduğunda, GD yönteminin genel bir durumudur [69].

ii. Kademeli sayı temelli yöntem:

X ve y iki kademeli doğal tam sayı olsun, herhangi bir atama işlemi (#) şu şekilde tanımlar, $a_{x \# y}(a) = a_x(a) \# a_y(a) = X_a \# Y_a, \forall a \in [0,1]$. Kademeli bir bağıl tamsayının α kesmesi

şu şekilde ifade edilir (x_a^+, x_a^-) . Kademeli bağıl tamsayı, α kesmelerinin birleşimiyle şu şekilde gösterilir; $x^c = \sum \frac{a_i}{(x_a^+ - x_a^-)}$. Kademeli rasyonel sayı, α kesmelerinin birleşimiyle şu şekilde gösterilebilir; $x^c = \sum \frac{a_i}{(x_a^p \div x_a^q)}$. P, tip-1 bulanık küme olan $S \cap W_g(S_g)$ 'nin kardinalitesi ve q, tip-1 bulanık küme olan $W_g(S_g)$ 'nin kardinalitesi olsun. Kademeli rasyonel sayı şöyle tanımlanır; $c(a) = |S \cap W_g(S_g)|_a / |W_g(S_g)|_a$. Tip-2 nicel bir cümle için aşamalı doğruluk derecesi (T_δ), $\mu_S(\alpha) = \mu_S(c(\alpha))$ olarak elde edilir. T_δ , dilsel niceleyiciye göre S ve $w_g(S_g)$ 'nin her α -kesmesinin doygunluğunu tanımlar. Aşağıdakiler kullanılarak skaler bir değer elde edilebilir (Eş. 2.59) [70]:

$$T_\delta = \int_0^1 (\mu_Q(a) x^p x^{p-1} da)^{\frac{1}{p}} \quad (2.59)$$

P, bulanık küme kardinalitesidir. Doğruluk derecesi tamamı şu şekilde ifade edilir (Eş. 2.60);

$$T_\delta = \sum_{a_i \in \Gamma(S|_{W_g(S_g)})} (\alpha_i - \alpha_{i+1}) x^p \mu_Q\left(\frac{|S \cap w_g(S_g)_{a_i}|}{|w_g(S_g)_{a_i}|}\right) \quad (2.60)$$

$w_g(S_g)$, normal bir tip-1 bulanık kümesi ise bu formül GD yöntemine çok benzer olur.

iii. Yarı bulanık niceleyici temelli yöntem:

Bulanık dilsel özetleme genelde iki formda bulunur; eğer-öyleyse ve niceleyici cümle formları. Niceleyici cümleler için ise kullanılan iki çeşit niceleyici vardır; mutlak ve göreceli niceleyicidir. Fakat “*üç öğrenci hariç hepsi uzun*” veya “*sarışın insanlara göre uzun insanlar 3 kişi daha fazla*” gibi cümleler mutlak ve göreceli niceleyiciler ile ifade edilemez. Klasik niceleyiciler yalnızca kesin argümanlarla ilgilenir; ancak, bulanık bir dilsel niceleyici, bulanık argümanları kabul eder ve doğruluk derecesi $[0,1]$ aralığındaki bir değere eşittir. Yarı bulanık niceleyici [71], klasik niceleyici ile bulanık niceleyici arasındaki orta noktadır. Yarı bulanık niceleyici, yalnızca klasik bir niceleyici olarak kesin argümanı kabul eder; ancak doğruluk derecesi, bulanık niceleyici olarak $[0,1]$ 'deki bir değere eşittir [72]. Bu nedenle, yarı bulanık niceleyici, niceleyici cümlelere dayalı olarak farklı türde özet formları oluşturmanın esnek bir yoludur.

Y dilsel evren olsun, $S_1, S_2, \dots, S_k \in \tilde{\mathcal{P}}(Y)$ dilsel özetler olsun, $\gamma \in [0,1]$ olsun. Her bir yarı bulanık niceleyici $Q: \mathcal{P}(Y)^K \rightarrow [0,1]$ için bulanık niceleyici $F^M(Q): \tilde{\mathcal{P}}(Y)^K \rightarrow [0,1]$ şu şekilde tanımlanır (Eş. 2.61) [73]:

$$F^M(Q)(S_1, S_2, \dots, S_k) = \int_0^1 Q_\gamma(S_1, S_2, \dots, S_k) d_\gamma \quad (2.61)$$

Birden fazla yarı bulanık niceleyici vardır, bunlardan birisi (“hariç hepsi”) şöyledir (Eş. 2.62) [73];

$$Q_{Y,1,all_exp_prop}^{FN}(S) = \left(\frac{|Y - S|}{|Y|} \right) \quad (2.62)$$

2.4.6. Tip-1 niceleyici cümle için kardinalite tabanlı olmayan yöntemler

i. Yagerin Non-OWA Yöntemi:

Kardinalite tabanlı olmayan ve tip-1 niceleyici özet yapısı için doğruluk derecesi şu şekilde hesaplanmaktadır [74]. Göreceli niceleyici için (Eş. 2.63);

$$Y'_Q(S) = \max_{C \subseteq Y} \otimes_1 \left(Q \left(\frac{|C|}{M} \right), \otimes_2 \mu_S(d_M) \right) \quad (2.63)$$

Burada $\otimes_1$ ve $\otimes_2$ iki farklı t-normdur ve C ise Y'nin bir alt kümesidir. Mutlak niceleyici için şöyle hesaplanır (Eş. 2.64);

$$Y'_Q(S) = \max_{C \subseteq Y} \otimes_1 \left(Q(|C|), \otimes_2 \mu_S(d_M) \right) \quad (2.64)$$

ii. Sugeno Integral Tabanlı Yöntem:

Kardinalite tabanlı olmayan ve tip-1 niceleyici özet yapısı için doğruluk derecesi şu şekilde hesaplanmaktadır [75]; Göreceli niceleyici için (Eş. 2.65);

$$S_Q(S) = \max_{1 \leq i \leq M} \min(Q\left(\frac{i}{M}\right), b_i) \quad (2.65)$$

Mutlak niceleyici için (Eş. 2.66);

$$S_Q(S) = \max_{1 \leq i \leq M} \min(Q(i), b_i) \quad (2.66)$$

b_i , tip-1 bulanık kümeye ait en büyük i . değerdir.

2.4.7. Tip-2 niceleyici cümle için kardinalite tabanlı olmayan yöntemler

i. *Vila ve ark. Yöntemi*:

Vila ve diğerleri (2001) [76] tarafından önerilen yöntem, doğruluk derecesini, Yager tarafından önerilen “orness” derecesini kullanarak $Q = \exists$ ve $Q = \forall$ iki uç durumun dışbükey bir kombinasyonu olarak hesaplar (Eş. 2.67) [77].

$$V_Q(S|w_g(S_g)) = (1 - Q_0)T_\forall + Q_0T_\exists \quad (2.67)$$

Burada, $T_\exists$, $T_\forall$ ve Q_0 Eş. 2.68-2.70'deki gibi tanımlanır.

$$T_\exists = \bigotimes_{v_k^m \in Y} \left(\bigotimes_{k=1}^K \mu_{S_K}(v_k^m) \otimes \mu_{w_g(S_g)}(v_k^m) \right) \quad (2.68)$$

$$T_\forall = \bigotimes_{v_k^m \in Y} \left(\bigotimes_{k=1}^K \mu_{S_K}(v_k^m) \otimes (1 - \mu_{w_g(S_g)}(v_k^m)) \right) \quad (2.69)$$

$$Q_0 = \sum_{i=1}^M \left(\frac{M-i}{M-1} \right) x \left(Q\left(\frac{i}{M}\right) - Q\left(\frac{i-1}{M}\right) \right) \quad (2.70)$$

ii. *Kütle Atama Temelli Yöntemi*:

Eğer-öyleyse kural tabanlı protoformların doğruluk derecelerini ölçmek için de kullanılan bu yöntem, kardinalite tabanlı olmayan ve tip-1 bulanık temelli niceleyici kullanan tip-2 niceleyici özetin doğruluk derecesi şu şekilde hesaplanmaktadır (Eş. 2.71-2.73) [78, 79];

$$T_m(\mathfrak{M}) = \frac{\sum_{i,j} m_{i,j} x \left| w_g(S_g)_i \cap S_j \right|}{\sum_{i=1}^{I_{w_g(S_g)}} \left(\sum_j m_{ij} x \left| w_g(S_g)_i \right| \right)} \quad (2.71)$$

$$\sum_{j=1}^{I_s} m_{ij} = m_{w_g(S_g)}(w_g(S_g)_i) \quad (2.72)$$

$$\sum_{i=1}^{I_{w_g(S_g)}} m_{ij} = m_s(S_j) \quad (2.73)$$

Burada i , $w_g(S_g)$ için satırı; j , S_j için sütunu temsil etmektedir.

iii. Küme Merkezli Fonksiyonel Yöntem:

Bu metot, niceleyici cümleleri değerlendirmek amacıyla Lietard (2012) tarafından önerilmiştir [80]. $S_1 \times S_2 \times \dots \times S_K$, tip-1 bulanık kümelerin kartezyen çarpımı olsun. Küme merkezli bir fonksiyon olan F_n , tip-1 bulanık kümelerin kartezyen çarpımında Eş. 2.74'deki gibi tanımlanır:

$$F_n(S_1 \times S_2 \times \dots \times S_K) = \max_{\alpha \in [0,1]} \min(F_n((S_1)_\alpha \times (S_1)_\alpha \times \dots \times (S_K)_\alpha)) \quad (2.74)$$

α , sonsuz sayıda değer aldığı için hesaplama açısından sınırlandırılması gerekir. Fonksiyon yeniden düzenlendiğinde Eş. 2.75'deki gibi olur [81];

$$T_\omega = F_n(S_1 \times S_2 \times \dots \times S_K) = \max_{\alpha \in [0,1]} \min(\alpha, F_n((S_1)_\alpha \times (S_1)_\alpha \times \dots \times (S_K)_\alpha)) \quad (2.75)$$

Burada α , değerlerini $\mathbb{D} = \{\min(\mu_{S_1}(v_1^m), \mu_{S_2}(v_2^m), \dots, \min(\mu_{S_K}(v_K^m))) \mid m = 1, 2, \dots, M\}$ kümesinden almaktadır.

F_n fonksiyonu, $Y_m \in ((S_1)_\alpha \times (S_1)_\alpha \times \dots \times (S_K)_\alpha)$, $\alpha \in \mathbb{D}$ için Eş. 2.76'deki gibi tanımlanmıştır;

$$Fn((S_1)_\alpha \times (S_1)_\alpha \times \dots \times (S_K)_\alpha) = \frac{|\sum_{m=1}^M Y_m|}{|Y|} \quad (2.76)$$

2.4.8. Kalite göstergeleri

Kalite ölçüm göstergeleri, yapılan bir özetin farklı açılardan kalitesini göstermek için kullanılmıştır. Bir özetin doğruluk derecesine bakılması, özetin kalitesini tek başına gösteremeyebilir. Mesela verinin sadece çok az bir kısmıyla ilgili olan bir özet, genelini kapsamadığı için veriyi anlamlı ve doğru bir şekilde yansıtmaz veya yapacağınız bir özetin doğruluk derecesi [1.0] olduğu halde kullanıcıyı ilgilendirmiyor ise bu özet çok fazla bir anlam ifade etmez. Bunun için bir özetin kalitesini ölçmek için sadece doğruluk derecesini kullanmak yetmez, diğer göstergelerin de kullanılması gerekmektedir. Literatürde toplamda çalışılmış 21 kalite göstergesi görülmektedir. Bu göstergelerden bazıları benzer şeyleri ölçse de çok küçük de olsa farkları vardır.

a) Miktar:

Özetin, gerektiği kadar bilgilendirici ancak gereğinden fazla bilgilendirici olmadığını ölçen göstergedir [82]. Bu kalite göstergesini doğrudan bir formülle hesaplayan herhangi bir çalışma literatürde yoktur. Sadece bir kaç farklı göstergenin yorumlanmasıyla anlaşılabilir bir kalite göstergesidir [83]. Bu göstergeler; özgüllük, bulanıklık, bilgi düzeyi ve uygunluk göstergeleridir.

b) Kalite:

Bu gösterge, özetin doğruluk derecesiyle aynıdır [84].

c) İlişki:

Dilsel açıklamanın, nihai hedeflerine uyma anlamında hedef kullanıcı ile ilgili olması gerektiğine işaret eder. Verilerle tam olarak eşleşen ve anlaşılabilir olan açıklamalar, verilerin ilgi ve ihtiyaçlarının dışında kalan yönlerini açıklıyorsa, kullanıcı için uygun olmayabilir. Ayrıca açıklamalar, kullanıcının ilgisini çekmeyen bir karar probleminde, karar vermede faydalı olması açısından çok bilgilendirici olabilir. Metinsel özetler oluşturan

sistemler, belirli kullanıcıların belirli ilgi alanları ve görevleri ile ilgili modeller tarafından kontrol edilmelidir [85].

d) Netlik:

Bu kalite göstergesinin temeli, özeti uzatmadan, sade ve belirli olma fikrine dayalıdır. Düzenli, kısa ve belirsizlikten uzak bir özet amaçlanmaktadır [86, 87].

e) Bilgilendirme:

Özetin içerdiği bilgi miktarını göstermektedir. Yager (1992) [88] çalışmasında Eş. 2.77'de gösterildiği gibi hesaplamıştır. Burada P^c , P'nin; Q^c , Q'nun olumsuzudur. $S_p(Q)$, Q'nun özgüllüğüdür.

$$I(y's Q P) = (T. S_p(Q). S_p(P)) \vee ((1 - T). S_p(Q^c). S_p(P^c)) \quad (2.77)$$

f) Granül seviyesi:

Özetin ne kadar detaya indiğini gösterir. Özetin detaylı veya yüzeysel olduğunu tanımlayan göstergedir [89].

g) Genellik:

Makul miktarda verinin özeti desteklemesi esastır. Bu özellik iki açıdan değerlendirilmelidir. İlk olarak, bir veri seti küçük ve temsili olmayan bir örneklem ise, verilerin %99'u özeti karşılasa bile sonuç temsili değildir. İkincisi, eğer veri seti yeterince büyükse (Örn. bir örneklem yerine, tüm ilgili nüfus analiz edilir), o zaman yüksek geçerlilik, sadece birkaç değişken grubu (Örn. 2 000'lik 2 değişken grubu) tamamen (veya kısmen) olduğu durumlarda yanıltıcı olabilir. İkincisi ile ilgili olarak, genellik kapsam olarak ifade edilir [85]. Genellik göstergesini hesaplamak için önce kapsama oranı hesaplanmaktadır (Eş. 2.78-2.79) [81].

$$r_c = \left(\frac{\sum_{m=1}^M t_m}{M} \right) \quad (2.78)$$

$$t_m = \begin{cases} 1, & \mu_{S_1}(v_1^m) > 0 \text{ ve } \mu_{S_2}(v_2^m) > 0 \\ 0, & \text{diğer} \end{cases} \quad (2.79)$$

Her kural, yüksek boyutlu girdi-çıkı uzayının yalnızca küçük bir bölgesini kapsadığından, r_c genellikle çok küçüktür (örneğin, çoğunlukla 0.1'den küçüktür). Bu nedenle, $r_c = 0.15$ yeterli kapsam olarak kabul edilebilir. Eş. 2.80'deki parçalı fonksiyon, kapsam oranını genellik derecesine dönüştürür [85];

$$C = f(r_c) = \begin{cases} 0, & r_c \leq r_1 \\ 2 \left(\frac{r_c - r_1}{r_2 - r_1} \right)^2, & r_1 < r_c < \frac{r_1 + r_2}{2} \\ 1 - 2 \left(\frac{r_2 - r_c}{r_2 - r_1} \right)^2, & \frac{r_1 + r_2}{2} \leq r_c < r_2 \\ 1, & r_c \geq r_2 \end{cases} \quad (2.80)$$

Wu ve Mendel [51] çalışmalarında $r_1 = 0.02$ ve $r_2 = 0.15$ olarak almıştır.

h) Kapsam:

Özetin veritabanının ne kadarını kapsadığını göstermek için kullanılan ölçümdür. “ $Q \ X \ A' \text{dir}$ ” cümlesi için kapsamı Lietard [80] şöyle hesaplamıştır (Eş. 2.81).

$$\text{cov}(A, X)(Q \ X \ A' \text{dir}) = \frac{\text{card}(\text{destek}(XA))}{\text{card}(X)} \quad (2.81)$$

Burada XA , bulanık A yüklemine sağlayan X 'ten gelen öğelerden oluşan kümedir.

i) Odaklanma:

Kapsam ölçümüne benzetmektedir. Fakat kapsamda tüm detaya bakılırken, odaklanma ölçümünde sadece R özelliğinin ne kadarını kapsadığı ölçülmektedir (Eş. 2.82) [51].

$$d_{sf}(R \text{ olan tüm } Y \text{ nesneleri içinde } Q \text{ P'dir}) = \frac{1}{n} \sum_{i=1}^n \mu_R(y_i) \quad (2.82)$$

Odak derecesi, belirli bir zaman serisinden elde edilen kaç trendin, çıkarılan tüm trendlere kıyasla R niteleyicisini sağladığını tanımlar. Odaklanma derecesi yüksekse, böyle bir özetin birçok trendi ilgilendirdiğinden emin olabiliriz, böylece daha genel olur. Ancak, odaklanma derecesi düşükse, böyle bir özetin nadiren meydana gelen (yerel) bir modeli tanımladığından emin olabiliriz [80].

j) Kısalık:

Bu gösterge, özetin ne kadar kısa olduğunu gösterir [86]. $len(s)$, s özetini oluşturan nicelleştirilmiş cümlelerin sayısı olursa kısalık Eş. 2.83'deki gibi hesaplanır;

$$b(s) = 1/len(s) \quad (2.83)$$

k) Özgüllük:

Özetteki kavramların verileri ne ölçüde açıkça tanımladığıdır. Konuyu anlatımındaki berraklık ve veriyi ne kadar açık tanımladığıdır (Eş. 2.84) [86].

$$Sp(A) = \int_0^{a_{max}} \frac{1}{card(A_\alpha)} d\alpha \quad (2.84)$$

a_{max} 'ın A 'daki en büyük üyelik derecesi olduğu yerde, A_α , A 'nın α -düzey kümesidir. Literatürde bu gösterge hakkında yapılmış farklı hesaplamalar da vardır [81].

l) Fayda:

Bu özellik, özetin ne kadar yararlı olduğunu ifade eder [85]. v , doğruluğu ve C , genellik ölçüsündeki kapsamı gösterir ise bir cümlemin fayda değeri şöyle hesaplanır (Eş. 2.85);

$$U = \min(v, C) \quad (2.85)$$

m) Sadelik:

Bu ölçü, anlamsal karmaşıklıkla ilgilidir. Özetin sadeliği, kısıtlama ve özetleyici bölümlerinde kaç özniteliğin olduğunu ifade eder. Kural temelleri açısından bu ölçü, kuralın öncül ve sonuç bölümlerinde kaç tane özniteliğin olduğunu ifade eder. Sadelik Eş. 2.86'daki gibi hesaplanır [85]. Burada t , öncüllerin ve sonuçların toplam sayısıdır.

$$S_{im} = 2^{(2-t)} \quad (2.86)$$

n) Bulanıklık:

Lietard (2012), " $Q X A'dır$ " cümlesi için bulanıklığı Eş. 2.87'deki gibi hesaplamıştır [85];

$$\text{cov}(A, X)(Q X A'dır) = 1 - \frac{\text{card}(\text{destek}(A))}{\text{card}(\text{Uzay}(X))} \quad (2.87)$$

o) Uygunluk:

Temel olarak, uygunluk derecesi fikri şöyledir; Çalışanlarla ilgili bir veri tabanımız olduğunu varsayalım. %50'si 25 yaşın altında ve %50'si yüksek nitelikli ise, çalışanların %25'inin 25 yaşından küçük ve yüksek nitelikli olmasını bekleyebiliriz; bu tamamen beklenen bir duruma karşılık gelir. Ancak, uygunluk derecesi örneğin 0.39 ise (yani %39'u 25 yaşından küçük ve yüksek niteliklidir), o zaman bulunan özet, verilerimizde tam olarak beklenmeyen ilginç bir ilişkiyi yansıtmaktadır. Bu gösterge, bulunan özeti belirli bir veritabanı için ne kadar karakteristik olduğunu açıklar. Uygunluk göstergesinin çok önemli olduğuna dikkat edilmeli, çünkü örneğin, "satışın %100'ü herhangi bir maldandır" gibi önemsiz bir özet, geleneksel doğruluk derecesini kullanırsak tam geçerliliğe sahiptir, ancak uygunluk derecesi 0'a eşit olabilir [85]. Bu gösterge şu formülle hesaplanmaktadır (Eş. 2.88) [80];

$$d_a = \left| \prod_{i=1}^m \frac{\text{card}\{y: \mu_{A_i}(y) > 0\}}{n} - \frac{\text{card}\{y: \forall A_i \mu_{A_i}(y) > 0\}}{n} \right| \quad (2.88)$$

("Tüm R segmentlerinin içerisinde $Q P'dir$ " cümlesi için) A_i , özetleyici P 'ye karşılık gelen bir yüklemidir veya ek olarak genişletilmiş özet niteleyicisi R durumundadır. Bu ölçü, yalnızca bir yüklem içeren basit form özetinde 0'a eşittir [11].

p) Benzerlik:

Bu gösterge, 2 cümle arasındaki benzerliği hesaplar. Literatürde birden fazla benzerlik göstergesi vardır. En yaygın kullanılanı Jaccard benzerliğidir (Eş. 2.89) [90];

$$\text{sim}(A, B) = \left(\frac{\int_0^1 \mu_A(x) \wedge \mu_B(x) dx}{\int_0^1 \mu_A(x) \vee \mu_B(x) dx} \right) \quad (2.89)$$

Burada $\mu_A(x)$, A'nın üyelik fonksiyonudur ve $\mu_B(x)$, B'nin üyelik fonksiyonudur, $\wedge$ minimum ve $\vee$ maksimumdur.

q) Farklılık:

Farklılık ölçümü, veri alt grupları arasındaki özet cümlelerin farklılığını gösterir. Örn. “Q B1 Y'ler A'dır, Q B2 Y'ler değildir” şeklinde ifade edilen bu durum, tıbbi bir uygulamada: “Erkek hastalarda düşük kalp atış hızına sahip birkaç gözlem varken; kadın hastalarda durum böyle değildir” gibi bir cümle ile gösterilebilir [91].

r) Güvenilirlik:

Özetin ne kadar güvenilir olduğunu ölçen göstergedir. T'nin doğruluk derecesi, C'nin kapsam olduğu varsayılır ise güvenilirlik şöyle hesaplanır (Eş. 2.90) [51];

$$R = \min(T, C) \quad (2.90)$$

s) Tereddüt:

Bir öznitelik A ve bir veri kümesi $D = \{r_1, \dots, r_n\}$ olmak üzere, A'nın D'deki değeri hakkındaki tereddüt şu şekilde ifade edilmektedir (Eş. 2.91) [92];

$$h_A^D = \frac{\text{card}(\{r | r \in D \wedge A[r] = \perp\})}{n} \quad (2.91)$$

Tereddüt, A için boş değere sahip D kayıtlarının oranı olarak kabul edilir.

t) Yenilik:

Verilerdeki aykırılığı özetleyen cümlelerin, diğer özetlere göre ne kadar yeni, aykırı ve farklı olduğunu ölçmek için kullanılır. v , özetin doğruluğunu ve C , özetin kapsamını belirtir ise bu gösterge şöyle hesaplanmaktadır (Eş. 2.92) [51].

$$O = \begin{cases} \min(\max(v, 1 - v), 1 - C), & v > 0 \\ 0, & v = 0 \end{cases} \quad (2.92)$$


u) Aykırılık:

Özetin ne kadar aykırı verileri yansıttığını gösteren ölçümdür. Yenilik göstergesiyle aynıdır [92].

2.5. Zaman Serilerinde Dilsel Özetleme

Bir zaman serisi, her biri belirli bir t anında kaydedilen bir gözlemler kümesidir ($X = x_1, x_2, \dots, x_t$). İki tip zaman serisi vardır; birincisi, ayrık zaman serisi: sabit zaman aralığında yapılan gözlemlerden oluşan kümedir. Diğeri ise sürekli zaman serileri: gözlemler belirli bir zaman aralığında sürekli olarak kaydedildiğinde elde edilir.


Zaman serilerinde dilsel özetleme yapılabilmesi için verilerin işlenmesi gerekmektedir ve literatürde geliştirilen bazı yöntemler vardır. Bu işlemlerden en önemlisi, serinin trendlere ayrılmasıdır (trend segmentasyon). Trend segmentasyon, zaman serisindeki tek karakterli veriyi, farklı karakter ve parametrelere çeviren işlemidir. Örneğin doların zamansal değer grafiği tek parametrelidir. Segmentasyon uygulandığı zaman, verinin dinamikliği, değişkenliği ve bunların süreleri hakkında bilgi verecek 3 farklı parametreye çevrilir. Buradaki amaç, veriyi kullanıcının isteğine ve anlayışına uygun hale getirmektir. Bu uygulama ilk defa 2006 yılında Kacprzyk, Wilbik ve Zadrozny tarafından geliştirilmiştir [14, 51, 85, 93-95]. Şekil 2.13’de trendlerine ayrılmış örnek bir zaman serisi gösterilmektedir. Siyah çizgiler, zaman serisini; kırmızı kesik çizgiler ise trendleri ifade etmektedir.



Şekil 2.13. Trendlerine ayrılmış bir zaman serisi

Literatürde trend segmentasyonu için önerilen bir çok çalışma vardır. Bunlardan en önemlileri: Kacprzyk ve ark.'nın [93, 96, 97]. çalışmalarında kullandığı sklansky ve gonzales algoritması [97]. parçalı-doğrusal fonksiyon yaklaşımı [14, 96, 98-101]. iteratif-end point fit algoritması [16, 102, 103]. f-transform [104]. temporal fuzzy model (TFM) [52, 105, 106].

Zaman serilerinde yerel trendler bulunduğundan sonra, trendlerin üç özelliği dikkate alınarak özetleme işlemi yapılır. Bunlar; dinamiklik, süre ve değişkenliktir. Dinamiklik, trendin değişim hızıyla ilgilidir. Trendi gösteren doğrunun x eksenine yaptığı açının eğimiyle ifade edilir. Açı değeri $\eta(-90^\circ, 90^\circ)$ arasında değişmektedir. Bu değer dilsel özetleme işleminde doğrudan kullanımı oldukça zordur. Bu nedenle trendin değişimi dilsel olarak ifade edilir. Trendlerin diğer özelliği, değişkenliktir. Yerel trendler ile zaman serisinin değerleri arasındaki farklılık ölçülerek δ' değerinin ortalaması bulunur. Böylece verilerin değişkenliği dilsel olarak özetlenebilmektedir. Diğer bir trend özelliği ise trendin süresidir. Bu ise, kısa, orta ve uzun etiketleriyle özetlenebilmektedir. Şekil 2.14'de trend segmentasyonu ve trend özelliklerinin bulanık kümeler ile dilsel etiketlere çevrildiği şematize edilmiştir [107, 108].



Şekil 2.14. Trend segmentasyonu ve trendlerin özellikleri (dinamiklik, süre, değişkenlik)

Her trend için bu üç özellik çıkarıldıktan sonra, her özellik etiketlere göre bulanık kümeye çevrilir (Çizelge 2.2). Bu etiketler üçlü, beşli, yedili veya dokuzlu olabilir. Trendlerin özellikleri bulanık küme olarak ifade edildikten sonra bu özellikler hakkında özetleme yapılabilir. Özet yapısı olarak protoformlar kısmında bahsedilen temel tip-1, tip-2 niceleyici cümleler veya diğer gelişmiş protoform yapıları kullanılabilir.

Çizelge 2.2. Trendlerdeki üç özelliğin dilsel etikete dönüşümü (Süre={kısa, orta, uzun}, Dinamiklik={azalan, sabit, artan}, Değişkenlik={düşük, orta, yüksek})

Trend	Süre	μ_K	μ_O	μ_U	Dinamiklik	μ_{Az}	μ_S	μ_{Ar}	Değişkenlik	μ_D	μ_O	μ_Y
1	3	0	0,1	0,9	5,26	0	0	1	4,4	0	0	1
2	5	0	0	1	-4,13	1	0	0	3,7	0	0,3	0,7
3	4	0	0,2	0,8	2,47	0	0,9	0,1	2,1	0,1	0,9	0
4	1	1	0	0	0,65	0	1	0	1,55	0,3	0,7	0
5	3	0	0,1	0,9	-3,01	0,9	0,1	0	0,56	1	0	0

3. NÖROPAZARLAMA

Nöropazarlama, nörobilimi kullanılarak tüketici davranışının bilişsel ve duyuşsal yönlerini birbirine bağlayan ve 2002’de başlayıp hızla gelişmekte olan bir alandır. Nöropazarlama stratejileri, reklamcılık ve pazarlama uzmanları arasında da güvenilir bir metot olarak yerini almıştır [22, 109]. Nöropazarlama, tüketicilerin beyinlerinin farklı reklamları nasıl değerlendirdiğini anlamada ve ürünleri satın alırken seçimlerini etkileyen faktörleri tanımlamada yardımcı olabilir. Nöropazarlama araştırması, insanların beyinlerinde neler olduğunun her zaman fark edilmediğini göstermiştir. Ayrıca, insanların tercihlerinde veya niyetlerinde her zaman açık sözlü olmadıkları kanıtlanmıştır [110]. Firma sahipleri reklamlar için her yıl toplamda yaklaşık 400 milyar dolar yatırım yapmaktadır [111], bu nedenle reklamlardaki harcamaların doğru ve verimli şekilde harcanması gereklidir. Bu ise müşteriyi daha iyi tanımakla ve bilinçaltında neler hissettiğini anlamaktan geçer. Tam bu sebepten dolayıdır ki nöropazarlama, pazarlama alanında yerini almıştır. Nöropazarlama, tüketici tercihlerini ve kararlarını etkileyen tüketici grupları içinde ve arasında heterojenlik probleminin üstesinden gelebilmektedir. Bu heterojenlik yaşa, cinsiyete, hormonlar ve genler gibi çeşitli biyolojik faktörlere ve çeşitli fizyolojik faktörlere dayanabilir [112].

Tüketici tercihlerini, ihtiyaçlarını ve satın alma niyetlerini değerlendirmek için görüşmeler ve anketler gibi geleneksel pazarlama araçlarının kullanılması, yanıltıcı veya yanlış sonuçların üretilmesine yol açabilir [113, 114]. Benzer şekilde, tercihlerin sözlü ifadesi bilinçli veya bilinçsiz önyargılar üretebilir. Tüketicilerin ürünü alma konusunda gerçek fikir, duygu ve hislerini geleneksel pazarlama teknikleri açığa çıkaramayabilir [115]. Nöropazarlama ise tüketici davranışını anlayabilmek için daha etkili yöntemler önerir. Son zamanlarda geliştirilen beyin görüntüleme yöntemleri, tüketici davranışlarını incelemek için etkili bir yaklaşım sağlar. Bu tür yöntemler, başarılı veya başarısız reklamların altında yatan bilinçaltı prosedürler hakkında anlamlı bilgiler elde etmek için tüketicilerin beyinlerini incelemelerine yardımcı olur. Bu bilgi, geleneksel pazarlama araştırmalarında en önemli problem olan insanlara güvenmeye ihtiyaç duymadan elde edilir [116].


Duygular, insan iletişiminde, etkileşiminde ve çevresinde gördüğü veya duyduğu şeylere olan tepkisini anlamada temel olmasına rağmen, duygu tanıma için otomatik sistemler, hala tam ulaşılamamış bir hedeftir [117]. Mevcut ve giderek daha fazla kullanılan insan-makine

ara yüzlerinde duyguların otomatik olarak tanınması için yeni algoritmaların geliştirilmesi ve uygulanması çok önemli hale gelmektedir. Bu şekilde, insanlarla makineler arasındaki etkileşimi geliştirmek ve insanileştirmek mümkün olacaktır [118].

3.1. EEG

Beyin-bilgisayar ara yüzleri (BBA'lar), duyguların tespit edilmesi açısından nöropazarlamada umut verici beyin görüntüleme araçlarıdır. Bu teknoloji, kullanıcıların bilgisayar sistemleriyle etkin bir şekilde iletişim kurmasını sağlar. Bir BBA, komutları üretmek için herhangi bir harici cihazın kullanımını veya kas müdahalesini gerektirmez [116]. Ayrıca, bir BBA, bir sistemi sinyaller aracılığıyla kontrol etmek için katılımcı olan kişinin beyin aktivitesini kullanır, bu da yakın çevre ile iletişim kurma veya etkileşim kurma yeteneğiyle sağlanır. EEG, beyin aktivitesini incelemek için kullanılan ana araçlardan biridir [117]. EEG sinyal ölçümü, müşterinin hem bilinçsiz tepkisini hem de duyuşsal tepkisini anlamak için kayda değer bir gecikme olmaksızın beyin aktivitesinin sıralı değişimini tespit eden [118], gerçek zamanlı analizini gerçekleştiren, pratik, çok yönlü, uygun fiyatlı, taşınabilir, damar yoluna ihtiyaç duyulmayan BBA'dır [27, 110, 118].

EEG sinyalleri, beyin korteksindeki nöronların sinaptik bağlantılarından türetilen elektriksel aktiviteyi temsil eder. Kafatasının ve onları önemli ölçüde azaltan diğer dokuların altında elektrik sinyalleri üretilmesine rağmen, çoğu bu katmanları delege kadar güçlüdür ve kafa derisinde 10 ila 100 mV arasında genlikler sunar [119]. Bu nedenle, bu elektriksel darbeler, doğrudan kafa derisine yerleştirilen elektrotlar aracılığıyla bozulmadan ölçülür. Hastaların kafa boyutlarına göre EEG kanallarının yerlerini belirleyen bazı standart elektrot konumlandırma sistemleri mevcuttur (Şekil 3.1). Bu gerçek, deneylerin tekrarlanabilirliğini ve farklı deneklerden elde edilen sonuçların karşılaştırılmasını garanti eder. En yaygın olarak kullanılan düzenleme, 128 elektrotu kadar yer alan uluslararası standart 10-20 sistemidir [120]. İsimlendirme açısından, her kanal bir harf ve bir sayı ile temsil edilir. Harfler, elektrotun bulunduğu beyin lobunu gösterir: Fp (frontopolar), F (frontal), C (merkezi), T (temporal), P (parietal) ve O (oksipital). İki alan arasındaki elektrotlar, karşılık gelen iki harfle temsil edilir. Öte yandan sayılar, bir elektrotun bulunduğu beyin yarım küresini temsil eder, sağ yarım küre için kullanılan çift sayılar ve sol için tek sayılardır [121].



Şekil 3.1. EEG elektrot yerleşimi [121]

EEG spektrumu 0,5 ile 45 Hz aralığındadır ve farklı frekans bantlarına bölünmüştür (Çizelge 3.1) [116]. 0,5 ile 4 Hz arasında değişen delta (δ) bandı derin uyku ile ilgilidir. 4 ile 7,5 Hz arasında değişen teta (θ) dalgaları meditasyon ve hafif uyku evrelerinde ortaya çıkar. 8 ile 13 Hz arasında giden alfa (α) bandı, bilinçli deneklerin gevşemiş hallerinde ortaya çıkar. Aksine, 14 ila 26 Hz arasında değişen beta (β) dalgaları, denek aktif olarak düşünürken veya karmaşık problemleri çözerken ortaya çıkar. Son olarak, 30 ile 45 Hz arasında değişen gama (γ) bandı dikkat, biliş ve öğrenme süreçleri ile ilgilidir [121-123].

