

METİN ÖZETLEME İÇİN CÜMLE SEÇİM METOTLARI

SENTENCE SELECTION METHODS FOR TEXT SUMMARIZATION

Aysun Güran¹, Sümeyra Nur Arslan², Esma Kılıç², Banu Diri²

1. Bilgisayar Mühendisliği Bölümü
Doğuş Üniversitesi
adogrusoz@dogus.edu.tr

2. Bilgisayar Mühendisliği Bölümü
Yıldız Teknik Üniversitesi

{snurarslan, esmakilic92}@gmail.com, banu@ce.yildiz.edu.tr

ÖZETÇE

Özetçe — Bu çalışmanın amacı, bir dokümandaki en önemli cümleleri seçerek ilgili dokümanın özetini çıkarmaktır. Bu amaçla 15 farklı cümle seçim metodu kullanılmıştır. Bu metotlar, 15 kadın ve 15 erkek olmak üzere, toplam 30 kişi tarafından çıkarılmış özet dokümanlarının oluşturduğu bir değerlendirme veri seti üzerinde kiyaslanmıştır. Ayrıca, bu metodlardan en başarılı olanların birlikte kullanılması ile elde edilen farklı özellik gruplarının başarım değerleri sergilenmiş ve analiz sonuçları paylaşılmıştır.

Anahtar Kelimeler — *metin özetleme; cümle seçim metotları; varlık ismi tanıma.*

ABSTRACT

Abstract—The aim of this work is to create text summaries by selecting the most important sentences of documents. For this aim 15 sentence selection methods are used. These methods are compared on the evaluation set created by 15 women and 15 men evaluators. The performance results of the systems that are obtained by using different sentence selection methods together are also analyzed and the results are shared.

Keywords — *text summarization; sentence selection methods; name entity recognition.*

1. GİRİŞ

Özet, bir veya aynı konu ile ilgili birden fazla dokümandan çıkarılan ve kaynağındaki en temel bilgiyi içeren metin parçasıdır. Bir özet dokümanın bilgisayar tarafından otomatik olarak çıkartılması ise “Otomatik Metin Özetteleme (OMÖ)” olarak adlandırılır. OMÖ işleminde özetlenecek dokümanı sayısına göre “tekli” veya “çoklu” doküman özetteleme işlemlerinden bahsetmek mümkündür. Tekli doküman özettemede bir tane kaynak doküman mevcutken, çoklu doküman özettemede birbirleri ile ilgili olan birden fazla kaynaktan yararlanılmaktadır. Özetteleme sisteminin çıktısı “yorum” ya da “çıkarma” dayalı olan bir özet olabilir. Yorumda dayalı olan özettelemede orijinal metindeki ifadeler kısaltılarak tekrar yazılmaya çalışılır. Çıkarma dayalı olan özettelemede ise özetlenecek dokümandaki cümleler değiştirilmeksızın seçilmektedir. Bir özet “genel” ya da “kullanıcıya yönelik” olabilir. Bu iki kavram özetin etki alanı ile ilgilidir. Genel özet, metnin ana temalarıyla ilgili olan ayrıntılı özettir. Kullanıcıya yönelik özet ise kullanıcının yazdığı sorgu ile ilgili olan özettir. Bu çalışmada çıkışma dayalı ve genel bir doküman özetteleme sistemi üzerinde durmuştur.

Verilen bir doküman içerisindeki en önemli cümlelerin seçilmesi adına kullanılan bazı metotlar mevcuttur. Bu metotları kullanan ve İngilizce dokümanlar üzerinde çalışan ilk yol gösterici çalışma Luhn’ın [1] çalışmasıdır. Bu çalışmada cümleler terim frekanslarına göre puanlandırılmıştır. Edmunson [2], Luhn’ın [1] çalışmasındaki

