

TÜRKÇE METİNLERDE ŞARTLI RASTGELE ALANLARLA VARLIK İSMİ TANIMA

NAMED ENTITY RECOGNITION BY CONDITIONAL RANDOM FIELDS FROM TURKISH INFORMAL TEXTS

Serap Özka¹, Banu Diri¹

1. Bilgisayar Mühendisliği Bölümü, Yıldız Teknik Üniversitesi
serap.ozkaya@gmail.com, banu@ce.yildiz.edu.tr

ÖZETÇE

Varlık İsmi Tanıma, Doğal Dil İşleme'nin alanlarından biri olup, resmi ve resmi olmayan dokümanlarda alana bağlı veya alandan bağımsız olarak kişi, yer, kurum, tarih, formül ve para gibi farklı varlık isimlerini bulmayı hedeflemektedir. Kural tabanlı veya makine öğrenmesi teknikleri veya bunların birlikte kullanıldığı sistemler ile tanıma yapılmaktadır. Bu çalışmada, konudan bağımsız ancak e-posta gibi resmi olmayan dokümanlardan Şartlı Rastgele Alanlar kullanılarak kişi, kurum ve yer isimlerinin etiketlenmesi gerçekleştirılmıştır.

ABSTRACT

Named Entity Recognition (NER) being one of the areas of Natural Language processing can be domain dependent or independent for formal and informal texts aims to extract information about name entity such as person, location, organization, dates, formula and money. Rule Based methods and machine learning methods can be implemented in the system. In this study, Conditional Random Fields has been used to extract name entities which are person, location and organization names from informal texts.

1. GİRİŞ

Varlık İsmi Tanıma-VİT olarak Türkçe'ye çevirdiğimiz "Name Entity Recognition-NER", veri ve doküman madenciliği, doğal dil işleme, bilgi çıkarımı ve bilgiye erişim gibi birçok disiplinle ilişkilidir. VİT'in amacı resmi olan ve olmayan bir dilde yazılmış, belli bir çalışma alanına bağlı veya bağımsız olan tüm dokümanlar içerisinde dile bağlı veya bağımsız olarak varlık isimlerini bulmak ve bunları kişi, kurum ve yer ismi, zaman, tarih ve parasal ifadeler olarak sınıflandırmaktır.

Varlık İsmi Tanıma ile ilgili çalışmalar 1900'lü yıllarda başlamış olup, "Message Understanding Conference-MUC" platformunda farklı diller için yapılan çalışmalar yer almıştır. Çalışmalarda özellikle yaygın olarak kullanılan dil İngilizce olup, Varlık İsmi Tanıma da başarı %90'larda olmaktadır. İngilizce'nin dışında Arapça, Çince, Japonca gibi farklı dillerde de çok sayıda çalışma yapılmıştır. Bu alandaki ilk çalışmaların biri Rau [1] tarafından yapılan doküman içerisinde şirket isimlerini çıkarmak ve tanıtmaktır. VİT için kullanılan ilk sistemler kural tabanlı algoritmalar iken, son zamanlarda makine öğrenmesi tekniklerini kullanan modern sistemlerde geliştirilmiştir. Hem kural tabanlı hem de makine öğrenmesini birlikte kullanan hibrit sistemler de mevcuttur. Yapılan çalışmalar, kullanılan dile (tek dil veya çok dilli),

dokümanın türüne veya alanına, ve varlık isminin çeşidine göre değerlendirilmektedir [2].