Çizelge 3.1. EEG sinyalinin frekansa göre sınıflandırılması [121]

Ritim	Frekans (Hz)	Beynin durumu	Farkındalık
Delta (δ)	0,5-4 Hz	Derin uyku düzeni	Daha düşük
Teta (θ)	4-7,5 Hz	Hafif uyku düzeni	Düşük
Alpha (α)	8-13 Hz	Gözleri kapatma, rahatlama durumu	Orta
Beta (β)	14-26 Hz	Aktif düşünme, odaklanma, yüksek uyarı, endişeli	Yüksek
Gamma (γ)	30-45 Hz	Algı ve bilinç dâhil olmak üzere daha yüksek zihinsel aktivite	Daha yüksek




4. LİTERATÜR ARAŞTIRMASI

“Zaman serilerinde dilsel özetleme” konusu hakkında literatür taraması, 1980-2023 yılları için Scopus’da yapılmıştır. Çalışma ilk önce 2 farklı anahtar kelime setine göre yapılmıştır. Bulunan çalışmalarda, ortak kullanılan diğer anahtar kelimeler (3. anahtar kelime seti) tespit edilmiş ve tekrar arama yapılmıştır. 4. anahtar kelime seti ise diğerlerinden farklı olarak taranmıştır. Tüm bu aramalar neticesinde, konu hakkında en çok çalışma yapan yazarların tüm çalışmaları incelenmiş ve konuyla alakalı çalışmaları (önceden indirilenlerden farklı olanlar) eklenmiştir.

Literatür taraması sonucunda, 2616 adet makale gözden geçirilmiş ve (filtrelemeler yapıldığında) konuyla alakalı toplamda 285 makale elde edilmiştir. Bu filtreler şöyledir; çalışmanın başlığı, özet ve detay. Okunan her çalışmanın sonunda atıf yaptıkları referanslar gözden geçirilerek, 36 ilgili çalışma eklenmiştir. Bu literatür çalışması esnasında, Scopus’da yayınlanan 13 güncel çalışma da eklenerek 304 çalışma ile sonlandırılmıştır. Literatür çalışmasının genel akışı Şekil 4.1’dir.

Bu tez çalışmasında, zaman serilerinde dilsel özetleme yapılacağı için sadece zaman serilerindeki dilsel özetleme çalışmaları incelenecektir. Zaman serilerinde ilk dilsel özetleme çalışması, Kacprzyk ve ark. tarafından 2006 yılında yapılmıştır [124]. Bu çalışmada Sklansky ve Gonzales segmentasyon yöntemi kullanılarak zaman serisi trendlere ayrılmıştır [125, 126]. Elde edilen 3 özellik, Yager’in geliştirdiği tip-1 ve tip-2 niceleyici özet yapıları [39] ile özetlenmiştir. Bu çalışmadan sonra hem tek değişkenli hem de çok değişkenli zaman serilerinde dilsel özetleme çalışması artmıştır.

Literatürdeki çalışmalar, tek değişkenli ve çok değişkenli zaman serilerinde dilsel özetleme olarak ikiye ayrılır. Bu iki farklı sınıf ise segmentasyon yapıları ile protoform yapıları, doğruluk dereceleri, değerlendirme ölçütleri ve uygulama alanlarına göre incelenecektir.



Şekil 4.1. Literatür çalışmasının genel akışı

4.1. Tek Değişkenli Zaman Serilerinde Segmentasyon Temelli Yöntemler

2006 yılında yapılan ilk çalışma Kacprzyk ve diğerleri [124]. ile başlamıştır. Bu çalışmada zaman serilerindeki trendler, Sklansky ve Gonzalez algoritması ile bulunmuştur. Segmentasyon için bu yöntemi ve özetleyici olarak tip-1 ve tip-2 niceleyici protoform yapıları [14, 21, 39, 87, 93-97, 108, 124-139]. ve bu protoformların genişletilmiş hali [47, 86, 89, 140-147]. farklı veriler için kullanılmıştır. Bu çalışmaların çoğu Kacprzyk ve diğerlerine aittir. Bu çalışmalarda farklı olan, uygulama alanı veya doğruluk derecesi hesaplama yöntemleridir. Doğruluk derecesi, genelde skaler kardinalite tabanlı yaklaşımlarla hesaplanmıştır.

Segmentasyon için kullanılan bir diğer yaygın metot ise F-transform yöntemidir. İlk kez Novak ve Perfilieva tarafından 2006 yılında kullanılmıştır [52]. F-transform, bulanık küme ve eğer-öyleyse kural tabanlı geliştirilmiş bir metottur. Bundan dolayı, bu metodun kullanıldığı çalışmaların çoğunda dilsel özetleme için eğer-öyleyse yapısı kullanılmıştır [18, 52, 148-160]. Fakat sadece Novak'ın iki çalışmasında Tectogramatical tree yapısı [161-163]. birinde Syntactic structure [59] ve bir tanesinde de dilsel etiketler [58]. özetleyici cümle yapısı olarak kullanılmıştır. Bu özetlerin doğruluk dereceleri özel bir formülle hesaplanır. Bu hesaplamada, tip-1 bulanık küme temelli kosinüs bulanık bölümlleme üyelik fonksiyonu ve Lukasiewicz operatörü kullanılmıştır.

Yaygın olarak kullanılan bir diğer yöntem ise, doğrusal parçalı fonksiyon yaklaşımı metodudur. Bu metodun farklı yapıları vardır; sliding window, bottom-up ve top down algoritmalarıdır. Bu metotlarla segmentasyon yapılan çalışmalarda, tip-1 ve tip-2 protoform yapıları [61, 99-101, 164]. ve özel protoform yapıları [102]. kullanılmıştır.

Moreno-Garcia ve diğerlerinin yaptıkları iki çalışmada petri ağlarını, hem trend segmentasyon için hem de protoform yapısı için kullanmışlardır [103, 165]. Jain (2019) yılında [43]. ve Ros (2011) yılında [166]. tek değişkenli zaman serilerinde trend segmentasyon için lineer regresyon yöntemini kullanmıştır. Özetleme için özel protoform yapıları kullanılmıştır. Castillo-Ortega [16]. ve Martinez-Cruz [105]. trend segmentasyon için Iteratif End-Point Fit algoritmasını kullanmıştır. Castillo-Ortega, tip-1 niceleyici protoform yapısını özetleme için kullanırken, Martinez-Cruz, özel bir protoform yapısı tercih etmiştir.

Tek değişkenli zaman serilerinde yapılan diğer segmentasyon işlemleri ise şöyledir; Harguess ve diğerlerinin [167]. Lemire's algoritmasını, Kobayashi ve diğerlerinin [168]. zaman serisini eşit aralıklara bölme yöntemini, Chen ve diğerlerinin [169]. iki nokta arası açı hesabını trend hesaplamak için kullanmıştır. Umano ve diğerlerinin [170]. ise zaman serisini, bulanık kümelemeyle hem global hem de yerel olarak üç farklı alana bölerek trend segmentasyonu yapmıştır. Bu dört çalışma da tek kelimelik özet yapılarını kullanmışlardır.

Albertetti ve diğerlerinin [171]. segmentasyon için SwiftSeg algoritmasını kullanmıştır. Bu çalışmada dilsel özetleme, eğer-öyleyse kural tabanlı yapılmıştır. Son olarak, 2020 yılında Özdoğan ve diğerlerinin [30]. tek değişkenli zaman serilerinde segmentasyon yapmıştır. Segmentasyon için MACD-histogram tabanlı algoritma kullanılmıştır. Çalışmada tip-1 ve tip-2 niceleyici protoform kullanılırken, doğruluk derecesi tip-2 bulanık küme tabanlı skaler kardinalite yaklaşımıyla hesaplanmıştır. Tek değişkenli zaman serilerinde segmentasyon temelli çalışmalar Çizelge 4.1'de özetlenmiştir.

Çizelge 4.1. Tek değişkenli zaman serilerinde segmentasyon temelli çalışmalar

Yazarlar	Segmentasyon Yöntemi	Protoform Yapısı
[14, 21, 30, 87, 93-97, 108, 124-139, 171]	Sklansky ve gonzales alg.	Tip-1 ve tip-2
[47, 86, 89, 140-146]		Genişletilmiş tip-1, tip-2
[18, 52, 147-160]	F-transform	Eğer-öyleyse kuralları
[161]		Syntactic structure
[61, 162]		Tectogramatical tree
[59]		Etiket (kelime)
[58]		Özel protoform
[99-101, 103, 163]	Parçalı-doğrusal fonksiyon yaklaşımı	Tip-1 ve tip-2
[102, 164]	Petri ağları	Petri ağları
[165], [57]	Iterative end-point fit alg.	Tip-1
[16], [105]	Lineer regresyon	Özel protoform
[43]	Eşit aralıklara bölünür	Etiket (kelime)
[166]	İki nokta arası açı	
[168]	Bulanık küme tabanlı formül	
[169]	Lemire's alg.	
[170]	SwiftSeg alg.	Eğer-öyleyse kuralı
[167]	MACD-histogram tabanlı alg.	Tip-1 ve tip-2

4.2. Tek Değişkenli Zaman Serilerinde Segmentasyon Temelli Olmayan Yöntemler

Zaman serilerinde segmentasyon işlemi, veriyi farklı açılardan görmeyi sağlamaktadır. Fakat zaman serilerinde her dilsel özetleme çalışmasında segmentasyon yapılmamıştır. Bu çalışmalarda veri, doğrudan değerlendirilerek veya işlem yapılarak özetlenir. Bu çalışmalar, kullandıkları protoform yapılarına göre özetlenecektir.

Sadece 2021 yılında ilk defa görülen ve özetlemenin en basit hali olan harflerle özetleme yapılmıştır. Baklan (2021) [172]. bu çalışmasında elektrokardiyogram (ECG) verilerini, her birisi ayrı bir anlam ifade eden harflere indirgeyerek özetlemiştir. Dilsel özetlemede kullanılan en yalın özetlemeden bir diğeri de kelimelerle özetleme yapmaktır. Bu etiketlerin bir kısmı zaman serisini tarif etmek için [30, 172, 173]. bir kısmı da özetlemek için yapılmıştır [40, 174-178]. Bu çalışmalarda, zaman serisindeki veri (GLMP protoform yapısındaki gibi) ya bir formülle hesaplanır [179]. ya da zaman serisindeki her verinin bulanık üyeliği bulunarak işlem yapılır [180]. Tek kelimelik özetlerin doğruluk dereceleri genelde tip-1 bulanık kümesine dayalı üyelik dereceleriyle bulunur.

Diğer çalışmalara bakıldığında, bazılarında tip-1 niceleyici protoform yapısıyla özetleme yapılırken [22, 44, 85, 181-188]. tip-1 ve tip-2 niceleyici protoform yapılarını birlikte kullanan çalışmalar da vardır [9, 20, 90, 140, 189-200]. Bu çalışmalarda, tip-1 bulanık kümesine dayalı skaler kardinalite yaklaşımıyla doğruluk dereceleri hesaplanmaktadır. Bu çalışmaların amacı, verinin genel özetlenmesidir. Fakat Jain 2016 yılındaki çalışmasında [186], üyelik fonksiyonlarının dilsel özetlemede doğruluk derecesine olan etkilerini karşılaştırmıştır. Bu alanda yapılan çok nadir bir çalışmadır. Wilbik ise 2013 ve 2014 yıllarındaki çalışmalarında [196, 199]. dilsel etiketleri, yaşlıların hareketlerindeki farklılıkları tespit etmek için kullanmıştır.

Zaman serilerinde segmentasyona ihtiyaç olmadan kullanılan en yaygın protoform yapısı, eğer-öyleyse kural yapılarıdır. Bu yapılarda, zaman serisindeki ham veri, bulanık kümeye göre etikete çevrilir ve eğer-öyleyse protoform yapısında kullanılır. Bu yapı, iki amaçla kullanılmaktadır: birinci amacı dilsel özetleme [50, 53, 196, 197, 201-211]. diğeri ise tahminlemedir. Eğer-öyleyse yapısının sadece özetleme amaçlı kullanıldığı çalışmalar, doğruluk derecesini skaler kardinalite tabanlı hesaplamıştır.

En gelişmiş protoform yapısı olan GLMP, segmentasyon yapılmayan zaman serilerinin özetlenmesi için kullanılmıştır. Bu yapı, 2017 yılında Conde-Clemente ve diğerlerinin [212]. tarafından geliştirilerek yazılım haline getirilmiştir. Çalışmaların genelinde dilsel özetleme yapılmıştır [19, 51, 55, 213-223]. GLMP protoform yapılarının kullanıldığı çalışmalarda doğruluk derecesi şöyle hesaplanmaktadır; eklenen her kelimenin, tip-1 bulanık kümesiyle elde edilen üyelik derecesi hesaplanır, herhangi bir toplama fonksiyonu ile tüm kelimelerin üyelik derecelerinden ortak bir doğruluk derecesi hesaplanır.

Zaman serilerinde dilsel özetleme yapılırken sadece sabit kalıplı protoformlar değil, aynı zamanda çalışmaya özel tasarlanmış protoform yapıları da vardır. Bunlar, uzun bir metin içerisinde sadece anahtar kelimelerin değişeceği özet yapılarıdır. Bu çalışmaların bir kısmında özet oluşturulurken en yüksek üyelik dereceli etiket alınmış; fakat özeti geneli için doğruluk derecesi hesaplanmamıştır [42, 49, 224-230]. Sadece üyelik dereceleriyle doğruluk derecesini hesaplayan çalışmalar [231-234] ve tip-1 bulanık küme tabanlı skaler kardinalite yaklaşımlarıyla doğruluk derecesi hesaplayan çalışmalar da vardır [235-245].

Aoki ve Kobayashi [62]. 2016 yılında bi-gram dil modelini kullanarak trend segmentasyon kullanmadan zaman serilerinde dilsel özetleme yapmıştır. Çalışmada, hisse senetleri özetlenmiştir. Tek değişkenli zaman serilerinde segmentasyon temelli olmayan çalışmalar Çizelge 4.2’de özetlenmiştir.

Çizelge 4.2. Tek değişkenli zaman serilerinde segmentasyon temelli olmayan çalışmalar

Yazarlar	Protoform
[50, 53, 62, 202-210, 245]	Eğer-öyleyse kuralları
[42, 49, 51, 211, 225-229], [230-233], [234-243]	Özel Protoform
[44, 85, 182-188, 244, 245]	Tip-1
[9, 20, 90, 140, 189-200]	Tip-1 ve Tip-2
[15], [19, 55, 201, 212-222]	GLMP
[173, 223, 224], [40, 174-178]	Etiket (Kelime)
[179]	Harf
[180]	Bi-Gram

4.3. Çok Değişkenli Zaman Serilerinde Segmentasyon Temelli Yöntemler

Çok değişkenli zaman serilerinin özetlenmesinde, aynı birimli ve farklı birimli çok değişkenli zaman serileri olmak üzere iki farklı durum vardır.

Castillo-Ortega, Martinez-Cruz ve Sanchez (2017) [104]. çalışmasında iki ülkenin karbondioksit miktarları hakkında zaman serisi verilerini özetlemişlerdir. Bu veriler, üç farklı işlemle tek bir zaman serisi haline getirilmiştir. Bu işlemler; mutlak fark, küresel fark ve yerel fark işlemleridir. Böylece tek değişkenli 3 farklı zaman serisi üretilmiştir. Daha sonra bu zaman serileri, ayrı ayrı iteratif end-fit point algoritması ile trendlere ayrılarak dilsel özetlemeye hazır hale getirilmişlerdir. Çalışmada özel protoform yapısı kullanılmıştır.

Banaee, Ahmed ve Loutfi, 2013 yılında yaptıkları çalışmada [98] aynı birimli iki farklı zaman serisi üzerinde çalışmışlardır. Bu veriler, kalp atışı ve solunum oranı verileridir. Zaman serileri, kendi içerisinde parçalı-doğrusal fonksiyon algoritması ile trendlere ayrılmıştır. Her trend, yükseklik ve zaman parametrelerine göre etiketlere çevrilmiş ve bu etiketler, sabit form olan özet yapısında kullanılmıştır. Özet yapısı, özel bir protoform yapısıdır. Sadece ilgili kelime veriye göre değişmektedir.

Moreno-Garcia ve diğerlerinin 2014 [107]. ve 2016 [22]. yıllarında iki farklı çalışmada, birimleri farklı üç farklı zaman serisi üzerinde çalışmışlardır. Eğer-öyleyse kural tabanlı geliştirdikleri yöntemde, zaman serilerindeki her nokta dilsel etikete çevrilir. Bu etiketler, eğer-öyleyse kural tabanlı özet cümlelerine çevrilir. Bu üretilen kuralları, temporal fuzzy models (TFM) ve temporal fuzzy rules (TFR) olarak isimlendirmişlerdir. TFR'ler, TFM'leri oluşturan alt kurallardır.

Castillo ve Melin [246]. 2008 yılında birimleri farklı olan üç zaman serisi üzerinde çalışmışlardır. Bu veri, üç boyutlu zaman serisidir. Çalışmada, her bir değişkenin verileri ayrı ayrı bulanık üyelik derecesine göre dilsel etikete çevrilmiştir. Zamana bağlı olan bu veriler, aynı zaman dilimi içinde gösterdikleri davranışlara göre eğer-öyleyse kurallarıyla özetlenmişlerdir.

Özet olarak, literatürde 3 adet farklı birimli çok boyutlu zaman serisi segmente edilerek özetlenmiştir. Bu çalışmaların hepsinde eğer-öyleyse kuralları kullanılarak özetleme

yapılmıştır. Aynı birimli olan çok değişkenli zaman serisinde ise zaman serileri, fark alma işlemi ile tek değişkenli zaman serisi haline getirilerek özetlenmiştir.

4.4. Çok Değişkenli Zaman Serilerinde Segmentasyon Temelli Olmayan Yöntemler

Çok değişkenli zaman serilerinde segmentasyon yapmadan veriyi kullanarak dilsel özetleme yapan çalışmalar da vardır. Bu çalışmaların bir kısmında [22, 247, 248] değişkene ait her bir veri, bulanık dilsel etikete çevrilir. Daha sonra bu etiketler, eğer-öyleyse kural tabanlı özetlerde kullanılmıştır.

Castillo-Ortega, Marin ve Sanchez (2009) [249, 250]. çok değişkenli zaman serilerindeki her veriyi üyelik derecesi en yüksek olan dilsel etikete çevirmiş ve veriyi özel bir protoform içerisinde özetlemiştir. Anderson ve diğerlerinin (2009) bir kameradan alınan 3 boyutlu görüntüyü anlık olarak değerlendirerek, kişinin konumu hakkında özetleme yapmıştır [251]. Konum verisi, üç boyutlu grafiğe aktarılarak konum tespiti yapılmış ve her ardışık iki görüntü arasında bir örüntü tanımlayarak, kişinin hareketi hakkında özetleme yapılmıştır.

Çok değişkenli zaman serileri trendlere ayrılmamış ise; veri, en yüksek üyelik dereceli dilsel etikete çevrilmiştir. Daha sonra ya özel bir protoform içerisinde veya eğer-öyleyse kural tabanlı yapılarda özetlenmiştir.

4.5. Zaman Serilerinde Doğruluk Derecesi Ölçümü

Doğruluk derecesi, dilsel özetlerde ölçülen en önemli kalite göstergesidir. Çalışmanın amacına göre farklı kalite göstergeleri kullanılsa da, her özetin sonunda veriyi ne kadar doğru ifade ettiği sorgulanmaktadır.

Herhangi bir özetin doğruluk derecesi, verinin etikete çevrilmesinde kullanılan bulanık kümeye bağlıdır. Bunlardan bazıları; tip-1 bulanık küme, tip-2 bulanık küme, aralıklı tip-1 ve tip-2 veya daha farklı bir bulanık kümedir. Bulanık kümeler ise üyelik fonksiyonlarına göre oluşturulur. Doğruluk derecesinin hangi formül ile hesaplanacağı (Bölüm 2.4’de özetlenmiştir) ve o formülde hangi operatörün kullanılacağı literatürde çalışılan önemli konulardır.

Zaman serilerinde dilsel özetleme yapan çalışmaların geneline bakıldığında, özel çalışmalar haricinde en çok üç sınıf üzerinde gruplanabilir; Bunların en önemlisi ve çalışmaların çoğunu yapan Kacprzyk, Zadrozny, Wilbik ve diğerleridir. Çalışmalarının genelinde formül olarak skaler kardinalite tabanlı Zadeh'in metodu, operatör olarak minimum t-norm ve üyelik fonksiyonu olarak yamuk kullanılmıştır [9, 14, 20, 21, 86, 87, 89, 90, 94-96, 99-102, 108, 126, 128-130, 132, 133, 140, 164, 181, 191, 193-195, 251, 252]. Diğer bir çalışma grubu ise Novak, Perfilieva ve diğerleridir. Çalışmalarında doğruluk derecesini, destek, güven [152, 157, 198, 199, 204-207]. ve Lukasiewicz MV algebra yöntemiyle [52, 253]. hesaplamışlardır. Operatör olarak lukasiewicz yöntemini, üyelik fonksiyonu olarak da kosinüs bulanık bölümlmeyi kullanmışlardır. Son grup ise; GLMP protoform yapısını çalışmalarında kullanan Eciolaza, Sanches-Valdes, Trivino, Conde-Clemente ve Alvarez-Alvazer'dir [55, 58, 59, 214-223, 254]. Doğruluk derecesi, etiketin üyelik derecesine göre hesaplanmıştır. Operatör olarak toplama fonksiyonu ve üyelik fonksiyonu olarak yamuk kullanılmıştır. Yazarlara göre doğruluk derecesi hesaplama metotları Şekil 4.2'de ağ şeklinde sunulmuştur.

Protoform yapılarına göre bakıldığında; tip-1 ve tip-2 niceleyici temel yapılarda skaler kardinalite tabanlı formüller, GLMP ve etiket yapılarında ise sadece üyelik derecesi kullanılmıştır. Eğer-öyleyse protoformlarında skaler kardinalite tabanlı Zadeh'in metodu ve üyelik dereceleri kullanılmıştır. Tüm çalışmalar detaylarıyla Çizelge 4.3'de verilmiştir.

Çizelge 4.3. Zaman serilerinde doğruluk derecesi için yapılan çalışmalar

Yazarlar	Protoform	Formül	Operatör	Üyelik Fonksiyonu
[224]	Tip-1	Skaler kardinalite tabanlı Zadeh'in metodu		Üçgensel
[181, 189, 212, 250]				Yamuk
[183]			t-norm (min. operatörü)	Yamuk, Üçgensel, pi-şekilli
[182, 186]				Yamuk
[44, 85, 190]				Üçgensel
[9, 14, 20, 21, 86, 87, 89, 90, 94-96, 99-102, 108, 126, 128-130, 132, 133, 140, 164, 187, 188, 191, 193-195, 252]	Tip-1 ve Tip-2	Skaler kardinalite tabanlı Zadeh'in metodu	t-norm (min. operatörü)	Yamuk
[134, 139, 198, 199]			t-norm (min. operatörü)	Yamuk
			Product	
			Lukasiewicz	
			Drastic	
[139]		Skaler kardinalite tabanlı Choquet integrali	t-norm (min. operatörü)	Yamuk
[97, 131, 136-138]		Skaler kardinalite tabanlı olmayan Sugeno integrali	t-norm (min. operatörü)	Yamuk
[135]		Skaler kardinalite tabanlı Yager'in OWA metodu	t-norm (min. operatörü)	OWA
[93, 127, 141, 143, 255]	Tip-1 ve Tip-2 tabanlı özel protoformlar	Skaler kardinalite tabanlı Zadeh'in metodu	t-norm (min. operatörü)	Yamuk
[145]		Skaler kardinalite tabanlı Yager'in OWA metodu	t-norm (min. operatörü)	OWA
[47, 55, 142, 214-223, 254]	GLMP	Üyelik Derecesi	Toplama fonksiyonu	Yamuk
[224]		Skaler kardinalite tabanlı Zadeh'in metodu	t-norm (min. operatörü)	Yamuk
[212, 213]	Eğer-öyleyse kural tabanlı	Destek ve Güven formülleri	t-norm (min. operatörü)	Kosinüs bulanık bölümlleme
[53, 152, 157, 203-207]			Lukasiewicz	Kosinüs bulanık bölümlleme
[253]		BL-algebra		Pi-şekilli
[52, 208]		Skaler kardinalite tabanlı Zadeh'in metodu	t-norm (min. operatörü)	Üçgensel
[202]	Özel Protoform	Skaler kardinalite tabanlı Zadeh'in metodu	t-norm (min. operatörü)	Üçgensel
[50, 80, 237, 239-241]				Yamuk
[242]		Anlamsal sıralama yöntemi	t-norm (min. operatörü)	Yamuk
[243]		Üyelik Derecesi		Yamuk
[43]			t-norm (min. operatörü)	Yamuk
[244]				Yamuk
[232]		Uzman değerlendirme		
[236]		Etiket (kelime)	Üyelik Derecesi	
[235]				Üçgensel
[201]				Özel
[176]	Syntactic modeli	Skaler kardinalite tabanlı Zadeh'in metodu	Lukasiewicz	Üçgensel
[40, 61]	Tectogramatical tree	Lukasiewicz MV algebra	Lukasiewicz	Kosinüs bulanık bölümlleme

4.6. Zaman Serilerinde Diğer Değerlendirme Yöntemleri

Bölüm 2.4.8’de bahsedilen kalite göstergeleri, doğruluk derecesiyle birlikte çalışmalarda özetin kalitesini gösteren farklı değerlendirme kıstaslarıdır. Bu yöntemlerden en çok kullanılan özgüllük [58, 59]. kapsam [101]. ve odaklanma [102]. göstergesidir (Çizelge 4.4).

Çizelge 4.4. Zaman serilerinde yapılan özetler için diğer değerlendirme ölçütleri


	Özgüllük	Kapsam	Odaklanma	Benzerlik	Bulanıklık	Kısalık	Ayrıklık	Uygunluk	Bilgilendiricilik	Basitlik	İlişki	Miktar	Kalite	Netlik	Genellik	Fayda	Güvenilirlik	Granül seviyesi	Farklılık	Yenilik	Tereddüt
[81]	1	1				1			1	1		1	1	1				1			
[85]	1	1				1	1				1				1	1					
[51]		1					1				1				1	1	1				1
[132]	1		1					1	1										1		
[100]		1			1	1		1													
[91]		1					1				1						1				
[128]									1			1	1	1							
[58]	1	1				1						1	1	1							
[59]	1		1		1																
[256]	1	1			1																
[87]	1		1							1											
[80]	1		1							1											
[101]		1					1														
[102]			1					1													
[257]	1		1																		
[89]		1																			
[100]			1																		
[132]				1																	
[86]				1																	
[90]				1																	
[193]				1																	
[194]				1																	
[195]					1																

Zaman serilerinin özetlenmesinde tereddüt göstergesi hariç diğer göstergelerin hepsi kullanılmıştır. Bu gösterge ise sadece statik verilerin özetlenmesinde kullanılmıştır. Bugarin ve diğerleri [81]. Hudec [85]. ve Wu ve Mendel [51]. zaman serilerinde dilsel özetleme yaparken en çok değerlendirme göstergesi kullanan çalışmaları yapmıştır.

4.7. Zaman Serilerinde Dilsel Özetleme Kullanım Alanları

Dilsel özetleme, ilk sentetik (yapay) veriler ve kişisel veriler üzerinden yapılırken, zamanla diğer alanlarda da uygulanmaya başlandı. Bu çalışmalar en çok insan sağlığı, finans, sağlık, meteoroloji, trafik ve teknoloji alanında yapılmıştır. Bunların yanında çok nadir görülen

çalışmalar da vardır. Bunlar; görüntü üzerinde yapılan Banaee'nin yaptığı çalışma [49], ses verisi üzerinde yapılan Novak ve diğerlerinin [155], ve Polo-Rodriguez ve diğerlerinin [201], yaptıkları çalışmalardır. Castillo ve diğerlerinin [246], coğrafi görüntüler üzerine dilsel özetleme yaparken, Moreno-Garcia ve diğerlerinin 2021 yılında [245], tedarik zinciri verileri üzerinde dilsel özetleme yapmıştır. Çalışma alanları ve oranları Şekil 4.3'de verilmiştir.




Şekil 4.3. Zaman serilerinde dilsel özetleme kullanım alanları

Bu literatür araştırması, dilsel özetleme tekniğinin çeşitli sektörlerde yaygın bir şekilde kullanıldığını ortaya koyarken, nöropazarlama alanında dilsel özetlemenin kullanılmadığı görülmektedir. Nöropazarlama gibi verilerin analizine ve yorumlanmasına dayalı bir alanda dilsel özetleme tekniğinin uygulanması, karar verme süreçlerini hızlandırabilir ve bu alanda yeni bir perspektif sağlayabilir. Bu eksiklik, nöropazarlama alanında yapılacak dilsel özetleme odaklı çalışmalar için yeterli bir motivasyondur.

5. YÖNTEM

5.1. EEG İle Duygu Durum Tespiti

EEG sinyalleri, frekans aralığına göre sınıflandırılarak beynin farklı durumlarını gösterir. Fakat delta, teta, alfa, beta ve gama olarak isimlendirilen bu ritim sınıfları, kişinin daha detaylı duygusal aktivitelerini gösterebilmek için formülize edilmiş ve beynin gözlemlendiği lobuna göre duyguya çevrilmiştir [110]. Literatürde, birkaç temel duygudan [258], temel duyguların birleştirilmesinden türetilen düzinelerce karmaşık duruma [259] kadar birçok farklı duygu durumu tanımlanmıştır. Hepsi farklı yaklaşımlar kullanılarak sınıflandırılabilir, en yaygın kullanılanlardan biri olan Russell'ın dolaylı etki modelidir [260]. Bu iki boyutlu modelde, tüm duygular, Şekil 5.1'de gösterildiği gibi, değerlik (valence) ve uyarılma (arousal) seviyelerine göre dağıtılır.



Şekil 5.1. Russell'ın duygu sınıflandırma modeli (sağ: temel duygular [258]. sol: detaylı duygular [259])

Değerlik ve uyarılma değerleri frekansa göre sınıflandırılmış EEG sinyalleriyle hesaplanmaktadır. Frontal EEG asimetrisinin, uyarılma ve duygu değerinin bir göstergesi olduğu hipotezini destekleyen çok sayıda çalışma yapılmıştır. Aynı zamanda değerlik ve uyarılmayı hesaplamak için farklı frontal asimetri denklemleri kullanılır [261, 262]. Uyarılma değeri, beta ile alfa değerlerinin oranıyla hesaplanmaktadır. Beta dalgaları, uyanık veya heyecanlı zihin durumları ile ilişkilendirilirken, alfa dalgaları, rahatlamış veya beyin inaktivasyon durumları ile ilişkilendirilmiştir. Dolayısıyla beta ile alfa oranı, kişinin uyarılma durumunun bir göstergesi olarak değerlendirilebilir. Değerlik, frontal EEG

asimetrisinin aktivasyonundan bulunmaktadır [263]. Duygunun pozitif veya negatif olduğunu gösterir. Mesela kişide aşırı bir uyarılma varken, bu mutluluktan mı yoksa üzüntüden mi olduğunu tespit eder.

Literatürde farklı şekillerde, uyarılma ve değerlik değerleri hesaplanmıştır (Çizelge 5.1). En yaygın kullanılanlar [28] [110]:

Çizelge 5.1. Uyarılma ve değerlik değerleri hesaplama yöntemleri

	Değerlik	Uyarılma
[28]	$= sol\left(\frac{\beta}{\alpha}\right) - sağ\left(\frac{\beta}{\alpha}\right)$	$= \log_2 sol\left(\frac{\beta}{\alpha}\right)$
[264]	$= \ln\left(\frac{Frontal_{sol(\alpha)}}{Frontal_{sağ(\alpha)}}\right)$	$= -\ln Frontal_{sağ(\alpha)} + \ln Frontal_{sol(\alpha)}$
[265], [266]	$= Frontal_{sağ(\frac{\beta}{\alpha})} - Frontal_{sol(\frac{\beta}{\alpha})}$	$= \frac{Frontal(\alpha)}{Frontal(\beta)}$
[267]	$= Frontal_{sağ(\alpha)} - Frontal_{sol(\alpha)}$	$= \frac{Frontal(\beta)}{Frontal(\alpha)}$

Çalışmada, uyarılma ve değerlik değerlerinin hesaplanması için Ramirez ve diğerlerinin [268] kullandıkları formüller (Eş. 5.1-5.2) kullanılmıştır;

$$Değerlik = Frontal_{sağ(\alpha)} - Frontal_{sol(\alpha)} \quad (5.1)$$

$$Uyarılma = \frac{Frontal(\beta)}{Frontal(\alpha)} \quad (5.2)$$

Hesaplanan değerlerin, duygu durum matrisinde kullanılabilmesi için normalizasyon yapılmıştır. Bu normalizasyon (Eş. 5.3), bütün değerleri bilgi kaybı olmadan [-1,1] arasındaki değerlere sıkıştırır [28].

$$Norm_x = 2 * \left(\frac{(x - \min(x))}{\max(x) - \min(x)} \right) - 1 \quad (5.3)$$

5.2. Russell'in Çemberinde Dilsel Etiketlerin Tespiti

Çalışmada duygu durumları kullanılarak özetler oluşturulacaktır. Fakat uyarılma ve değerlik değerleri dilsel etiketlere dönüştürülürken bulanık kümede kullanılabilmesi için tek bir

parametreye indirilmeleri gerekmektedir. Uyarılma ve değerlik değerlerinin oranları alınıp arktanjan ile duygu durum çemberindeki açı bulunur. Bu açı, kişide görülen EEG sinyalinin hangi duyguya karşılık geldiğini Russell'in çemberinden tespit etmek için kullanılmaktadır. Eş. 5.4'de hesaplanan bu açı, yatay düzlem ile merkezden düzlemdeki noktalara (uyarılma - değerlik değerlerinin kesişim noktasına) uzanan ışın arasındaki açıdır.


$$\theta = \arctan\left(\frac{Uyarılma}{Değerlik}\right) \quad (5.4)$$

Uyarılma ve değerlik değerlerinin işareti her bölgede değiştiği için açı hesaplama formülü de değişmiştir. Koordinat düzlemindeki her bölge için θ açısının hem aralığı, hem hesaplama formülü Çizelge 5.2'de verilmiştir.

Çizelge 5.2. Bölgelere göre θ açısının hesaplanması

	Uyarılma	Değerlik	Θ aralık	Θ formül
1. Bölge	+	+	$0 - \pi$	$\theta = \arctan\left(\frac{Uyarılma}{Değerlik}\right)$
2. Bölge	+	-	$\pi/2 - \pi$	$\theta = \pi - \left \arctan\left(\frac{Uyarılma}{Değerlik}\right)\right $
3. Bölge	-	+	$\pi - 3\pi/2$	$\theta = \pi + \arctan\left(\frac{Uyarılma}{Değerlik}\right)$
4. Bölge	-	-	$3\pi/2 - 2\pi$	$\theta = 2 * \pi - \left \arctan\left(\frac{Uyarılma}{Değerlik}\right)\right $

Duygu durum çemberindeki her koordinat bölgesi için farklı bir bulanık küme tanımlanmıştır. Her küme için tanımlanan etiketler, duygu durum çemberinde tanımlanan duygulardır. Bulanık küme tanımı Ruspini şartına göre tanımlanmıştır [156]. Bu şekilde tanımlanmasının sebebi ise, duygu durumlarının uyarılma ve değerlik değerlerine göre homojen bir geçişlerinin olmasıdır [110]. Koordinat düzleminde her bir alan için hesaplanan açının gösterimi, oluşturulan bulanık kümeler ve bulanık kümelerde tanımlanan etiketler Şekil 5.2'deki gibidir.



Şekil 5.1. Koordinat düzlemindeki tüm bölgelerin bulanık küme ile dilsel etikete dönüşümü

5.3. Nöropazarlama İndeksi

Literatürde nöropazarlama ile ilgili kişinin çevresindeki şeye yakınlaştığını-uzaklaştığını ifade eden AW (approach-withdrawal) indeksi kullanılmıştır [156]. AW indeksi aynı zamanda motivasyonu, isteği veya yaklaşmaktan kaçınmayı gösteren frontal alfa asimetrisi olarak da bilinir. 1985 yılında başlatılan ön asimetri teorisi, sırasıyla, sol ve sağ hemisferlerin ön bölgelerinin olumlu duygulardan (yaklaşma motivasyonu) ve olumsuz duygulardan (çekilme motivasyonu) sorumlu olduğunu belirtir [261]. Bu indeks, formül (Eş. 5.5)'de gösterildiği gibi prefrontal alfa bandındaki iki yarımküre arasındaki farkla, yani ön sol yarımkürenin sağ ile karşılaştırıldığında göreceli olarak birbirine bağlanması olarak tanımlanabilir. Pozitif AW değerleri, sol frontal korteksin daha yüksek aktivasyonu olarak ifade edilen pozitif motivasyona (yaklaşma davranışları) karşılık gelir. Buna karşılık, negatif AW değerleri, sol frontal korteksin daha yüksek aktivasyonu olarak ifade edilen negatif motivasyona (kaçınma davranışları) karşılık gelir [110, 270-273].


$$AW = \frac{\text{alfa}(\text{Frontal_sağ}) - \text{alfa}(\text{Frontal_sol})}{\text{alfa}(\text{Frontal_sağ}) + \text{alfa}(\text{Frontal_sol})} \quad (5.5)$$



6. DİLSEL ÖZETLEME PROTOFORM YAPILARI

Kişilerin duygularını bulanık duygu şeklinde ifade eden Θ açısı ve AW verisi, dört temel ve onaltı gelişmiş duygu durumuna çevrilerek özetlenmiştir. Özetlemede üç farklı bulanık kümeye ait ve kişinin duygu durumlarını ifade eden toplamda 23 etiket kullanılmıştır.