kelime sıklığı bilgisine ek olarak “ipucu sözcük öbekleri”, “başlık terimleri” ve “cümle konumu” gibi üç yeni özellik daha kullanılmıştır. Literatürde bir cümlenin önemini tespit etmek adına sıklıkla kullanılmış olan diğer özellikler: “cümle uzunluğu”, “ünlem, soru işaretri ya da tırnak işaretri gibi vurgu belirten bazı noktalama işaretleri”, “tarih bilgisini belirten ifadeler”, “önemli N-gramlar”, “doküman içindeki isimler ya da nümerik karakterler” gibi özelliklerdir. Bu özelliklerin kullanımı [3]’deki tez çalışmasında ayrıntılı bir şekilde anlatılmıştır. [4-9]’da ise çıkışma dayalı özetteleme konusunda Türkçe dokümanlar üzerinde çalışılmıştır.

Bu çalışmanın örnek çalışmalarından [4],[5] farkı, Türkçe özetlerin çıkışmasında fazla sayıda cümle seçim metodunun kullanılmış olması ve bu metodların başarılarının değerlendirilmesinde birden fazla değerlendirmeinin çıkardığı olduğu özetlerin dikkate alınmasıdır. Cümle seçim metodlarından “varlık ismi tanıma metodu” ilk kez bu çalışma ile Türkçe metinler üzerinde analiz edilmiştir. Yapılan analizler 15’i kadın, 15’i erkek olmak üzere 30 farklı değerlendirmeinin özetini çıkardığı 20 doküman üzerinde yapılmıştır.

Bildirinin ikinci bölümünde çıkışma dayalı olan metin özetlemeye cümle seçimi için kullanılan metodlar anlatılmıştır; üçüncü bölümde veri seti tanıtılmış ve cümle seçim özelliklerinin bu veri seti üzerindeki başarım değerleri kiyaslanmıştır. Son olarak, sonuçlar bölümünde analizler özetlenmiş ve gelecek çalışmalarдан bahsedilmiştir.

2. CÜMLE SEÇİM METOTLARI

Çalışmamızın ana mantığı doküman içerisinde geçen cümleleri farklı metotlara göre puanlandırmak ve en yüksek puana sahip olan cümleleri seçerek özet dokümanlarını oluşturmaktır.

Tablo 1: Cümle seçim metotları

Grup	Cümle Seçim Metotları
Benzeme Özelliği	ö ₁ : Cümle konumu
	ö ₂ : Cümle uzunluğu
	ö ₃ : İlk cümleye benzerlik
	ö ₄ : Son cümleye benzerlik
	ö ₅ : Başlığa olan benzerlik
	ö ₆ : Toplam benzerlik
Kelime Sıklığı ve Dağılımı	ö ₇ : Ortak proximité sayısı
	ö ₈ : Dağılımsal özellik
	ö ₉ : Kelime sıklığı bilgisi
Özel Belirteçleri İçerme Durumu	ö ₁₀ : Sayısal karakter içermeye
	ö ₁₁ : “?” ve “!” içermeye
	ö ₁₂ : Pozitif kelimeleri içermeye
	ö ₁₃ : İsim soyolu kelimeleri içermeye
	ö ₁₄ : Varlık ismi içermeye
Anlamsal Özellik	ö ₁₅ : Gizli anlamsal analiz

Puanlandırmada kullanılan metotlar Tablo 1’de belirtilen gruplar altında toplanmıştır. Metotlar hakkında ayrıntılı açıklamalar ise aşağıda belirtilmiştir:

ö₁-Cümle Konumu: Çalışmamızda dokümanı oluşturan her cümlede cümlenin konumuna göre eşitlik (1) ile belirtilen skor değeri verilmiştir:

$$Skor_{\delta_1}(C_i) = \frac{N - P_i}{N} \quad (1)$$

Burada N dokümandaki toplam cümle sayısı iken, P_i değeri cümlenin doküman içinde kaçinci cümle olduğunu belirtmektedir.

ö₂-Cümle Uzunluğu:

Bu özellik, dokümandaki her bir cümleye cümlenin sahip olduğu kelime sayısına göre bir skor değeri vermektedir.