Varlık İsmi Tanıma'da kullanılan öğrenme yöntemleri eğiticili, yarı-eğiticili ve eğiticisiz olmak üzere üç grupta ele alınmaktadır. Eğiticili sistemlerde Saklı Markov Modeli [3], Karar Ağacıları [4], Maksimum Entropy Modeli [5], Destek Vektör Makineleri [6], ve Şartlı Rastgele Alanların [7,8] kullanımı örnek olarak verilebilir. Bu sistemlerde işaretlenmiş geniş bir derlem, ezberlenecek varlıklar listesi ve belirsizliği gidererek kurallar kullanılır. Yarı eğiticili sistemlerde ise, başlangıçta öğrenmek için küçük bir küme kullanılarak eğitim yapılır, sonrasında sistem kendi kendine öğrenir [9]. Eğiticisiz yöntemlerde, ise grup içi benzerlikler minimum, gruplar arası benzerlikler maksimum tutularak varlık isimleri tanımaya çalışılır. Bu yöntemlerde bazen WordNet gibi sözlüksel kaynaklarda kullanılır [10].

Türkçe için yapılan VİT çalışmaları ise, sınırlıdır. Bunlardan ilki [11] tarafından gerçekleştirilen dilden bağımsız olan varlık tanıma çalışmasıdır. 2003 yılında [12] tarafından Türkçe için, istatistiksel isim etiketleme, finans haber metinlerinden kişi isimlerinin çıkarılması [13], Türkçe haber metinleri için varlık isimlerini etiketleme [14] ve yine alandan bağımsız dört farklı varlık ismi tanıma üzerine [15] çalışmalar yapılmıştır.

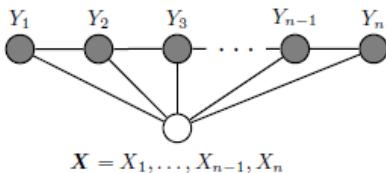
Bu çalışmada resmi olmayan bir dilde yazılmış olan Türkçe e-postalar içerisinde Şartlı Rastgele Alanlar kullanılarak yer, kurum-kuruluş ve özel isimlerin etiketlenerek çıkarılması için bir sistem geliştirilmiştir. Makalenin ilerleyen bölümlerinde sırasıyla kullanılan yöntem, geliştirilen sistem, özellik çıkarımı ve alınan deneyel sonuçlardan bahsedilmektedir.

2. KULLANILAN YÖNTEM

Geliştirilen uygulamada Şartlı Rastgele Alan yöntemi kullanılarak, kural tabanlı varlık ismi tanıma gerçekleştirilmiştir. Doğal Dil işlemede sözdizimsel analiz ile sıralı veri etiketlenebilir [16]. Örneğin;

```
<Isim>Ahmet<Isim><TamlayanEki>in<TamlayanEki><Isim>bab
a<Isim><TamlananEki>si<TamlananEki>,<Sifat>beyaz<Sifat>
<Isim>koyun<Isim><NesneEki>u<NesneEki><Isim>araba<Isim>
<DiğerZarflar>ile<DiğerZarflar><Isim>köy<Isim><DolaylıTümle
çEki>e<DolaylıTümleçEki><Yüklem>getir<Yüklem><ZamanEki>
di<ZamanEki>
```

Şartlı Rastgele Alan ise sıralı veriyi işaretlemek ve bölmelere ayırmak için kullanılan, Maksimum Entropi Markov Model ve Gizli Markov Modelin genel halini yansitan bir olasılık sunar. Şartlı Rastgele Alanda Şekil 1'de görüldüğü üzere, *y* gibi belirli bir işaret dizisinin *x* değeriyle şartlı olasılığını hesaplamak için, yönüz çizge modelini kullanmaktadır[16].



Şekil 1. Yönsüz Çizge Model

Eşitlik 1'de $f_k(y_{t-1}, y_t, x, t)$ fonksiyonu, tüm gözlem dizisinin ve $t, t-1$ pozisyonundaki işaretlerin geçiş özelliğini ifade etmektedir. λ_k ise öğrenilen veri sonucunda optimize edilen parametreyi ifade etmektedir. Z_k da normalizasyon faktörüdür. Geçiş özelliği fonksiyon her biri, gerçek gözlem özellik değerlerinin $f(x, i)$ birini alır. Dolayısıyla tüm özellik fonksiyonları gerçek değerlere sahiptirler.