Çalışmada üç farklı veri tipiyle özetleme yapılacaktır (Şekil 6.1). İlk özet yapıları, her bir bireyin üç farklı reklamdaki tek boyutlu zaman serisiyle yapılacaktır. Bu özet yapılarının amacı, reklamların kişi üzerinde etkisini, reklamın dört farklı bölümünün kendi arasında karşılaştırılmasını birey bazında özetlemektir. İkinci özet yapıları, tüm bireylerin her bir reklamdaki verilerinden oluşan çok boyutlu zaman serilerinin özetlenmesi olacaktır. Bu özet yapısında cinsiyet ve yaş faktörü dikkate alınacaktır. Buradaki amaç ise, reklamların kişiler üzerinde yaptığı etkiyi ve dört farklı bölümünün kendi aralarında karşılaştırılmasını, bütün popülasyon bazında görüp, özetlemektir. Son olarak, çok boyutlu zaman serilerinin toplu hareketlerini tespit eden çok parçalı trend algılama algoritması ile elde edilmiş serilerin özetlenmesidir. Trend algılama yaklaşımı, kişilerin eş zamanlı hissettikleri aynı duyguları tespit etmek içindir. Aynı anda birden fazla kişi aynı duyguları hissediyorsa, reklamın o kısmının o duyguyu verdiği daha ispatlanabilir bir gerçektir. Fakat 2. kısımdaki tüm bireylerin genel duygularını tespit etmek bu bilgiyi bize veremeyebilir. Çünkü o duygu, bireylerde farklı zamanlarda ortaya çıkmış olabilir.




Şekil 6.1. Özetlemede kullanılan veri tipleri gösterimi

6.1. Tek Boyutlu Zaman Serisi Özet Yapıları

Θ açısının duyguları ifade eden dilsel etiketlere nasıl çevrildiği ve bulanık kümenin nasıl oluşturulduğu Bölüm 5.2’de verilmiştir. Şekil 6.2’de ise üç reklamdan birini izleyen bir katılımcının verisini ifade eden tek boyutlu zaman serisi ve AW indeksinin ifade ettiği üç duygu, dört temel duygu ve tüm duyguların bulanık kümesi gösterilmektedir.

Özet yapıları ikiye ayrılmıştır; genel tanımlamalar ve karşılaştırmalı özet yapılarıdır. Genel tanımlamaların amacı, her bir reklamın genel ve bölümsel olarak kişi üzerindeki etkisini görmektir. Karşılaştırmalı özet yapılarında ise hem reklamların, hem de aynı reklamın farklı zamanlarının kişi üzerindeki etkileri karşılaştırılmıştır.

Özetlerin protoform yapıları, örnekler ve kullanılan notasyonlar, tanımlardan önce verilmiştir. Tip-1 ve tip-2 temelli veya farklı protoform yapılarının doğruluk dereceleri verilmiştir. Doğruluk derecesi hesaplanırken minimum t-norm operatörü ($\otimes$) kullanılmıştır.




Şekil 6.2. Θ açısı ve AW indeksi zaman serisi ve bulanık kümeler

Genel tanımlamalar:

$$Y = \left\{ \begin{matrix} \text{web} \\ \text{sesli} \\ \text{video} \end{matrix} \right\}, \quad Q = \left\{ \begin{matrix} \text{çok az} \\ \text{çok} \\ \text{yarısı} \\ \text{en az yarısı} \\ \text{tümü} \end{matrix} \right\}, \quad (Y_{segment}) = \left\{ \begin{matrix} \text{birinci} \\ \text{ikinci} \\ \text{üçüncü} \\ \text{dördüncü} \end{matrix} \right\}$$

$$S = \left\{ \begin{array}{l} \text{mutlu} \\ \text{sevinçli} \\ \text{heyecanlı} \\ \text{uyanık} \\ \text{gergin} \\ \text{sinirli} \\ \text{stresli} \\ \text{üzgün} \\ \text{mutsuz} \\ \text{depresif} \\ \text{bitkin} \\ \text{yorgun} \\ \text{sakin} \\ \text{rahatlamış} \\ \text{dingin} \\ \text{memnun} \end{array} \right\} / \left\{ \begin{array}{l} \text{heyecanlı} \\ \text{stresli} \\ \text{depresif} \\ \text{rahat} \end{array} \right\} / \left\{ \begin{array}{l} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{array} \right\}, \quad S' = \left\{ \begin{array}{l} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{array} \right\}$$



Şekil 6.3. Niceleyici çeşitleri ve onların bulanık küme tanımları

1) $Q Y, N S. [T_1]$ (N , katılımcı numarasıdır.), (Eş. 6.1), (Şekil 6.3)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_s(d_{Y,N})}{R} \right) \quad (6.1)$$

$$R = \begin{cases} M, & \text{Göreceli niceleyici ("çoğu")} \\ 1, & \text{Mutlak niceleyici ("4'den büyük")} \end{cases}$$

"Sesli reklamın çoğunda 3.kişi mutludur."

2) $Q_{Y_{segment} Y, N S. [T_1]}$ (Eş. 6.2)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_s (d_{Y_{segment}, N})}{R} \right) \quad (6.2)$$

"Sesli reklamın 2.çeyreğinin yarısında 2. kişi gergindir."

3) $Q_{Y, N S'. [T_1]}$ (Eş. 6.3)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{s'} (d_{Y, N})}{R} \right) \quad (6.3)$$

"Video reklamın az bir kısmında 4.kişinin pozitif meyli vardır."


4) $Q_{Y_{segment} Y, N S'. [T_1]}$ (Eş. 6.4)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{s'} (d_{Y_{segment}, N})}{R} \right) \quad (6.4)$$

"Video reklamın 2.çeyreğinin yarısında 7.kişinin pozitif meyli vardır."

Karşılaştırmalı tanımlamalar:

$$Y = Y' = \left\{ \begin{array}{l} \text{web} \\ \text{sesli} \\ \text{video} \end{array} \right\}, \quad Y_1 = Y_2 = \left\{ \begin{array}{l} \text{birinci} \\ \text{ikinci} \\ \text{üçüncü} \\ \text{dördüncü} \end{array} \right\}, \quad S' = \left\{ \begin{array}{l} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{array} \right\}$$



Şekil 6.4. "daha" niceleyicisinin bulanık küme tanımı

5) $N Y_1, Y S' Y_2. [T_1]$ (Eş. 6.5), (Şekil 6.4)

$$T_1 = \mu_{daha} \left(\max(0, \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y_1, (N)})}{R} - \frac{\sum_{m=1}^M (\mu_{S'} d_{Y_2, (N)})}{R} \right) \right) \right) \quad (6.5)$$

"5.kişiye göre web reklamının 1.çeyreği, 2.çeyreğinden daha etkileyicidir."

6) $N, Y \text{ daha } S' Y'. [T_1]$ (Eş. 6.6)

$$T_1 = \mu_{daha} \left(\max(0, \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y, (N)})}{R} - \frac{\sum_{m=1}^M (\mu_{S'} d_{Y', (N)})}{R} \right) \right) \right) \quad (6.6)$$

"4.kişiye göre web reklamı sesli reklamdan daha etkileyicidir."

7) $N, S' Q_1 Y_1 Y'_1, Q_2 Y_2 Y'_2. [T_1]$ (Eş. 6.7)

$$T_1 = \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y_1, Y'_1})}{R} \right) \otimes \mu_{Q_2} \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y_2, Y'_2})}{R} \right) \quad (6.7)$$

"Web reklamının 1.çeyreğinin çoğunda, sesli reklamın 2.çeyreğinin yarısında 3.kişide pozitif meyil olmuştur."

$$S_1/S_2 = \left\{ \begin{array}{c} \text{mutlu} \\ \text{sevinçli} \\ \text{heyecanlı} \\ \text{uyanık} \\ \text{gergin} \\ \text{sinirli} \\ \text{stresli} \\ \text{üzgün} \\ \text{mutsuz} \\ \text{depresif} \\ \text{bitkin} \\ \text{yorgun} \\ \text{sakin} \\ \text{rahatlamış} \\ \text{dingin} \\ \text{memnun} \end{array} \right\} / \left\{ \begin{array}{c} \text{heyecanlı} \\ \text{stresli} \\ \text{depresif} \\ \text{rahat} \end{array} \right\} / \left\{ \begin{array}{c} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{array} \right\}, \quad Q_1/Q_2 = \left\{ \begin{array}{c} \text{çok az} \\ \text{çok} \\ \text{yarısı} \\ \text{en az yarısı} \\ \text{tümü} \end{array} \right\}$$

8) A) $N, S_1 Q_1 Y_1, S_2 Q_2 Y_2. [T_1]$ (Eş. 6.8)

$$T_1 = \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S_1} d_{Y_1, N})}{R} \right) \otimes \mu_{Q_2} \left(\frac{\sum_{m=1}^M (\mu_{S_2} d_{Y_2, N})}{R} \right) \quad (6.8)$$

"7.kişi için web reklamının çoğunda gerginlik görülürken, sesli reklamın çoğunda heyecan görülmüştür".

B) $N, S_1 Q_1 Y_1, Q_2 Y_2. [T_1]$ (Eş. 6.9)

$$T_1 = \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S_1} d_{Y_1, N})}{R} \right) \otimes \mu_{Q_2} \left(\frac{\sum_{m=1}^M (\mu_{S_1} d_{Y_2, N})}{R} \right) \quad (6.9)$$


"7.kişi için sesli ve web reklamların ikisinde de çoğu zaman stres görülmüştür."

6.2. Çok Boyutlu Zaman Serisi Özet Yapıları

Bu bölümde tüm katılımcı bireylerin deneyimledikleri üç reklamın da verileri birlikte değerlendirilmiştir. Şekil 6.5’de herhangi bir reklamı izleyen bütün bireylerin verisini ifade eden çok boyutlu zaman serisi ve AW indeksinin ifade ettiği üç duygu, dört temel duygu ve tüm duyguların bulanık kümesinin temsili gösterilmektedir.

Özet yapıları ikiye ayrılmıştır; genel tanımlamalar ve karşılaştırmalı yapılarıdır. Genel tanımlamaların amacı, her bir reklamın genel ve bölümsel olarak kişiler üzerindeki etkisini görmektir. Karşılaştırmalı özet yapılarında ise hem reklamların, hem de aynı reklamın farklı zamanlarının kişiler üzerindeki etkileri karşılaştırılmıştır. Bu özetlerde ilk özet yapılarından farklı olarak, özetler cinsiyet ve yaş gruplarıyla genişletilmiştir.

Özetlerin protoform yapıları, örnekler ve kullanılan notasyonlar, tanımlardan önce verilmiştir. Tüm protoform yapılarının doğruluk dereceleri verilmiştir. Doğruluk derecesi hesaplanırken minimum t-norm operatörü ($\otimes$) kullanılmıştır.



Şekil 6.5. Θ açıları ve AW indeksinden oluşan çok boyutlu zaman serisi ve bulanık kümeler

$$Y = \begin{Bmatrix} \text{web} \\ \text{sesli} \\ \text{video} \end{Bmatrix}, \quad Q = \begin{Bmatrix} \text{çok az} \\ \text{çok} \\ \text{yarısı} \\ \text{en az yarısı} \\ \text{tümü} \end{Bmatrix}, \quad (Y_{segment}) = \begin{Bmatrix} \text{birinci} \\ \text{ikinci} \\ \text{üçüncü} \\ \text{dördüncü} \end{Bmatrix}$$

$$S = \begin{Bmatrix} \text{mutlu} \\ \text{sevinçli} \\ \text{heyecanlı} \\ \text{uyanık} \\ \text{gergin} \\ \text{sinirli} \\ \text{stresli} \\ \text{üzgün} \\ \text{mutsuz} \\ \text{depresif} \\ \text{bitkin} \\ \text{yorgun} \\ \text{sakin} \\ \text{rahatlamış} \\ \text{dingin} \\ \text{memnun} \end{Bmatrix} / \begin{Bmatrix} \text{heyecanlı} \\ \text{stresli} \\ \text{depresif} \\ \text{rahat} \end{Bmatrix} / \begin{Bmatrix} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{Bmatrix}, \quad S' = \begin{Bmatrix} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{Bmatrix}$$

Genel tanımlamalar:

1) $Q Y, S, [T_1]$ (Eş. 6.10)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_S(d_Y)}{R} \right) \quad (6.10)$$

"Sesli reklamın çoğunda insanlar mutludur."

2) $Q Y_{segment} Y, S, [T_1]$ (Eş. 6.11)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{s'}(d_Y, Y_{segment})}{R} \right) \quad (6.11)$$

"Sesli reklamın 2.çeyreğinin yarısında insanlar gergindir."

3) $Q Y, S'. [T_1]$ (Eş. 6.12)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{s'}(d_Y)}{R} \right) \quad (6.12)$$

"Video reklamın az bir kısmında insanların pozitif meyli vardır."

4) $Q Y_{segment}, S'. [T_1]$ (Eş. 6.13)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{s'}(d_Y, Y_{segment})}{R} \right) \quad (6.13)$$

"Video reklamın 2.çeyreğinin yarısında insanların pozitif meyli vardır."

Aşağıdaki protoformlardaki notasyonlar şöyle tanımlanmıştır;

$$Q = \left\{ \begin{array}{c} \text{çok az} \\ \text{çok} \\ \text{yarısı} \\ \text{en az yarısı} \\ \text{tümü} \end{array} \right\}, Y_1 = Y'_1 = \{ \text{erkek}, \text{kadın} \}, Y_2 = Y'_2 = \left\{ \begin{array}{c} \text{web} \\ \text{sesli} \\ \text{video} \end{array} \right\},$$

$$Y_3 = Y'_3 = \left\{ \begin{array}{c} \text{birinci} \\ \text{ikinci} \\ \text{üçüncü} \\ \text{dördüncü} \end{array} \right\}$$

$$S = \left\{ \begin{array}{l} \text{mutlu} \\ \text{sevinçli} \\ \text{heyecanlı} \\ \text{uyanık} \\ \text{gergin} \\ \text{sinirli} \\ \text{stresli} \\ \text{üzgün} \\ \text{mutsuz} \\ \text{depresif} \\ \text{bitkin} \\ \text{yorgun} \\ \text{sakin} \\ \text{rahatlamış} \\ \text{dingin} \\ \text{memnun} \end{array} \right\} / \left\{ \begin{array}{l} \text{heyecanlı} \\ \text{stresli} \\ \text{depresif} \\ \text{rahat} \end{array} \right\} / \left\{ \begin{array}{l} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{array} \right\},$$

$$(W_g(S_g)) = (W_g(S_g))' = \left\{ \begin{array}{l} \text{genç} \\ \text{yetişkin} \\ \text{yaşlı} \end{array} \right\},$$

5) $Q(W_g(S_g)) Y_1, S Y_2. [T_1]$ (Eş. 6.14)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m) \otimes \mu_S(d_{Y_3, Y_1})}{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m)} \right) \quad (6.14)$$

"Çoğu yetişkin erkek sesli reklamda pozitiftir."

6) $Q(W_g(S_g)) Y_1, S Y_3 Y_2. [T_1]$ (Eş. 6.15)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m) \otimes \mu_S(d_{Y_1, Y_3 Y_2})}{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m)} \right) \quad (6.15)$$

"Çoğu genç erkek sesli reklamın 2. çeyreğinde gergindir."

Karşılaştırmalı tanımlamalar:

7) $Y_1 Y, S' Y_2. [T_1]$ (Eş. 6.16)

$$T_1 = \mu_{daha} \left(\max(0, \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y_1})}{R} - \frac{\sum_{m=1}^M (\mu_{S'} d_{Y_2})}{R} \right) \right) \right) \quad (6.16)$$

"Web reklamının 1. çeyreği, 2. çeyreğinden daha etkileyicidir."

8) Y daha S', Y'. [T₁] (Eş. 6.17)

$$T_1 = \mu_{daha} \left(\max(0, \left(\frac{\sum_{m=1}^M (\mu_{S'} d_Y)}{R} - \frac{\sum_{m=1}^M (\mu_{S'} d_{Y'})}{R} \right) \right) \right) \quad (6.17)$$

"Genel olarak, web reklamı sesli reklamdan daha etkileyicidir."

9) S'Q₁ Y₃ Y₂, Q₂ Y₃' Y₂'. [T₁] (Eş. 6.18)

$$T_1 = \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y_3, Y_1'})}{R} \right) \otimes \mu_{Q_2} \left(\frac{\sum_{m=1}^M (\mu_{S'} d_{Y_3', Y_2'})}{R} \right) \quad (6.18)$$

"Web reklamının 1. çeyreğinin çoğunda, sesli reklamın 2. çeyreğinin yarısında kişilerde pozitif meyil olmuştur."

10) A) S₁ Q₁ Y₂, S₂ Q₂ Y₂'. [T₁] (Eş. 6.19)

$$T_1 = \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S_1} d_{Y_2})}{R} \right) \otimes \mu_{Q_2} \left(\frac{\sum_{m=1}^M (\mu_{S_2} d_{Y_2'})}{R} \right) \quad (6.19)$$

"Web reklamının çoğunda gerginlik görülürken, sesli reklamın çoğunda heyecan görülmüştür".

B) S₁ Q₁, Y₂ Y₂'. [T₁] (Eş. 6.20)

$$T_1 = \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S_1} d_{Y_2})}{R} \right) \otimes \mu_{Q_1} \left(\frac{\sum_{m=1}^M (\mu_{S_1} d_{Y_2'})}{R} \right) \quad (6.20)$$

"Sesli ve web reklamların ikisinde de çoğu zaman gerginlik görülmüştür."

11) Q W_g(S_g) Y₁, S Y₃ Y₂ Y₃', S(pozitif). [T₁] (Eş. 6.21)

$$T = \mu_{daha} \left(\max(0, \left(\mu_Q \left(\frac{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m) \otimes \mu_{S_p}(d_{Y_3})}{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m)} \right) - \mu_Q \left(\frac{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m) \otimes \mu_{S_p}(d_{Y_3'})}{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m)} \right) \right) \right) \right) \quad (6.21)$$

"Genç erkekler sesli reklamın 2.çeyreğine nispeten 4.çeyrekten daha pozitif etkilenmiştir."

Not: Burada (S), pozitif olarak alınacak.

12) $Y_2, Y_1 Y'_2, S(\text{pozitif}). [T_1]$ (Eş. 6.22)

$$T_1 = \mu_{\text{"daha"}} \left(\text{maks} \left(0, \left(\frac{\sum_{m=1}^M (\mu_{S(\text{pozitif})} d_{Y_2, Y_1})}{R} - \frac{\sum_{m=1}^M (\mu_{S(\text{pozitif})} d_{Y'_2, Y_1})}{R} \right) \right) \right) \quad (6.22)$$

"Sesli reklam, kadınları web reklamından daha fazla pozitif etkiler."

Not: Burada (S), pozitif olarak alınacak.

13) $W_g(S_g) Y_1, Y_2 (W_g(S_g))' Y_1, S(\text{pozitif}). [T_1]$ (Eş. 6.23)

$$T_1 = \mu_{\text{"daha"}} \left(\text{maks} \left(0, \left(\frac{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m) \otimes \mu_{S_p}(d_{Y_2})}{\sum_{m=1}^M \mu_{W_g(S_g)}(d_g^m)} - \frac{\sum_{m=1}^M \mu_{W_g(S_g)'}(d_g^m) \otimes \mu_{S_p}(d_{Y_2})}{\sum_{m=1}^M \mu_{W_g(S_g)'}(d_g^m)} \right) \right) \right) \quad (6.23)$$

"Genç kadınlar, sesli reklamda olgun kadınlara göre daha pozitif etkilenmiştir."

Not: Burada (S), pozitif olarak alınacak.

14) $Y_1 Y_2 Y'_1, S(\text{pozitif}). [T_1]$ (Eş. 6.24)

$$T_1 = \mu_{\text{"daha"}} \left(\text{maks} \left(0, \left(\frac{\sum_{m=1}^M (\mu_{S(\text{pozitif})} d_{Y_1})}{R} - \frac{\sum_{m=1}^M (\mu_{S(\text{pozitif})} d_{Y'_1})}{R} \right) \right) \right) \quad (6.24)$$

"Kadınlar, erkeklere göre sesli reklamdan daha pozitif etkilenmiştir"

Not: Burada (S), pozitif olarak alınacak.

6.3. Granül Tespitli Zaman Serisi Özet Yapıları


Bu bölümde önce çok boyutlu zaman serilerindeki toplu hareketler çok parçalı trend algılama metoduyla tespit edilecektir. Kişilerin eş zamanlı olan duygularının tespit edilmesi için bu yaklaşım önemlidir. Bu bölümdeki dilsel özetlerin diğerlerinden farkı, reklamların kişilerde eş zamanlı olarak ortaya çıkardığı duyguları ve o duyguyu yaşayan kişi miktarını tespit etmektir.

6.3.1. Çok parçalı trend algılama algoritması

Sensör veya farklı kaynaklardan alınan zaman serisi verilerinin önemli bir kısmı topluluk halinde bulunmaktadır [274]. Topluluk şeklinde olan zaman serileri, bir modelin zaman içerisindeki yayılımını gösterebilir ve farklı kaynaklardan gelen verilerle kıyaslama imkânı sunabilir [275]. Fakat bu ham veriler, doğrudan doğal karmaşıklık ve belirsizlikleriyle kullanılırsa analiz edilmeleri zorlaşır. Bu nedenle, verilerdeki belirsizliğin analiz ve görselleştirilmesi için bazı teknikler geliştirilmiştir [275, 276]. Bu tekniklerden en yaygını olan verileri temel istatistiklerine indirgemek yaklaşımı (ısı haritaları gibi), karmaşıklığı azaltıp veriyi görselleştirir. Fakat bu tarz temel yaklaşımlarda, uç noktaların fazlasıyla vurgulanması, yanlış görsel sonuçlar çıkaracağı için veri hakkında ön bilgisi olmayanlara faydalı olmayacaktır.

Hem belirsizliği azaltıp hem de karmaşıklık içerisinde net bilgi sunmayı amaçlayan topolojik gruplama temelli trend belirleme yaklaşımı kullanılmıştır. Buchin ve diğerlerinin [277] ve Van Krevelde ve diğerlerinin [278] çalışmalarına dayanan yöntem, matematiksel alt yapıya sahip olduğu için kanıtlanabilir bilgiler sunmaktadır. Yöntem, girdi verilerindeki bilgileri korurken, yığılma yöntemiyle karmaşıklığı azaltır. Belirlenmiş uzaklık ve süre parametrelerine göre gruplandırma yapılmaktadır.

Seriler, kendi aralarındaki uzaklığa ve bu mesafenin ne kadar süre korunduğuna dayanarak gruplanır. Her grup, dört parametre ile ifade edilir; destek, süre, aralık ve dağılımdır (Şekil 6.6). Destek, grup içerisindeki üye sayısını; süre, grubun başlangıç ve bitiş arasında geçen zamanı; aralık, grubun dikeydeki maksimum genişliğini ve dağılım ise oluşturulan grubun trendini ifade eder [274]. Gruplar oluşturulurken bazı parametreler için limit belirlenir. Bu limitler şöyledir (m, ϵ, δ) ; m , grup içerisindeki minimum üye sayısını; ϵ , gruptaki ardışık iki üyenin arasındaki maksimum uzaklığı ve δ ise grubun minimum süre aralığını göstermektedir [279].




Şekil 6.6. Destek, süre, aralık ve dağılım parametreleri

Algoritmanın genel adımları şöyledir: topluluk halinde olan zaman serilerinin gruplandırılmasında tüm gruplar, başlangıç zamanı olarak kabul edilen t_s anında başladığı kabul edilir. Gruplar, alt gruplara ayrılabilir fakat birleşemezler [274].

- Tüm seriler t_s zamanında artan şekilde sıralanır.
- Ardışık seriler ϵ uzaklığına göre gruba eklenir.
- Grupları tespit etmek için doğrusal tarama yapılır.
- N adet serinin olduğu varsayılır ise t_s anında çalışma süresi $O(N \log N)$ kadar sürer.
- Başlangıçta gruplar belirlendikten sonra grupların durumu tarama ile belirlenir.

Zamanla 3 farklı değişim gözlemlenebilir [274] (Şekil 6.7);



Şekil 6.7. Serilerin farklı durumları; a) tepe durumu, b) kesişim durumu, c) ayrılma durumu

- Tepe Durumu:** Bu durumda önceki komşuluklar iptal edilir ve tüm komşuluklar yeniden hesaplanır.
- Kesişim Durumu:** Ardışık çiftlerin yerleri değiştirilir ve ardışıklık sırası güncellenir.

- c) Ayrılma Durumu: G grubu, G_1 ve G_2 gruplarına ayrılır. Bu alt grupların yeniden tanımlanması için t_s 'den yeniden gruplandırma yapılır.

N adet zaman serisinin uzunluğu τ olduğu varsayılır ise, yukardaki üç duruma göre algoritmanın çalışma süresi $O(\tau n^3 \log n)$ 'dir. Algoritmanın özet kodu Çizelge 6.1'de verilmiştir.


Çizelge 6.1. Algoritmanın özet kodu

Algoritma	
Girdi: $[t_s, t_e]$ aralığında n zaman serisinin boş olmayan bir T kümesi.	
Çıktı: t_s 'den başlayan maksimal grupların $\mathfrak{S}$ kümesi.	
	$\{\epsilon \text{ bağılı başlangıç gruplarını bulun}\}$
1:	t_s 'deki T serilerini artarak sırala
2:	t_s anında tüm maksimum ϵ -bağılı kümeleri bulmak için T 'yi tarayın.
3:	For all başlangıçtaki maksimum ϵ -bağılı G kümeleri için do
4:	E, G 'deki tüm zaman serileri tarafından tümleyen topluluk olsun.
5:	G 'nin G_1 ve G_2 'ye ayrıldığı t' zamanındaki ilk ϵ -bölünmeyi bulmak için E 'yi tarayın. Böyle bir bölünme yoksa $t' = t_e$ olsun.
	$\{G, [t_s, t'] \text{ zaman aralığında maksimal grupta olsun}\}$
6:	G 'yi $[t_s, t']$ zaman aralığı için $\mathfrak{S}$ 'ye ekle.
7:	if $t' \neq t_e$ then
8:	$\mathfrak{S}_1 = G_1$
9:	$\mathfrak{S}_2 = G_2$
10:	$\mathfrak{S}_1$ ve $\mathfrak{S}_2$ 'den $\mathfrak{S}$ 'ye t' 'den daha uzun süren alt gruplar ekleyin.
11:	Return $\mathfrak{S}$

6.3.2. Geliştirilen çok parçalı trend algılama algoritması

Goethem ve diğerlerinin [274] geliştirdikleri algoritma, çok parçalı trend algılama yöntemlerinin en temel hallerinden biridir. Çalışmada kullandıkları algoritmanın temelinde; gruplandırma ilk başlangıç noktasından başlar ve zaman içerisinde gruptaki bir üye gerekli şartı sağlamıyorsa çıkartılır ve alt gruplar oluşturulur. “Gruplar ayrılabilir fakat birleşemez” [274] ilkesiyle ilerlediği için, bu algoritma sadece başlangıç noktasında gerçek yığılmaların trendini çıkartabilir. İlerleyen zaman süreçlerinde, birleşerek oluşan zaman serisi yığılmalarını tespit etmez ve trendini bulamaz.


Şekil 6.8’de görüldüğü gibi gruplandırma başlarda yoğun fakat sonlara doğru ayrılarak ve eksilerek ilerlemektedir. Teknik olarak örnek verilecek olursa; $\{1,2,3,4,5\}$ elemanları bir grup oluştursun. Bu grup eğer üç ana şartı (m, ϵ, δ) sağlamazsa ilerde ayrılıp, $\{1,2\}$ ve $\{3,4,5\}$ gibi iki alt gruba ayrılır. Fakat bu iki alt grup üç ana şartı da sağlayıp tekrar bir yığılma oluştursa bile yeniden tek bir grup olamayacaklardır. Algoritmanın bu özelliği, tüm zamanlardaki yığılmaları tespit edemediğini göstermektedir (Şekil 6.8).



Şekil 6.8. Çok parçalı trend algılama yönteminin en temel hali


Dilsel özetleme çalışması için tüm zaman aralıklarında oluşan yığılmalardaki trendlerin bulunması gereklidir. Çünkü dilsel özetler, tüm veriye bakar. Sadece başlarda yapılan yığılma tespiti, dilsel özetleme için yetersizdir. Özetler, veriyi tam yansıtmaz ve sonuçlar veriyle tutarlı olmaz.

Algoritmanın bu eksikliği, kayan pencere yöntemine dayalı olarak iyileştirilmiştir. Son hali, dilsel özetlemeye elverişlidir. Çünkü verideki tüm yığılmalar, tüm zamanlar için tespit edilebilmektedir. Kayan pencere yönteminde; tüm veri yerine bir birim kaydırılarak veriler parça parça işlenmiştir. Kullanıcının belirlediği süre aralığı (δ) ele alınarak grupta yapılır ve son aralığa kadar bir birim ilerleyerek, her aralıkta algoritma yeniden çalıştırılır. Grup oluşabilmesi için belirlenen minimum süre için algoritma çalıştırıldığında, o aralıktaki tüm yığılmalar tespit edilerek trendler oluşturulmaktadır. Mesela, minimum sürenin $\delta = 3$ olduğu farzedilirse, bakılacak süre aralıkları şöyle olur; $\{1,2,3\}$, $\{2,3,4\}$, ..., $\{8,9,10\}$ (Şekil 6.9).



Şekil 6.9. Kayan pencere yöntemine dayalı bir örnek gösterimi

Her aralık için yeniden çalıştırılan algoritma, yine üç temel parametreye (m, ϵ, δ) bağlı olarak çalışır. Daha sonra tüm trendler birleştirilir ve gruplar, iki şekilde çizdirilir; ilk önce yığılma genişliği kadar şeffaf bir çizim ile grubun geneli gösterilir. Bu genişlik aynı zamanda gruptaki eleman sayısını gösteren bir işlemdir. İkinci çizim ise, grubun ortalaması ile bulunan trend noktalarının çizimidir. Bu çizim şekli (Şekil 6.8), temel alınan çalışmaya dayanmaktadır [274].



Şekil 6.10. Geliştirilmiş algoritma ile elde edilen sonuçlar

Şekil 6.10'da kayan pencere ile geliştirilmiş algoritmanın sonuçları ($m = 3, \epsilon = 0.2, \delta = 3$ değerleri temel alındığında) sunulmuştur. Şekillerde görüldüğü gibi, başlangıçta olmayan gruplanma, şartların sağlanmasıyla sonradan oluşmaktadır. Değişen parametrelerin şartları sağlandığında gruplama yapılabilir. İki seri arası uzaklık (ϵ), verinin maksimum ve minimum farkının seri miktarına bölünmesiyle elde edilmiştir (Eş. 6.25).


$$\epsilon = \frac{\text{maks} - \text{min}}{\text{seri miktarı}} \quad (6.25)$$

Geliştirilmiş bu algoritmanın sonucunda oluşan trendler, dilsel özetleme için kullanılabilir. Çünkü verinin her hangi bir zaman aralığında oluşabilecek yığılmaların davranışları tespit edilebilmektedir.

6.3.3. Dilsel özet yapıları

Şekil 6.11’de herhangi bir reklamı izleyen bütün bireylerin verisini ve tespit edilmiş trendleri ifade eden çok boyutlu zaman serisi ve AW indeksinin ifade ettiği üç duygu, dört temel duygu ve tüm duyguların bulanık kümesi gösterilmektedir.

Özet yapılarında, hem reklam bazlı, hem de zaman bazlı özetler sunulmuştur. Reklamlarda hangi duyguların hangi zaman aralığında çoğu bireyde eş zamanlı görüldüğü özetlenmiştir. Özetlerin protoform yapıları, örnekler ve kullanılan notasyonlar, tanımlardan önce verilmiştir. Tüm protoform yapılarının doğruluk dereceleri verilmiştir. Doğruluk derecesi hesaplanırken minimum t-norm operatörü ($\otimes$) kullanılmıştır.



Şekil 6.11. Granüler trendleri tespit edilen Θ açılı ve AW indeksinden oluşan çok boyutlu zaman serisi ve bulanık kümeler

$$Q = \left\{ \begin{array}{l} \text{çok az} \\ \text{çok} \\ \text{yarısı} \\ \text{en az yarısı} \\ \text{tümü} \end{array} \right\}, \quad Y_1 = Y'_1 = \left\{ \begin{array}{l} \text{web} \\ \text{sesli} \\ \text{video} \end{array} \right\}, \quad Y_2 = Y'_2 = \left\{ \begin{array}{l} \text{birinci} \\ \text{ikinci} \\ \text{üçüncü} \\ \text{dördüncü} \end{array} \right\}$$

$$S = \left\{ \begin{array}{l} \text{mutlu} \\ \text{sevinçli} \\ \text{heyecanlı} \\ \text{uyanık} \\ \text{gergin} \\ \text{sinirli} \\ \text{stresli} \\ \text{üzgün} \\ \text{mutsuz} \\ \text{depresif} \\ \text{bitkin} \\ \text{yorgun} \\ \text{sakin} \\ \text{rahatlamış} \\ \text{dingin} \\ \text{memnun} \end{array} \right\} / \left\{ \begin{array}{l} \text{heyecanlı} \\ \text{stresli} \\ \text{depresif} \\ \text{rahat} \end{array} \right\} / \left\{ \begin{array}{l} \text{pozitif} \\ \text{nötr} \\ \text{negatif} \end{array} \right\},$$

1) $Q Y_1, S, [T_1]$ (Eş. 6.26)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M (\mu_S d_{Y_1})}{R} \right) \quad (6.26)$$

“Sesli reklamlarda çoğu zaman grup olarak aynı anda mutluluk duygusu gözlemlenmiştir.”

2) $Q Y_2 Y_1, S, [T_1]$ (Eş. 6.27)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M (\mu_S d_{Y_2, Y_1})}{R} \right) \quad (6.27)$$

"Sesli reklamın 1.çeyreğinde, çoğu zaman stres duygusu grup olarak aynı anda gözlemlenir."

$$w_{g(S_g)} = \left\{ \begin{array}{l} \text{küçük} \\ \text{orta} \\ \text{yüksek} \end{array} \right\},$$

3) $Q w_{g(S_g)}, Y_1 S, [T_1]$ (Eş. 6.28)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{w_{g(S_g)}}(d_g^m) \otimes \mu_S(d_{Y_1})}{\sum_{m=1}^M \mu_{w_{g(S_g)}}(d_g^m)} \right) \quad (6.28)$$

"Sesli reklamda yüksek bir kalabalık tarafından stres gözlemlendi."

4) $Q_{w_{g(S_g)} Y_2 Y_1, S. [T_1]}$ (Eş. 6.29)

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_{w_{g(S_g)}}(d_g^m) \otimes \mu_S(d_{Y_2, Y_1})}{\sum_{m=1}^M \mu_{w_{g(S_g)}}(d_g^m)} \right) \quad (6.29)$$

"Sesli reklamın 2. çeyreğinde yüksek bir kalabalık tarafından stres gözlemlendi"

5) $S_{Y'_1, Y_1. [T_1]}$ (Eş. 6.30)

$$T_1 = \mu_{daha} \left(\max(0, \left(\frac{\sum_{m=1}^M (\mu_{S(pozitif)} d_{Y_1})}{R} - \frac{\sum_{m=1}^M (\mu_{S(pozitif)} d_{Y_1})}{R} \right) \right) \right) \quad (6.30)$$

"Web reklamında grupsal olarak görülen olumlu etki, sesli reklamdan daha fazladır."