ö₃- İlk Cümleye olan Benzerlik:

Bu özellik dokümandaki her bir cümleye, cümlenin dokümanın ilk cümlesine olan benzerliğine göre bir skor değeri vermektedir. Cümleler arasındaki benzerlik kosinus benzerliğine göre hesaplanmaktadır.

$$Skor_{\delta_3}(C_i) = \text{kosinüs } (C_i, C_{ilk}) \quad (2)$$

ö₄ - Son Cümleye olan Benzerlik:

Bu özellik dokümandaki her bir cümleye, cümlenin dokümanın son cümlesine olan benzerliğine göre bir skor değeri vermektedir.

$$Skor_{\delta_4}(C_i) = \text{kosinüs } (C_i, C_{son}) \quad (3)$$

ö₅ - Başlığı olan Benzerlik:

Bu özellik dokümandaki her bir cümleye, cümlenin dokümanın başlığını olan benzerliğine göre bir skor değeri vermektedir.

$$Skor_{\delta_5}(C_i) = \text{kosinüs } (C_i, baslik) \quad (4)$$

ö₆ - Toplam Benzerlik:

Toplam benzerlik dokümda bulunan bir cümlenin, diğer cümlelere olan kosinüs benzerliklerinin toplamıdır.

ö₇ - Ortak Yakınlık Sayısı:

Ortak yakınlık sayısı, i ve j birbirinden farklı iken aşağıdaki gibi hesaplanır:

$$Skor_{\delta_7}(C_i) = \sum_{j=1}^N \text{yakinlik}(C_i, C_j) = \sum_{j=1}^N \frac{C_i(\text{yakinları}) \cap C_j(\text{yakinları})}{C_i(\text{yakinları}) \cup C_j(\text{yakinları})} \quad (5)$$

C_i (yakinları) ifadesi C_i cümlesine benzerlik değeri belirli bir sınırın üzerinde olan cümleler listesinin elaman sayısıdır. C_j (yakinları) ifadesi C_j cümlesine benzerlik değeri belirli bir sınırın üzerinde olan cümleler listesinin elaman sayısıdır. $C_i(\text{yakinları}) \cap C_j(\text{yakinları})$ ifadesi ise benzerlik listesinin kesişimi olan listenin elaman sayısıdır.

ö₈ - Dağılımsal Özellikler:

Referans [10]'nun doküman sınıflama için önerdiği dağılımsal özellikler ile bir dokümanda eşit sıklıkta geçen terimler, dokümanın içindeki yayılma durumlarına göre birbirinden farklılaştırılabilirler. Biz bu çalışmada, [10] ile belirtilen üç dağılımsal özelliğin toplayarak elde ettiğimiz değeri metin özetlemeye bir cümle puanlama方法 olarak kullandık. Referans [10]'nun önerdiği üç dağılımsal özellik "bölüm yoğunluğu", "ilk ve son konum yoğunluğu", "pozisyonların varyansı" özellikleridir. Bu özellikler hakkındaki bilgiler aşağıda belirtilemiştir:

Bölüm yoğunluğu: Bir terimin, bir doküman içindeki bölüm yoğunluğu eşitlik (6) ile hesaplanmaktadır.

$$Y_{Bölüm}(t, d) = \sum_{i=0}^{n-1} c_i > 0 ? 1 : 0 \quad (6)$$

Burada c_i değeri, terim t 'nin i indeksli cümle içindeki geçme sıklığı bilgisidir.

İlk ve Son Konum Yoğunluğu: Bu özellik ile bir terimin bir dokümanındaki ilk ve son konumları arasındaki fark alınmıştır. İlk ve son konum farkı özelliği aşağıdaki şekilde hesaplanır:

$$Y_{ilk-Son}(t, d) = Son_{Gorunum}(t, d) - İlk_{Gorunum}(t, d) \quad (7)$$

$$\text{İlk}_{Gorunum}(t, d) = \min_{i \in \{0..n-1\}} c_i > 0 ? i : n \quad (8)$$

$$Son_{Gorunum}(t, d) = \max_{i \in \{0..n-1\}} c_i > 0 ? i : -1 \quad (9)$$

Burada c_i değeri, terim t 'nin i indeksli cümle içindeki geçme sıklığı bilgisidir. n değeri ise terimin bulunduğu cümle indeks bilgisidir.