$$P_\lambda(y|x) = \frac{1}{Z_x} \exp\left(\sum_{t=1}^T \sum_k \lambda_k f_k(y_{t-1}, y_t, x, t)\right) \quad (1)$$

Örneğin,

$$f_k(y_{t-1}, y_t, x, t) = \begin{cases} 1 & y_{t-1} \text{ sıfat ise, } y_t \text{ isimdir} \\ 0 & \text{Diğer Durum} \end{cases}$$

Öncelikli amaç, işlenilecek verinin benzerliğini maksimuma çıkarmak için tahminlerde bulunmaktadır. İfadenin logaritması alındıktan sonra (Eşitlik 2) elde ettigimiz formülde benzerlik-log (log-likelihood) fonksiyonu konkavdır ve global bir optimuma sahiptir, o yüzden bir optimizasyon problemdir.

$$\log P_\lambda(y|x) = \left(\sum_{t=1}^T \sum_k \lambda_k f_k(y_{t-1}, y_t, x, t) \right) - \log Z_x \quad (2)$$

Türevini alıp 0 değerine eşitledikten sonra, maksimum entropi sınırını elde etmiş oluruz. Parametreler ard arda yapılacak ölçelendirme algoritmasıyla bulunabilir (Eşitlik 3).

$$\maximize \left(\sum_{t=1}^T \sum_k \lambda_k f_k(y_{t-1}, y_t, x, t) \right) - \log Z_x \quad (3)$$

İkinci amacımız ise, verilen gözlem dizisine en benzer işaret dizisini bulmaktır (Eşitlik 4).

$$s = \arg \max p_\Lambda(s|o) \quad (4)$$

Sınırlı Viterbi algoritmasını, optimal s çözümünü bulmak için kullanabiliyoruz [17].

Bu çalışmada, Şartlı Rastgele Alan için Java programlama dilinde geliştirilmiş kütüphane kullanılmıştır[18].

3.GELİŞTİRİLEN SİSTEM

Varlık İsmi Tanıma sistemi bir java uygulaması olarak yazılmış ve e-posta içerisindeki her kelime bir java nesnesi olarak düşünülmüştür. Oluşturulan bu nesnelerde kelime ve kelimenin uzunluğu, adedi, kısaltma olup olmadığı, tipi (isim, sıfat, zamir, vd.), cümlenin ilk kelimesi mi gibi özellik değişkenleri tutulmaktadır.Uygulama çalıştırıldığında, veri setindeki her e-posta ve içerisindeki her farklı kelime için bir nesne oluşturulup:

- Özellik çıkarımında kullanılmak üzere kelime sıklıkları ve karakter tabanlı 1-gram, 2-gram, 3-gram'lar çıkartılır.
- Çıkarılan her kelimenin daha önceden oluşturulan kaynaklar listesinde yer alıp olmadığı kontrol edilir.

- Kelimenin büyük harfle başlaması, noktalama işaretlerini içermesi, başlık bilgisinde yer olması gibi özelliklere bakılarak, her özellik için kelime nesnesindeki özellik etiket değerine 1 atanır.

- Etiketleme işlemi bittikten sonra veri setinden çıkartılan özellikler kullanılarak sınıflandırma için optimizasyon parametreleri belirlenir.

Son aşamada Şartlı Rastgele Alanlar yöntemiyle etiket sınıfı belirlenir. Ancak, sınıflandırma işleminden önce uygulamaya belirlenen kural tanımları verilmelidir. Örneğin, bir kelimenin kişi ismi olabilmesi için çıkarılan kurallardan bir kaç aşağıda verilmektedir.