7. UYGULAMA

Literatürde araştırmacılar marka algısı [274]. marka değerlendirme kararı [280, 281]. marka ilişkileri [282, 283]. marka tercihleri [284, 285]. fiyatlandırma [286], ürün paketlenme [287, 288], marka adlandırma [289]. yeşil tüketim [290]. mağaza aydınlatması [291]. reklam [292]. ve yeni ürün geliştirme [293]. gibi farklı pazarlama parametrelerine odaklanmışlardır. Bu çalışmada ise, bir otele ait web sitesi, sesli tanıtım ve video tanıtım olmak üzere 3 farklı reklam, deney seti olarak kullanılmıştır. Çoğu araştırma, deneklerin reklamları izlerken nasıl hissettiklerini yorumlamak amacıyla EEG sinyallerini kaydederken görsel tabanlı reklamları kullanmıştır [294, 295]. Fakat nöropazarlamada yazılı ve sesli deney setleri de kullanılmıştır [296]. Uygulamanın amacı, 3 farklı reklam tipinin, farklı yaş ve cinsiyetlerde etkisinin araştırılmasıdır. EEG verileri duygulara çevrilerek, reklamların tüm zamanlarda kişilerde ortaya çıkardığı duygular incelenmiş ve dilsel özetlemede bu duygular kullanılmıştır.

7.1. Veri Toplama

Her bir reklam 15 kişi tarafından yaklaşık 4-5 dk. incelenirken saniyede iki EEG verisi alınmıştır. Beyin sinyalleri, alına temas eden dört kanallı (TP9, AF7, AF8, TP10) beynin elektriksel aktivitesini kaydeden ve ölçen bir MUSE 2 kafa bandı kullanılarak toplandı (Şekil 7.1) [297-299]. Ek olarak, EEG okumalarının CSV dosya formatına kaydedilmesi için Mind Monitor uygulaması kullanıldı. Uygulama, sestten arındırılmış ve kişilere etki edecek herhangi bir dış etken olmadan yapılmıştır. Deney yapılan katılımcı kişiler, sağlıklı, herhangi bir ilacın etkisinde olmayan kişilerdir. Deney öncesinde veya sırasında kişilere herhangi bir yönlendirme yapılmadan reklamlar izletilmiştir. Her bir katılımcı, bu üç reklamı da rastgele izlemiştir. Deney setinin her bireyde rastgele olması, kişilerde görülen duyguları sağlıklı analiz etmek için önemlidir [300].

Farklı yaş grupları ve farklı cinsiyetler, farklı tercihlere sahip olduğundan, tüketici grupları içinde ve arasında heterojenliğin korunması önerilir [301, 302]. Orta yaş grubundaki (20-35 yaş) kişilerin, ürünlerin çoğunluğunun aktif kullanıcıları olmaları nedeniyle büyük ölçüde bu yaş grubu üzerinde deney yapılmıştır.




Şekil 7.1. MUSE 2 cihazı ve sinyal alınan kanal konumları [301]

7.2. Veri Ön İşleme

EEG sinyalleri genellikle gürültü ve doğal yollarla (artefaktlar ile) bozulur. Sinyal kalitesini ve çıktı doğruluğunu iyileştirmek için bu bozulmaları azaltmak veya ortadan kaldırmak için EEG'yi bazı ön işlemlerle hazırlamak ciddi önem taşır. Gürültülere elektronik amplifikatörler, güç hattı paraziti ve harici parazit neden olur. Bu sapmalar, çoğunlukla göz kırpması ve EEG verilerini kirlüten ve birkaç kanala yayılan baş, omuz, diz ve parmakların hareketleridir. Beyin dalgaları, beş banda karşılık gelen verileri izole etmek için 0,5-50 Hz'lik bir bandpass filtresi [303] kullanılarak filtrelenmiştir. Filtrelenen bu veriler delta, teta, alfa, beta ve gama olarak kategorize edilmiştir [299]. Kişinin gözlem yaparken gözünü kırpması, çene sıkması veya güç hattından kaynaklanan gürültüler sonucunda oluşabilecek problemler için artefakt iyileştiren otomatik algoritmalar, Mind Monitor tarafından uygulanmıştır [304]. Muse2 cihazının belirli alın şekillerine uymaması nedeniyle zaman zaman veri setinde boş değerler görünebilir. Bu değerler, MATLAB'da hareketli ortalama yöntemine dayanan eksik değer doldurma metoduyla tamamlanmıştır. Toplanan ve iletilen EEG verilerindeki gereksiz veri sütunları, göz kırpma, çene sıkma, kas aktivitesi, cihaz ivmeölçer, cihaz pil gücü durumu vb. ile ilgili verileri içerir. Bu alakasız sütunlar veri setinden çıkarılmıştır [305].

Diğer ön işlemler ise, Bölüm 5.1, 5.2 ve 5.3'de detaylandırılan; uyarılma/değerlik değer hesaplaması, uyarılma/değerlik değerlerinin normalizasyonu, duygu-durum tespiti için θ açısının hesaplanması ve son olarak AW indeksinin hesaplanmasıdır. Böylece tüm ön işlemler (Şekil 7.2), verimli bir veri elde etmek için uygulanmış oldu.



Şekil 7.2. Veri ön işleme adımları

7.3. Özellik Çıkarma

MUSE2 kafa bandı, verileri dört kanaldan iletir. Bu nedenle alfa, beta, gama, beta, teta, delta okumaları her kanaldan gelir. Fakat nöropazarlama çalışmalarında duruma göre farklı özellikler kullanılmıştır. Yapılan çalışmalar gösteriyor ki her araştırma, odaklandığı konu için farklı sinyal bantlarını ve farklı EEG konumlarını kullanmaktadır [27].

Film fragmanlarını izleyen tüketicilerin beta ve gama salınımları, gişe satışlarını ve sipariş iptalini tahmin etmek için kullanılmıştır [305]. Bu faktörler aynı zamanda tüketici tercihini ve seçimini değerlendirmek için ödeme istekliliğinin bir göstergesi olarak kullanılmıştır [110]. Alfa salınımları, sinirsel benzerliği hesaplamak ve iptal edilen siparişleri ve bilet satışlarını tahmin etmek için kullanılmıştır. Yüksek frekanslı EEG bileşenleri hem bireysel tercihe (beta dalgası) hem de kalabalığın tercihine (gama dalgası) bağlıdır [306].

Bunlara ek olarak, alfa frontal asimetri, tüketicilerin ürünün çekiciliğine karşı bilinçsiz tepkileriyle bağlantılıdır [273]. Benzer şekilde, Modica ve diğerlerinin [306]. yüksek alfa frekanslarını, yabancı gıda ve lezzetli yiyeceklerle alakalı olduğunu göstermiştir. Ayrıca, sigara karşıtı kamu hizmeti duyurularında ödüllü kampanyalar (yani ödül alan kampanyalar) daha yüksek alfa frekanslarıyla ilişkili iken [270]. düşük teta frekansları, ürün seçimine yönelik olumsuz sonuçlar vermektedir [306]. Ayrıca, teta frekanslarının, yerel ürün reklamlarına kıyasla sigara karşıtı kamu hizmeti duyurularıyla [271]. ve yabancı ürünlerle [114]. daha çok ilişkili olduğu gösterilmiştir.

Bu çalışmada ise 3 farklı reklam karşısında kişilerin duygu durumları tespit edileceğinden, uyarılma ve değerlik değerlerini ilgilendiren ve AW indeksini veren EEG noktaları ve frekans tipleri hesaba alınmıştır. Uyarılma değeri, beta ile alfa değerlerinin oranıyla; değerlik

ise, frontal EEG asimetrisinin aktivasyonu ile bulunmaktadır [271]. Bölüm 5.1’de bahsedilen uyarılma ve değerklik değerklerinin hesaplanması için Ramirez ve diğerlerinin [264]. kullandıkları yaygın hesaplama yöntemleri kullanılmıştır. AW indeksinde ise pozitif AW değerkleri, sol frontal korteksin daha yüksek aktivasyonu olarak ifade edilen pozitif motivasyona (yaklaşma davranışları) karşılık gelir. Buna karşılık, negatif AW değerkleri, sol frontal korteksin daha yüksek aktivasyonu olarak ifade edilen negatif motivasyona (kaçınma davranışları) karşılık gelir [110, 269]. Özet olarak, bu çalışmada (formülleri bölüm 5.1’de detaylı verilen) AF7 ve AF8 EEG konumları ve alfa ve beta frekans bantları kullanılmıştır.



8. SONUÇ VE ÖNERİLER

8.1. Tek Boyutlu Zaman Serisi Özet Sonuçları

Bu bölüm, tüm bireylerin her reklama göre bireysel olarak özetlenmesi amaçlı oluşturulmuştur. 1. protoform, her bireyin her bir reklama göre hissettiği duygunun özetini, 2. protoform, her reklamın her bir bölümünde görülen duyguların bireysel özetini, 3. ve 4. protoform yapıları ise duygular yerine AW indeksi etiketlerini kullanarak reklamların ve reklam bölümlerinin bireylere göre özetini sunmuştur.

Karşılaştırmalı özet yapısında ise; 5. protoform, her reklamın bölümlerini kendi içinde ve 6. protoform, reklamları birbirleriyle karşılaştırarak birey bazında özetlemiştir. 7. protoform, bireylerin olumlu etkilendiği reklam bölümlerini sunarak özet çıkartırken; 8. protoform yapısında duygu bazında iki reklamı karşılaştırmış ve birleştirmiştir. Doğruluk derecesi en yüksek olan bazı anlamlı ve kullanılabılır dilsel özetleme sonuçları aşağıda verilmiştir;

1. protoformda sesli reklam için rastgele örnek olarak alınan özet sonuçlarında kişilerde mutluluk duygusu ile rahatlama görülmüştür. Fakat bunun aksine video ile web reklamında stres ve depresif duygular görülmüştür. Hem kişilerin karşılaştırılacağı hem de reklamların aynı kişiler üzerinden karşılaştırılacağı özetler elde edilmiştir (Çizelge 8.1).

Çizelge 8.1. Tek boyutlu zaman serileri için protoform-1 sonuçları

	Protoform-1	TD
Sesli	Sesli reklamın en az yarısında, 15. katılımcı mutlu	1
	Sesli reklamın en az yarısında, 17. katılımcı bitkin	0,86
	Sesli reklamın çoğu sırasında, 7. katılımcı rahatlamış	0,85
Video	Video reklamın en az yarısında, 15. katılımcı stresli	1
	Video reklamın en az yarısında, 17. katılımcı depresif	1
	Video reklamın en az yarısında, 7. katılımcı rahatlamış	1
Web	Video reklamın çoğu sırasında, 15. katılımcı stresli	0,97
	Video reklamın en az yarısında, 17. katılımcı depresif	1
	Video reklamın en az yarısında, 7. katılımcı rahatlamış	1

Protoform-2’de reklamlar aynı kişiler ve aynı reklam bölümleri üzerinden ele alınmış ve sesli reklamın 1. bölümünün daha olumlu duygular verdiği gözlemlenmiştir (Çizelge 8.2).

Çizelge 8.2. Tek boyutlu zaman serileri için protoform-2 sonuçları

	Protoform-2	TD
Sesli	Sesli reklamın 1. çeyreğinin en az yarısında, 15. katılımcı mutlu görünüyor.	1
	Sesli reklamın 1. çeyreğinin en az yarısında, 17. katılımcı halsiz görünüyor.	0,83
	Sesli reklamın 1. çeyreğinin az bir kısmında, 5. katılımcı rahatlamış görünüyor.	0,97
Video	Video reklamın 1. çeyreğinin çoğunda, 15. katılımcı zorlanmış görünüyor.	1
	Video reklamın 1. çeyreğinin en az yarısında, 17. katılımcı kötümser görünüyor.	1
	Video reklamın 1. çeyreğinin en az yarısında, 5. katılımcı kötümser görünüyor.	1
Web	Web reklamının 1. çeyreğinin en az yarısında, 15. katılımcı gergin görünüyor.	0,9
	Web reklamının 1. çeyreğinin az bir kısmında, 17. katılımcı halsiz görünüyor.	0,78
	Web reklamının 1. çeyreğinin az bir kısmında, 5. katılımcı dingin görünüyor.	0,9

Protoform-3’de rasgele yine aynı kişiler üzerinden AW göstergesine göre duygulara bakılmış ve web reklamının bu kişiler üzerinde daha etkili olduğu görülmüştür (Çizelge 8.3).

Çizelge 8.3. Tek boyutlu zaman serileri için protoform-3 sonuçları

	Protoform-3	TD
Sesli	Sesli reklamın çoğunda, katılımcı 15’in reklam için olumsuz eğilimleri var	1
	Sesli reklamın çoğunda, katılımcı 17’nin reklam için olumsuz eğilimleri var	1
	Sesli reklamın çoğunda, katılımcı 7’nin reklam için olumsuz eğilimleri var	1
Video	Video reklamın en az yarısında, katılımcı 15’in reklam için nötr eğilimleri var	1
	Video reklamın en az yarısında, katılımcı 17’nin reklam için olumsuz eğilimleri var	1
	Video reklamın çoğunda, katılımcı 5’in reklam için olumlu eğilimleri var	0,72
Web	Web reklamının en az yarısında, katılımcı 15’in reklam için olumlu eğilimleri var	1
	Web reklamının çoğunda, katılımcı 17’nin reklam için olumsuz eğilimleri var	0,74
	Web reklamının en az yarısında, katılımcı 5’in reklam için nötr eğilimleri var	1

Protoform-4’de rasgele seçilen aynı kişilerin reklam bölümlerine AW göstergesi üzerinden duygulara bakılmış ve web reklamının bu kişiler üzerinde daha etkili olduğu görülmüştür (Çizelge 8.4).

Çizelge 8.4. Tek boyutlu zaman serileri için protoform-4 sonuçları

	Protoform-4	TD
Sesli	Sesli reklamın 1. çeyreğinin çoğunda, katılımcı 15’in olumsuz eğilimleri var	1
	Sesli reklamın 1. çeyreğinin çoğunda, katılımcı 17’nin olumsuz eğilimleri var	1
	Sesli reklamın 1. çeyreğinin çoğunda, katılımcı 5’in olumlu eğilimleri var	1
Video	Video reklamın 1. çeyreğinin en az yarısında, katılımcı 15’in nötr eğilimleri var	1
	Video reklamın 1. çeyreğinin en az yarısında, katılımcı 17’nin olumsuz eğilimleri var	1
	Video reklamın 1. çeyreğinin çoğunda, katılımcı 5’in olumlu eğilimleri var	1
Web	Web reklamın 1. çeyreğinin en az yarısında, katılımcı 15’in nötr eğilimleri var	1
	Web reklamın 1. çeyreğinin en az yarısında, katılımcı 17’nin olumsuz eğilimleri var	1
	Web reklamın 1. çeyreğinin çoğunda, katılımcı 5’in olumlu eğilimleri var	1

Protoform-5’de reklam bölümleri karşılaştırılmış ve şu sonuç elde edilmiş; sesli reklamda kişiyi daha çok etkileyen reklam bölümlerinin sırası 1, 3, 2, 4’dür, video reklamda 1, 4, 3, 2’dir ve web reklamında 3, 4, 1, 2’dir (Çizelge 8.5).

Çizelge 8.5. Tek boyutlu zaman serileri için protoform-5 sonuçları

	Protoform-5	TD
Sesli	Sesli reklamın 1. çeyreği, katılımcı 2 için 2. çeyreğe göre daha olumlu bir etki oluşturdu.	0,39
	Sesli reklamın 1. çeyreği, katılımcı 2 için 4. çeyreğe göre daha olumlu bir etki oluşturdu.	0,65
	Sesli reklamın 3. çeyreği, katılımcı 2 için 2. çeyreğe göre daha olumlu bir etki oluşturdu.	0,21
	Sesli reklamın 3. çeyreği, katılımcı 2 için 4. çeyreğe göre daha olumlu bir etki oluşturdu.	0,48
Video	Video reklamın 1. çeyreği, katılımcı 12 için 2. çeyreğe göre daha olumlu bir etki oluşturdu.	0,73
	Video reklamın 1. çeyreği, katılımcı 12 için 3. çeyreğe göre daha olumlu bir etki oluşturdu.	0,38
	Video reklamın 4. çeyreği, katılımcı 12 için 2. çeyreğe göre daha olumlu bir etki oluşturdu.	0,59
	Video reklamın 4. çeyreği, katılımcı 12 için 3. çeyreğe göre daha olumlu bir etki oluşturdu.	0,25
Web	Web reklamının 3. çeyreği, katılımcı 7 için 2. çeyreğe göre daha olumlu bir etki oluşturdu.	0,38
	Web reklamının 3. çeyreği, katılımcı 7 için 1. çeyreğe göre daha olumlu bir etki oluşturdu.	0,33
	Web reklamının 4. çeyreği, katılımcı 7 için 2. çeyreğe göre daha olumlu bir etki oluşturdu.	0,38
	Web reklamının 4. çeyreği, katılımcı 7 için 1. çeyreğe göre daha olumlu bir etki oluşturdu.	0,32

Protoform-6’da iki kişinin özet sonuçları ele alınmış ve 5. kişide reklamların olumlu etki sırası video, sesli ve web olarak sıralanırken, 10. kişide web, sesli ve videodur (Çizelge 8.6).

Çizelge 8.6. Tek boyutlu zaman serileri için protoform-6 sonuçları

Protoform-6	TD
Katılımcı 5 için video reklam, sesli reklama göre daha olumlu bir etki oluşturdu.	0,15
Katılımcı 5 için video reklam, web reklamına göre daha olumlu bir etki oluşturdu.	1
Katılımcı 5 için sesli reklam, web reklamına göre daha olumlu bir etki oluşturdu.	1
Katılımcı 10 için web reklamı, video reklama göre daha olumlu bir etki oluşturdu.	1
Katılımcı 10 için web reklamı, sesli reklama göre daha olumlu bir etki oluşturdu.	0,83
Katılımcı 10 için sesli reklam, video reklama göre daha olumlu bir etki oluşturdu.	0,93

Protoform-7’de kişilerde en çok görülen pozitif duygunun hangi iki reklam bölümünde olduğunu özetlemiştir. Videonun 1. bölümünde ve web’in 1., 2., 3. ve 4. bölümünde çoğu zaman görülmektedir (Çizelge 8.7).

Çizelge 8.7. Tek boyutlu zaman serileri için protoform-7 sonuçları

Protoform-7	TD
Katılımcı 7 için, pozitif eğilimler video reklamın 1. çeyreğinin çoğunda ve web reklamının 1. çeyreğinin çoğunda gözlemlendi	1
Katılımcı 7 için, pozitif eğilimler video reklamın 1. çeyreğinin çoğunda ve web reklamının 2. çeyreğinin çoğunda gözlemlendi	1
Katılımcı 7 için, pozitif eğilimler video reklamın 1. çeyreğinin çoğunda ve web reklamının 3. çeyreğinin çoğunda gözlemlendi	1
Katılımcı 7 için, pozitif eğilimler video reklamın 1. çeyreğinin çoğunda ve web reklamının 4. çeyreğinin çoğunda gözlemlendi	1

Protoform-8’de kişiler üzerinde çoğu zaman görülen aynı duygu ile birbirine zıt iki duygunun özetlerini oluşturmuştur (Çizelge 8.8).

Çizelge 8.8. Tek boyutlu zaman serileri için protoform-8 sonuçları

	Protoform-8	TD
Benzer	Katılımcı 15 için, sıkılmış duygusu hem video reklamda hem de web reklamında en çok gözlemlenen duygudur.	0,97
	Katılımcı 17 için, kötümser duygu hem sesli reklamda hem de video reklamda en çok gözlemlenen duygudur.	0,60
Zıt	Katılımcı 14 için, sesli reklamda en çok kötümser duygu gözlemlenirken, buna karşılık video reklamda en çok heyecanlı duygu gözlemlenmiştir.	0,51
	Katılımcı 4 için, sesli reklamda en çok kötümser duygu gözlemlenirken, buna karşılık video reklamda en çok sıkılmış duygusu gözlemlenmiştir.	0,48

8.2. Çok Boyutlu Zaman Serisi Özet Sonuçları

Bu bölümde, her reklama göre bireylerin duyguları toplu bir şekilde özetlenmiştir. 1. protoform, her reklamda hissedilen duyguların özetini, 2. protoform, her reklamın her bir bölümünde görülen duyguların özetini, 3. ve 4. protoform yapıları ise AW indeks duygularının reklam ve reklam bölümlerine göre özetini sunmuştur. 5. ve 6. protoformlarda reklamlar ve reklam bölümleri cinsiyete ve yaşa göre özetleme yapmıştır.

Karşılaştırmalı protoform yapılarında ise; 7. protoformda reklamların bölümleri, 8. protoformda ise reklamlar kendi aralarında karşılaştırılarak özetlenmiştir. 9. protoform, bireylerin olumlu etkilendiği reklam bölümlerini sunarak özet çıkartırken; 10. protoform yapısında duygu bazında iki reklam karşılaştırılmış ve birleştirilmiştir. Protoform-11, reklam bölümlerini cinsiyet ve yaş bazında karşılaştırıp özetlemiştir. 12. protoform yapısında, cinsiyetlere göre reklamların etkisi karşılaştırılarak özetlenmiştir, 13. protoform yapısında ise reklamların etkileri kişilerin yaşlarına göre özetlenmiştir. Reklamların, cinsiyetler ve yaşlar üzerindeki etkisi görülmüştür. Son olarak, 14. protoformda cinsiyetlerin reklamlardan etkilene oranları karşılaştırılmıştır. Reklamlara göre cinsiyetlerin etkilene durumunu ifade eder.

1. protoform yapısında, genel olarak sesli reklamın, kişileri olumlu yönde daha çok etkilediği özetlerden anlaşılmaktadır (Çizelge 8.9).

Çizelge 8.9. Çok boyutlu zaman serileri için protoform-1 sonuçları

	Protoform-1	TD
Sesli	Sesli reklamın çoğunda, katılımcılar heyecanlı	1
	Sesli reklamın çoğunda, katılımcılar sakin	1
	Sesli reklamın az bir kısmında, katılımcılar sıkılmış	0,87
Video	Video reklamın az bir kısmında, katılımcılar sakin	0,9
	Video reklamın az bir kısmında, katılımcılar kötümser	0,9
	Video reklamın az bir kısmında, katılımcılar sıkılmış	0,9
Web	Web reklamının az bir kısmında, katılımcılar sakin	0,95
	Web reklamının az bir kısmında, katılımcılar sıkılmış	0,9
	Web reklamının az bir kısmında, katılımcılar heyecanlı	0,88

Reklam bölümlerinin özetlendiği protoform-2 'de, sesli reklamın bölümlerinin de kişileri heyecanlandığı görülmüştür (Çizelge 8.10).

Çizelge 8.10. Çok boyutlu zaman serileri için protoform-2 sonuçları

	Protoform-2	TD
Sesli	Sesli reklamın 1. çeyreğinin çoğunda, katılımcılar heyecanlı	1
	Sesli reklamın 2. çeyreğinin çoğunda, katılımcılar heyecanlı	1
	Sesli reklamın 3. çeyreğinin çoğunda, katılımcılar heyecanlı	1
Video	Video reklamın 1. çeyreğinin az bir kısmında, katılımcılar kötümser	0,98
	Video reklamın 4. çeyreğinin az bir kısmında, katılımcılar kötümser	0,98
	Video reklamın 2. çeyreğinin az bir kısmında, katılımcılar sıkılmış	0,97
Web	Web reklamının 3. çeyreğinin az bir kısmında, katılımcılar sakin	0,97
	Web reklamının 2. çeyreğinin az bir kısmında, katılımcılar heyecanlı	0,96
	Web reklamının 4. çeyreğinin az bir kısmında, katılımcılar sıkılmış	0,95

3. protoformda AW indeksine göre özetleme yapılmış ve video reklamında nötr ve web reklamında ise pozitif duygunun hakim olduğu görülmüştür (Çizelge 8.11).

Çizelge 8.11. Çok boyutlu zaman serileri için protoform-3 sonuçları

	Protoform-3	TD
Sesli	Sesli reklamın en az yarısında, katılımcılar olumsuz eğilimlere sahip.	0,82
	Sesli reklamın en az yarısında, katılımcılar nötr eğilimlere sahip.	0,8
	Sesli reklamın az bir kısmında, katılımcılar olumlu eğilimlere sahip.	0,74
Video	Video reklamın en az yarısında, katılımcılar nötr eğilimlere sahip.	1
	Video reklamın yarısında, katılımcılar nötr eğilimlere sahip.	0,96
	Video reklamın az bir kısmında, katılımcılar olumsuz eğilimlere sahip.	0,7
Web	Web reklamının az bir kısmında, katılımcılar olumsuz eğilimlere sahip.	0,99
	Web reklamının en az yarısında, katılımcılar olumlu eğilimlere sahip.	0,79
	Web reklamının en az yarısında, katılımcılar nötr eğilimlere sahip.	0,7

4. protoform yapısında reklam bölümlerinde görülen duygular AW indeksi bazında özetlenmiştir ve reklamların hangi bölümünde negatif duygu oluştuğu tespit edilmiştir (Çizelge 8.12).

Çizelge 8.12. Çok boyutlu zaman serileri için protoform-4 sonuçları

	Protoform-4	TD
Sesli	Sesli reklamın 2. çeyreğinin en az yarısında, katılımcılar olumsuz eğilimlere sahip	0,86
	Sesli reklamın 4. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	0,86
	Sesli reklamın 3. çeyreğinin en az yarısında, katılımcılar olumsuz eğilimlere sahip	0,84
Video	Video reklamın 2. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	1
	Video reklamın 4. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	1
	Video reklamın 3. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	1
Web	Web reklamının 2. çeyreğinin az bir kısmında, katılımcılar olumsuz eğilimlere sahip	0,95
	Web reklamının 4. çeyreğinin az bir kısmında, katılımcılar olumsuz eğilimlere sahip	0,94
	Web reklamının 3. çeyreğinin az bir kısmında, katılımcılar olumsuz eğilimlere sahip	0,92

Protoform-5’de reklamlar, cinsiyet ve yaşa göre özetler oluşturulmuştur. Kadınların yaşlarına göre alınan örnek cümlelerde, web reklamının tüm yaşları olumlu etkilediği görülmüştür. Fakat en çok olumlu etki, yaşlı grubunda olan kişilerde görülmüştür (Çizelge 8.13).

Çizelge 8.13. Çok boyutlu zaman serileri için protoform-5 sonuçları

	Protoform-5	TD
Sesli	Sesli reklamın 2. çeyreğinin en az yarısında, katılımcılar olumsuz eğilimlere sahip	1
	Sesli reklamın 4. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	1
	Sesli reklamın 3. çeyreğinin en az yarısında, katılımcılar olumsuz eğilimlere sahip	0,78
Video	Video reklamın 2. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	1
	Video reklamın 4. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	1
	Video reklamın 3. çeyreğinin en az yarısında, katılımcılar nötr eğilimlere sahip	0,87
Web	Web reklamının 2. çeyreğinin az bir kısmında, katılımcılar olumsuz eğilimlere sahip	0,86
	Web reklamının 4. çeyreğinin az bir kısmında, katılımcılar olumsuz eğilimlere sahip	0,85
	Web reklamının 3. çeyreğinin az bir kısmında, katılımcılar olumsuz eğilimlere sahip	0,67

Protoform-6’da reklamların bölümleri, cinsiyet ve yaşa göre özetler oluşturulmuştur. Reklamların 3. bölümü örnek olarak alınmış ve kişilerin kötümser bir duygu hissettiği görülmüştür (Çizelge 8.14).

Çizelge 8.14. Çok boyutlu zaman serileri için protoform-6 sonuçları

	Protoform-6	TD
Sesli	Sesli reklamın 3. çeyreğinde genç erkeklerin en az yarısı sakin	0,8
	Sesli reklamın 3. çeyreğinde yetişkin erkeklerin az bir kısmı kötümser	0,9
	Sesli reklamın 3. çeyreğinde yaşlı erkeklerin en az yarısı sakin	0,9
Video	Video reklamın 3. çeyreğinde genç erkeklerin en az yarısı gergin	0,7
	Video reklamın 3. çeyreğinde yetişkin erkeklerin az bir kısmı coşkulu	0,7
	Video reklamın 3. çeyreğinde yaşlı erkeklerin az bir kısmı stresli	0,7
Web	Web reklamının 3. çeyreğinde genç erkeklerin en az yarısı kötümser	0,9
	Web reklamının 3. çeyreğinde yetişkin erkeklerin az bir kısmı heyecanlı	0,8
	Web reklamının 3. çeyreğinde yaşlı erkeklerin en az yarısı kötümser	1

7. protoformda reklamlara göre reklam bölümlerinin etkileri karşılaştırılmış ve sesli reklamda etki sırası şöyle görülmüştür; bölüm 1, 2, 4 ve 3. Video reklamda, bölüm 2, 3, 1 ve 4 ve son olarak web reklamında sırasıyla bölüm 2, 1, 3 ve 4 daha etkilidir (Çizelge 8.15).

Çizelge 8.15. Çok boyutlu zaman serileri için protoform-7 sonuçları

	Protoform-7	TD
Sesli	Sesli reklamın 1. çeyreği, 3. çeyreğe göre daha olumlu bir etkiye sahip	0,06
	Sesli reklamın 2. çeyreği, 3. çeyreğe göre daha olumlu bir etkiye sahip	0,04
	Sesli reklamın 4. çeyreği, 3. çeyreğe göre daha olumlu bir etkiye sahip	0,03
	Sesli reklamın 2. çeyreği, 4. çeyreğe göre daha olumlu bir etkiye sahip	0,01
Video	Video reklamın 2. çeyreği, 1. çeyreğe göre daha olumlu bir etkiye sahip	0,04
	Video reklamın 2. çeyreği, 4. çeyreğe göre daha olumlu bir etkiye sahip	0,04
	Video reklamın 2. çeyreği, 3. çeyreğe göre daha olumlu bir etkiye sahip	0,02
	Video reklamın 3. çeyreği, 1. çeyreğe göre daha olumlu bir etkiye sahip	0,02
Web	Web reklamının 1. çeyreği, 4. çeyreğe göre daha olumlu bir etkiye sahip	0,03
	Web reklamının 1. çeyreği, 3. çeyreğe göre daha olumlu bir etkiye sahip	0,01
	Web reklamının 3. çeyreği, 4. çeyreğe göre daha olumlu bir etkiye sahip	0,01
	Web reklamının 2. çeyreği, 3. çeyreğe göre daha olumlu bir etkiye sahip	0,01

Reklamlar hakkında en genel özet, protoform-8'de verilmiştir. Bu özet yapısında, reklamların etkileri karşılaştırılmış ve etki sırası iyiden kötüye şöyledir, web, sesli ve video reklamıdır (Çizelge 8.16).

Çizelge 8.16. Çok boyutlu zaman serileri için protoform-8 sonuçları

Protoform-8	TD
Genel olarak, web reklamı, video reklama göre daha olumlu bir etkiye sahip	0,46
Genel olarak, web reklamı, sesli reklama göre daha olumlu bir etkiye sahip	0,42
Genel olarak, sesli reklam, video reklama göre daha olumlu bir etkiye sahip	0,03

Protoform-9'da kişilerin reklamlara pozitif eğilimlerinin hangi bölümlerde görüldüğü özetlenmiştir (Çizelge 8.17).

Çizelge 8.17. Çok boyutlu zaman serileri için protoform-9 sonuçları

Protoform-9		TD
	Olumlu eğilim, sesli reklamın 1. çeyreğinin az bir kısmında ve web reklamının 1. çeyreğinin en az yarısında gözlemlenmiştir	0,79
	Olumlu eğilim, sesli reklamın 1. çeyreğinin az bir kısmında ve web reklamının 2. çeyreğinin en az yarısında gözlemlenmiştir	0,79
	Olumlu eğilim, sesli reklamın 1. çeyreğinin az bir kısmında ve web reklamının 3. çeyreğinin en az yarısında gözlemlenmiştir	0,79

Protoform-10'da kişiler üzerinde çoğu zaman görülen aynı duygu ile birbirine zıt iki duygunun özetleri oluşturulmuştur. Kişilerin çoğu zaman reklamlara karşı nötr bir durumda oldukları görülmektedir (Çizelge 8.18).

Çizelge 8.18. Çok boyutlu zaman serileri için protoform-10 sonuçları

Protoform-10		TD
Be	Hem sesli reklamda hem de video reklamda nötr duygu çoğu zaman gözlemlenmiştir	0,03
	Hem video reklamda hem de web reklamında nötr duygu çoğu zaman gözlemlenmiştir	0,03
Zıt	Sesli reklamda olumlu duygu çoğu zaman gözlemlenirken, buna karşılık video reklamda nötr duygu çoğu zaman gözlemlenmiştir	0,51
	Video reklamda nötr duygu çoğu zaman gözlemlenirken, buna karşılık web reklamında olumsuz duygu çoğu zaman gözlemlenmiştir	0,48

Protoform-11, reklam bölümlerini cinsiyet ve yaş bazında karşılaştırıp özetlemiştir. Reklamların 1. bölümlerinin daha etkili olduğu anlaşılmaktadır (Çizelge 8.19).

Çizelge 8.19. Çok boyutlu zaman serileri için protoform-11 sonuçları

Protoform-11		TD
Sesli	Yaşlı erkeklerin en az yarısı, sesli reklamın 1. çeyreğinden 2. çeyreğe göre daha fazla etkilenmiştir	0,28
	Yaşlı erkeklerin en az yarısı, sesli reklamın 1. çeyreğinden 3. çeyreğe göre daha fazla etkilenmiştir	0,46
Video	Yaşlı erkeklerin az bir kısmı, video reklamın 1. çeyreğinden 2. çeyreğe göre daha fazla etkilenmiştir	0,31
	Yaşlı erkeklerin az bir kısmı, video reklamın 1. çeyreğinden 3. çeyreğe göre daha fazla etkilenmiştir	0,01
Web	Yaşlı erkeklerin az bir kısmı, web reklamının 1. çeyreğinden 2. çeyreğe göre daha fazla etkilenmiştir	0,01
	Yaşlı erkeklerin az bir kısmı, web reklamının 1. çeyreğinden 3. çeyreğe göre daha fazla etkilenmiştir	0,05

12. protoform yapısında, cinsiyetlere göre reklamların etkisi karşılaştırılarak özetlenmiştir. Erkekleri sırasıyla en çok web, video ve sesli reklamlar etkilerken, kadınları en çok web, sesli ve video reklamı etkilemiştir (Çizelge 8.20).

Çizelge 8.20. Çok boyutlu zaman serileri için protoform-12 sonuçları

	Protoform-12	TD
Erkek	Genel olarak, video reklam erkekleri sesli reklama göre daha olumlu etkiliyor	0,04
	Genel olarak, web reklamı erkekleri sesli reklama göre daha olumlu etkiliyor	0,43
	Genel olarak, web reklamı erkekleri video reklama göre daha olumlu etkiliyor	0,38
Kadın	Genel olarak, sesli reklam kadınları video reklama göre daha olumlu etkiliyor	0,15
	Genel olarak, web reklamı kadınları sesli reklama göre daha olumlu etkiliyor	0,40
	Genel olarak, web reklamı kadınları video reklama göre daha olumlu etkiliyor	0,56

13. protoform yapısında ise reklamların etkileri aynı cinsiyette olan kişilerin yaşları üzerinden özetlenmiştir. Reklamların, cinsiyetler ve yaşlar üzerindeki etkisi görülmüştür. Buna göre, sesli reklamdan en çok etkilenen sırasıyla genç, yaşlı ve yetişkin; video reklamdan en çok etkilenen yaşlı, genç ve yetişkin ve son olarak web reklamından en çok etkilenen yaş grubu yetişkin, yaşlı ve gençtir (Çizelge 8.21).

Çizelge 8.21. Çok boyutlu zaman serileri için protoform-13 sonuçları

	Protoform-13	TD
Sesli	Genç kadınlar, sesli reklamdan yaşlı kadınlara göre daha olumlu etkileniyor	0,01
	Yaşlı kadınlar, sesli reklamdan yetişkin kadınlara göre daha olumlu etkileniyor	0,05
Video	Genç kadınlar, video reklamdan yetişkin kadınlara göre daha olumlu etkileniyor	0,03
	Yaşlı kadınlar, video reklamdan genç kadınlara göre daha olumlu etkileniyor	0,15
Web	Yaşlı kadınlar, web reklamından genç kadınlara göre daha olumlu etkileniyor	0,09
	Yetişkin kadınlar, web reklamından yaşlı kadınlara göre daha olumlu etkileniyor	0,06

Son olarak, 14. protoformda cinsiyetlerin reklamlardan etkilenme oranları karşılaştırılmıştır. Reklamlara göre cinsiyetlerin etkilenme durumunu ifade eder. Tüm reklamlarda, erkekler kadınlara göre daha çok etkilenmiştir (Çizelge 8.22).