Pozisyonların Varyansı:

Bu özellikle incelenen terimin yoğunluk hesabı için terimin tüm görünüşlerinin varyansları kullanılmıştır. İlk önce incelenen terimin tüm görünüşlerinin ortalaması alınmıştır. Daha sonra her bir görünüşün ortalama görünüşten farkı alınmış ve elde edilen ortalama konum bilgisi pozisyonların varyansı olarak isimlendirilmiştir:

$$Y_{PozVar}(t, d) = \frac{\sum_{i=0}^{n-1} c_i |i - \text{merkez}(t, d)|}{say(t, d)} \quad (10)$$

$$say(t, d) = \sum_{i=0}^{n-1} c_i \text{ ve } \text{merkez}(t, d) = \frac{\sum_{i=0}^{n-1} c_i * i}{say(t, d)} \quad (11)$$

Eşitlik (6-11) ifadelerinin daha iyi anlaşılmasına adına referans [10]'da belirtilen sayısal örnek incelenmelidir.

Çalışmamızda bir dokümani oluşturan her bir terime ait 3'er dağılımsal özellik değeri (Bölüm Yoğunluğu, İlk ve Son Konum Yoğunluğu, Pozisyonların Varyansı) bulunduktan sonra bu değerlerin ortalaması alınarak, her terimin toplam dağılımsal özellik değeri bulunmuştur.

$$T_{Dagittimsal}(t, d) = \left(\frac{Y_{Bölüm}(t, d) + Y_{ilk-Son}(t, d) + Y_{PozVar}(t, d)}{3} \right) \quad (12)$$

Dokümani oluşturan cümlelere puan vermek için dokümandaki her terimin $T_{Dagittimsal}$ değerinin toplamı bulunmuş ve bu toplam cümlelere atanmıştır.

ö₉ - Kelime Sıklığı Bilgisi:

Bu özellik ile doküman içerisinde yer alan her terimin frekansi hesaplanır ve cümlelere içerdigi terimlerin frekans bilgilerinin toplanmasıyla bir skor değeri verilmektedir.

ö₁₀ - Sayısal Karakter İçerme Durumu:

Bu özellik ile cümlelere içerdikleri sayısal karakter sayısına göre bir puan verilmektedir.

ö₁₁ - "?" ve "!" İçerme Durumu:

Bir cümlein ülem işaretü veya soru işaretü ile bitmesi diğer cümlelere göre daha önemli olduğunu bir işaretidir. Buna göre eğer cümle soru işaretü ya da ülem işaretü içeriyorsa cümleye bir puan verilir.

ö₁₂ - Pozitif Kelimeleri İçerme Durumu:

Bu özellik ile cümlelerin "özetle", "sonuçta", "neticede" gibi toparlayıcı kelimeleri içerip içermediği incelenir. Cümlelere içerdikleri toplam pozitif kelime sayısı kadar puan verilir.

ö₁₃ - İsim Soyu Kelimeleri İçerme Durumu:

Metinlerde yer alan isimler, metnin içeriği hakkında bilgi vermektedir. Bu yüzden metin özetleme sistemi isimlerin geçtiği cümlelere sahip olduğu isim sayısı kadar puan vermektedir. Metinler içindeki terimlerin isim olup olmadığı Zemberek yazılımı [12] kullanılarak tespit edilmiştir.

ö₁₄-Varlık isimlerini İçerme Durumu

Varlık ismi tanıma, doğal dil işleme biliminin önemli alanlarından biri olup, dokümanlarda geçen isimleri kişi, yer ve organizasyon ismi olarak ayırmadan yanı sıra formül, tarih ve parasal ifadeleri de bulabilmeyi hedeflemektedir. Çalışmamızda ilk önce veri setinde bunan her bir doküman içindeki varlık isimleri tespit edilmiştir. Varlık isimleri tespit edilirken [13]'de belirtilen algoritma kullanılmıştır. Varlık isimleri tespit edildikten sonra cümle içinde geçen varlık isimleri sayısına göre her bir cümleye bir puan verilmiş ve yüksek puanlı cümleler özete eklenmiştir. Bu çalışma ile ilk kez varlık isimlerinin Türkçe doküman özetleme konusu üzerindeki etkisi analiz edilmiştir.

