Doküman Benzerliğinin Çıkarılması

Geliştirilen bu araç ile dokümanların birbirlerine olan benzerlikleri hesaplanmaktadır.

Program “Online” ve “Offline” olarak iki modda çalışmaktadır.

Offline Mod

Bu mod seçildiğinde ilgili ekranda “Similarity for all Documents”, “Similarity Between a Document to all Documents” ve “Similarity Between Two Documents” isimli üç ayrı sekme yer almaktadır şekil-1.

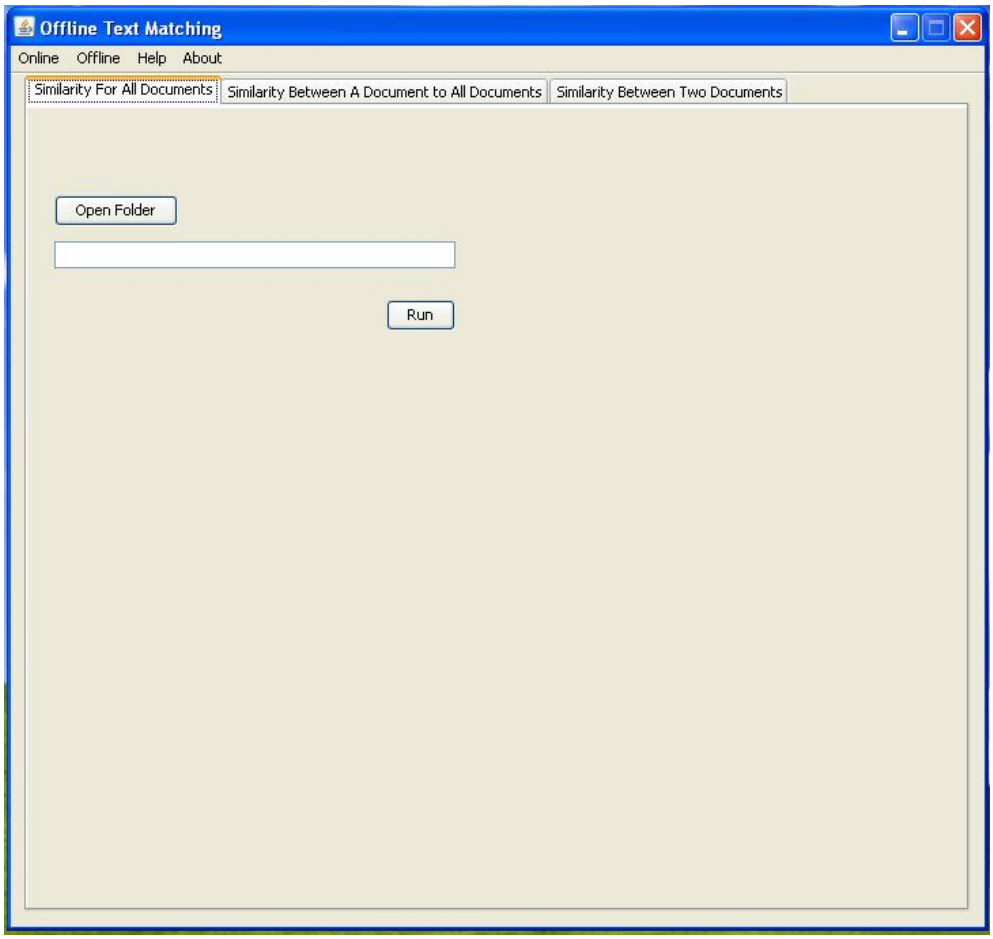

Şekil-1 Offline çalışma ekranı

Similarity for all Documents : Bu sekmede “Open Folder” dan seçeceğimiz bir klasör altında yer alan dosyaların birbirlerine göre benzerlikleri hesaplanarak sonuç döndürülür. Şekil-2 ‘de ki örnekte seçilmiş olan klasör altında 6 tane txt uzantılı dosya bulunmaktadır. Daha sonra “Run” tuşuna bastığımızda bu altı dosyanın birbirine olan benzerliklerini

hesaplayarak 0-1 aralığında bir sayı ile ifade eder. Şekil-1 de iki ile dört numaralı dosyaların birbirlerine en fazla benzerlik gösterdiklerini söyleyebiliriz.