Çizelge 8.22. Çok boyutlu zaman serileri için protoform-14 sonuçları

	Protoform-14	TD
Erkekler, video reklamdan kadınlara göre daha olumlu etkileniyor		0,23
Erkekler, web reklamından kadınlara göre daha olumlu etkileniyor		0,05
Erkekler, sesli reklamdan kadınlara göre daha olumlu etkileniyor		0,03

8.3. Granüler Trend Tespitli Zaman Serisi Özet Sonuçları

Bu bölümde, toplamda 5 protoform yapısı ile reklamlarda duygu yoğunluğu/yığılması özetlenmiştir. Protoform-1'de reklamlardaki, protoform-2 de ise reklam bölümlerindeki duygu yığılmaları genel olarak özetlenmiştir. Protoform-3 ve protoform-4'de, tespit edilen

duygu yoğunluklarının nasıl bir kalabalık tarafından hissedildiği reklam ve bölümleri bazında özetlenmiştir. Son olarak, protoform-5’de ise pozitif duygu yoğunluklarını reklamları karşılaştırarak özetlenmiştir.

Protoform-1’de kişilerin reklamlara karşı nötr kalma durumları aynı anda en çok hissedilen duygular arasında gelmektedir. Bunun haricinde kişilerde olumsuz duygu yoğunluğu hâkimdir (Çizelge 8.23).

Çizelge 8.23. Granül tespitli zaman serileri için protoform-1 sonuçları

	Protoform-1	TD
Sesli	Sesli reklamda kısa süreliğine grup olarak heyecan gözlemlenmiştir	0,9
	Sesli reklamda kısa süreliğine grup olarak sakinlik gözlemlenmiştir	0,9
	Sesli reklamda en az yarısı boyunca grup olarak nötr duygular gözlemlenmiştir	1
Video	Video reklamda kısa süreliğine grup olarak karamsarlık gözlemlenmiştir	0,9
	Video reklamda kısa süreliğine grup olarak sakinlik gözlemlenmiştir	0,9
	Video reklamda en az yarısı boyunca grup olarak nötr duygular gözlemlenmiştir	0,9
Web	Web reklamında en az yarısı boyunca grup olarak nötr duygular gözlemlenmiştir	1
	Web reklamında kısa süreliğine grup olarak olumlu duygular gözlemlenmiştir	0,9
	Web reklamında kısa süreliğine grup olarak olumsuz duygular gözlemlenmiştir	0,8

2. protoform yapısında, reklam bölümleri karşılaştırılmıştır. Alınan örnek özetlere göre reklamların ilk üç bölümünde de tespit edilen yığılmalar, nötr duygusunu yansıtmaktadır. Yani, kişiler reklama karşı nötr kalmışlardır (Çizelge 8.24).

Çizelge 8.24. Granül tespitli zaman serileri için protoform-2 sonuçları

	Protoform-2	TD
Sesli	Sesli reklamın 1. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	0,93
	Sesli reklamın 2. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	1
	Sesli reklamın 3. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	1
Video	Video reklamın 1. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	0,89
	Video reklamın 2. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	1
	Video reklamın 3. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	0,82
Web	Web reklamının 1. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	1
	Web reklamının 2. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	1
	Web reklamının 3. çeyreğinin en az yarısında grup olarak nötr duygular görülmüştür	1

Protoform-3’de yığılma içerisinde kişi sayısını bildiren özetler kullanılmıştır. Reklamlardaki yığılmalar farklı duygu durumları için olsa bile, bu yığılmalar normal bir grup tarafından hissedildiği özetlenmiştir (Çizelge 8.25).

Çizelge 8.25. Granül tespitli zaman serileri için protoform-3 sonuçları

	Protoform-3	TD
Sesli	Sesli reklamın en az yarısında normal bir kalabalık tarafından negatif duygular görülmüştür.	1
	Sesli reklamın en az yarısında normal bir kalabalık tarafından nötr duygular görülmüştür.	1
	Sesli reklamın en az yarısında normal bir kalabalık tarafından pozitif duygular görülmüştür.	1
Video	Video reklamın en az yarısında normal bir kalabalık tarafından negatif duygular görülmüştür.	1
	Video reklamın en az yarısında normal bir kalabalık tarafından nötr duygular görülmüştür.	0,8
	Video reklamın en az yarısında büyük bir kalabalık tarafından pozitif duygular görülmüştür.	1
Web	Web reklamının en az yarısında normal bir kalabalık tarafından negatif duygular görülmüştür.	1
	Web reklamının en az yarısında normal bir kalabalık tarafından nötr duygular görülmüştür.	1
	Web reklamının en az yarısında normal bir kalabalık tarafından pozitif duygular görülmüştür.	1

Protoform-4’de reklam bölümlerine göre yığılma miktarı özetlenmiştir. Sesli ve video reklamlarında çoğunlukla olumsuz duygular ilk üç bölümde büyük bir grup tarafından gözlemlenmiştir. Web reklamında görülen olumlu duygular, normal bir kalabalık tarafından hissedilmiştir (Çizelge 8.26).

Çizelge 8.26. Granül tespitli zaman serileri için protoform-4 sonuçları

	Protoform-4	TD
Sesli	Sesli reklamın 1. çeyreğinin en az yarısında büyük bir kalabalık tarafından karamsarlık görülmüştür.	1
	Sesli reklamın 2. çeyreğinin en az yarısında büyük bir kalabalık tarafından karamsarlık görülmüştür.	1
	Sesli reklamın 3. çeyreğinin en az yarısında büyük bir kalabalık tarafından karamsarlık görülmüştür.	1
Video	Video reklamın 1. çeyreğinin en az yarısında büyük bir kalabalık tarafından gerginlik görülmüştür.	1
	Video reklamın 2. çeyreğinin en az yarısında büyük bir kalabalık tarafından tedirginlik görülmüştür.	1
	Video reklamın 3. çeyreğinin en az yarısında büyük bir kalabalık tarafından heyecan görülmüştür.	1
Web	Web reklamının 1. çeyreğinin en az yarısında normal bir kalabalık tarafından heyecan görülmüştür.	1
	Web reklamının 2. çeyreğinin en az yarısında normal bir kalabalık tarafından heyecan görülmüştür.	1
	Web reklamının 3. çeyreğinin en az yarısında normal bir kalabalık tarafından heyecan görülmüştür.	1

Son özet yapısı olan protoform-5’de ise pozitif duygunun gruplar halinde görülmesi reklamlara göre karşılaştırıldığında, en çok sırasıyla web, video ve sesli reklamda görülmüştür (Çizelge 8.27).

Çizelge 8.27. Granül tespitli zaman serileri için protoform-5 sonuçları

Protoform-5	TD
Grup olarak gözlemlenen olumlu etki web reklamında sesli reklama göre daha fazladır.	0,37
Grup olarak gözlemlenen olumlu etki video reklamda sesli reklama göre daha fazladır.	0,30
Grup olarak gözlemlenen olumlu etki web reklamında video reklama göre daha fazladır.	0,06

8.4. Özetler için Kalite Doğrulaması

Ramos-soto ve diğerlerinin [235] sunduğu bir anket, oluşturulan özetlerin kalitesini değerlendirmek için üç pazarlama uzmanına sunuldu. Bu anket, özetlerin üç temel boyutuna dayanmaktadır.

- 1) İlgililik: Özetler, bir uzmanın istediği tüm bilgileri sağlıyor mu?
- 2) Doğruluk: Özetler, verileri doğru bir şekilde temsil ediyor mu?
- 3) Biçim: Özetler, düzgün ve açık bir şekilde ifade edilmiş mi?

En yüksek doğruluk derecesine sahip özetler her uzmana sunuldu ve üç önemli doğrulama anahtarı için aşağıdaki sorular soruldu:

1. Soru: Özetlerin bilgilendirici düzeyi nedir?
2. Soru: Özetler, reklamları ne kadar doğru bir şekilde ifade ediyor?
3. Soru: Özetler ne kadar basit ve anlaşılır?
4. Soru: Özetlerin içerik zenginliği hangi düzeyde?
5. Soru: Genel, karşılaştırmalı ve demografik özelliklere dayalı özetlerin olması ne kadar yararlıdır?

Uzmanlardan soruları 1-10 (1 “çok olumsuz” ile 10 “çok olumlu”) arasında bir ölçekte değerlendirmeleri istendi. Sonuçlar aşağıdaki formüllere göre hesaplandı:

P1, P2, P3, P4 ve P5 terimleri sırasıyla uzmanlardan alınan 1-5 numaralı sorulara verilen yanıtların ortalamasıdır. Bu nedenle, oluşturulan özetler için küresel kalite (GQ) puanı doğrulamanın ortalaması olarak elde edilir. Q_{s_i} , iki boyutun aritmetik ortalaması olarak tanımlanır ve bizim çalışmamızda n, 23'tür (uzmanlara sunulan özet sayısı).

Değerlendirmeler Çizelge 8.28'de verilmiştir. Bu değerlere göre özetlerin GQ puanı 10 üzerinden 8,64'tür. Bu puan özetlerin kalitesinin yeterince yüksek olduğunu göstermektedir.

$$Q_{s_i} = \frac{\frac{P_1+P_2}{2} + \frac{P_3+P_4+P_5}{3}}{2} \quad (8.1)$$

$$GQ = \sum_{i=1}^n \frac{Q_{s_i}}{n} \quad (8.2)$$

Çizelge 8.28. Doğrulama anket puanı

Sorular	Ortalama Skor	Standart Sapma
S-1	8,3	0,47
S-2	9	0,81
S-3	8,3	0,47
S-4	8,3	0,94
S-5	9,3	0,94
GQ	8,64	0,72

8.5. Tartışma ve Öneri

Üç farklı veri türü ile onlarca özet yapısı ve binlerce özet oluşturulmuştur. Bu özetler doğruluk derecelerine göre filtrelenmiş ve en doğru cümleler seçilmiştir. Bu cümleler aracılığıyla müşteriler üzerindeki bilinçaltı etkiler yorumlanmıştır.

Tezin amaçlarından biri, daha geniş ve daha hassas ölçümlerle duygu analizi yapmaktır. Russell'ın modeli duygu çeşitliliğine olanak sağlarken, bulanıklaştırma ise hassas ölçüm yapılmasına olanak tanımıştır. Bu nedenle, Russell'ın modeli ile uyarılma ve değerlik indekslerinin kullanımı kaçınılmaz hale gelmiştir. Bu çeşitlilik ve hassasiyet, özetlerin anlamsal kapasitesini ve analiz yeteneğini artırmıştır. Aksi takdirde, sınırlı duygu etiketleri bu denli zengin bir özetlemeyi mümkün kılamazdı.

Tek değişkenli verilerde, reklamlar ve bölümleri her katılımcı için bireysel olarak özetlenmiştir. Aynı zamanda, karşılaştırmalı cümle yapılarında, reklamlar ve bölümler karşılaştırılarak sunulmuştur. Örneğin, 15. katılımcı için video reklamın ikinci çeyreği, ilk çeyreğe göre daha olumlu bir etki sağlamış olup, bu katılımcı için en etkileyici olan video reklamdır. Bu özet yapısı, reklamlar hakkında genel bir görüş sunmamakla birlikte bireysel analizler için oldukça uygundur.

Bu özetlerde en çok vurgulanan olgulardan biri, bazen kişinin zihinsel durumunun reklamın etkisinden daha baskın olabilmesidir. Uyarıcı etkisi, katılımcının ruh halini bastırmaz ve belirli bir eşik değerin üzerine çıkamazsa, EEG verileri reklamın etkisini yansıtmaz; yalnızca katılımcının anlık ruh halini gösterir. Reklamın bireysel olarak analiz edilmesi, reklamların mı yoksa katılımcıların ruh hallerinin mi daha baskın olduğunun anlaşılması açısından kritik öneme sahiptir.

Çok değişkenli verilerle daha genel ve kritik bilgiler çıkarılmıştır. Bu özetlerle her reklamın tüm katılımcılar üzerindeki etkisi elde edilmiştir. Örneğin, 'heyecanlı' duygusu ağırlıklı olarak sesli reklamda, 'olumlu' etki ise web sayfasında tespit edilmiştir. Ayrıca, bu özetler reklamın bölümlerini karşılaştırmıştır. Örneğin, katılımcılar genel olarak video reklamda 'rahatlamış' hissederken, aslında ilk bölümde 'stresli' oldukları görülmüştür. Merak uyandıran bir diğer bilgi ise AW indeksine dayalı olarak elde edilen olumlu etki sıralamasıdır; web, sesli ve video reklamlar sırasıyla bu etkiyi göstermektedir. Web sayfasının olumlu etkisi oldukça yüksek, ancak sesli ve video reklamlar birbirine yakındır. Web reklamının olumlu etkisi, okumanın, beyni izlemekten daha olumlu etkilediğini desteklemektedir [273].

Bir diğer analiz özelliği ise cinsiyettir. Cinsiyete dayalı olarak reklamlarda elde edilen olumlu etki, kadınlar için sırasıyla web, sesli ve video; erkekler içinse web, video ve sesli olarak belirlenmiştir. Web reklamı her iki cinsiyette de en olumlu etkiyi göstermekte, ancak sesli ve video reklamlar arasında neredeyse aynı düzeydedir. Sonuçlar, oteli daha cazip hale getirmek için web reklamına odaklanılması gerektiğini göstermektedir. Ancak pazarlamanın cinsiyet temelli geliştirilmesi planlanıyorsa, erkekler için sesli, kadınlar için video reklamlara dikkat edilmelidir. Farklı bir bakış açısıyla, üç reklamda da erkeklerin kadınlara göre daha fazla etkilendiği görülmüştür. Bu durum, cinsiyet hassasiyetini ve potansiyel müşterinin cinsiyetini ortaya koymaktadır. Bu bilgi, pazarlamada yatırım alanlarını belirlemek için önemlidir. Pazarlama için diğer kritik bir özellik olan 'yaş' da analiz edilmiştir. Özetler, en olumlu etkilenen yaş gruplarının sırasıyla gençler, yaşlılar ve yetişkinler olduğunu göstermektedir. Bu sonuçlar doğrultusunda, reklam içeriği güncellenirken öncelikli olarak gençler ve erkekler dikkate alınmalı, kadınlara yönelik daha cazip içerikler kullanılmalıdır. İlginç bir şekilde, diğerlerine kıyasla reklamlar genel olarak belirgin bir olumlu etkiye sahip gibi görünse de, reklam bölümlerinin daha yakından incelenmesi bu durumun geçerli olmadığını ortaya koymuştur. Bu durum web sayfası için

de geçerlidir. Ancak bu özetler, otel tanıtımı ve pazarlama stratejisi açısından faydalıdır. Pazarlama yatırımlarını yönlendirerek hangi reklamlara daha fazla vurgu yapılması gerektiğini ve mevcut reklamların hangi bölümlerinin iyileştirilmesi gerektiğini göstermektedir. Bu çalışmada ele alınan reklamlardan, özellikle video reklamın ilk çeyreği başta olmak üzere, sesli ve video reklamların iyileştirilmesi gerektiği gözlemlenmiştir. Ayrıca, web sayfasının ve burada yer alan reklamların, web reklamlarından en fazla olumlu etkilenen genç erkekler için tasarlanması gerektiği belirtilmektedir. Özetler daha ayrıntılı incelendiğinde, reklamın hangi bölümünün hangi cinsiyet ve yaş grubu için geliştirilmesi gerektiği konusunda daha hassas bilgi sunmaktadır.

Granüler trend tespitli özetler, reklamların ve bölümlerinin bir topluluk üzerindeki eşzamanlı etkisini sunmaktadır. Özetlerde, sesli reklam eşzamanlı olarak nötr bir etki gösterirken, video ve web reklamları genel olarak olumlu bir etki göstermektedir. Ancak, web sayfası daha olumlu bir etki ortaya koymaktadır. Sesli reklam çok boyutlu veri yapısında daha olumlu görünse de, granüler veri yapısında video reklamın sesli reklama göre daha olumlu olduğu anlaşılmıştır. Bu durum, sesli reklamdaki olumlu etkinin eşzamanlı olmamasından ve zamana yayılmasından kaynaklanmaktadır. Bu net karşılaştırma yalnızca granüler veri yapılarıyla anlaşılabilmektedir. Zamanla dağılan bireysel tercihler, gerçeği yansıtmayabilir; ancak aynı anda büyük bir katılımcı oranını etkileyen uyaran, nöropazarlama için iyi bir ipucu olabilir. Çok katmanlı algoritmanın bu noktada önemli bir rolü bulunmaktadır. Nöropazarlama uzmanı duygulardan yola çıkarak reklamları analiz edebilir, ancak tüm veride belirli bir zaman aralığında aynı duyguları hisseden kişi sayısını ortaya çıkarmak zordur ve veri büyüdükçe imkânsız hale gelir. Bu yöntem, nöropazarlama veri analizinde önemli bilgileri ortaya çıkarabilecek bir yaklaşımdır ve diğer analiz yöntemlerinde gözden kaçan veya yanlış anlaşılan bilgileri dahi düzeltebilir. Video ve sesli reklamlar arasındaki olumlu etki analizi buna bir örnektir.

Bu çalışma, ilk bakışta garip görünen önemli bir gerçeği açığa çıkarmaktadır. Bir otel reklamının insanları rahatlatması, hayal gücünü harekete geçirmesi ve heyecan ile mutluluk duygularını tetiklemesi beklenirken, katılımcılar reklamlara karşı yoğun stres ve kötümserlik yaşamışlardır. Bu durum, insanların kendilerine bir şeyler satmak üzere tasarlanan sunumlara veya nesnelere karşı başlangıçta önyargılı olduklarına dair önemli bir noktayı vurgulamaktadır. Bu önyargının şiddetinin bireylerin gelir düzeyine bağlı olarak değişebileceği ileri sürülebilir. Ekonomik olarak karşılanamayacak iyi şeylerin sunulması

kişide olumsuz etkiler ortaya çıkarmakta ve istenmeyen sunumlar veya reklamlar da insanların üzerinde olumlu bir etki bırakmamaktadır.

Bu tez çalışması, sadece bu reklamlar için değil, belki tüm alanlarda nöropazarlama uzmanlarına yardımcı olmak için kaynak olabilir. Bulanık dilsel özetleme, her bir reklamın her bölümünde ortaya çıkan duygular ve reklamların farklı cinsiyet ve yaş grupları üzerindeki etkileri hakkında net bilgiler sağlamaktadır. Bu çalışmada ilk kez ele alınan bulanık dilsel özetleme ve nöropazarlama kombinasyonu, gelecekteki çalışmalara ışık tutacaktır. Bulanık dilsel özetleme, bulanık küme tabanlı olduğundan, EEG sinyalleri, açısall dönüşürme modifikasyonu ile Russell'ın çemberinde bulanık duygu etiketlerine dönüştürülmüştür. Bu yaklaşım, temel duygular arasında homojen bir geçiş sağlarken, duyguları algılama sürecinde daha gerçekçi ve hassas sonuçlar elde edilmesini mümkün kılmıştır. Bulanıklaştırılmış duygu tanıma, nöropazarlama ve duygu tanıma alanında farklı ve daha gerçekçi bir bakış açısı sunarak bu alanda başarılı çalışmalara zemin hazırlamıştır.

Dilsel özetlerin anlamsal değeri, cümleler tarafından sunulan bilgiye göre değişiklik göstermektedir. Tek değişkenli ve çok değişkenli verilerin özetlenmesi önemli bilgiler sunsa da, geliştirilen granüler trend tespit algoritmasıyla yığılma miktarı ile eşzamanlı duyguyu ortaya koymak, reklam analizinde daha gerçekçidir. Bu yaklaşım, nöropazarlama veri analizinde farklı bir bakış açısı sunmuş ve gelecek çalışmalarda dikkate alınması muhtemeldir.

Tezin bu bölümünde, uygulamalı olarak elde edilen veri seti için sonuçlar bu şekildedir ve metodolojinin doğruluğunun başka verilerde uygulanması ve literatürdeki diğer metotlarla karşılaştırılması gerekmektedir. Özellikle, literatürde en çok kullanılan ve performans karşılaştırması her detayıyla yapılabilen veri setleri kullanılmalıdır. İşte bu sebeple, tezin ikinci bölümünde SEED veri seti üzerinde, geliştirilen metodoloji uygulanmıştır. Bu çalışmadan ilham alarak, nöropazarlama alanında daha kapsamlı ve yenilikçi araştırmalar gerçekleştirilecektir. Gelecekte, daha geniş katılımcılarla yapılan deneyler ve daha karmaşık dilsel özetlemeler içeren bir karar destek sistemi, nöropazarlama uzmanları için geliştirilecektir.

9. BULANIK DİLSEL ÖZETLEME İLE EEG TABANLI DUYGU SINIFLANDIRMA: SEED VERİ SETİ ÜZERİNDE BİR ÇALIŞMA

9.1. Giriş

Tezin bu bölümünde, ilk bölümde geliştirilen metodoloji daha da genişletip, geliştirilerek literatürde en çok kullanılan ve DEAP verisine göre dört kat daha uzun olan SEED verisiyle uygulandı ve sonuçlar ML/DL metotlarıyla karşılaştırıldı. Bu bölümdeki gelişim, EEG tabanlı duygu tanımanın doğruluğunu ve yorumlanabilirliğini artırmak için Russell'ın boyutsal modeli üç farklı bulanık üyelik fonksiyonları ile birleştirildi. Öncelikle, frontal EEG'nin alfa ve beta frekans bantlarından dört farklı formül kullanılarak değerlik ve uyarılma değerleri hesaplanmıştır. Russell modelindeki açı (teta), uyarılma/değerlik oranının arkatanjantı alınarak bulunmuş ve bu açı bir duygu etiketine karşılık getirilmiştir. Duyguların kesin sınırlarla ayıramayacağı gerçeğinden hareketle, model bulanık kümeler ile geliştirilmiştir: üçgen, yamuk ve Gauss tipi üyelik fonksiyonları kullanılarak her bir EEG veri noktasının farklı duygu etiketlerine ne kadar ait olduğunu gösteren üyelik dereceleri hesaplanmıştır. Onaltı temel duygu etiketi, Larsen ve Diener'in 45° teorisi ile SEED veri setindeki pozitif, nötr ve negatif olarak üç sınıfa gruplanmıştır. Son aşamada, bu bulanıklaştırılmış etiketler FLS içinde kullanılarak sınıflandırma yapılmış ve geleneksel ML/DL modelleri ile karşılaştırılmıştır. Ek olarak, duyguların zaman içinde grup halinde ortaya çıkma anlarını tespit etmek için GTD algoritmasıyla modifiye edilmiş veri versiyonu üzerinde analizler yapılmış ve tüm EEG veri noktaları alınırken çıkan sonuçlarla karşılaştırılmıştır. Böylelikle, iki farklı veri seti de analiz edilmiş oldu.

Tezin bu bölümünün temel katkıları şunlardır: Russell modelinin üç bulanık üyelik fonksiyonu ile zenginleştirilmesi ve performans karşılaştırması, frontal EEG bantlarından türetilen değerlik/uyarılma formüllerinin SEED üzerinde kıyaslanması, 16 duygu etiketinin bulanıklaştırılarak üyelik dereceleri ile çoklu etiketlemeye olanak tanınması, FLS tabanlı sınıflandırmanın uygulanması ve GTD algoritmasının grup duygu davranışlarını analiz etmek için kullanımının değerlendirilmesi. Ve en önemlisi, geleneksel ML/DL yöntemlerine karşı hesaplamalı duygu modellerinin bulanıklaştırılarak rekabet edebileceği ispat edilmiştir. Bu yaklaşım, mevcut yöntemlerin genelleme ve yorumlanabilirlik zorluklarının yanında, kısıtları ve ciddi ihtiyaçlarına karşın alternatif yaklaşımların olduğunu göstermeyi hedeflemektedir.

Tezin bu bölümünde genel akış aşağıdaki gibi devam etmektedir;

- Literatür araştırması kısmında, yapılan çalışmalar 3 kısımda incelenmiştir. Hesaplamalı duygu modelleri, ML ve DL yöntemleri ile yapılan duygu tanıma çalışmaları ele alınmıştır.
- Sonraki adımda, genişletilmiş metodoloji verilmiştir. Öncelikle SEED veri seti tanıtılmış, veri ön işleme işlemleri verilmiş, özellik çıkarımı sunulmuş ve Russell'in çemberinin bulanık kümelerle geliştirilmesi verilmiş. Ve son olarak FLS ile sınıflandırmanın nasıl yapılacağı verilmiştir.
- Sonuçlar kısmında, tüm alternatif sonuçlar hesaplanmış ve ML/DL metotlarıyla karşılaştırılmıştır.
- Sonuçlar, tartışma bölümünde ele alınmış ve karşılaştırmalar daha detaylı verilmiştir.
- Son olarak sonuç kısmında, tezin ikinci bölümünde neler yapıldığı özetlenmiş ve gelecekte neler yapılabileceği vurgulanmıştır.

9.2. Literatür Araştırması

EEG tabanlı duygu tanıma, insan-bilgisayar etkileşimi, sağlık hizmetleri ve sinirbilimde önemli bir araştırma konusu haline gelmiştir [11]. ML algoritmaları, DL modelleri ve boyutlu duygu modelleri kullanılarak EEG sinyallerinden duyguları tanıma üzerine çok sayıda çalışma yürütülmüştür. Bu bölümde, literatürdeki ilgili çalışmalar üç ana başlık altında incelenmiştir: (1) ML algoritmalarıyla EEG tabanlı duygu tanıma, (2) DL modelleriyle EEG tabanlı duygu tanıma ve (3) Hesaplamalı boyutlu duygu modelleriyle EEG tabanlı duygu tanıma. Literatür, özellikle SEED veri setine odaklanılarak incelenmiştir.

9.2.1. Duygu tanıma için ML yaklaşımları

Literatürde EEG tabanlı duygu tanıma için, yüksek performanslarından dolayı ML teknikleri -SVM, kNN, Rastgele Ormanlar (RF), Lojistik Regresyon (LR), vb.- kullanılmıştır. Özellikle SVM yaygın olarak kullanılır; örneğin, Li ve diğerleri [307] bir SVM sınıflandırıcısı kullanarak SEED veri kümesinde yaklaşık %83,3 doğruluk elde etmiştir. Karar ağacı ve orman topluluk modelleri de kullanılmıştır: Fang ve diğerleri [308] DEAP üzerinde duygu sınıflandırması için Çok Özellikli Derin Orman (MFDF) modelini önermiş ve MFDF'nin (%71,05 doğruluk) RF, kNN ve SVM temel çizgilerinden daha iyi performans

gösterdiğini bulmuştur. Diğer çalışmalar, gelişmiş ML varyantlarını da incelemiştir. Örneğin, Zheng ve diğerleri [309], EEG duygu verileri üzerinde standart kNN, LR ve SVM yöntemlerinden daha iyi performans gösteren, diferansiyel entropi özellikleriyle birlikte Grafik-düzenlemeli Aşırı Öğrenme Makinesi (ELM) kullanmıştır. Genel olarak, dikkatli özellik seçimiyle birlikte ML yaklaşımları, ikili veya üç sınıflı SEED görevlerinde genellikle %80–90 oranında güçlü performans sağlayabilir [310–311]. Ancak, manuel özellik çıkarımına olan bağımlılık bir sınırlılık olarak kalmakta; bu da alan bilgisi gerektirmekte ve ham EEG verilerindeki karmaşık desenlerin gözden kaçırılmasına yol açabilmektedir [307].

9.2.2. Duygu tanıma için DL yaklaşımları

DL yöntemleri, ham ya da minimal işlenmiş sinyallerden hiyerarşik özellikleri otomatik olarak öğrenebilme yetenekleri sayesinde EEG tabanlı duygu tanımda öne çıkmıştır. EEG verileri içindeki karmaşık uzamsal-zamansal desenleri yakalamak için çeşitli mimariler geliştirilmiştir. Örneğin, dikkat mekanizmasıyla güçlendirilmiş yinelemeli modeller, zamansal dinamikleri etkili bir şekilde modellemek için kullanılmıştır; dikkat temelli Uzun Kısa Süreli Bellek (A-LSTM) ağı, LSTM birimlerini dikkat mekanizmalarıyla birleştirerek %72,18 doğruluk elde etmiştir [312]. Alan uyarlama teknikleri, bireyler arası değişkenliği ele almakta kritik bir rol oynamaktadır. Alan-Çekişmeli Sinir Ağı (DANN) %75,08 doğruluk vermiştir [313]. Derin Adaptasyon Ağı (DAN) ise %83,81 doğrulukla daha iyi genelleme göstermiştir [314]. Graf tabanlı yaklaşımlar, EEG elektrotlarının uzamsal bağlantılarından faydalanır; zamansal bilgiyi graf konvolüsyonlarına entegre eden Dinamik Graf Konvolüsyonel Sinir Ağı (DGCNN), %79,95 doğruluk sağlamıştır [315]. Saf Grafik Sinir Ağları (GNN'ler) ise EEG elektrot graf yapısı üzerinde uçtan uca temsillerle eğitilerek %88,38 doğruluğa ulaşmıştır [316]. Farklı sinir ağı bileşenlerini birleştiren hibrit modeller de güçlü performans sergilemektedir; örneğin, Konvolüsyonel Sinir Ağları ile Fourier Dönüşümü'nü entegre eden (CNN+TF) bir model, uzamsal-spektral desenleri yakalayarak %83,03 doğruluk elde etmiştir [317]. Çoklu dikkat mekanizmasını EEG özelliklerine uygulayan Gruplandırılmış Dikkat Ağı (GAN) ise %92,12 doğrulukla en yüksek performansa ulaşmıştır [318]. Bu DL modelleri, uzamsal filtreleme, zamansal sıralama ve adaptasyon stratejilerini etkili bir şekilde birleştirerek EEG tabanlı duygu sınıflandırmasında önemli ilerlemeler göstermektedir. Ancak, yüksek hesaplama maliyetleri ve büyük ölçekli veri kümelerine olan bağımlılık, pratik uygulama açısından önemli zorluklar olarak öne çıkmaktadır [310–311]. En yüksek doğruluğa ulaşan GAN modeli bile, yüksek hesaplama

gereksiniminin yanı sıra, performansının yalnızca kullanılan veri kümesine özgü olması, gerçek zamanlı verilere uygulanabilirliğinin ispat edilmemiş olması ve çeşitli EEG kayıtları arasında genelleme eksikliği gibi önemli sınırlamalara sahiptir [317].

9.2.3. Hesaplamalı boyutlu duygu modelleri

Sürekli duygusal modeller, duyguları nicel eksenler üzerinde tanımlar. En yaygın olanı, Russell'ın iki boyutlu modeli (değerlik ve uyarılma), duyguları bir $[x, y]$ düzlemine yerleştirir [86]. Memnuniyet-uyarılma-baskınlık (PAD) modeli, buna üçüncü bir "baskınlık" eksenini ekler [89], Plutchik'in tekerleği ise sekiz birincil duyguyu dairesel bir şema içerisinde düzenler [88]. EEG çalışmalarında, bu boyutsal şemalar; sinyal özelliklerinin değerlik, uyarılma (ve bazen baskınlık) eksenlerine eşlenmesi yoluyla operasyonelleştirilir. Örneğin, değerlik verisi genellikle hemisferik asimetri (pozitif duygular için sol yarımkürenin sağa kıyasla daha yüksek aktivite göstermesi) üzerinden çıkarılır; oysa uyarılma, genel kortikal aktivasyon ya da yüksek frekanslı güç ile ilişkilendirilir [89]. Pratikte, araştırmacılar değerlik için frontal alfa asimetrisi [91], uyarılma için ise bant-güç oranları ya da küresel enerji gibi farklı indeksler hesaplar. Bu indeksler daha sonra farklı duygusal durumları sınıflandırmak amacıyla kategorize edilebilir [97].

Birçok EEG çalışması bu modelleri açıkça uygulamıştır. Yoon ve Chung'un çalışması [319], uluslararası duygusal resim sistemi (IAPS) uyarınları altında EEG spektralarını analiz etmek için değerlik-uyarılma modelini kullanmıştır. Farklı bir yaklaşım olan Kaya ve diğerleri [320], hesaplamalı model çalışmalarını bir adım öteye taşıyarak, Russell'ın çevre modelini bulanık kümelerle bütünleştirmiş; ancak bu çalışma sınıflandırma veya karşılaştırma içermemektedir. Son olarak, daha az kullanılan baskınlık boyutu üzerine odaklanan bazı çalışmalar mevcuttur. Örneğin, Zhao ve diğerleri [321], ile Bos [322], frontal EEG oranlarının baskınlığı indekslediğini belirtmişlerdir: frontal kortekste daha yüksek beta/alfa güç oranı, daha baskın duygusal durumlara karşılık gelmiştir. Bos [322], ayrıca frontal teta asimetrisinin, öz bildirim yoluyla elde edilen baskınlık (öfke vs. korku) ölçümlerini izlediğini bulmuştur. Özetle, boyutsal modelleri benimseyen EEG tabanlı duygu çalışmaları genellikle değerlik ve uyarılma sinyallerini, frontal asimetri ve bant-güç oranları gibi özelliklerden türeterek elde eder ve ardından bu sinyalleri modelin eksenlerine göre sınıflandırır [92]. Bu yaklaşımlar, EEG'nin çevre ya da PAD gibi modellere doğrudan hizalanabileceğini göstermektedir.

Mevcut literatürün eleştirel bir incelemesi, ML ve DL yöntemlerinin [317]. -örneğin küçük veri kümeleriyle yetersiz performans, aşırı öğrenme ve algoritmaya özgü kısıtlar gibi-sınırlamalara tabi olduğunu ortaya koyarken, boyutsal modellerin doğrudan hesaplamalı analiz imkânı sunarak bu tür kısıtlamalardan kaçındığını göstermektedir [318]. ML/DL tekniklerine ek olarak, literatürde diğer boyutsal modellerle yürütülen çalışmaların da yetersiz kaldığı görülmektedir. Çalışmanın bu kısmı, literatüre bu alanda üç temel yaklaşım ile katkıda bulunmayı amaçlamaktadır: (1) uyarılma/değerlik formüllerinin sistematik performans değerlendirmesi, (2) Russell'ın boyutsal modelinin üç ayrı bulanık küme aracılığıyla geliştirilmesi ve (3) duygusal sınıflandırma için bulanık duygu etiketleri kullanarak FLS uygulanması. Bu yenilikler, mevcut teorik çerçeveleri ileri taşımakta ve gelecek araştırmalar için metodolojik temeller sunmaktadır; çalışmanın yenilikçiliğini daha da güçlendirmektedir. Ayrıca, bu çalışmada eş zamanlı olarak kaydırmalı pencere tekniğiyle modifiye edilen GTD algoritması kullanılarak EEG verilerinde duygu kümelenmesinin tespitine de yer verilmiştir [77]. Buna ek olarak, bu çalışma, Russell'ın çevre modelinin üçlü kategoriler üzerinden sınıflandırılmasına öncülük ederek, duygu taksonomisi açısından kavramsal bir ilerleme sağlamaktadır.

9.3. Metodoloji


Bu bölüm, EEG tabanlı duygu tanıma ve dilsel özetleme yapısı oluşturmak için geliştirilen metodolojik çerçeveyi sunmaktadır. Süreç, önce EEG veri setinin ön işlenmesi ve özellik çıkarımı ile başlamaktadır. Ardından, çıkarılan özellikler, duygu etiketini daha esnek ve yorumlanabilir kılmak amacıyla bulanık kümeler aracılığıyla Russell'ın modelinin modifiye edilmiş bir versiyonunu sunacaktır.

Bulanık duygu etiketleri tanımlandıktan sonra, bu etiketler dilsel özetleme yapısı içinde kullanılmaktadır. Özetin doğruluk derecesi, videoların duygusal etiketini (pozitif, nötr veya negatif) sınıflandırmak için kullanılmaktadır.

Son olarak, eşzamanlı duygu kümelenmesini tespit etmek üzere GTD algoritması [320] verilmektedir. Tüm EEG verilerini ayrılmaz gözetmeksizin analiz etmek yerine, bu algoritma birden fazla katılımcının eşzamanlı duygusal tepkiler gösterdiği veri segmentlerini belirlemektedir. Buradaki amaç, anlam kaybı olmaksızın duygu tanıma güvenilirliğini artırmaktır.