ö₁₅-Gizli Anlamsal Analize Dayalı Puanlama

Gizli Anlamsal Analiz (GAA) sistem girdisi olarak bir metnin içeriğini almaktır ve metin içindeki terimler ile cümleler arasındaki gizli anlamsal ilişkiye ortaya çıkarmaktadır. GAA'nın sistem girdisi bir terim-cümle matrisidir (A matrisi). GAA'de A matrisinin Tekil Değer Ayrımı (TDA) gerçekleştirilir ve matris üç çarpana ayrılır ($A=USV^T$). [11]'de belirtilen çalışmada bu çarpan matrislerine dayalı bir metin özetleme sistemi önerilmiştir. Bu çalışmada eşitlik (13)'deki, B matrisi oluşturulduktan sonra, bu matrisin hücre değerleri ile oluşturulmuş olan S_k (14) değerlerine göre her bir cümleye bir puan değeri verilmiş ve yüksek puanlı cümleler seçilerek özete eklenmiştir.

$$B = S^2 V^T \quad (13)$$

$$S_k = \sqrt{\sum_{i=1}^r b_{ik}^2} \quad (14)$$

3. VERİ SETİ VE PERFORMANS DEĞERLENDİRİMESİ

Cümle seçim metotlarının başarım değerleri gazetelerden toplanan 20 haber dokümanı üzerinde değerlendirilmiştir. Bu veri seti ile ilgili istatistikler Tablo 2 ile belirtildiği gibidir. Bu veri setinin hazırlanmasındaki amaç cümle seçim metotlarının istikrarını göstermektir. Bu nedenle 20 dokümanı içeren değerlendirme seti 15'i kadın ve 15'i erkek olmak üzere toplam 30 farklı kişiye verilmiş ve kişilerden doküman özetlerinin %35'lik bir özetleme oranı çıkarılması istenmiştir.

Çalışmamızda cümle seçim metotlarının performansı eşitlik (15) ile ifade edilmiştir. Burada S değeri cümle seçim metotları ile seçilen cümle sayısını ifade ederken, T değeri değerlendirme kişiler tarafından seçilmiş olan cümle sayısını belirtmektedir.

$$\text{performans} = \frac{|S \cap T|}{|S|} \quad (15)$$

Tablo 2: Veri seti istatistikleri

Değerlendirme veri setine ait olan istatistikler	
Veri Setindeki Toplam Doküman Sayısı	20
Veri Setindeki Toplam Cümle Sayısı	201
Veri Seti İçindeki Dokümalardan en az Cümleye Sahip olan Dokümanın Cümle Sayısı	7
Veri Seti İçindeki Dokümalardan en fazla Cümleye Sahip olan Dokümanın Cümle Sayısı	13

Cümle seçim metotlarının kullanımı sırasında dokümanlardaki kelimeler Zemberek yazılımı [12] ile köklere ayrılmış ve dokümanlar durak kelimelarından arındırılmıştır.

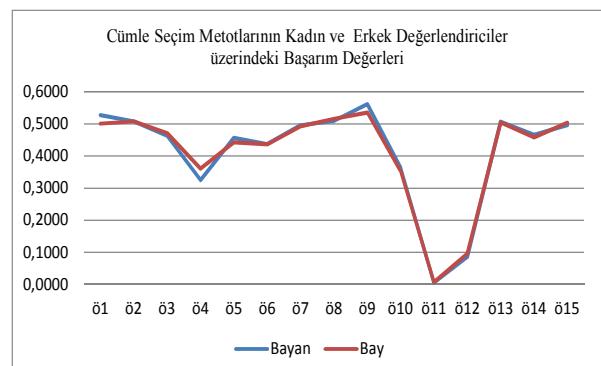
Tablo 3, çalışmamızda kullanılan cümle seçim metodlarının 30 farklı değerlendirmeye göre hesaplanan ortalama başarım değerlerini azalan sırada göstermektedir. Bu tablo aynı zamanda metod performanslarının 30 değerlendirme bazındaki standart sapma değerlerini de içermektedir.