<kisi_ismi>From/BüyükHarfleBaşlama/<kisi_ismi>

Örneğin: From:Serap Özkarayserap.ozkaya@gmail.com

<kisi_ismi>ForwardedBy/BüyükHarfleBaşlama/BüyükHarfle Başlama<kisi_ismi>

Örneğin: Forwarded By Banu Diri

<kisi_ismi>Ünvan/BüyükHarfleBaşlama/<kisi_ismi>

Örneğin: Dr. Haluk Bey

<kisi_ismi>BüyükHarfleBaşlama/Ünvan<kisi_ismi>

Örneğin: Merhaba Ahmet Bey

<kisi_ismi>DiğerÖzelKelime/BüyükHarfleBaşlama<kisi_ismi>

Örneğin: Sayın Banu Hanım

<kisi_ismi>DiğerÖzelKelime/Ünvan/BüyükHarfleBaşlama<ki si_ismi>

Örneğin: Saygılarımla Av. Ayşen

4. VERİ SETİ VE KULLANILAN ÖZELLİKLER

Resmi olmayan Türkçe metinlerden kişi, kurum ve yer varlık isimlerini çıkarmak için kullanılan veri seti akademik, kurumsal ve kişisel e-postalardan eşit sayıda toplanmış 150 adet e-postadan oluşmaktadır. E-postalar, maksimum 792 kelime, minimum da 98 kelime olmak üzere ortalama 158 kelime uzunluğundadır. E-postalar yazım kurallarına dikkat edilerek yazılmış dokümanlar olmasa da kendilerine özgü bir formata sahiptirler. Bir e-posta iletisiniin özelliklerinden biri daha az söz dizimine sahip iyi tanımlanmış bir başlık bilgisi ve iletinin sonunda yer alan ve genellikle kişi ismi olan imza bilgisidir. Ancak e-postalarda metin bilgisi yapısal ve gramer olarak bir çok hatayı içerisinde bulunduran, alıcı ve gönderici tarafından anlaşılabilen özel kısaltmalar ve jargonları da içermektedir (Şekil 2).

Message-ID: <7789106.1072119990022.JavaMail.evans@thyme>

Date: Mon, 6 SEP 2010 09:27:45 -0800 (PST)

From: serap.ozkaya@gmail.com

To: banu@ce.yildiz.edu.tr

Subject: Updated: Ilgaz Turu

Cc: vildan@ce.yildiz.edu.tr

Mime-Version: 1.0

Content-Type: text/plain; charset=us-ascii

Content-Transfer-Encoding: 7bit

Merhaba Banu,

Ilgaz turmuzun ayrıntılı programı ektedir.

10 kişi ve üzeri sayıda gruplar için tur fiyatı 15 YTL indirimlidir.

keyifli gezilerde buluşmak üzere.

İyi çalışmalar

Serap Ozkaya

Şekil 2: Örnek E-Posta

4.1 Kullanılan Dış Kaynaklar

Temel özelliklerin çıkarılmasında yardımcı olan kısaltmalar, ünvanlar ve bazı özel kelimelerin tutulduğu sözlüklerde de ihtiyaç duyulmaktadır. Bu çalışmada 175 adet kısaltma listesi (Ing., Fr., Tşk, Sok., Mah., TD, Sn, A.Ş., Ltd.,...), 35 adet ünvan listesi (Prof., Dr., Av., Gen.,...), ve 32 adet özel

kelimeler listesi (Sayın, Hanım, Bey, Hocam, Üniversite, Bakanlık, Hastane, Dağ, Tepe,...) kullanılmıştır.

4.2 Temel Özellikler

Temel özellikler, herhangi bir kaynak kullanılmadan sadece veri setinden çıkartılmaktadır. E-posta için çıkartılan bu özellikler; e-posta başlık bilgisi özellikleri, etiketlenebilen özellikler ve kural tabanlı özellikler şeklinde 3 farklı grupta değerlendirilmektedir.

Başlık Bilgisi Özellikleri

Her e-posta bir başlık bilgisiyle başlamaktadır. İyi tanımlanmış bir başlık bilgisinde varlık isimleri yer alabilecekinden uygulamada aşağıdaki başlık bilgisi alanlarına bakılmaktadır.