9.3.1. SEED veri seti

SEED, EEG tabanlı duygu tanıma alanında yaygın şekilde kullanılan bir kıyaslama setidir ve Shanghai Jiao Tong Üniversitesi'nden Zheng ve Lu (2015) tarafından geliştirilmiştir [323]. Bu veri seti, her biri pozitif, nötr veya negatif duygular uyandırmak amacıyla tasarlanmış ve 15 video izleyen 15 katılımcının EEG kayıtlarını içermektedir (Şekil 9.1). Her katılımcı üç oturum boyunca kayda alınmış olup, bu sayede oturumlar arası ve uzunlamasına performans değerlendirmesi yapmak mümkün hale gelmiştir. SEED'in tercih edilme sebepleri arasında; yapılandırılmış tasarımı, yaklaşık 4 dakikalık uzun video süreleri sayesinde zamansal olarak istikrarlı duygusal desenlerin elde edilebilmesi ve FLS gereksinimleriyle uyumlu, açıkça tanımlanmış etiketlerin bulunması yer almaktadır.



Şekil 9.1. SEED veri seti

EEG sinyalleri, 10–20 uluslararası sistemine uygun yerleştirilmiş 62 kanallı bir düzeneğe ve 1000 Hz örnekleme frekansı ile toplanmıştır. Veriler, 0,5–70 Hz bant geçiren filtreleme ve artefakt giderme teknikleriyle ön işleme tabi tutulmuştur. Duygusal etiketler, uyarının öngörülen değeri ve katılımcıların öz-bildirimlerine dayanarak atanmıştır.

Özellik çıkarımı aşamasında, standart EEG frekans bantları (delta, teta, alfa, beta ve gamma) üzerinden güç spektral yoğunluğu (PSD) ve diferansiyel entropi (DE) hesaplanmıştır. SEED'in iyi yapılandırılmış duygusal uyaranları ve zengin zamansal-uzamsal çözünürlüğü, hem kategorik duygu sınıflandırması hem de değerlik-uyarılma eksenlerini kullanan boyutsal modellemeler için uygun bir temel sunmaktadır.

9.3.2. Veri ön işleme

Ön işleme iki aşamada gerçekleştirilmektedir. İlk aşamada, SEED veri seti başlangıçta önceden işlenmiş formda sunulmaktadır. Ham EEG sinyallerine, düşük frekanslı sapma ve yüksek frekanslı gürültüyü ortadan kaldırmak amacıyla 0,5 Hz–70 Hz aralığında bant geçiren filtreler uygulanmıştır. Göz kırılması ve kas hareketleri kaynaklı artefaktları temizlemek için Bağımsız Bileşen Analizi (ICA) uygulanmıştır [324]. Ardından, veri boyutunu azaltmak ancak zamansal çözünürlüğü korumak için sinyaller 200 Hz'e indirgenmiş örnekleme hızına tabi tutulmuştur.

İkinci aşamada, yöntemlerimize uyum sağlamak üzere, 62 kanal yerine yalnızca AF3 ve AF4 kanallarından alfa ve beta bantları elde edilmiştir. Bu kanallardan elde edilen alfa ve beta bileşenleri, frontal kortikal ölçümler üzerinden uyarılma ve değerlik değerlerinin hesaplanması için yeterli bilgi sunmaktadır.

9.3.3. Özellik çıkarımı

Özellik çıkarma, çalışmanın amacıyla uyumlu olmalıdır. Bu araştırma FLS aracılığıyla sınıflandırmaya odaklandığından, duygu etiketlerini bulanık bir küme bağlamında tanımlamak gerekir. Bu tür tanımlar, uyarılma ve değerlik, birincil boyutları, genellikle frontal alfa ve beta aktivitesinden türetildiği Russell'in Circumplex Modeli içinde oluşturulabilir. Literatürde, frontal alfa ve betaya dayalı dört farklı formül geliştirilmiştir [126]. Çalışmada performansları da karşılaştırılan bu formüller şunlardır (Çizelge 9.1);

Çizelge 9.1. Literatürdeki uyarılma ve değerlik formülleri [61]

	Formül	Değerlik	Uyarılma
[28]	1	$= sol\left(\frac{\beta}{\alpha}\right) - sağ\left(\frac{\beta}{\alpha}\right)$	$= \log_2 sol\left(\frac{\beta}{\alpha}\right)$
[264]	2	$= \ln\left(\frac{Frontal_{sol(\alpha)}}{Frontal_{sağ(\alpha)}}\right)$	$= -\ln Frontal_{sağ(\alpha)} + \ln Frontal_{sol(\alpha)}$
[265], [266]	3	$= Frontal_{sağ(\frac{\alpha}{\beta})} - Frontal_{sol(\frac{\alpha}{\beta})}$	$= \frac{\sum(\alpha)}{\sum(\beta)}$
[267]	4	$= Frontal_{sağ(\alpha)} - Frontal_{sol(\alpha)}$	$= \frac{\sum(\beta)}{\sum(\alpha)}$


Seçilen formüllerin her birini kullanarak uyarılma ve değerlik hesaplandıktan sonra, arktanjan fonksiyonu bu değerlere uygulanarak Russell'ın Circumplex Modeli içinde açısıl bir gösterim elde edilir (Eş. 9.1). Bu açı, değerlik-uyarılma koordinatlarındaki duygusal koordinatı gösterir. Duyguyu ve önceden tanımlanmış bulanık bir kümeye üyelik derecesini tanımak için kullanılır [32].

$$\theta = \arctan\left(\frac{Uyarılma}{Değerlik}\right) \quad (9.1)$$

SEED video verileri üç ayrık etiket sunar -pozitif, nötr ve negatif- ancak analizimiz Russell'ın on altı duyguyu içeren modeline (Şekil 9.2-B) dayanmaktadır. On altı duygusal durumun her birini SEED'in üç kategorisinden birine atamaktayız. Bunun için, pozitif, nötr ve negatif bölgeleri tanımlamak amacıyla 45° döndürülmüş iki boyutlu çevre modelini [325]. (Şekil 9.2-A) uygulayarak, her bir duygu durumunu karşılık geldiği SEED etiketine atamaktayız (Çizelge 9.2) (Şekil 9.2-C).

Çizelge 9.2. SEED'in üç etiketine atanmış on altı duygu

SEED etiketleri	Atanmış duygular
Pozitif	Uyanık, Heyecanlı, Coşkulu, Mutlu, Memnun, Huzurlu
Nötr	Rahat, Sakin, Yorgun, Uyuşuk
Negatif	Gergin, Sinirli, Stresli, Mutsuz, Üzgün, Depresif




Şekil 9.2. A. İki boyutlu Russell modeli için 45° dönüş hipotezi [325]. B. On altı duygu noktasıyla Russell'in sirkumpleks modeli [260]. C. On altı duygunun atandığı Russell'in sirkumpleks modeli (duyguların üç kategoriye atanması için A ve B birleşmiştir).

9.3.4. Bulanık kümelerle değiştirilmiş Russell'in sirkumpleks modeli

Her biri dört ayrı formül kullanılarak hesaplanan uyarılma ve değerlik değerleri, Russell'in sirkumpleks'indeki yerlerini belirlemek için arktanjanant fonksiyonu aracılığıyla önce bir açıl koordinata (θ) dönüştürülür. Önceden tanımlanmış bulanık kümeler içinde, her noktaya üyelik derecesiyle birlikte karşılık gelen duygu etiketi atanır. Bu duygu etiketleri daha sonra SEED kategorilerine (pozitif, negatif, nötr) eşlenir ve her kategori için toplanan üyelik dereceleri dilsel özetleri oluşturmak için kullanılır.

Sınıflandırmanın hassasiyetini ve doğruluğunu artırmak için, üç ayrı bulanık üyelik fonksiyonu -üçgen, yamuk ve Gauss- kullanıldı. MATLAB kütüphanesinde önceden tanımlanmış üyelik fonksiyonları kullanıldı; bu fonksiyonlar minimal, kolay yorumlanabilir parametreler kullanır. Parçalı doğrusal üçgen ve yamuk formlar sezgisel eşik ayarı ve düşük hesaplama maliyeti sağlarken, Gauss parametrelendirmesi kademeli geçişleri ve ölçüm belirsizliğini modellemek için düzgün, sonsuz derecede farklılaştırılabilir bir çan eğrisi üretir [326]. Ayrıca, üyelik fonksiyonlarının yapısı simetrik olduğu için homojen duygu geçişi için uygundur. Tüm prosedürler her üyelik fonksiyonu için bağımsız olarak yürütüldü ve elde edilen çıktılar, hangi fonksiyonun en iyi performansı sağladığını belirlemek için karşılaştırıldı (Şekil 9.3).




Şekil 9.3. Üç bulanık üyelik fonksiyonuna (üçgen, yamuk ve Gauss) dayalı dilsel etiketlerin üyelik derecelerinin hesaplanması.

9.3.5. Bulanık dilsel özetleme yapıları

Üç dilsel etiket için de zamanla değişen üyelik dereceleri hesaplandıktan sonra dilsel özetler oluşturulur. Bu çalışma için basit bir özet yapısı kullanıldı. Doğruluk derecesi [T1] (Eş. 9.2) hesaplanan “Q Y, S” [T1] yapısı kullanılmaktadır. Burada, Q niceleyici “çoğu”, Y nesneyi ve S özetleyiciyi belirtir. Örneğin, “Çoğu zaman, pozitif duygu gözlemlendi” [0,9].

$$T_1 = \mu_Q \left(\frac{\sum_{m=1}^M \mu_S(d_m)}{R} \right) \quad (9.2)$$

Dilsel özetlemenin temel ilkesi, mevcut niceleyicileri ve etiketleri kullanarak tüm olası özetleri çıkarmak ve bunların doğruluk derecelerini hesaplamaktır. Buradaki amacımız sınıflandırma olduğundan, en yüksek doğruluk derecesine sahip cümleyi seçip etiketini sınıf olarak atıyoruz. Özetle, SEED veri setinin ön işlenmesinin ardından, uyarılma ve değerlik değerleri dört farklı formül kullanılarak hesaplandı. Bu değerler daha sonra, üç bulanık üyelik fonksiyonu (üçgen, yamuk ve Gauss) içindeki her EEG veri noktası için karşılık gelen duygu etiketini ve üyelik derecelerini belirlemek için kullanıldı. Daha sonra, tüm etiketlerin üyelik dereceleri her video için hesaplandı ve dilsel özetleme yapısına dahil edildi. Her videonun son duygu sınıflandırması, en yüksek doğruluk derecesine sahip özet cümlesine dayanmaktadır (Şekil 9.4).



Şekil 9.4. Önerilen EEG tabanlı duygu tanıma metodolojisinin adımları

9.4. Sonular

Bu blm uygulamaların sonularını sunmaktadır. İki farklı veri tr kullanıldı: tm EEG noktaları ve GTD noktaları. Her iki veri tr iin drt ayrı forml uygulandı ve her forml iin Russell'ın sirkumpleks'i iinde  bulanık kme tanımlandı ve bu da yirmi drt alternatif yntemle sonulandı. Tm alternatifler, MATLAB'da katılımcılardan bağımsız olarak kodlandı ve uygulandı. Aağıdaki alt blmler, tm alternatif yaklaşımların sonularını ve literatrde bildirilen ML ve DL yntemleriyle karşılaştırmalı bir zet sunar.

9.4.1. Deney sonuları

Yirmi drt alternatif yaklaşımın tm iin, on be video dilsel zetlerinin doėruluėuna gre sınıflandırıldı (izelge 9.3). Her video iin en yksek doėruluėa sahip zet seildi ve bu seimler daha sonra karışıklık matrisleri kullanılarak analiz edildi.

izelge 9.3. Dilsel zetleme ile sınıflandırma gsterimi

Forml-1 ve gen yelik fonksiyonu kombinasyonunun rnek zetleri		TD	Etiket
Video-1	oėu zaman, videoda pozitif duygu gzlemlendi	0,81	Pozitif
Video-2	oėu zaman, videoda ntr duygu gzlemlendi	0,93	Ntr
Video-3	oėu zaman, videoda negatif duygu gzlemlendi	0,78	Negatif

izelge 9.4'te grldė zere, tm EEG ve GTD noktalarına uygulanan  bulanık yelik fonksiyonu kullanılarak her bir formln sonuları elde edilmiřtir. Tm EEG noktaları kullanıldığında, gensel yelik fonksiyonu %80 ile en yksek performansı gstermiřtir. zellikle, Forml-3 hem gensel hem de gauss fonksiyonları altında daha iyi sonular vermiřtir. Genel geer bir sonuca varmak zor olsa da, Forml-2 srekli olarak en dřk skoru retirken, Forml-3 en yksek skoru elde etmiřtir.

izelge 9.4. Tm EEG noktaları iin formllere gre yelik fonksiyonlarının doėrulukları


	gen	Yamuk	Gauss
Forml-1	80,00 %	66,67%	53,33%
Forml-2	33,33%	53,33%	33,33%
Forml-3	80,00%	73,33%	80,00%
Forml-4	73,00%	66,67%	66,67%

GTD noktaları için yapılan analizde (Çizelge 9.5), Formül-2 yine en düşük skorları elde etmiştir. Formül-2, farklı veri türlerinde sürekli olarak zayıf performans gösterdiğinden, görece olarak etkisiz olduğu sonucuna makul bir şekilde varılabilir. GTD noktaları için Formül-4 en yüksek skoru elde etmiştir. Formül-1, Formül-3 ve Formül-4 farklı değerler vermekle birlikte, hepsi nispeten güçlü bir performans sergilemiştir.

Çizelge 9.5. GTD noktaları için formüllere göre bulanık üyelik fonksiyonlarının doğrulukları

	Üçgen	Yamuk	Gauss
Formül-1	66,67 %	66,67%	66,67%
Formül-2	46,67%	53,33%	46,67%
Formül-3	66,67%	66,67%	66,67%
Formül-4	73,33%	73,33%	66,67%

Veri tipleri arasında yapılan karşılaştırma, ilk bakışta tüm EEG noktaları veri tipinin daha iyi performans metrikleri sunduğunu ortaya koymaktadır. Her ne kadar bu veri tipi en yüksek gözlemlenen doğruluğu (%80) elde etse de, en düşüğünü (%33,33) de üretmektedir. Buna karşılık, GTD noktaları veri tipi bu kadar uç performanslar göstermemekte, ne çok yüksek ne de çok düşük. Dahası, ortalama doğruluk dikkate alındığında, GTD veri tipi, tüm veriler versiyonuna göre daha iyi performans sergilemektedir. Bu sonuç, GTD algoritmasının daha sağlam bir çerçeve oluşturduğunu göstermektedir (Şekil 9.5).




Şekil 9.5. EEG ve GTD verilerinin ortalama doğruluk değeri karşılaştırmaları

Sonuçların daha detaylı incelenmesi için, her bir formül için karışıklık matrisi analizi, tüm noktalar (Şekil 9.6) ve GTD nokta veri türleri (Şekil 9.7) açısından ayrı ayrı incelenmiş ve her iki veri türü için ortalama ile birleştirilmiştir (Çizelge 9.6). Bu inceleme, Formül-2'nin


son derece tutarsız sonuçlar ürettiğini ve güvenilirlik eksikliğini açıkça ortaya koymaktadır. Buna karşın, Formül-3 hemen hemen tüm etiketler için yüksek doğruluk oranı elde etmektedir. Etiket bazında incelendiğinde, nötr etiket en yüksek doğrulukla sınıflandırılmışken, pozitif etiket en düşük doğrulukla sınıflandırılmıştır.

Çizelge 9.6. Her formül için etiket sınıflandırma doğruluğu (her iki veri türünün ortalaması alınarak elde edilmiştir)

	Pozitif	Nötr	Negatif
Formül-1	73,33%	80,00%	46,67%
Formül-2	0,00%	93,33%	40,00%
Formül-3	80,00%	76,67%	60,00%
Formül-4	30,00%	80,00%	100,00%
Ort. Doğruluk	45,83%	82,50%	61,67%



Şekil 9.6. Tüm EEG noktaları veri türü için formüllere göre karışıklık matrisi



Şekil 9.7. GTD noktaları veri türü için formüllere göre karışıklık matrisi


9.4.2. Diğer yaklaşımlarla karşılaştırma

Bu çalışmada, literatürde bildirilen SEED veri seti üzerinde uygulanan çeşitli ML ve DL yöntemlerinin konu-bağımsız performans sonuçları karşılaştırılmıştır. Yöntemler, ML ve DL olarak ayrı gruplarda toplanıp değerlendirildikleri için, iki paradigmanın performansları doğrudan karşılaştırılabilmektedir.

ML yöntemleri arasında değerlendirmeye alınan algoritmalar şunlardır: Kullback–Leibler Önem Tahmin Prosedürü (KLIEP) [327]. Sınırlandırılmamış En Küçük Kareler Önem Uyumu (ULSIF) [328]. Seçmeli Transfer Makinesi (STM) [329]. SVM [330]. Transfer Bileşeni Analizi (TCA) [331]. Alt uzay hizalaması (SA) [332]. Jeodezi Akış Çekirdeği (GFK) [333]. Projeksiyon Sözlüğü Çift Öğrenme (PDPL) [334]. Kernel Temel Bileşen Analizi (KPCA) [335]. Genetik Algoritma ile Optimizasyonlu PDPL (GA-PDPL) [336]. k-NN [316]. ve LR [317].

DL yöntemleri ise şu modellerin performans sonuçlarını içermektedir: Derin Pekiştirmeli Öğrenme (DRL) [313]. A-LSTM [321]. DANN [314]. DGCNN [336]. Grafik Sinir Ağları + Uzun-Kısa Süreli Hafıza (GNN+LSTM) [337]. Transpozisyon MLP + Örnek Ağırlıklı Alan Uyarlama Ağı (TMLP+SRDANN) [338]. Grafik Konvolüsyon Ağı (GCN) [339]. CNN+TF [340]. Çift Yarımküre Alan Düşmanca Ağı (BiDANN) [315]. DAN [308]. Alan Uyarlama (DA) [309]. Çift Yarımküre Fark Modeli (BiHDM) [341]. GNN [342]. ve GAN [322].

Karşılaştırmada, bu çalışmada en yüksek performans gösteren üç yaklaşım (formül-1 ve üçgen üyelik fonksiyonu, formül-3 ve üçgen/Gauss üyelik fonksiyonları kombinasyonları) dikkate alınmıştır. Sonuçlarımız (%80), genel olarak ML yöntemlerinin başarı oranlarını aşmıştır. DL yöntemlerinin ortalama doğruluğu, FLS yaklaşımımızın ortalamasından bir miktar yüksek olsa bile bu fark, önemsiz düzeydedir. Literatürde sunulan yöntemler arasında yalnızca GAN (%92,12 doğruluk) daha yüksek bir başarı göstermiştir (Şekil 9.8). ML yöntemlerinin ortalama doğruluğu %62,11, DL yöntemlerinin ortalaması ise %81,03 olarak bulunmuştur. Yüksek hesaplama maliyeti, büyük veri ihtiyacı ve uzun eğitim süreleri gibi DL yöntemlerinin dezavantajlarına rağmen, FLS yöntemi benzer doğruluk değerlerine bu tür kısıtlar olmadan ulaşabilmektedir.



Şekil 9.8. SEED veri setinde FLS, ML ve DL yöntemlerinin karşılaştırılması

9.5. Tartışma

Deneysel sonuçlar, EEG tabanlı duygu tanımda FLS yaklaşımını, Russell'ın çember modeliyle bütünleştirmenin etkinliğini ortaya koymaktadır. Yaklaşımımız, ML ve DL yöntemleriyle karşılaştırılabilir bir doğruluk (%80) sağlarken, aynı zamanda hesaplama karmaşıklığı, aşırı öğrenme ve yorumlanabilirlik gibi önemli sınırlamaları da ele almaktadır. Aşağıda, bu bulguları vurguluyor, etkilerini analiz ediyor ve çalışmanın sınırlılıklarını ele alıyoruz.

Sonuçlar, üçgen üyelik fonksiyonuyla eşleştirilen formül-3'ün en yüksek sınıflandırma doğruluğuna (%80) ulaştığını göstermiştir. Formül-3'ün ön alfa/beta oranlarına dayanması, ön asimetriyi değerlik ve uyarılma ile ilişkilendiren önceki çalışmalarla uyumludur [307, 311]. Buna karşılık, formül-2, her iki veri tipinde tutarlı şekilde düşük performans sergilemiş ve en düşük doğrulukları vermiştir. Bunun nedeni, alfa asimetrisinin logaritmik dönüşümünün düşük genlikli EEG sinyallerindeki gürültüyü artırabilmesi olabilir. Bu da, doğrusal olmayan dönüşümler kullanırken sağlam ön işlemenin gerekliliğini vurgulamaktadır.

Aynı formül koşulları altında, üçgen üyelik fonksiyonları genel olarak yamuk veya gauss şekillerine kıyasla en iyi sonuçları (%80 doğruluk) üretmiştir. Bu, parçalı-doğrusal

geçişlerin, Russell'ın modelindeki duygu kategorileri arasındaki keskin sınırları daha iyi yakaladığını gösterebilir. Bu bulgular, uyarılma/değerlik hesaplama formüllerinin ve bulanıklaştırma seçimlerinin performansı güçlü bir şekilde etkilediğini ve formül-3 ile üçgen bulanık kümelerimizin en ayırt edici duygu tanımayı sağladığını göstermektedir.

Karışıklık matrisi analizi, sınıfa özgü davranışı daha da netleştirmiştir. Formül-3 yine en güvenilir olarak kanıtlanmış, pozitif, nötr ve negatif etiketlerde yüksek doğruluk sağlarken, formül-2 düzensiz sonuçlar üretmiştir. Tüm formüllerin ortalaması alındığında, nötr duygu etiketi en doğru şekilde sınıflandırılmıştır (ortalama %82,5) buna karşılık pozitif etiketler en zorlayıcı olmuştur (ortalama %45,8). Bu, kullanılan formüllerin nötr duyguları daha iyi tanıdığını, pozitif duyguları ise daha zayıf tanıdığını göstermektedir. Tek faktör formüller olmayabilir. Çalışmada AF3 ve AF4 noktalarının alfa ve beta bantları kullanılmıştır. Farklı alternatifler (farklı kanallar ve bantlar) farklı sonuçlar üretebilir. Ayrıca, Russell'ın modeli dışında başka boyutsal modeller kullanmak da sonuçları değiştirebilir [261].

GTD algoritması, tüm EEG noktalarını kullanmaya kıyasla daha fazla sağlamlık göstermiştir. Tüm EEG noktaların kullanıldığı veri en yüksek (%80) ve en düşük (%33,33) doğrulukları verirken, GTD ile türetilen veri asla bu uç değerlere ulaşmamıştır. Ama daha önemlisi, GTD verileriyle biraz daha yüksek ortalama doğruluk (%63,50'ye karşı %63,25) ve çok daha düşük değişkenlik (standart sapma %8,76'ya karşı %16,11) sağlanmıştır. Bu varyans düşüklüğü, GTD algoritmasının EEG noktalarının eşzamanlı kümeleşmesini tespit etme özelliğinden kaynaklanmaktadır. Başka bir deyişle, GTD'nin sinyalleri eşzamanlı olarak kümelenmesi daha sağlam bir performans sağlayabilmektedir.

Literatürde SEED veri setine uygulanan ML ve DL yöntemleriyle karşılaştırıldığında, FLS tabanlı bulanık boyutsal duygu modelimiz, oldukça rekabetçi bir performans sergilemektedir. Şekil 9.8'de sunulduğu gibi, geleneksel ML sınıflandırıcıları genellikle %45-82 doğruluk elde ederken, gelişmiş DL modelleri yaklaşık %63-92'ye ulaşmaktadır. Sunulan yaklaşımlarımızın en iyisi, neredeyse tüm ML algoritmalarını geride bırakmış ve çoğu DL yöntemiyle aynı sonucu vermiş veya çok az geride kalmıştır. DL yöntemlerinin ortalamasıyla (%81) neredeyse aynı doğruluk sonucunu vermektedir.

Literatürdeki ML ve DL metotları, tüm SEED veri setini, 62 EEG kanalını ve çoklu frekans bantlarını kullanmaktadır. Bunun aksine, FLS yöntemimiz yalnızca iki ön kanal (AF3, AF4)

ve iki bant (alfa, beta) kullandı ve yine de birçok ML/DL sonucuna eşit veya onları aşan %80 oranında bir doğruluk elde etti. Bu, FLS'de özenle seçilmiş kanalların/bantların, veri boyutunu büyük ölçüde azaltırken, duyguyla ilgili bilginin çoğunu yakalayabileceğini göstermektedir.

DL yaklaşımları daha güçlü olmakla birlikte, sınırları ve dezavantajları da vardır [308]. İlk olarak, evrimsel, yinelemeli, grafik tabanlı ve hibrit modelleri kapsayan derin sinir mimarileri, kapsamlı matris çarpımları ve çok katmanlı geri yayılım işlemleri gerektirir. Dolayısıyla, GPU hızlandırmalı kümeler veya bulut tabanlı yüksek performanslı bilgi işlem gücüne ihtiyaç duyarlar. Sonuç olarak, hem eğitim hem de çalışması saatler, hatta günler alabilir. İkincisi, bu yöntemler büyük EEG veri kümelerine bağımlıdır; ancak, onların da elde edilmesi zahmetli ve maliyetlidir. Üçüncüsü, büyük EEG verisinin yüksek maliyetle elde edilmesi zor olduğundan daha küçük EEG verileri kullanılmaktadır ama bu durumda da modeller aşırı öğrenme sorununa yatkındır [14]. Dördüncüsü, evrimsel bloklar, dikkat mekanizmaları ve alan uyarılma katmanları gibi bileşenlerle modern DL işlem hatlarının karmaşıklığı, uzmanlar tarafından kapsamlı ayar gerektiren geniş bir hiperparametre alanı ortaya çıkarır. Bu hiperparametrelerin optimizasyonu ve yüksek doğruluk düzeylerine ulaşmak için büyük deneyimle uygulanması yalnızca uzmanlar tarafından başarılabilir. Bu durum, bu modellerin uygulanabilirliğini sınırlar. Beşincisi, sunulan çıktılar "kara kutu" dur ve belirli bir EEG segmentinin neden pozitif, nötr veya negatif olarak sınıflandırıldığına dair çok az bilgi sunar [323]. Son olarak, derin ağların eğitilmesinin enerji tüketimi ve karbon ayak izi, sürdürülebilirlik konusunda önemsenemeyecek kadar küçük olmayan kaygılar haline gelmiştir [324].

Tam aksine, FLS entegreli hesaplamalı boyutsal duygu çerçevemiz, bu sınırlamaları aşmaktadır. Tasarım gereği, FLS gradyan tabanlı öğrenme veya yinelemeli parametre güncellemeleri gerektirmez; bu da özel donanım ve uzun eğitim döngülerine olan ihtiyacı ortadan kaldırır. Modelimiz, uyarılma ve değerlik indekslerini yalnızca iki ön EEG kanalından türetir. Böylece, DL modellerinin ihtiyaç duyduğu kapsamlı veri olmadan sonuçlar elde edilebilir. Ayrıca, hesaplamalı sonuçları formüller aracılığıyla elde ettiğinden yüksek performanslı bilgi işleme gereksinim duymaz. Bulanık üyelik fonksiyonları ve dilsel protoformlar, doğaları gereği aşırı öğrenmeye yol açmaz ve kararlılık sağlar. Parametreleştirme en aza indirgenmiştir -yalnızca üçgen, yamuk ve gauss üyelik

fonksiyonlarının şekil ve parametrelerinin seçimiyle sınırlıdır- bu da hiperparametre optimizasyon problemini büyük ölçüde küçültmektedir.

Dahası, FLS şeffaf, insan tarafından okunabilir özetler üretir (örnek; "Zamanın çoğunda pozitif duygu gözlemlendi"), tam yorumlanabilirlik sunar ve alan uzmanları tarafından değerlendirilmeyi kolaylaştırır. Modelimiz her bir EEG verisini ayrı ayrı değerlendirip ilgili duygu etiketine ait üyelik derecesini sağladığı için, veri boyunca şeffaflığı koruyabilir ve verinin bölüm bölüm verdiği duyguyu kolayca anlaşılabilir kılmaktadır. Ancak DL modelleri, yalnızca tüm veriden sonuç çıkarır ve her bir EEG verisini yorumlayamaz, hangi duyguya karşılık geldiğini anlamak mümkün değildir.

Modelimizin bir diğer yönü, EEG verisini yorumlayabilmesidir. FLS, bir sınıflandırmadan ziyade bir özetleme aracıdır. Böylece, bir uzmana ihtiyaç duymadan ve belirsiz doğal ifadelerle veriyi yorumlayabilir. Literatürde, EEG verisini bu şekilde yorumlayan DL modellerine dair henüz böyle bir iddia veya uygulama mevcut değildir. Son olarak, EEG örneklem sayısına bağlı doğrusal zaman karmaşıklığı ve GPU yoğun DL eğitime kıyasla ihmal edilebilir düzeyde enerji gereksinimiyle, FLS; sınıflandırma doğruluğundan ödün vermeden gerçek zamanlı, kaynak kısıtlı ve çevresel açıdan sürdürülebilir duygu farkındalığına sahip uygulamaları destekler.

Tüm bu karşılaştırmaların ötesinde, daha kritik bir nokta vardır: Literatürdeki mevcut ML ve DL çalışmaları, veriden sınıf etiketleri çıkarmakla sınırlı kalmakta ve nörobilime teknik bir katkı sunmamaktadır. Hangi kortikal kanalların hangi işlevlere aracılık ettiği veya belirli EEG bantlarının (alfa, beta) doğru sınıflandırma için yeterli olup olmadığı gibi temel soruları ele alamazlar. Sonuç olarak, yalnızca istenen sonuçları üretmek için modeller oluşturarak nörobilimin teknik gelişimine katkıda bulunamazlar. Buna karşılık, çalışmamız hem nörobilim alanını zenginleştirmekte hem de gelecekte bu alanlarda daha fazla çalışma yapılabileceğine dair kanıt sunmaktadır. Yalnızca iki ön kanalın ve alfa/beta bantlarına dayalı hesaplamalı formüllerin kullanımının etkinliğini göstermekteyiz. Ek olarak, boyutsal duygu modellerinin bulanıklaştırılmasının daha hassas ve doğru duygu analizlerini başarmayı mümkün kıldığını göstermekteyiz. Sonuç olarak, yaklaşımımız nörobilim alanında teknik bir ilerleme sağlamaktadır.

Basitliğine rağmen, FLS yaklaşımı birçok ML ve DL yaklaşımını geride bırakmış ve onlarla rekabet etmiştir. Bu sonuçlara, verinin küçük bir kısmını (62 kanal yerine yalnızca AF3 ve AF4) ve basit, kolay hesaplamalı modelleri kullanarak ulaşmıştır. Bu sonuçlar, EEG tabanlı duygu tanımda bulanık kümeler ve dilsel özetlemenin pratik bir alternatif olarak uygulanabilirliğini vurgulamakta ve ölçeklenebilirlik, şeffaflık ve esneklik konularında önemli avantajlar sunmaktadır.

9.6. Sonuç

Bu çalışmada, FLS'yi bulanıklaştırılmış Russell sirkumpleks modeliyle bütünleştirerek, EEG tabanlı duygu sınıflandırması için yeni bir çerçevenin tüm hedeflenen katkıları karşılayabileceğini gösterdik.

İlk olarak, frontal asimetriden oluşturulan dört uyarılma/değer formülünün karşılaştırmalı bir değerlendirmesini gerçekleştirdik. Bu analiz tutarlı farklılıklar gösterdi: bazı formüller daha ayırt edici değer/uyarılma sinyalleri üretirken, diğerleri güvenilir değildi. Paralel olarak, Russell'in sirkumpleks'ine 45° rotasyon uygulayarak 16 duygu etiketini üç kategoriye (pozitif, nötr, negatif) yeniden gruplandırdık ve sonuçlara bakılırsa, ilk kez uygulanan bu gruplama tatmin edici sonuçlar elde etti.

İkinci olarak, Russell'in sirkumpleks'ini üç bulanık üyelik fonksiyonuyla (üçgen, yamuk, Gauss) zenginleştirdik. Üçgen üyelik fonksiyonu genellikle duygusal bölgeler arasındaki en belirgin ayrımı elde etti. Bu, üyelik geometrisinin ayarlanmasının doğruluğu artırabileceğini göstermektedir. Bu katkılar, formülleri dikkatlice seçmenin ve bulanık kümelerle duyguları tasarlamının, daha sağlam modellere ulaştırabileceğini göstermektedir. Ayrıca, sürekli, örtüşen duygu çıkarımlarına olan ihtiyacı da ele aldık. Duygu etiketlerini bulanıklaştırarak (her EEG noktasının birden fazla kategoride kısmi üyeliğe sahip olmasına izin vererek), net etiketlerin kaçıracağı duygusal etkiyi yakaladık. Bu sürekli tanıma, özetlememizde girdiyi zenginleştirdi ve belirsiz beyin tepkilerini yakalanabilir hale getirdi.

Ayrıca, duygu tanımda güvenilirliği artırmak için, verileri eş zamanlı yığılmalara göre işleyen, değiştirilmiş bir GTD algoritması kullanıldı ve sonuçları daha sağlam hale getirdiği kanıtlandı. Çalışmadaki en yüksek sonuçları vermese de, daha düşük değişkenlik ve daha yüksek ortalama sonuçlar sağlayabileceğini gösterdi. Yani, tüm veriyi işlemenin

maliyetinden kaçınabilen ve sağlamlığı artırabilen bu yaklaşım, gelecekte veri ön işlemede yerini bulacaktır.

Son olarak, sınıflandırmanın bir parçası olarak FLS kullanıldı. Burada, bulanıklaştırılmış etiketler, sınıflandırma için kullanılan özetlere dönüştürüldü. Bu yaklaşım, neredeyse tüm ML yöntemlerini geride bıraktı ve DL yöntemleriyle karşılaştırılabilir bir doğruluk elde etti. Böylece, geliştirdiğimiz bu yaklaşım, verimlilik ve performans gibi iddialarını kanıtlamış oldu.

Sonuç olarak, çalışmanın ilk hedefi, SEED gibi yaygın kullanılan büyük bir veri kümesinde boyutsal bir modeli -ilk kez- farklı alternatiflerle uygulamak ve farklı formüllerle zenginleştirerek kapsamlı sonuçlara ulaşmaktır. ML/DL yöntemlerine karşı yüksek performans elde etmesi, gelecek çalışmalara ilham vereceğini göstermektedir. Veri ön işleme, boyutsal modellerin bulanıklaştırılması, FLS ile sınıflandırma ve diğer ince katkılara dair yeni bakış açıları, çalışmanın hedefine ulaşmasını sağladı.

Gelecekte, çalışma bazı noktalarla daha da zenginleştirilebilir. Öncelikle, SEED veri setinin üç sınıflı yapısı ayrıntıyı kısıtlar; gelecekteki çalışmalar daha ince duygu eşlemelerini inceleyebilir veya baskınlığı üçüncü bir boyut olarak dâhil edebilir. İkinci olarak, frontal alfa/beta özelliklerine güvenmek diğer beyin bölgelerinden gelen katkıları göz ardı edebilir. Özellik çıkarmayı temporal ve parietal sinyalleri içerecek şekilde genişletmek, sağlamlığı artırabilir. Son olarak, çeşitli deneysel kurulumlar için GTD parametrelerini (örneğin, küme boyutunu, "m") optimize etmek daha fazla araştırmayı gerektirmektedir.