Tablo 3: Cümle seçim metodlarının ortalama performansları ve standart sapma değerleri

Metotlar	Ortalama Performans	Standart Sapma
ö ₉	0.547	0.072
ö ₁	0.517	0.076
ö ₈	0.499	0.053
ö ₁₃	0.498	0.064
ö ₂	0.495	0.065
ö ₇	0.490	0.043
ö ₁₅	0.488	0.066
ö ₃	0.462	0.045
ö ₁₄	0.459	0.049
ö ₅	0.448	0.052
ö ₆	0.431	0.034
ö ₁₀	0.351	0.055
ö ₄	0.337	0.054
ö ₁₂	0.087	0.019
ö ₁₁	0.007	0.006

Tablo 3'ten görüldüğü üzere en başarılı cümle seçim metodu “ö₉-kelime frekansı” bilgisidir. Değerlendiriciler, sıklıkla en çok geçen kelimeleri içeren cümleleri seçmişlerdir. Bu özelliği “ö₁.cümle konumu”, “ö₈.dağılımsal özellikler”, “ö₁₃.isim soylu kelimeler” ve “ö₂.cümle uzunluğu” izlemektedir. Tablo 3'deki dikkat çekici noktalardan biri, metodların standart sapma değerlerinin düşük olmasıdır. Bu durum metodların farklı kişiler üzerindeki etkilerinin çok fazla değişkenlik taşımadığını göstermektedir. Tablo 3'de dikkat çeken noktalardan bir diğer de Türkçe dokümanlar üzerindeki etkisi ilk kez bu çalışma ile analiz edilen varlık ismini tanıma metodunun (ö₁₄) birçok özelliğini geçmesidir. Bu durum sonucunda varlık ismi tanıma özelliğinin Türkçe doküman özetleme üzerindeki etkisinin önemli olduğu söylenebilir. Varlık ismi tanıma sisteminin Türkçe dokümanlar üzerindeki başarım sonucu iyileşikçe, özelliğin metin özetleme üzerindeki etkisi daha da önem kazanacaktır.

Şekil 1, cümle seçim metodlarının kadın ve erkek değerlendirme üzerindeki başarım değerlerini göstermektedir.



Şekil 1: Cümle seçim metodlarının kadın ve erkek değerlendirme üzerindeki başarım değerleri

Şekil 1 ile belirtilen analiz sonuçlarına göre cümle seçim özelliklerinin kadın ve erkek değerlendirciler üzerindeki ortalama başarım sonuçlarının hemen hemen aynı olduğu görülmektedir. Bu durum cinsiyetten bağımsız bir şekilde kişilerin özet çıkarırken dikkat ettikleri özelliklerin benzer olduğunu göstermektedir.

Son olarak cümle seçim metodlarını tek tek kullanmak yerine, metodların birleşimi ile elde edilen farklı grupların başarım değerleri analiz edilmiştir. Bu amaçla ortalama başarım sonucu 0,4'ün üzerinde olan 11 adet cümle seçim metodu ($\ddot{o}_1, \ddot{o}_2, \ddot{o}_3, \ddot{o}_5, \ddot{o}_6, \ddot{o}_7, \ddot{o}_8, \ddot{o}_9, \ddot{o}_{13}, \ddot{o}_{14}, \ddot{o}_{15}$) farklı şekillerde (2'li, 3'lü vs.) birleştirilmiş ve pek çok deney yapılmıştır. Gruplar oluştururken cümle seçim metodlarının skor değerleri 0-1 aralığında getirilerek normalize edilmiş ve skor değerleri toplanmıştır. Başarım sonuçları değerlendirilirken cümle seçim metodlarının, üzerinde en başarılı olduğu değerlendircisinin çıkartmış olduğu özet dokümanları dikkate alınmıştır. Deneyler sonucunda elde edilen *en başarılı* gruplar Tablo 4 ile sergilenmiştir.