- From, To, Cc ,Bcc, Send, Sender, In-Reply-to, Followup-to, Reply-to, Forwarded by
- Konu bilgisi

Etiketlenebilen Özellikler

Şartlı Rastgele Alan yönteminde, veri setindeki kelimelerin özellikleri etiket bilgisi ile gösterilebilmektedir. Örneğin, "ilk_kelime_mi=1" ataması kelimenin bir cümlede ilk kelime olduğunu göstermektedir. Eğer kelime cümledeki ilk kelime değilse bu değer 0 olacaktır [16].

E-postada geçen bir kelime aşağıdaki özelliklere sahip olduğu durumda etiket değerlerine 1 atanır. Böylece kelimenin sahip olduğu özellik bilgisi tutulur.

- Büyük harfle başlama : Kelime büyük harf ile başlıyor ise,
 - Noktalama işaretleri : Kelime (-; „“) gibi noktalama işaretleriyle birlikte yazılmış ise,
 - İlk kelime : Cümplenin ilk kelimesi ise,
 - Başlık bilgisi : Kelime başlık bilgisinde yer alıysa,
 - Ünvanla başlama : Kelimededen önce gelen kelime ünvan listesinde var ise,
 - Özel kelimelerle başlama : Kelimededen önce gelen kelime özel kelimeler listesinde var ise,
- özellik etiket değerlerine 1 ataması yapılır.

Kural Tabanlı Özellikler

Kural tabanlı özellikler bir varlık isminin kişi, yer ve kurum isimlerinden biri olup olmadığını tahmininde kullanmak için e-postalardan çıkartılan özelliklerdir.

- Ard arda gelen kelimeler : Veri setinde ele alınan her kelime için kelimededen önce gelen ve kelimededen sonra gelen kelimeler belirlenir. Bu özellik daha çok isim-soy isim eşleştirme içinde kullanılmaktadır.
- Karekter tabanlı 1-gram, 2-gram, 3-gram : Bazı son ekleri belirleyebilmek için bu özellik kullanılmaktadır.
- Kelime uzunluğu : Kelimenin kısaltma, ünvan, vd. olup olmayacağı tahmin edilebilmektedir.
- İsim, Soy İsim : Ard arda gelen kelimelerden kişi ismi olabilecek kelimelerin hangisinin isim, hangisinin soy isim olduğunun belirlenmesidir.

5. DENEYSEL SONUÇLAR

Geliştirilen sisteme test için akademik, kurumsal ve kişisel olmak üzere üç farklı alanın herbiri için 50 farklı e-posta seçilmiştir. Bu e-postalar içerisinde bulunan kişi, yer ve kurum isimleri etiketlenmeye çalışılmıştır. Sistemin başarısını ölçmek için eşitlik-5'deki kesinlik (precision), (6)'deki çağrı

(recall), (7)'deki kesinlik ve ölçüm değerlerinin harmonik ortalaması olan F-Ölçüm (F-measure) kullanılmıştır.

$$\text{Kesinlik}(P)=\frac{\text{Doğru tespit edilen varlık sayısı}}{\text{Tespit edilen varlık sayısı}} \quad (5)$$

$$\text{Çağrı}(R)=\frac{\text{Doğru tespit edilen varlık sayısı}}{\text{Test kümesindeki toplam varlık sayısı}} \quad (6)$$

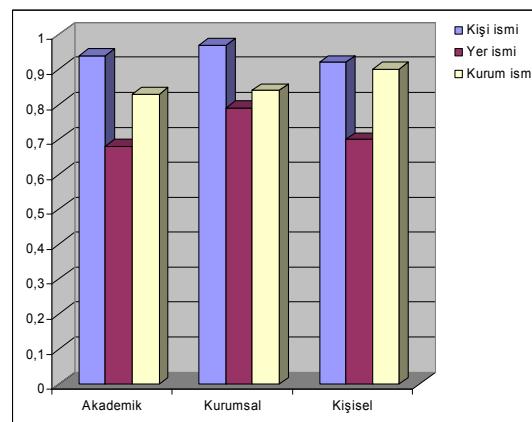
$$F\text{-Ölçüm}=(2*P*R) / (P+R) \quad (7)$$