KAYNAKLAR

1. Yang, X.-S. (2019). *Introduction to Algorithms for Data Mining and Machine Learning*. (5th edition). United Kingdom: Academic Press,173.
2. Boran, F. E. (2013). *Aralıklı tip-2 bulanık kümelerle dilsel özetleme*. Yayınlanmamış Doktora Tezi, Gazi Üniversitesi Fen bilimleri Enstitüsü, Ankara.
3. Han, J., Kamber, M., Pei, J. (2012). *Data Mining Concepts and Techniques*. (3rd edition). United States of America: Elsevier, 213.
4. Tan, P. N., Steinbach, M., Kumar, V. (2006). *Introduction to data mining*. (4th edition). Wesley Boston: Pearson Addison, 147.
5. Hatipoğlu, H. (2017). *Zaman serilerinin dilsel özetlenmesi: Avrupa Brent Petrol spot piyasa fiyatı üzerine bir uygulama ve Türkiye perspektifinden yorumlar*. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 1-142.
6. Niewiadomski, A. (2008). A Type-2 Fuzzy Approach to Linguistic Summarization of Data. *IEEE Transactions on Fuzzy Systems*, 16(2), 198-212.
7. Yager, R. R. (1982). A new approach to the summarization of data. *Information Sciences*, 28(1), 69-86.
8. Boran, F. E., Akay, D., Yager, R. R. (2016). An overview of methods for linguistic summarization with fuzzy sets. *Expert Systems with Applications*, 61, 356-377.
9. Bouchon-Meunier, B., Moyse, G. (2012). Fuzzy Linguistic Summaries: Where Are We, Where Can We Go? *IEEE Access*, 56, 1-8.
10. Marín, N., Sánchez, D. (2015). On generating linguistic descriptions of time series. *Fuzzy Sets and Systems*, 285, 1-27.
11. Kacprzyk, J., Yager, R. R. (2001). Linguistic summaries of data using fuzzy logic. *International Journal of General Systems*, 30(2), 133-154.
12. Zadrozny, S., Kacprzyk, J., Gola, M. (2005). *Towards Human Friendly Data Mining: Linguistic Data Summaries and Their Protoforms*. In W. Duch, J. Kacprzyk, E. Oja, & S. Zadrozny, *Artificial Neural Networks: Formal Models and Their Applications -- ICANN 2005* (s. 697-702). Berlin Heidelberg: Springer.
13. Niewiadomski, A. (2005). *On Two Possible Roles of Type-2 Fuzzy Sets in Linguistic Summaries*. In P. Szczepaniak, J. Kacprzyk, & A. Niewiadomski, *Advances in Web Intelligence*, Switzerland: Springer. 341-347.
14. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2006). *Linguistic Summarization of Trends: A Fuzzy Logic Based Approach*. Proceedings of the 11th International Conference Information Processing and Management of Uncertainty in Knowledge-based Systems, 2166-2172.

15. Almeida, R. J., Marie-Jeanne, L., Bouchon-Meunier, B., Kaymak, U., Moyse, G. (2013). *Linguistic Summaries of Categorical Time Series for Septic Shock Patient Data*. 2013 IEEE International Conference on Fuzzy Systems, Paris:AGARD, 1-8.
16. Castillo-Ortega, R., Marín, N., Martínez-Cruz, C., Sanchez, D. (2014). *A proposal for the hierarchical segmentation of time series. Application to trend-based linguistic description*. 2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Beijing, China: IEEE, 489-496.
17. Kacprzyk, J., Zadrozny, S. (2016). Fuzzy logic-based linguistic summaries of time series: a powerful tool for discovering knowledge on time varying processes and systems under imprecision. *Data Mining and Knowledge Discovery*, 30(1), 1-12.
18. Novak, V., Perfilieva, I. (2015). *Time Series Mining by Fuzzy Natural Logic and F-Transform*. 2015 48th Hawaii International Conference on System Sciences, Hawaii:IEEE,1493-1502.
19. Sanchez-Valdes, D., Alvarez-Alvarez, A., Trivino, G. (2016). Dynamic linguistic descriptions of time series applied to self-track the physical activity. *Fuzzy Sets and Systems*, 286, 1-20.
20. Kacprzyk, J., Wilbik, A. (2010). *Temporal Linguistic Summaries of Time Series Using Fuzzy Logic*. IPMU 2010. Berlin Heidelberg: Springer-Verlag, 436-445.
21. Kacprzyk, J., Wilbik, A. (2008). *Linguistic summarization of time series using linguistic quantifiers: augmenting the analysis by a degree of fuzziness*. 2008 IEEE International Conference on Fuzzy Systems. Paris: IEEE, 1146-1153.
22. Moreno-Garcia, J., Rodriguez-Benitez, L., Jimenez-Linares, L., Trivino, G. (2016). Description of multivariate time series by means of trends characterization in the fuzzy domain. *Fuzzy Sets and Systems*, 291, 118-139.
23. Jain, A., Marie-Jeanne, L., Keller, J. (2017). *A decision support system for home BP measurements*. Proceedings of the 11th EAI International Conference on Pervasive Computing Technologies for Healthcare. Barcelona, Spain, AGARD, 231-234.
24. Zaltman, G., Kosslyn, S. (1998). *Neuroimaging as a marketing tool*. USA Patent No. US6099319A.
25. Boricean, V. (2009). *Brief History of Neuromarketing*. The International Conference of Administration and Business, Spain: IEEE, 119-121.
26. Yadava, M., Kumar, P., Saini, R., Roy, P., Dogra, D. (2017). Analysis of EEG signals and its application to neuromarketing. *Multimedia Tools and Applications*, 76(24), 15-37.
27. Khurana, V., Gahalawat, M., Kumar, P., Roy, P., Dogra, D., Scheme, E., Soleymani, M. (2021). A Survey on Neuromarketing Using EEG Signals. *IEEE Transactions on Cognitive and Developmental Systems*, 13(4), 732-747.

28. Al-Nafjan, A., Al-Wabil, A., Hosny, M., Al-Ohali, Y. (2017). Classification of Human Emotions from Electroencephalogram (EEG) Signal using Deep Neural Network. *International Journal of Advanced Computer Science and Applications*, 8(9), 1-7.
29. Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353.
30. Özdoğan, İ., Boran, F. E., Akay, D. (2020). A possibilistic approach for interval type-2 fuzzy linguistic summarization. *Artificial Intelligence Review*, 53(1), 1-28.
31. Ünal, C. (2009). *Bulanık Mantık Uygulamasıyla Konfeksiyonda İşin Ve Personelin Değerlendirilmesi*. Doktora Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 1-184.
32. Ross, T. J. (1995). *Fuzzy Logic with Engineering Applications*. (2th edition). USA: McGraw-Hill Inc, 257.
33. Klir, G. J., Yuan, B. (1995). *Fuzzy sets and fuzzy logic: theory and applications*. (3rd Edition). River, NJ, USA: Prentice Hall, 198.
34. Zadeh, L. A. (1975). The concept of a linguistic variable and its application to approximate reasoning. *Information Sciences*, 8(3), 199-249.
35. Klir, G. J., Yuan, B. (1995). *Fuzzy sets and fuzzy logic: theory and applications*. (3rd Edition). River, NJ, USA: Prentice Hall, 198.
36. Delgado, M., Sanchez, D., Vila, M. A. (2000). Fuzzy cardinality based evaluation of quantified sentences. *International Journal of Approximate Reasoning*, 23(1), 23-66.
37. Zadeh, L. A. (1983). A computational approach to fuzzy quantifiers in natural languages. *Computers & Mathematics with Applications*, 9(1), 149-184.
38. Delgado, M., Sanchez, D., Martin-Bautista, M., Vila, M. A. (2002). A probabilistic definition of a nonconvex fuzzy cardinality. *Fuzzy Sets and Systems*, 126(2), 177-190.
39. Yager, R. R. (1982). A new approach to the summarization of data. *Information Sciences*, 28(1), 69-86.
40. Poli, J.-P., Boudet, L., Yaouanc, J.-M. (2018). *Online Spatio-Temporal Fuzzy Relations*. 2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Brasil: IEEE, 1-8.
41. Jain, A., Keller, J. M. (2015). On the Computation of Semantically Ordered Truth Values of Linguistic Protoform Summaries. *IEEE Access*, 1-8.
42. Yu, J., Reiter, E., Hunter, J., Melish, C. (2006). Choosing the content of textual summaries of large time-series data sets. *Natural Language Engineering*, 12(1), 25-49.
43. Jain, A., Popescu, M., Keller, J. M., Rantz, M., Markway, B. (2019). Linguistic summarization of in-home sensor data. *Journal of Biomedical Informatics*, 89, 1-14.
44. Kacprzyk, J. (1999). *An interactive fuzzy logic approach to linguistic data summaries*. 1999 IEEE International Fuzzy Systems Conference Proceedings, Paris: IEEE, 595-599.

45. Dziedzic, M., Zadrozny, S., Kacprzyk, J. (2012). *Towards bipolar linguistic summaries: a novel fuzzy bipolar querying based approach*. 2012 IEEE World Congress on Computational Intelligence, Brisbane, Australia: WCCI, 10-15.
46. Zadrozny, S., Kacprzyk, J., Tre, G. (2012). Bipolar queries in textual information retrieval: A new perspective. *Information Processing and Management*, 48(3), 390-398.
47. Kacprzyk, J., Wilbik, A. (2010). *Comparison of Time Series via Classic and Temporal Protoforms of Linguistic Summaries: An Application to Mutual Funds and Their Benchmarks*. In J. Kacprzyk, *Advances in Intelligent and Soft Computing*. Berlin: Springer. 369-378.
48. Baaj, Í., Poli, J.-P. (2019). *Natural Language Generation of Explanations of Fuzzy Inference Decisions*. 2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Dublin: IEEE, 1-15.
49. Banaee, H., Schaffernicht, E., Loutfi, A. (2018). Data-Driven Conceptual Spaces: Creating Semantic Representations for Linguistic Descriptions of Numerical Data. *Journal of Artificial Intelligence Research*, 62, 691-742.
50. Mirzakhonov, V., Gardashova, L. (2019). Modification of the Wu-Mendel approach for linguistic summarization. *Journal of Experimental & Theoretical Artificial Intelligence*, 31(1), 77-97.
51. Wu, D., Mendel, J. M. (2011). Linguistic Summarization Using IF--THEN Rules and Interval Type-2 Fuzzy Sets. *IEEE Transactions on Fuzzy Systems*, 19(1), 136-150.
52. Perfilieva, I., Novak, V., Dvohrak, A. (2006). *How to Mine Linguistic Associations using Fuzzy Transform*. 2006 IEEE International Conference on Fuzzy Systems, Moskov: IEEE, 645-648.
53. Kupka, J., Rusnok, P. (2017). Regression analysis based on linguistic associations and perception-based logical deduction. *Expert Systems with Applications*, 67, 107-114.
54. Jain, A., Marie-Jeanne, L., Keller, J. (2017). *A decision support system for home BP measurements*. Proceedings of the 11th EAI International Conference on Pervasive Computing Technologies for Healthcare, Barcelona, Spain: ACM, 231-234.
55. Trivino, G., Sugeno, M. (2013). Towards linguistic descriptions of phenomena. *International Journal of Approximate Reasoning*, 54(1), 22-34.
56. Moreno-Garcia, J., Rodriguez-Benitez, L., Jimenez-Linares, L., Trivino, G. (2019). *A Linguistic Extension of Petri Nets for the Description of Systems: An Application to Time Series*. *IEEE Transactions on Fuzzy Systems*, 27(9), 1819-1833.
57. Moreno-Garcia, J., Castillo, E., Rodriguez-Benitez, L. (2020). *TrPM: A Linguistic Petri Nets module to describe the trends of a time series*. 2020 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Paris: IEEE, 1-8.

58. Novak, V. (2017). *Tectogrammatical Trees and Fuzzy Natural Logic in Linguistic Characterization of Dynamic Processes*. 17th World Congress of International Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems (IFSA-SCIS), Otsu, Shiga, Japan: IFSA, 1-6.
59. Novak, V. (2016). Mining information from time series in the form of sentences of natural language. *International Journal of Approximate Reasoning*, 78, 192-209.
60. Novak, V. (2017). *Tectogrammatical Trees and Fuzzy Natural Logic in Linguistic Characterization of Dynamic Processes*. in IFSA-SCIS 2017, Otsu, Shiga, Japan: IEEE, 1-6.
61. Novak, V. (2017). Fuzzy Logic in Natural Language Processing. *IEEE Xplore*, 36, 1-6.
62. Aoki, K., Kobayashi, I. (2016). Linguistic Summarization using a Weighted N-gram Language Model based on the Similarity of Time-series Data. *IEEE Access*, 22(2), 595-601.
63. Yager, R. R. (1988). On ordered weighted averaging aggregation operators in multicriteria decision. *IEEE Transactions on Systems, Man, and Cybernetics*, 18(1), 183-190.
64. Kacprzyk, J. (2013). *Hierarchical bipolar fuzzy queries: towards more human consistent flexible queries*. 2013 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Dublin: IEEE, 123-138.
65. Bosc, P., Lietard, L. (1995). *On the comparison of the sugeno and the choquet fuzzy integrals for the evaluation of quantified statements*. In Proceedings of EU-fit'95, Paris, AGARD, 709-716.
66. Yager, R. R. (1991). *Fuzzy quotient operators for fuzzy relational databases*. In Proceedings of ifes'91, Brasil:IFES, 289-296.
67. Delgado, M., Sanchez, D., Vila, M. A. (2000). Fuzzy cardinality based evaluation of quantified sentences. *International Journal of Approximate Reasoning*, 23(1), 23-66.
68. Sanchez, D., Delgado, M., Vila, M. A. (2009). *Fuzzy Quantification Using Restriction Levels*. In V. Di Gesu, S. K. Pal, & A. Petrosino, *Fuzzy Logic and Applications*. Berlin/Heidelberg: Springer. 28-35.
69. Sanchez, D., Delgado, M., Vila, M. A. (2009). Fuzzy Quantification Using Restriction Levels. *Lecture Notes in Computer Science*, 71, 28-35.
70. Dubois, D., Prade, H. (2008). Gradual elements in a fuzzy set. *Soft Computing*, 12(2), 165-175.
71. Glockner, I., Knoll, A. (2001). *A formal theory of fuzzy natural language quantification and its role in granular computing*. In W. Pedrycz, *Granular computing: An emerging paradigm*, Physica-Verlag: Springer. 215-256.

72. Diaz-Hermida, F., Bugarin, A. (2011). *Semi-fuzzy quantifiers as a tool for building linguistic summaries of data patterns*. 2011 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Turkey: IEEE, 15-27.
73. Diaz-Hermida, F., Bugarin, A., Barro, S. (2003). Definition and classification of semi-fuzzy quantifiers for the evaluation of fuzzy quantified sentences. *International Journal of Approximate Reasoning*, 33(1), 49-88.
74. Yager, R. R. (1984). General multiple-objective decision functions and linguistically quantified statements. *International Journal of Man-Machine Studies*, 21(5), 389-400.
75. Bosc, P., Lietard, L. (1994). *Monotonic quantified statements and fuzzy integrals*. IEEE Conference on Fuzzy Systems, Hawaii:IEEE, 8-12.
76. Vila, M. A., Cubero, J. C., Medina, J. M., Pons, O. (1997). *Using OWA operator in flexible query processing*. In R. R. Yager & J. Kacprzyk, *The ordered weighted averaging operators: Theory, methodology and applications*, New York: Kluwer Academic Publishers. 58-274.
77. Vila, M. A. (1997). *Using OWA operator in flexible query processing*. In R. R. Yager & J. Kacprzyk, *The ordered weighted averaging operators: Theory, methodology and applications*, Kluwer Academic Publishers. 258-274.
78. Baldwin, J. (1992). *The management of fuzzy and probabilistic uncertainties for knowledge based systems*. In D. Ciucci, C. Inés, J. Medina, D. Ślęzak, D. Petturiti, B. Bouchon-Meunier, R. Yager, *Encyclopedia of AI*, Milan, Italy: John Wiley & Sons. 528-537.
79. Baldwin, J., Lawry, J., Martin, T. (1996). A mass assignment theory of the probability of fuzzy events. *Fuzzy Sets and Systems*, 83(3), 353-367.
80. Lietard, L. (2012). A functional interpretation of linguistic summaries of data. *Information Sciences*, 189, 1-16.
81. Bugarín, A., Marin, N., Sánchez, D., Trivino, G. (2015). *Aspects of quality evaluation in Linguistic Descriptions of Data*. 2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Luxemburg: IEEE, 1-8.
82. Marín, N., Sánchez, D. (2015). On generating linguistic descriptions of time series. *Fuzzy Sets and Systems*, 285, 1-27.
83. Sripada, S., Reiter, E., Hunter, J., Yu, J. (2003). *Generating english summaries of time series data using the gricean maxims*. Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining, Netherland: ACM, 187-196.
84. Yager, R. R., Ford, K. M., Canas, A. J. (1990). *An approach to the linguistic summarization of data*. 3rd International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems, IPMU '90, Paris, France:AGARD, 456-468.

85. Hudec, M. (2016). *Linguistic Summaries*. In M. Hudec, *Fuzziness in Information Systems* (s. 67-99). Slovakia: Springer.
86. Kacprzyk, J., Wilbik, A. (2009). *Towards an efficient generation of linguistic summaries of time series using a degree of focus*. 2009 Annual Meeting of the North American Fuzzy Information Processing Society (NAFIPS), Cincinnati, Ohio, USA: IEEE, 1-6.
87. Kacprzyk, J., Wilbik, A. (2010). *Linguistic Summaries of Time Series: On Some Additional Data Independent Quality Criteria*. Foundations of Reasoning under Uncertainty, STUDFUZZ, Berlin: Springer, 143-166.
88. Yager, R. R. (1988). On ordered weighted averaging aggregation operators in multicriteria decision. *IEEE Transactions on Systems, Man, and Cybernetics*, 18(1), 183-190.
89. Kacprzyk, J., Wilbik, A. (2009). *Linguistic summarization of time series using a degree of appropriateness as a measure of interestingness*. 2009 Ninth International Conference on Intelligent Systems Design and Applications, Berlin: Springer, 385-390.
90. Kacprzyk, J., Wilbik, A. (2010). *A Comprehensive Comparison of Time Series Described by Linguistic Summaries and its Application to the Comparison of Performance of a Mutual Fund and its Benchmark*. 2010 IEEE International Conference on Fuzzy Systems, France: IEEE, 1-8.
91. Lesot, M.-J., Moyse, G., Bouchon-Meunier, B. (2016). Interpretability of fuzzy linguistic summaries. *Fuzzy Sets and Systems*, 292, 1-11.
92. Tre, G., Dziedzic, M., Britsom, D., Zadrozny, S. (2014). *Dealing with Missing Information in Linguistic Summarization: A Bipolar Approach*. In J. Kacprzyk, *Intelligent Systems'2014*, Paris, France: Springer. 528-537.
93. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2006). *Linguistic Summaries of Time Series via a Quantifier Based Aggregation Using the Sugeno Integral*. 2006 IEEE International Conference on Fuzzy Systems, Vancouver, BC, Canada: IEEE, 16-21.
94. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2006). A Linguistic Quantifier Based Aggregation for a Human Consistent Summarization of Time Series. *Advances in Soft Computing*, 34, 183-190.
95. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2006). *A Linguistic Approach to a Human-Consistent Summarization of Time Series Using a SOM Learned with a LVQ-Type Algorithm*. ICANN 2006, Berlin: Springer, 171-180.
96. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2006). *On some types of linguistic summaries of time series*. 3rd International IEEE Conference Intelligent Systems, Berlin: IEEE, 373-378.
97. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). *Mining time series data via linguistic summaries of trends by using a modified Sugeno integral based aggregation*. 2007 IEEE Symposium on Computational Intelligence and Data Mining, Moskov:IEEE, 742-750.

98. Banaee, H., Ahmed, M. U., Loutfi, A. (2013). *A framework for automatic text generation of trends in physiological time series data*. 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Paris: Springer 3876-3881.
99. Boulanouar, K., Hadjali, A., Lagha, M. (2020). *A Hybrid Approach for Linguistic Summarization of Time Series*. 2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy, New York: Plenum Press, 1-5.
100. Wilbik, A., Kacprzyk, J. (2010). *A Multi-criteria Evaluation of Linguistic Summaries of Time Series via a Measure of Informativeness*. 10th International Conference, ICAISC 2010, Zakopane, Poland: Springer, 105-113.
101. Wilbik, A., Kacprzyk, J. (2010). *On the evaluation of the linguistic summarization of temporally focused time series using a measure of informativeness*. 2010 International Multiconference on Computer Science and Information Technology, Berlin: IEEE, 155-162.
102. Wilbik, A., Kacprzyk, J. (2012). Towards a multi-criteria analysis of linguistic summaries of time series via the measure of informativeness. *International Journal of Data Analysis Techniques and Strategies*, 4(2), 181-204.
103. Moreno-Garcia, J., Moreno-Garcia, A., Jimenez-Linares, L., Rodriguez-Benitez, L. (2020). *Describing Time Series Using Fuzzy Piecewise Linear Segments*. In J. Kacprzyk, *Studies in Computational Intelligence*, Switzerland: Springer Nature. 149-155.
104. Castillo-Ortega, R., Marin, N., Martínez-Cruz, C., Sanchez, D. (2015). *Linguistic comparison of time series using the End-Point Fit algorithm*. 2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Paris: IEEE, 1-8.
105. Martinez-Cruz, C., Rueda, A., Popescu, M., Keller, J. (2015). A New Linguistic Description Approach for Time Series and its Application to Bed Restlessness Monitoring for Eldercare. *Journal of Latex Class Files*, 14(8), 1-12.
106. Moreno-Garcia, J., Jimenez, L., Castro-Schez, J. J. (2004). *A Direct Induction Algorithm of Temporal Fuzzy Models*. 2004 IEEE International Conference on Fuzzy Systems, Budapest, Hungary, 25-29.
107. Moreno-Garcia, J., Rodriguez-Benitez, L., Giral, J., Castillo, E. d. (2014). The generation of qualitative descriptions of multivariate time series using fuzzy logic. *Applied Soft Computing*, 24, 546-555.
108. Hatipoğlu, H. (2017). *Zaman Serilerinin Dilsel Özetlenmesi: Avrupa Brent Petrol Spot Piyasa Fiyatı Üzerine Bir Uygulama Ve Türkiye Perspektifinden Yorumlar*. Yüksek Lisans Tezi, Gazi Fen Bilimleri Enstitüsü, Ankara, 1-142.
109. Morin, C. (2011). Neuromarketing: The new science of consumer behavior. *Society*, 48(2), 131-135.

110. Aldayel, M., Ykhlef, M., Al-Nafjan, A. (2020). Deep Learning for EEG-Based Preference Classification in Neuromarketing. *Applied sciences*, 10(4), 1-23.
111. Ait Hammou, K., Galib, M. H., Melloul, J. (2013). The Contributions of Neuromarketing in Marketing Research. *Journal of Management Research*, 5(4), 20.
112. Morin, C. (2011). Neuromarketing: The new science of consumer behavior. *Society*, 48(2), 131-135.
113. Joy, M. M. (2018). *The potential and challenge of using neuromarketing as a marketing tool*. Proceedings of the National Conference on New Age Marketing, Paris:AGARD, 1-14.
114. Telpaz, A., Webb, R., Levy, D. J. (2015). Using EEG to Predict Consumers' Future Choices. *Journal of Marketing Research*, 52(4), 511-529.
115. Barros, R. Q., Tavares, A. C., Albuquerque, W. W., da Silva, J. F., de Lemos, I. F., de Albuquerque Car, R. C., Cairao, M. (2016). *Analysis of Product Use by Means of Eye Tracking and EEG: A Study of Neuroergonomics*. In A. Marcus, *Lecture Notes in Computer Science*, Cham, Switzerland: Springer International Publishing. 539-548.
116. García-Martínez, B., Martínez-Rodrigo, A., Alcaraz, R., Fernandez-Caballero, A. (2021). A Review on Nonlinear Methods Using Electroencephalographic Recordings for Emotion Recognition. *IEEE Transactions on Affective Computing*, 12(3), 801-820.
117. Picard, R. W. (1997). *Affective computing*. (2th Edition). Massachusetts Ave, Cambridge: MIT Press, 184.
118. Abdulkader, S. N., Atia, A., Mostafa, M. S. (2015). Brain computer interfacing: Applications and challenges. *Egyptian Informatics Journal*, 16(2), 213-230.
119. Ramadan, R. A. (2015). *Brain-Computer Interfaces*. (1th Edition). Cham, Switzerland: Springer International Publishing, 127.
120. Ramadan, R. A., Vasilakos, A. V. (2016). Brain Computer Interface: Control Signals Review. *Neurocomputing*, 223, 1-19.
121. Sanei, S. (2013). *Adaptive Processing of Brain Signals*. (1th Edition). Hoboken, NJ, USA: Wiley, 175.
122. Klem, G. H., Lüder, H. O., Jasper, H. H., Elger, C. (1999). The ten-twenty electrode system of the International Federation. *Electroencephalography Clinical Neurophysiology*, 52(3), 3-6.
123. Kaiser, J., Lutzenberger, W. (2005). Human gamma-band activity: A window to cognitive processing. *Neuroreport*, 16(3), 207-211.
124. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2006). *Using a Genetic Algorithm to Derive a Linguistic Summary of Trends in Numerical Time Series*. 2006 International Symposium on Evolving Fuzzy Systems, Berlin: ACM, 137-142.

125. Boran, F. E., Akay, D., Yager, R. R. (2014). A Probabilistic Framework for Interval Type-2 Fuzzy Linguistic Summarization. *IEEE Transactions on Fuzzy Systems*, 22(6), 1640-1653.
126. Boran, F. E., Akay, D. (2014). A Generic Method for the Evaluation of Interval Type-2 Fuzzy Linguistic Summaries. *IEEE Transactions on Cybernetics*, 44(10), 1632-1645.
127. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). *Linguistic Summarization of Time Series via an OWA Operator Based Aggregation of Partial Trends*. IEEE International Conference on Fuzzy Systems, Dubai: IEEE, 1-6.
128. Kacprzyk, J., Zadrozny, S. (2010). Towards human consistent data driven decision support systems using verbalization of data mining results via linguistic data summaries. *Bulletin of the Polish Academy of Sciences*, 58(3), 359-370.
129. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). A Fuzzy Logic Approach to the Linguistic Summarization of Time Series. *Journal of Multiple-valued Logic and Soft Computing*, 22(1), 157-182.
130. Kacprzyk, J., Wilbik, A. (2009). *Using Fuzzy Linguistic Summaries for the Comparison of Time Series: an application to the analysis of investment fund quotations*. IFSA-EUSFLAT 2009, Turkey: Springer, 1321-1327.
131. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2008). Linguistic summarization of time series using a fuzzy quantifier driven aggregation. *Fuzzy Sets and Systems*, 159(12), 1485-1499.
132. Kacprzyk, J., Wilbik, A. (2008). *A New Insight into the Linguistic Summarization of Time Series Via a Degree of Support: Elimination of Infrequent Patterns*. In D. Dubois, *Soft Methods for Handling Variability and Imprecision*, Berlin: Springer. 393-400.
133. Kacprzyk, J., Wilbik, A. (2008). *Linguistic Summarization of Time Series Using Fuzzy Logic with Linguistic Quantifiers: A Truth and Specificity Based Approach*. ICAISC 2008, Nice, France: Springer, 241-252.
134. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). *Linguistic Summarization of Time Series Under Different Granulation of Describing Features*. In M. Kryszkiewicz, J. Peters, H. Rybinski, & A. Skowron, *Rough Sets and Intelligent Systems Paradigms*, Berlin Heidelberg: Springer-Verlag. 230-240.
135. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). *Towards Human Consistent Linguistic Summarization of Time Series via Computing with Words and Perceptions*. In M. Nikraves, *Forging New Frontiers: Fuzzy Pioneers*, Berlin: Springer. 17-35.
136. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). *Analysis of Time Series via their Linguistic Summarization: the Use of the Sugeno Integral*. Seventh International Conference on Intelligent Systems Design and Applications, Poland: IEEE, 262-267.

137. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2007). *Linguistic Summarization of Time Series by Using the Choquet Integral*. In P. Melin, O. Castillo, L. Aguilar, J. Kacprzyk, & W. Pedrycz, *Foundations of Fuzzy Logic and Soft Computing*, Berlin: Springer. 284-294.
138. Kacprzyk, J., Zadrozny, S., Wilbik, A. (2007). *On Linguistic Summaries of Time Series Using a Fuzzy Quantifier Based Aggregation via the Sugeno Integral*. In O. Castillo, P. Melin, J. Kacprzyk, & W. Pedrycz, *Hybrid Intelligent Systems*, Berlin: Springer. 415-433.
139. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2010). An Approach to the Linguistic Summarization of Time Series Using a Fuzzy Quantifier Driven Aggregation. *International Journal of Intelligent Systems*, 25(5), 411-439.
140. Kacprzyk, J., Zadrozny, S. (2013). *Comprehensiveness and interpretability of linguistic data summaries: a natural language focused perspective*. 2013 IEEE Symposium on Computational Intelligence for Human-like Intelligence (CIHLI), Dubai: IEEE, 33-40.
141. Kacprzyk, J., Zadrozny, S. (2016). Fuzzy logic-based linguistic summaries of time series: a powerful tool for discovering knowledge on time varying processes and systems under imprecision. *WIREs Data Mining and Knowledge Discovery*, 6(1), 7-46.
142. Kacprzyk, J., Zadrozny, S. (2016). Linguistic summarization of the contents of Web server logs via the Ordered Weighted Averaging (OWA) operators. *Fuzzy Sets and Systems*, 285, 182-198.
143. Kacprzyk, J., Zadrozny, S. (2015). *Linguistic Summaries of Time Series: A Powerful and Prospective Tool for Discovering Knowledge on Time Varying Processes and Systems*. In R. Seising, E. Trillas, & J. Kacprzyk, *Towards the Future of Fuzzy Logic* Berlin: Springer. 65-77.
144. Kaczmarek-Majer, K., Hryniewicz, O. (2019). Application of linguistic summarization methods in time series forecasting. *Information Sciences*, 477, 580-594.
145. Kaczmarek-Majer, K., Hryniewicz, O., Dominiak, M., Swiecicki, L. (2019). *Personalized linguistic summaries in smartphone-based monitoring of bipolar disorder patients*. 11th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT 2019), Hungary: Atlantis press, 400-407.
146. Kaczmarek, K., Hryniewicz, O., Kruse, R. (2015). *Human Input about Linguistic Summaries in Time Series Forecasting*. The Eighth International Conference on Advances in Computer-Human Interactions, Prag: Springer, 1-5.
147. Kaczmarek, K., Hryniewicz, O. (2015). *Time Series Classification with Linguistic Summaries*. 9th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT), New York: Atlantis Press, 471-478.

148. Kaczmarek, K., Hryniewicz, O. (2016). *Forecasting of Short Time Series with Intelligent Computing*. In G. Tré, *Challenging Problems and Solutions in Intelligent Systems*, Switzerland: Springer. 59-75.
149. Habiballa, H. (2016). *Pattern Recognition using Linguistic Fuzzy Logic Predictors*. International Conference of Numerical Analysis and Applied Mathematics 2015, India: AIP Publishing, 1-4.
150. Nguyen, L., Novák, V. (2019). Forecasting seasonal time series based on fuzzy techniques. *Fuzzy Sets and Systems*, 358, 115-129.
151. Nguyen, L., Novak, V. (2017). *Trend-cycle Forecasting Based on New Fuzzy Techniques*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Berlin: IEEE, 1-6.
152. Novak, V. (2013). On modelling with words. *International Journal of General Systems*, 42(1), 21-40.
153. Novák, V., Pavliska, V., Perfilieva, I., Štepnicka, M. (2013). *F-transform and Fuzzy Natural logic in Time Series Analysis*. 8th Conference of the European Society for Fuzzy Logic and Technology, Prag: Atlantis Press, 40-47.
154. Novak, V. (2014). Forecasting Trend of a Group of Time Series Using F-Transform and Fuzzy Natural Logic. *Computational Intelligence for Complex Engineering and Decision Support Systems*, 1-16.
155. Novak, V., Mirshahi, S., Pavliska, V. (2019). *LFL Forecaster: Analysis, Forecasting and Mining Information from Time Series*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Moskov: IEEE, 1-6.
156. Novak, V., Perfilieva, I., Dvorak, A. (2016). *Analysis and Forecasting of Time Series*. In V. Novak, *Insight into Fuzzy Modeling*, Czech Republic: John Wiley & Sons, Inc. 3-10.
157. Novák, V., Pavliska, V., Štepnicka, M., Štepnickova, L. (2014). *Time Series Trend Extraction and Its Linguistic Evaluation Using F-transform and Fuzzy Natural Logic*. In L. Zadeh, *Studies in Fuzziness and Soft Computing*, Switzerland: Springer. 429-437.
158. Novak, V. (2014). *Forecasting Trend of a Group of Time Series Using F-Transform and Fuzzy Natural Logic*. World Scientific Proceedings Series on Computer Engineering and Information Science, 1-10.
159. Novák, V. (2015). Linguistic characterization of time series. *Fuzzy Sets and Systems*, 285, 1-21.
160. Štepnicka, M., Dvorak, A., Pavliska, V., Vavrickova, L. (2011). A linguistic approach to time series modeling with the help of F-transform. *Fuzzy Sets and Systems*, 180(1), 164-184.

161. Stepnicka, M., Dvorak, A., Pavliska, V., Vavrickova, L. (2010). *Linguistic Approach to Time Series Analysis and Forecasts*. IEEE World Congress on Computational Intelligence, Paris:AGARD, 1-9.
162. Volna, E., Kotyrba, M., Habiballa, H. (2014). ECG Prediction Based on Classification via Neural Networks and Linguistic Fuzzy Logic Forecaster. *The Scientific World Journal*, 1-11.
163. Novak, V. (2018). Detection of Structural Breaks in Time Series Using Fuzzy Techniques. *International Journal of Fuzzy Logic and Intelligent Systems*, 18(1), 1-12.
164. Degtiarev, K. Y., Remneva, N. V. (2016). *Linguistic resumes in software engineering: the case of trend summarization in mobile crash reporting systems*. 12th International Conference on Application of Fuzzy Systems and Soft Computing, Vienna, Austria: Procedia Computer Science, 121-128.
165. Moreno-Garcia, J., Rodriguez-Benitez, L., Jimenez-Linares, L., Trivino, G. (2019). A Linguistic Extension of Petri Nets for the Description of Systems: An Application to Time Series. *IEEE Transactions on Fuzzy Systems*, 27(9), 1819-1833.
166. Ros, M., Pegalajar, M., Delgado, M., Vila, A., Anderson, D., Keller, J., Popescu, M. (2011). *Linguistic Summarization Of Long-Term Trends For Understanding Change In Human Behavior*. IEEE International Conference on Fuzzy Systems, Taipei, Taiwan: IEEE, 1-8.
167. Harguess, J., Aggarwal, J. K. (2009). *Semantic Labeling Of Track Events Using Time Series Segmentation And Shape Analysis*. 16th IEEE International Conference on Image Processing, Berlin: IEEE, 1-4.
168. Kobayashi, M., Kobayashi, I. (2012). *An approach to linguistic summarization based on comprasion among multiple time-series data*. IEEE International Conference on Fuzzy Systems, Dublin: IEEE, 1100-1103.
169. Chen, C.-H., Hong, T.-P., Tseng, V. S. (2008). *Mining Linguistic Trends from Time Series*. In T. Lin, Y. Xie, A. Wasilewska, & C.-J. Liao, *Data Mining: Foundations and Practice*, Berlin: Springer. 31-48.
170. Umamo, M., Okamura, M., Seta, K. (2009). *Improved Method for Linguistic Expression of Time Series with Global Trend and Local Features*. IEEE International Conference on Fuzzy Systems, Brasil: IEEE, 1169-1174.
171. Albertetti, F., Grossriederb, L., Ribaux, O., Stoffel, K. (2016). Change points detection in crime-related time series: An on-line fuzzy approach based on a shape space representation. *Applied Soft Computing*, 46, 441-454.
172. Baklan, I., Oliinyk, A., Mukha, I., Lishchuk, K., Gavrilenko, O., Reutska, S., Oliinyk, Y. (2021). *ECG signal processing based on linguistic chain fuzzy sets*. 5th International Conference on Computational Linguistics and Intelligent Systems, 1-11.