Tablo 4 : Birleştirilmiş metodlardan oluşan farklı sistem performansları

Özellik Grupları	Ortalama Performans
$\ddot{o}_1, \ddot{o}_{14}$	0.6983
$\ddot{o}_1, \ddot{o}_7, \ddot{o}_{13}$	0.7383
$\ddot{o}_1, \ddot{o}_3, \ddot{o}_9, \ddot{o}_{13}$	0.7133
$\ddot{o}_1, \ddot{o}_3, \ddot{o}_9, \ddot{o}_{11}, \ddot{o}_{13}$	0.7133
$\ddot{o}_1, \ddot{o}_3, \ddot{o}_7, \ddot{o}_9, \ddot{o}_{11}, \ddot{o}_{13}, \ddot{o}_{15}$	0.7008
$\ddot{o}_1, \ddot{o}_3, \ddot{o}_7, \ddot{o}_9, \ddot{o}_{11}, \ddot{o}_{13}, \ddot{o}_{15}$	0.6967
$\ddot{o}_1, \ddot{o}_2, \ddot{o}_3, \ddot{o}_5, \ddot{o}_6, \ddot{o}_7, \ddot{o}_8, \ddot{o}_{13}$	0.6575
$\ddot{o}_1, \ddot{o}_2, \ddot{o}_3, \ddot{o}_5, \ddot{o}_6, \ddot{o}_7, \ddot{o}_8, \ddot{o}_{12}, \ddot{o}_{13}$	0.6575
$\ddot{o}_1, \ddot{o}_2, \ddot{o}_3, \ddot{o}_5, \ddot{o}_6, \ddot{o}_7, \ddot{o}_8, \ddot{o}_{11}, \ddot{o}_{12}, \ddot{o}_{13}$	0.6575
$\ddot{o}_1, \ddot{o}_2, \ddot{o}_3, \ddot{o}_5, \ddot{o}_6, \ddot{o}_7, \ddot{o}_8, \ddot{o}_{13}, \ddot{o}_{14}, \ddot{o}_{15}$	0.6675

Tablodan görüldüğü üzere en başarılı grup \ddot{o}_1 -cümle konumu, \ddot{o}_7 -ortak yakınlık sayısı ve \ddot{o}_{13} -isim soyru kelime içermeye durumu metodlarının birleşiminden oluşan ikinci sıradaki gruptur. 3'lü gruplardan sonra başarım yüzdesinin düşüşü görülmektedir. Bazı durumlarda gruba yeni özelliğin katılması sistem performansını değiştirmemiştir.

Özelliklerin bireysel başarımlarını gösteren Tablo 3'e göre en başarılı ilk iki bireysel özellik \ddot{o}_1 ve \ddot{o}_9 'dur. Ancak yapılan 2'li grup değerlendirmelerine göre bu iki özelliğin toplanması diğer ikili grupların başarım oranlarını geçememiştir. Başka

bir deyişle, $\binom{11}{2}$ adet ikilinin performans değerlendirmesi

sonucu en iyi başarım sonucunu veren ikili grup \ddot{o}_1, \ddot{o}_9 değil, Tablo 4'den görüleceği üzere $\ddot{o}_1, \ddot{o}_{14}$ olmuştur. Benzer durumlar diğer grup deneyleri için de geçerlidir. Bu durumun sonucu olarak, ileriği çalışmalarda sezgisel yöntemlerin kullanımıyla metodların toplanması aşamasında bazı ağırlık değerlerinin kullanılması planlanmaktadır. Böylelikle bireysel performansları düşük olan özellikler ile yüksek performanslı özelliklerin belirli yüzdelere birleştirilmesi daha yüksek başarım değerlerinin elde edilmesini sağlayabilir.