Tablo-1'de üç farklı doküman türünde yer alan toplam metin sayıları, her alan içerisindeki yer, kurum ve isim varlık sayıları, sistem tarafından tespit edilen varlık ismi sayısı, sistem tarafından doğru tespit edilen varlık ismi sayısı ve sistemden bağımsız elle yapılan varlık ismi tespitleri gösterilmektedir. Uygulamanın doğru tespit sayısı, uygulama tarafından tespit edilen varlık ismi sayılarından hatalı tespitler çıkartılarak oluşturulmuştur.

Tablo 1. Tespit edilen varlık sayıları (UT, Uygulamanın Tespiti, DT, Uygulamanın Doğru Tespiti, GT, Gerçek Tespit)

e-Posta Türü	Akademik UT/DT/GT	Kurumsal UT/DT/GT	Kişisel UT/DT/GT
Kişi İsmi	159/146/150	175/172/180	160/141/145
F-Ölçüm	0.94	0.97	0.92
Yer İsmi	32 / 17 / 18	54 / 35 / 35	36 / 22 / 26
F-Ölçüm	0.68	0.79	0.70
Kurum İsmi	37 / 27 / 28	47 / 37 / 41	17 / 14 / 14
F-Ölçüm	0.83	0.84	0.90

Şekil-3'te üç farklı e-posta türünde kişi, yer ve kurum varlık isimlerinin tannmadaki başarısı f-ölçüm cinsinden verilmektedir. Geliştirilen kurallar ile en başarılı şekilde bulunan varlık *kişi ismi* olmuştur. İkinci sırada ise *kurum ismi* gelmektedir. En düşük performans *yer isimleri* olmuştur.



Şekil 3. Varlık isminlerinin farklı alanlarda ki F- Ölçüm değerleri

Kurum varlık isimlerinde başarının kişi isimlerine göre daha düşük olmasının sebebi öncelikli olarak yazım kurallarına

uyulmamış olmasıdır. Örneğin, e-postanın imza bölümünde “Tesevkurler” kelimesinden sonra gelen
“E.Yıldız

Mediation Solutions”
bilgisi olsun. *E.Yıldız* kelimesi yazılırken ilk isim ile soyadı arasında boşluk olmaması ve arada nokta işaretinin yer almasından dolayı ifadenin tamamı kurum ismi olarak etiketlenmektedir.

Tanımada başarının en düşük olduğu varlık, yer isimleridir. E-postalar içerisinde yer isimlerinin yazılmasında, yer isminden sonra gelen iyilik, durum ve bildirme eklerinde kesme işaretinin kullanılmadığı gözlemlenmiştir. Bu durumda yer isimlerinin hatalı etiketlenmesine sebep olmaktadır.

En başarılı e-postalar kurumsal içerikli olup, ortalama %87 doğrulukla tanıma yaparken, en az hata ile tanımlan varlık ismi %95 ile kişi ismi olmuştur. En başarısızda ortalama %72 ile yer varlık ismidir. Türkçe üzerine aynı veri setini kullanan bir çalışma olmadığından sistemin başarısı farklı çalışmalarla karşılaştırılmıştır. Çalışmanın ileri aşamaları yine dile bağlımlı, fakat dokümanın türünden bağımsız olarak daha fazla varlık ismi tanıtmaya yönelik devam edecektir.