173. Afanasieva, T., Sapunkov, A. (2016). *Selection of time series forecasting model, using a combination of linguistic and numerical criteria*. IEEE 10th International Conference on Application of Information and Communication Technologies (AICT), Turkey:IEEE, 1-5.
174. Afanasieva, T., Tronin, V., Afanaseva, N. (2020). *Framework for Analysis of Thematic Interest in Scientific Networks using Fuzzy Time Series*. 6th International Conference on Computer and Technology Applications, 1-5.
175. Afanasieva, T., Moshkina, I. (2020). Descriptive model of temporal features of multivariate time series based on granulation. *Information Technology and Nanotechnology*, 287-292.
176. Chou, M.-T., Lee, H.-S. (2006). *Increasing and Decreasing with Fuzzy Time Series*. Proceedings of the 2006 Joint Conference on Information Sciences, JCIS 2006, Kaohsiung, Taiwan: Springer, 1-4.
177. Mörchen, F., Ultsch, A. (2005). *Discovering Temporal Knowledge in Multivariate Time Series*. In C. Weihs, & W. Gaul, *Classification - the Ubiquitous Challenge*, Switzerland: Springer. 272-279.
178. Otsuka, N., Hasui, D., Matsushita, M. (2013). *A System for Retrieving Time-Series Data Based on Linguistic Expression*. Conference on Technologies and Applications of Artificial Intelligence, Nice: ACM, 252-256.
179. Sosnowski, Ł., Penza, T. (2020). Generating Fuzzy Linguistic Summaries for Menstrual Cycles. *Computer Science and Information Systems*, 119-128.
180. Stach, W., Kurgan, L. A., Pedrycz, W. (2008). Numerical and Linguistic Prediction of Time Series With the Use of Fuzzy Cognitive Maps. *IEEE Transactions on Fuzzy Systems*, 16(1), 61-72.
181. Castillo-Ortega, R., Marin, N., Sanchez, D. (2011). *Linguistic Local Change Comparison Of Time Series*. IEEE International Conference on Fuzzy Systems, Taipei, Taiwan: IEEE, 2909-2916.
182. Castillo-Ortega, R., Marín, N., Sánchez, D., Tettamanzi, A. (2011). *A Multi-Objective Memetic Algorithm for the Linguistic Summarization of Time Series*. GECCO'11, Dublin, Ireland: Springer, 171-172.
183. Castillo-Ortega, R., Marín, N., Sánchez, D., Tettamanzi, A. (2011). *Linguistic Summarization of Time Series Data using Genetic Algorithms*. EUSFLAT-LFA 2011, Paris: AGARD, 416-424.
184. Castillo-Ortega, R., Marin, N., Daniel, S. (2009). *Fuzzy Quantification-Based Linguistic Summaries in Data Cubes with Hierarchical Fuzzy Partition of Time Dimension*. IDEAL Verlag Berlin Heidelberg: Springer, 578-585.
185. Castillo-Ortega, R., Marin, N., Sanchez, D. (2009). *Linguistic Summary-Based Query Answering on Data Cubes with Time Dimension*. FQAS Berlin Heidelberg: Springer, 560-571.

186. Jain, A., Jiang, T., Keller, J. M. (2016). *Impact of the Shape of Membership Functions on the Truth Values of Linguistic Protoform Summaries*. IPMU Switzerland: Springer International Publishing, 204-213.
187. Kacprzyk, J., Strykowski, P. (1999). *Linguistic Summaries of Sales Data at a Computer Retailer via Fuzzy Logic and a Genetic Algorithm*. IEEE International Fuzzy Systems Conference Proceedings, Paris: IEEE, 937-943.
188. Ramos-Soto, A., Pereira-Farina, M., Bugarin, A., Barro, S. (2015). A Model Based on Computational Perceptions for the Generation of Linguistic Descriptions of Data. *IEEE International Conference on Fuzzy Systems*, 1-8.
189. Ramos-Soto, A., Pereira-Farina, M. (2018). *Reinterpreting Interpretability for Fuzzy Linguistic Descriptions of Data*. In A. Cuzzocrea, X. Du, O. Kara, T. Liu, D. Ślęzak, & X. Yang, *Communications in Computer and Information Science*, Zhuhai, China: Springer International. 40-51.
190. Romero, F. P., Olivas, J. A., Serrano-Guerrero, J. (2018). *Linguistic Description of the Evolution of Stress Level Using Fuzzy Deformable Prototypes*. In J. Medina, M. Ojeda-Aciego, J. Verdegay, D. Pelta, I. Cabrera, B. Bouchon-Meunier, & R. Yager, *Information Processing and Management of Uncertainty in Knowledge-Based Systems*, Cham, Switzerland: Springer. 443-452.
191. Donis-Díaz, C. A., Bello, R., Kacprzyk, J. (2013). Linguistic Data Summarization Using An Enhanced Genetic Algorithm. *Technical Transactions*, 110(1), 1-10.
192. Donis-Díaz, C. A., Bello, R., Kacprzyk, J. (2014). *Using Ant Colony Optimization and Genetic Algorithms for the Linguistic Summarization of Creep Data*. *Intelligent Systems'2014*, 81-92.
193. Wilbik, A., Keller, J. M. (2012). A distance metric for a space of linguistic summaries. *Fuzzy Sets and Systems*, 188, 79-94.
194. Wilbik, A., Keller, J. M., Alexander, G. L. (2012). Similarity Evaluation of Sets of Linguistic Summaries. *International Journal of Intelligent Systems*, 27(10), 926-938.
195. Wilbik, A., & Keller, J. M. (2012). A Fuzzy Measure Similarity Between Sets of Linguistic Summaries. *IEEE Transactions on Fuzzy Systems*, 20(1), 183-189.
196. Wilbik, A., Keller, J. M. (2013). *Anomaly Detection From Linguistic Summaries*. 2013 IEEE International Conference on Fuzzy Systems, Dublin: IEEE, 1-7.
197. Wilbik, A., Keller, J. M., Bezdek, J. C. (2014). Linguistic Prototypes for Data From Eldercare Residents. *IEEE Transactions on Fuzzy Systems*, 22(1), 110-123.
198. Wilbik, A., Keller, J. M., Bezdek, J. C. (2014). *Evaluation of the Truth Value of Linguistic Summaries -- Case with Non-monotonic Quantifiers*. In J. Kacprzyk, *Advances in Intelligent Systems and Computing*, London: Springer. 69-79.
199. Wilbik, A., Barreto, D., Backus, G. (2020). *On Relevance of Linguistic Summaries -- A Case Study from the Agro-Food Domain*. IPMU Prag: Springer, 289-300.

200. Duraj, A., Szczepaniak, P. (2021). *Linguistic Summaries using Interval-valued Fuzzy Representation of Imprecise Information - an Innovative Tool for Detecting Outliers*. (1th Edition). Springer, 1-14.
201. Polo-Rodriguez, A., Chiachio, J., Pagetti, C., Madine-Quero, J. (2021). Ambient sound recognition of daily events by means of convolutional neural networks and fuzzy temporal restrictions. *Applied Sciences*, 11(2), 1-16.
202. Chiang, D.-A., Chow, L. R., Wang, Y.-F. (2000). Mining time series data by a fuzzy linguistic summary system. *Fuzzy Sets and Systems*, 112(3), 419-432.
203. Kupka, J., Rusnok, P. (2015). *On regression methods based on linguistic descriptions*. 2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Berlin: IEEE, 1-7.
204. Novak, V., Perfilieva, I., Dvohrak, A. (2008). Mining pure linguistic associations from numerical data. *International Journal of Approximate Reasoning*, 48(1), 4-22.
205. Novak, V., Perfilieva, I., Dvohrak, A. (2006). *Mining Pure Linguistic Associations on the Basis of Perceptions in Numerical Data*. Conference of the North American Fuzzy Information Processing Society, Taiwan: ACM, 639-644.
206. Novak, V. (2010). *Modeling With Words And Its Applications*. In D. Ruan, *Computational Intelligence Foundations and Applications*, London: World Scientific. 17-28.
207. Novak, V. (2010). *Genuine Linguistic Fuzzy Logic Control: Powerful and Successful Control Method*. In E. Hüllermeier, R. Kruse, & F. Hoffmann, *Computational Intelligence for Knowledge-Based Systems Design*, Heidelberg: Springer-Verlag. 634-644.
208. Perfilieva, I., Novak, V. (2007). System of fuzzy relation equations as a continuous model of IF-THEN rules. *Information Sciences*, 177(16), 3218-3227.
209. Rusnok, P. (2016). *Probabilistic Coverage of Linguistic IF-THEN Rules*. 2016 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Moskov: IEEE, 798-803.
210. Rusnok, P., Hurtik, P., Kalab, O. (2018). *Data analysis of multivariate time series of insect tracking*. Joint 10th International Conference on Soft Computing and Intelligent Systems, New York: AGARD, 771-776.
211. Štěpničková, L., Štěpnička, M., Dvořák, A. (2013). *New results on redundancies of fuzzy/linguistic IF-THEN rules*. 8th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT), Dublin: Atlantis, 400-407.
212. Conde-Clemente, P., Alonso, J. M., Trivino, G. (2017). *rLDCP: R Package for Text Generation from Data*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Miami: IEEE, 1-6.
213. Ramos-Soto, A., Martin-Rodilla, P. (2021). Enriching linguistic descriptions of data: a framework for composite protoforms. *Fuzzy Sets and Systems*, 436, 1-26.

214. Alvarez-Alvarez, A., Sanchez-Valdes, D., Trivino, G., Sánchez, Á., Suárez, P. (2012). Automatic linguistic report of traffic evolution in roads. *Expert Systems with Applications*, 39(14), 11293-11302.
215. Alvarez-Alvarez, A., Trivino, G. (2013). Linguistic description of the human gait quality. *Engineering Applications of Artificial Intelligence*, 26(1), 13-23.
216. Eciolaza, L., Trivino, G. (2011). *Fuzzy Linguistic Reporting in Driving Simulators*. 2011 IEEE International Conference on Fuzzy Systems, Istanbul: IEEE, 13-28.
217. Eciolaza, L., Trivino, G. (2011). *Linguistic Reporting of Driver Behavior: Summary and Event Description*. IEEE International Conference on Fuzzy Systems, Prag: IEEE, 148-153.
218. Eciolaza, L., Pereira-Farina, M., Trivino, G. (2013). Automatic linguistic reporting in driving simulation environments. *Applied Soft Computing*, 13(9), 3956-3967.
219. Sanchez-Valdes, D., Eciolaza, L., Trivino, G. (2012). *Linguistic Description of Human Activity based on Mobile Phone's Accelerometers*. 4th International Workshop on Ambient Assisted Living and Home Care (IWAAL), India: ACM, 1-8.
220. Trivino, G., Sanchez, A., Montemayor, A., Pantrigo, J., Cabido, R., Pardo, E. (2010). *Linguistic Description of Traffic in a Roundabout*. IEEE International Conference on Fuzzy Systems, Barcelona: IEEE, 1-8.
221. Conde-Clemente, P., Alonso, J. M., Trivino, G. (2018). Toward automatic generation of linguistic advice for saving energy at home. *Soft Computing*, 22(2), 345-359.
222. Conde-Clemente, P., Trivino, G., Alonso, J. M. (2017). Generating automatic linguistic descriptions with big data. *Information Sciences*, 380-381, 12-30.
223. Trivino, G., Sanchez-Valdes, D. (2015). *Generation of Linguistic Advices for Saving Energy: Architecture*. 4th International Conference on the Theory and Practice of Natural Computing, New York: Springer, 1-13.
224. Sanchez-Valdes, D., Trivino, G. (2013). Computational Perceptions of uninterpretable data. A case study on the linguistic modeling of human gait as a quasi-periodic phenomenon. *Fuzzy Sets and Systems*, 231, 1-21.
225. Jain, A., Keller, J. M. (2015). *Textual Summarization of Events Leading to Health Alerts*. 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Paris: IEEE, 7634-7637.
226. Martínez-Municio, S., Rodríguez-Benítez, L., Castillo-Herrera, E., Giralt-Muina, J., Jimenez-Linares, L. (2019). Linguistic Modeling and Synthesis of Heterogeneous Energy Consumption Time Series Sets. *International Journal of Computational Intelligence Systems*, 12(1), 259-272.
227. Moyse, G., Lesot, M.-J., Bouchon-Meunier, B. (2013). *Mathematical morphology tools to evaluate periodic linguistic summaries*. International Conference on Flexible Query Answering Systems, Paris: IEEE, 257-268.

228. Moyse, G., Lesot, M.-J., Bouchon-Meunier, B. (2013). *Linguistic summaries for periodicity detection based on mathematical morphology*. IEEE International Conference on Fuzzy Systems, Paris: IEEE, 106-113.
229. Moyse, G., Lesot, M.-J. (2016). Linguistic summaries of locally periodic time series. *Fuzzy Sets and Systems*, 285, 1-33.
230. Fontenla-Seco, Y., Bugarin, A., Lama, M. (2020). *Process-To-Text: a framework for the quantitative description of processes in natural language*. International Workshop on the Foundations of Trustworthy AI, Berlin: Springer, 212-219.
231. Ramos-Soto, A., Vazquez-Barreiros, B., Bugarin, A., Gewerc, A., Barro, S. (2017). Evaluation of a Data-To-Text System for Verbalizing a Learning Analytics Dashboard. *International Journal of Intelligent Systems*, 32(2), 177-193.
232. Peláez-Aguilera, M. D., Espinilla, M., Olmo, M. D., Medina, J. (2019). *Fuzzy Linguistic Protoforms to Summarize Heart Rate Streams of Patients with Ischemic Heart Disease*. (1th Edition). Hindawi: Complexity, 111.
233. Ramos-Soto, A., Bugarin, A., Barro, S., Diaz-Hermida, F. (2013). *Automatic Linguistic Descriptions Of Meteorological Data. A Soft Computing Approach For Converting Open Data To Open Information*. 2013 IEEE International Conference on Fuzzy Systems, Dublin: IEEE, 1-7.
234. Ramos-Soto, A., Bugarin, A., Barro, S., Taboada, J. (2013). *Automatic Generation of Textual Short-Term Weather Forecasts on Real Prediction Data*. In H. Larsen, M. Martin-Bautista, M. Vila, T. Andreasen, & H. Christiansen, *Flexible Query Answering Systems*, Berlin Heidelberg: Springer. 269-283.
235. Ramos-Soto, A., Bugarin, A., Barro, S., Taboada, J. (2015). Linguistic Descriptions for Automatic Generation of Textual Short-Term Weather Forecasts on Real Prediction Data. *IEEE Transactions on Fuzzy Systems*, 23(1), 44-57.
236. Riza, L. S., Ridwan, M., Junaeti, E., Samah, K. (2021). Development of data-to-text (D2T) on generic data using fuzzy sets. *International Journal of Advanced Technology and Engineering Exploration*, 8(75), 382-390.
237. Wilbik, A., Keller, J. M., Alexander, G. L. (2011). *Linguistic summarization of sensor data for eldercare*. 2011 IEEE International Conference on Fuzzy Systems, Prag: IEEE, 2595-2599.
238. Wilbik, A., Keller, J. M., Bezdek, J. C. (2012). *Generation of prototypes from sets of linguistic summaries*. 2012 IEEE World Congress on Computational Intelligence, Hungary: IEEE, 1-8.
239. Wilbik, A., Kaymak, U. (2014). *Gradual Linguistic Summaries*. IPMU 2014, Moskov: Springer, 405-413.
240. Wilbik, A., Kaymak, U. (2015). *Linguistic Summarization of Processes - a research agenda*. 16th World Congress of the International Fuzzy Systems Association (IFSA), Berlin: Atlantis, 1636-1645.

241. Wilbik, A., Dijkman, R. M. (2015). *Linguistic summaries of process data*. 2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Taiwan: IEEE, 1-7.
242. Wilbik, A., Dijkman, R. M. (2016). *On the generation of useful linguistic summaries of sequences*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Istanbul: IEEE, 1-8.
243. Wilbik, A., Kaymak, U., Dijkman, R. M. (2017). *A method for improving the generation of linguistic summaries*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Dubai: IEEE, 1-6.
244. Heide, A. v. d., Trivino, G. (2009). *Automatically generated linguistic summaries of energy consumption data*. Ninth International Conference on Intelligent Systems Design and Applications, Brasil: Springer, 553-559.
245. Moreno-Garcia, J., Jimenez-Linares, L., Liu, J., Rodriguez-Benitez, L. (2021). *Generation of linguistic descriptions for daily noise pollution in urban areas*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Spain: IEEE, 1-6.
246. Castillo, O., Melin, P. (2008). *A New Approach for Plant Monitoring Using Type-2 Fuzzy Logic and Fractal Theory*. In O. Castillo, & P. Melin, *Type-2 Fuzzy Log.: Theory and Appl.*, Verlag Berlin Heidelberg: Springer. 187-202.
247. Bueno, L., Costa, P., Mendes, I., Cruz, E., Leite, D. (2015). *Evolving Ensemble of Fuzzy Models for Multivariate Time Series Prediction*. IEEE International Conference on Fuzzy Systems, Verlag Berlin Heidelberg: Springer, 1-6.
248. Batyrshin, I., Sheremetov, L. (2005). *Perception Based Time Series Data Mining with MAP Transform*. (2nd Edition). Springer, 3406.
249. Castillo-Ortega, R., Marin, N., Sanchez, D. (2010). *Time Series Comparison Using Linguistic Fuzzy Techniques*. In J. S. R. Goebel, *Lecture Notes in Artificial Intelligence* Dortmund, Germany: Springer. 330-339.
250. Castillo-Ortega, R., Marín, N., Sanchez, D. (2011). Linguistic Query Answering on Data Cubes with Time Dimension. *International Journal of Intelligent Systems*, 26(11), 1002-1021.
251. Anderson, D., Luke, R. H., Keller, J. M., Skubic, M., Rantz, M., Aud, M. A. (2009). Linguistic summarization of video for fall detection using voxel person and fuzzy logic. *Computer Vision and Image Understanding*, 113(1), 80-89.
252. Kacprzyk, J., Wilbik, A., Zadrozny, S. (2008). On Linguistic Summarization of Numerical Time Series Using Fuzzy Logic with Linguistic Quantifiers. *Studies in Computational Intelligence*, 109, 169-184.
253. Novak, V., Perfilieva, I. (2015). Forecasting Direction of Trend of a Group of Analogous Time Series Using F-Transform and Fuzzy Natural Logic. *International Journal of Computational Intelligence Systems*, 8(6), 15-28.

254. Sanchez-Valdes, D., Alvarez-Alvarez, A., Trivino, G. (2016). Dynamic linguistic descriptions of time series applied to self-track the physical activity. *Fuzzy Sets and Systems*, 286, 1-20.
255. Kacprzyk, J., Zadrozny, S. (2013). *Comprehensiveness of Linguistic Data Summaries: A Crucial Role of Protoforms*. In C. Moewes, & A. Nürnberger, *Computational Intelligence in Intelligent Data Analysis*, Berlin: Springer. 207-221.
256. Castillo-Ortega, R., Marin, N., Sanchez, D., Tettamanzi, A. (2012). *Quality Assessment in Linguistic Summaries of Data*. IPMU Verlag Berlin Heidelberg: Springer, 285-294.
257. Hudec, M. (2015). *Linguistically Summarizing Hierarchical Data The case of statistical territorial data*. 16th IEEE International Symposium on Computational Intelligence and Informatics, Budapest, Hungary: IEEE, 141-146.
258. Ekman, P. (1992). An argument for basic emotions. *Cognition and Emotion*, 6(3-4), 169-200.
259. Schröder, M., Cowie, R. (2005). *Toward emotion-sensitive multimodal interfaces: the challenge of the European Network of Excellence HUMAINE*. Adapting the Interaction Style to Affective Factors Workshop in conjunction with User Modeling, Brasil: ACM, 42-56.
260. Russell, J. A. (1980). A circumplex model of affect. *Journal of Personality and Social Psychology*, 39(6), 1161-1178.
261. Gobron, S., Ahn, J., Paltoglou, G., Thelwall, M., Thalmann, D. (2010). From sentence to emotion: a real-time three-dimensional graphics metaphor of emotions extracted from text. *The Visual Computer*, 26(6), 505-519.
262. Barrett, L. F., Russell, J. A. (1999). The Structure of Current Affect: Controversies and Emerging Consensus. *Current Directions in Psychological Science*, 8(1), 10-14.
263. Liberati, G., Federici, S., Pasqualotto, E. (2015). Extracting neurophysiological signals reflecting users' emotional and affective responses to I use: A systematic literature review. *NeuroRehabilitation*, 36(4), 341-358.
264. Ramirez, R., Planas, J., Escude, N., Mercade, J., Farriols, C. (2018). EEG-Based Analysis of the Emotional Effect of Music Therapy on Palliative Care Cancer Patients. *Frontiers in Psychology*, 9, 112-127.
265. Vamvakousis, Z., Ramirez, R. (2012). A Brain-Gaze Controlled Musical Interface. *Advances in Neurotechnology*, 3, 38-47.
266. Kirke, A., Miranda, E. R. (2011). *Combining EEG Frontal Asymmetry Studies with Affective Algorithmic Composition and Expressive Performance Models*. Proceedings of 37th International Computer Music Conference (ICMC), Dublin: Springer, 1-4.
267. Blaiech, H., Neji, M., Wall, A., Alimi, A. M. (2013). *Emotion Recognition by Analysis of EEG signals*. 13th International Conference on Hybrid Intelligent Systems (HIS), Paris: Atlantis, 312-318.

268. Ramirez, R., Vamvakousis, Z. (2012). Detecting Emotion from EEG signals Using the Emotive Epoc Device. *International Conference on Brain Informatics*, 175-184.
269. Ramirez, R., Palencia-Lefler, M., Giraldo, S., Vamvakousis, Z., Miller, E. (2015). Musical neurofeedback for treating depression in elderly people. *Method*, 2, 1-10.
270. Touchette, B., Lee, S. E. (2017). Measuring Neural Responses to Apparel Product Attractiveness: An Application of Frontal Asymmetry Theory. *Clothing and Textiles Research Journal*, 35(1), 3-15.
271. Cartocci, G., Caratu, M., Modica, E., Maglione, A., Rossi, D., Cherubino, P., Babiloni, F. (2017). Electroencephalographic, Heart Rate, and Galvanic Skin Response Assessment for an Advertising Perception Study: Application to Antismoking Public Service Announcements. *Journal of Visualized Experiments*, 126, 1-13.
272. Cherubino, P. (2018). *Application of Neuro-Marketing techniques to the wine tasting experience*. In Proceedings of the 11th Annual Conference of the EuroMed Academy of Business, Valletta, Malta: Springer, 290-298.
273. Ramsøy, T. Z., Skov, M., Christensen, M. K., Stahlhut, C. (2018). Frontal brain asymmetry and willingness to pay. *Frontiers in Neuroscience*, 12, 1-12.
274. Goethem, A. V., Staals, F., Offle, M. (2017). Multi-Granular Trend Detection for Time-Series Analysis. *IEEE Transactions on Visualization and Computer Graphics*, 23(1), 661-671.
275. Obermaier, H., Joy, K. I. (2014). Future Challenges for Ensemble Visualization. *IEEE Computer Graphics and Applications*, 34(3), 128-137.
276. Bonneau, G.-P., Hege, H.-C., Johnson, C., Oliveira, M., Potter, K., Rheingans, P., Schultz, T. (2014). *Scientific Visualization: Uncertainty, Multifield, Biomedical, and Scalable Visualization*. In G.-P. Bonneau, & H.-C. Hege, *Overview and State of the Art of Uncertainty Visualization*, London: Springer. 217-228.
277. Buchin, K., Buchin, M., van Kreveld, M., Speckmann, B., Staals, F. (2015). Trajectory Grouping Structure. *Journal of Computational Geometry*, 6(1), 1-14.
278. Van Kreveld, M., Löffler, M., Staals, F., Wir, L. (2016). *A Refined Definition for Groups of Moving Entities and its Computation*. 32th European Workshop on Computational Geometry, Berlin: Springer, 47-61.
279. Goethem, A. v., Staals, F., Offle, M. (2017). Multi-Granular Trend Detection for Time-Series Analysis. *IEEE Transactions on Visualization and Computer Graphics*, 23(1), 661-671.
280. Litt, A., Shiv, B. (2012). Manipulating basic taste perception to explore how product information affects experience. *Journal of Consumer Psychology*, 22(1), 55-66.
281. Milosavljevic, M., Navalpakkam, V., Koch, C., Rangel, A. (2012). Relative visual saliency differences induce sizable bias in consumer choice. *Journal of Consumer Psychology*, 22(1), 67-74.

282. Estes, Z., Gibbert, M., Guest, D., Mazursky, D. (2012). A dual-process model of brand extension: Taxonomic feature-based and thematic relation-based similarity independently drive brand extension evaluation. *Journal of Consumer Psychology*, 22(1), 86-101.
283. Saad, G., Stenstrom, E. (2012). Calories, beauty, and ovulation: The effects of the menstrual cycle on food and appearance-related consumption. *Journal of Consumer Psychology*, 22(1), 102-113.
284. Aggarwal, P., Larrick, R. P. (2012). When consumers care about being treated fairly: The interaction of relationship norms and fairness norms. *Journal of Consumer Psychology*, 22(1), 114-127.
285. Reimann, M., Castaño, R., Zaichkowsky, J., Bechara, A. (2012). How we relate to brands: Psychological and neurophysiological insights into consumer--brand relationships. *Journal of Consumer Psychology*, 22(1), 128-142.
286. Berns, G. S., Moore, S. E. (2012). A neural predictor of cultural popularity. *Journal of Consumer Psychology*, 22(1), 154-160.
287. Yılmaz, B., Korkmaz, S., Arslan, D. B., Güngör, E., Asyalı, M. H. (2014). Like/dislike analysis using EEG: Determination of most discriminative channels and frequencies. *Computer Methods and Programs in Biomedicine*, 113(2), 705-713.
288. Plassmann, H., Doherty, J. O., Rangel, A. (2007). Orbitofrontal cortex encodes willingness to pay in everyday economic transactions. *Journal of Neuroscience*, 27(37), 9984-9988.
289. Reimann, M., Zaichkowsky, J., Neuhaus, C., Bender, T., Weber, B. (2010). Aesthetic package design: A behavioral, neural, and psychological investigation. *Journal of Consumer Psychology*, 20(4), 431-441.
290. Stoll, M., Baecke, S., Kenning, P. (2008). What they see is what they get? An fMRI-study on neural correlates of attractive packaging. *Journal of Consumer Behaviour*, 7(4), 342-359.
291. Hillenbrand, P., Alcauter, S., Cervantes, J., Barrios, F. A. (2013). Better branding: Brand names can influence consumer choice. *Journal of Product and Brand Management*, 22(4), 300-308.
292. Lee, E.-J., Kwon, G., Shin, H.-J., Yang, S., Lee, S., Suh, M. (2014). The spell of green: Can frontal EEG activations identify green consumers? *Journal of Business Ethics*, 122(3), 511-521.
293. Bercik, J. (2015). *How can food retailing benefit from neuromarketing research: A case of various parameters of store illumination and consumer response*. Proceedings of 143rd Joint EAAE/AAEA Seminar, Taiwan: AGARD, 25-37.
294. Treleaven-Hassard, S. (2010). Using the P3A to gauge automatic attention to interactive television advertising. *Journal of Economic Psychology*, 31(5), 777-784.

295. Ariely, D., Berns, G. S. (2010). Neuromarketing: The hope and hype of neuroimaging in business. *Nature Reviews Neuroscience*, 11(4), 284-292.
296. Morillo, L. M. S., García, J. A., Gonzalez-Abril, L., Ramirez, J. (2015). *Advertising liking recognition technique applied to neuromarketing by using low-cost EEG headset*. International Conference on Bioinformatics and Biomedical Engineering (ICBBE), Dubai: Atlantis, 701-709.
297. Deitz, G. D. (2016). EEG-based measures versus panel ratings: Predicting social media-based behavioral response to super bowl ads. *Journal of Advertising Research*, 56(2), 217-227.
298. Michael, I., Ramsay, T. Z., Stephens, M., Kotsi, F. (2019). A study of unconscious emotional and cognitive responses to tourism images using a neuroscience method. *Journal of Islamic Marketing*, 10(1), 119-131.
299. Bandara, S. K., Wijesinghe, U. S., Jayalath, B. M., Bandara, S. V., Haddela, P. S., Wickramasinghe, L. K. (2021). *EEG Based Neuromarketing Recommender System for Video Commercials*. IEEE 16th International Conference on Industrial and Information Systems (ICIIS), India: IEEE, 11-17.
300. Heuberger, C. F., Dowell, N. M. (2017). *Computer Aided Chemical Engineering*. Spain: Elsevier.
301. Balconi, M., Stumpo, B., Leanza, F. (2014). Advertising, brand and neuromarketing or how consumer brain works. *Neuropsychology Trends*, 15, 15-21.
302. Gauba, H., Kumar, P., Roy, P. P., Singh, P., Dogra, D. P., Scheme, E. (2017). Prediction of advertisement preference by fusing EEG response and sentiment analysis. *Neural Networks*, 92, 77-88.
303. Lakshan, I. G., Wickramasinghe, L. K., Disala, S. D., Chand, S. K. (2019). *Real time deception detection for criminal investigation*. National Information Technology Conference (NITC), Spain: Elsevier, 90-96.
304. Dushantha, A. K., Akalanka, R., Gayan, H. M., Siriwar, K. M., Hadella, P. S. (2020). *Evaluation method for video advertisetments using eeg signals*. 2nd International Conference on Advancements in Computing (ICAC), Morocco: Wiley, 1-6.
305. Boksem, M. A. S., Smidts, A. (2015). Brain Responses to Movie Trailers Predict Individual Preferences for Movies and Their Population-Wide Commercial Success. *Journal of Marketing Research*, 52(4), 482-492.
306. Modica, E., Cartocci, G., Rossi, D., Martinez Levy, A. C., Cherubino, P., Maglione, A. G., Perrotta, D. (2018). Neurophysiological responses to different product experiences. *Computational Intelligence and Neuroscience*, 2018, 1-18.
307. Hamzah, H. A., Abdalla, K. K. (2024). EEG-based emotion recognition systems; comprehensive study. *Heliyon*, 10(1), 71-86.
308. Li, X., Song, D., Zhang, P., Zhang, Y., Hou, Y., Hu, B. (2018). Exploring EEG Features in Cross-Subject Emotion Recognition. *Frontiers in Neuroscience*, 12, 117-129.

309. Fang, Y., Yang, H., Zhang, X., Liu, H., Tao, B. (2021). Multi-Feature Input Deep Forest for EEG-Based Emotion Recognition. *Frontiers in Neurorobotics*, 15, 213-227.
310. Fernandes, J. V. M. R., Alexandria, A. R., Marques, J. A. L., Assis, D. F. d., Motta, P. C., Silva, B. R. d. S. (2024). Emotion Detection from EEG Signals Using Machine Deep Learning Models. *Bioengineering*, 11(2), 156-167.
311. Song, T., Zheng, W., Lu, C., Zong, Y., Zhang, X., Cui, Z. (2019). MPED: A multi-modal physiological emotion database for discrete emotion recognition. *IEEE Access*, 7, 12177-12191.
312. Ganin, Y. (2016). Domain-adversarial training of neural networks. *Journal of Machine Learning Research*, 17(59), 1-35.
313. Li, H., Jin, Y.-M., Zheng, W.-L., Lu, B.-L. (2018). *Cross-subject emotion recognition using deep adaptation networks*. International Conference on Neural Information Processing, Berlin: Elsevier, 403-413.
314. Song, T., Zheng, W., Song, P., Cui, Z. (2018). EEG emotion recognition using dynamical graph convolutional neural networks. *IEEE Transactions on Affective Computing*, 11(3), 1089-1104.
315. Song, T., Liu, S., Zheng, W. (2021). Variational instance adaptive graph for EEG emotion recognition. *IEEE Transactions on Affective Computing*, 13(7), 343-356.
316. Guo, J., Cai, Q., An, J. (2022). A Transformer based neural network for emotion recognition and visualizations of crucial EEG channels. *Physica A: Statistical Mechanics and its Applications*, 60, 942-960.
317. Guo, W., Li, Y., Liu, M. (2024). Functional connectivity-enhanced feature-grouped attention network for cross-subject EEG emotion recognition. *Knowledge-Based Systems*, 28, 182-199.
318. Zhang, Z., Fort, J., Mateu, L. G. (2024). Mini review: Challenges in EEG emotion recognition. *Frontiers in Psychology*, 15, 142-156.
319. Apicella, A., Arpaia, P., Mastrati, G., Moccaldi, N. (2021). EEG-based detection of emotional valence towards a reproducible measurement of emotions. *Scientific Reports*, 11(1), 456-464.
320. Kaya, Ü., Akay, D., Ayan, S. Ş. (2024). EEG-Based Emotion Recognition in Neuromarketing Using Fuzzy Linguistic Summarization. *IEEE Transactions on Fuzzy Systems*, 32(8), 4248-4259.
321. Yoon, H. J., Chung, S. Y. (2011). *EEG spectral analysis in valence and arousal dimensions of emotion*. 11th International Conference on Control, Automation and Systems, Bruno: Wiley, 2012-2021.
322. Bos, D.-O. (2006). *EEG-based emotion recognition: The influence of visual and auditory stimuli*. Master Thesis, University of Twente, Enschede, Hollanda, 145.

323. Zheng, W.-L., Lu, B.-L. (2015). Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development*, 7(3), 162-175.
324. Michel, C. M., Murray, M. M. (2012). Towards the utilization of EEG as a brain imaging tool. *NeuroImage*, 61(2), 371-385.
325. Başar, E., Başar-Eroglu, C., Karakaş, S., Schürmann, M. (2001). Gamma, alpha, delta, and theta oscillations govern cognitive processes. *International Journal of Psychophysiology*, 39(2-3), 241-248.
326. Klimesch, W. (1999). EEG alpha and theta oscillations reflect cognitive and memory performance: A review and analysis. *Brain Research Reviews*, 29(2-3), 2105-2116.
327. Jasper, H. H. (1958). The ten-twenty electrode system of the International Federation. *Electroencephalography and Clinical Neurophysiology*, 10, 371-375.
328. Murugappan, M., Ramachandran, N., Sazali, Y. (2010). Classification of human emotion from EEG using discrete wavelet transform. *Journal of Biomedical Science and Engineering*, 3(4), 390-396.
329. Lin, Y.-P., Wang, C.-H., Jung, T.-P., Wu, T.-L., Jeng, S.-K., Duann, J.-R., Chen, J.-H. (2010). EEG-based emotion recognition in music listening. *IEEE Transactions on Biomedical Engineering*, 57(7), 1056-1068.
330. Jenke, R., Peer, A., Buss, M. (2014). Feature extraction and selection for emotion recognition from EEG. *IEEE Transactions on Affective Computing*, 5(3), 327-339.
331. Davidson, R. J. (1992). Anterior cerebral asymmetry and the nature of emotion. *Brain and Cognition*, 20(1), 125-151.
332. Coan, J. A., Allen, J. J. (2004). Frontal EEG asymmetry as a moderator and mediator of emotion. *Biological Psychology*, 67(1-2), 7-49.
333. Harmon-Jones, E., Gable, P. A. (2018). On the role of asymmetric frontal cortical activity in approach and withdrawal motivation: An updated review of the evidence. *Psychophysiology*, 55(1), 2207-2216.
334. Chanel, G., Kronegg, J., Grandjean, D., Pun, T. (2006). Emotion assessment: Arousal evaluation using EEG's and peripheral physiological signals. *Multimedia Content Representation, Classification and Security*, 4105, 530-537.
335. Posner, J., Russell, J. A., Peterson, B. S. (2005). The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. *Development and Psychopathology*, 17(3), 715-734.
336. Zhao, J., Qu, Q., Zhang, F. (2017). Spatio-temporal analysis of passenger travel patterns in massive smart card data. *IEEE Transactions on Intelligent Transportation Systems*, 18(11), 3135-3146.

337. Subramanian, R., Wache, J., Abadi, M. K., Vieriu, R. L., Winkler, S., Sebe, N. (2018). ASCERTAIN: Emotion and personality recognition using commercial sensors. *IEEE Transactions on Affective Computing*, 9(2), 147-160.
338. Dündar, B., Özdemir, S., Akay, D. (2016). *Opinion mining and fuzzy quantification in hotel reviews*. International Symposium on Networks, Computers and Communications (ISNCC), Yasmine Hammamet, Tunisia: IEEE, 34-46.
339. Wu, D., Mendel, J. M. (2011). Linguistic Summarization Using IF--THEN Rules and Interval Type-2 Fuzzy Sets. *IEEE Transactions on Fuzzy Systems*, 19(1), 1-4.
340. Zhao, G., Zhang, Y., Ge, Y. (2018). Frontal EEG Asymmetry and Middle Line Power Difference in Discrete Emotions. *Frontiers in Behavioral Neuroscience*, 12, 879-889.
341. İnternet: MATLAB. (2025). Fuzzy Logic Toolbox User's Guide. The MathWorks, Inc. URL:<https://www.mathworks.com/help/fuzzy/foundations-of-fuzzy-logic.html>. Son Erişim Tarihi: 05.20, 2025.
342. Sugiyama, M., Nakajima, S., Kashima, H., Buenau, P. V., Kawanabe, M. (2008). Direct importance estimation with model selection and its application to covariate shift adaptation. *Annals of the Institute of Statistical Mathematics*, 60(4), 699-746.



Gazili olmak ayrıcalıktır