4. SONUÇLAR VE GELECEK ÇALIŞMALAR

Bu çalışmada çıkarıma dayalı olan bir metin özetleme sisteminde kullanılabilecek cümle seçim metodları

incelemiştir. Bu metodlar, 20 haber dokümanı ve bu haber dokümanlarını özetleyen 15'i kadın ve 15'i erkek olmak üzere toplam 30 kişinin çıkarmış oldukları özet dokümanını içeren bir değerlendirme veri seti üzerinde analiz edilmiştir. Analiz sonuçlarına göre 30 kişi üzerinde en başarılı olan metodlar paylaşılmıştır. Çalışmamız ile ilk kez varlık isimleri tanıma özelliğinin etkisi Türkçe dokümanlar üzerinde test edilmiş ve bu özellik ile başarılı sonuçlar elde edildiği gösterilmiştir.

Çalışmamız ile cümle seçim metodlarının bireysel performanslarının dışında bu metodların birleşimiyle elde edilen farklı grupların başarım sonuçları da analiz edilmiştir. Analiz sonuçlarına göre en başarılı olan gruplar sereğenmiştir. Bu deneylerde cümle seçim metodları eşit önem derecelerine sahip olacak şekilde birleştirilmiştir. İleriki çalışmamızda bu özellikler farklı ağırlık değerleri ile çarpılarak, özelliklerin sahip olması gereken ağırlık değerleri sezgisel metodlar ile otomatik olarak buldurulacaktır.

5. KAYNAKÇA

- [1] Luhn, H.R., (1958). "The automatic creation of literature abstracts.", IBM Journal of Research Development, 2(2):159–165.
- [2] Edmundson, H.P., (1969). "New methods in automatic extracting.", Journal of the Association for Computing Machinery, 16(2): 264–285.Smith, J. O. and Abel, J. S., "Bark and ERB Bilinear", *IEEE Trans. Speech and Audio Proc.*, 7(6):697-708, 1999.
- [3] Güran, A. (2013), "Metin Özetleme Sistemi", Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [4] Kutlu, M., Cıgır, C. and Cicekli,I., (2009). "GenericSummarization for Turkish", ISCIS 2009, Kıbrıs.
- [5] Uzundere, E., Dedja, E., Diri, B., Amasyali, M.F. (2008), "Türkçe Haber Metinleri için Otomatik Özetleme", In Proceedings of ASYU 2008, Isparta, Türkiye.
- [6] Pembe, C. (2011). Automated Query-Biased and Structure-Preserving Document Summarization for Web Search Tasks, PhD Thesis, Boğaziçi University, Turkey.
- [7] Güran, A., Güler, N. and Bekar, E., (2011). "Automatic summarization of Turkish documents using non-negative matrix factorization ", INISTA 2011, İstanbul, Türkiye.
- [8] Güran, A., Güler Bayazıt and N., Gürbüz, M.Z., (2013),"Efficient feature integration with Wikipedia based semantic feature extraction for Turkish text summarization", Turkish Journal of Electrical Engineering and Computer Science.
- [9] Güran, A., Güler, N., Bekar, E. "LSA-based Turkish Text Summarization with Consecutive Words Detection", CSIE 2011, Changchun, Çin.
- [10] Xue, X.B. and Zhou, Z.H., (2009). "Distributional Features for Text Categorization," *IEEE Trans. Knowledge and Data Eng.*, 21(3): 428–444.
- [11] Steinberger, J., (2007). Text Summarization within the LSA Framework, PhD Thesis, University of West Bohemia in Pilsen, Czech Republic, January 2007.
- [12] Zemberek Projesi Geliştirme Sayfaları, <https://zemberek.dev.java.net/>, 1 Haziran 2009.
- [13] Şeker, G.A., Eryiğit, G. (2012). Initial explorations on using CRFs for Turkish Named Entity Recognition. In Proceedings of the 24th International Conference on Computational Linguistics, COLING 2012, Mumbai, India, 8-15 December 2012.