6. SONUÇ

Varlık İsmi Tanıma, bilgi çıkarımı ve bilgiye erşim alanında kendisine yer edinse de, dile bağlı olarak geliştirdiğimiz kurallar ile doğal dil işleme altında da kendisine yer bulmuştur. Varlık İsmi Tanıma üzerine yapılan çalışmaları Türkçede sınırlı sayıda olup, çoğu alana bağlıdır. Ayrıca, tanımaya çalışılan varlıkların sayısında sınırlıdır. Bu çalışmada resmi olmayan (informal) Türkçe e-postalar üzerinde bazı kurallar çıkarılarak, Şartlı Rastgele Alanlar kullanılıp kişi, kurum ve yer gibi üç farklı varlık isminin tanınması gerçekleştirilmiştir. En yüksek başarı kurumsal e-postalarda kişi varlık ismi ile alınmıştır.

7. KAYNAKÇA

- [1] Rau, L.F., “Extracting Company Names from Text”, In *Proc. Conference on Artificial Intelligence Applications of IEEE*, 1991.
- [2] Nadeau, D., Sekine, S., “A survey of named entity recognition and classification”, *Linguistica Investigationes*, vol. 30, no. 1, pp.3-26, 2007.
- [3] Bikel, D.M., Miller, S., Schwartz, R., Weischedel, R., “A High-Performance Learning Name-finder”, In *Proc. Conference on Applied Natural Language Processing*, 1997.
- [4] Sekine, S., “Description of the Japanese NE System Used For Met-2”, In *Proc. Message Understanding Conference*, 1998.
- [5] Borthwick, A., Sterling, J., Agichtein, E., Grishman, R., “Description of the MENE Named Entity System as used in MUC-7”, In *Proc. Seventh Message Understanding Conference*, 1998.
- [6] Asahara, M., Matsumoto, Y., “Japanese Named Entity Extraction with Redundant Morphological Analysis”, In *Proc. Human Language Technology Conference – North American chapter of the Association for Computational Linguistics*, 2003.
- [7] McCallum, A., Li, W., “Early Results for Named Entity Recognition with Conditional Random Fields, Features Induction and Web-Enhanced Lexicons”, In *Proc. Conference on Computational Natural Language Learning*, 2003.
- [8] Minkov, E., Wang, R., Cohen, W., “Extracting Personal Names from e-mail: Applying Name Entity Recognition to Informal Text”, In *Proc. Human Language Technology and*

Conference on Empirical Method in Natural Language Processing, 2005.

- [9] Brin, S., “Extracting Patterns and Relations from the World Wide Web”, In *Proc. Conference of Extending Database Technology. Workshop on the Web and Databases*, 1998.
- [10] Alfonseca, E., Manandhar, S., “An Unsupervised Method for General Named Entity Recognition and Automated Concept Discovery”, In *Proc. International Conference on General WordNet*, 2002.
- [11] Cucerzan, S., Yarowsky, D., “Language independent named entity recognition combining morphological and contextual evidence”, In *Proceedings of the Joint SIGDAT Conference on Empirical Methods in Natural Language Processing and Very Large Corpora*, 1999.
- [12] Tür, G., Hakkani-Tür, D., ve Oflazer, K., “A statistical information extraction system for Turkish”, *Natural Language Engineering*, 9, 2:181-210, 2003.
- [13] Bayraktar, Ö., Taşkaya-Temizel, T., “Person name extraction from Turkish Financial news text using local grammar based approach”, In *Proceedings of the International Symposium on Computer and Information Sciences*, 2008.
- [14] Küçük, D., Yazıcı, A., “Named entity recognition experiments on Turkish texts”, In *Proceedings of the International Conference on Flexible Query Answering Systems*, 2009.
- [15] Dalkılıç, F.E., Gelişli, S., Diri, B., “Türkçe Kural Tabanlı Varlık İsmi Tanıma”, *18. Sinyal İşleme ve Uygulama Kurultayı*, Diyarbakır, 2010.
- [16] Wallach, H.M., “Conditional Random Fields: An Introduction”, *University of Pennsylvania CIS Technical Report*, 2004.
- [17] Chang, Y.S., Sung, Y.H., “Applying Name Entity Recognition to Informal Text”, *Stanford University*, 2006.
- [18] Sarawagi,S., Conditional Random Field Project Page, <http://crf.sourceforge.net/>