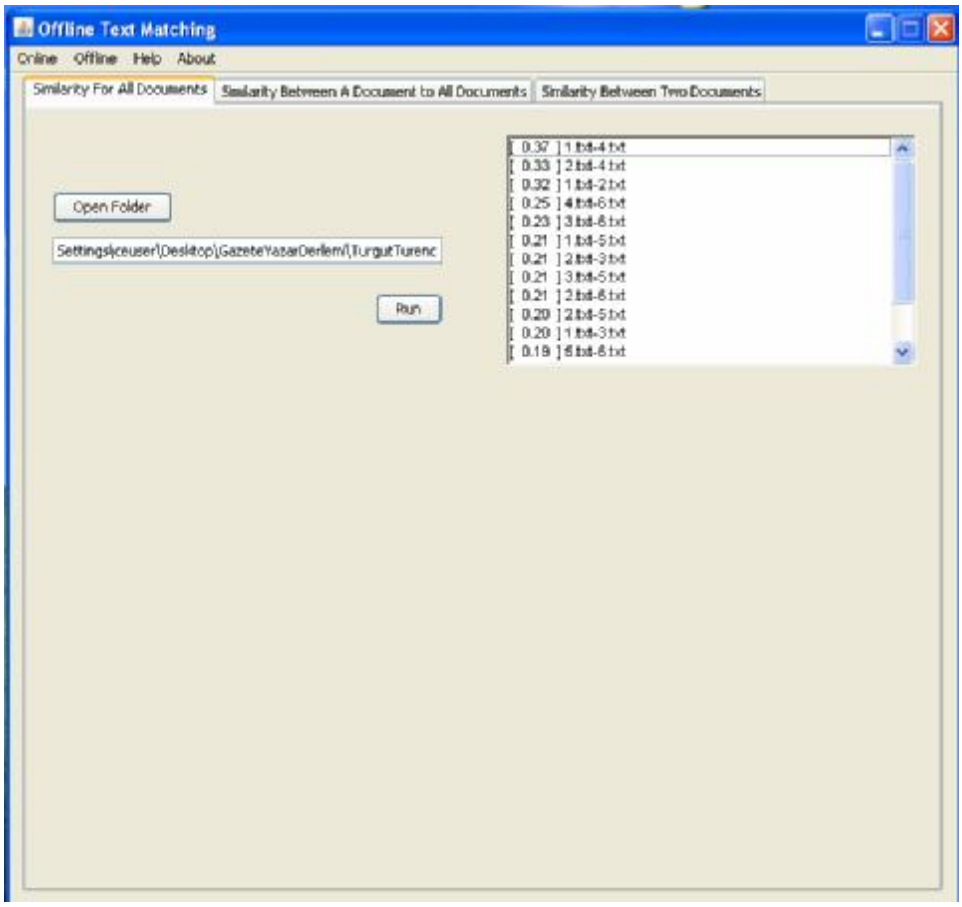

Şekil-2 Tüm dokümanların birbirlerine göre benzerlikleri

Similarity Between a Document to all Documents: Bu sekmenin görevi, seçilen tek bir dokümanın yine seçilen bir klasör içindeki dosyalar ile olan benzerliklerinin çıkarılmasını sağlamaktadır. Şekil-3 'te görüldüğü üzere seçilen klasör içerisinde 33 farklı doküman bulunmakta ve "Open File" düğmesini kullanarak seçtiğim 1 dokümanın diğer dokümanlar ile olan benzerliği sağdaki pencerede sunulmuştur. Bu örnekte 1.txt ile %100 benzerlik mevcuttur.

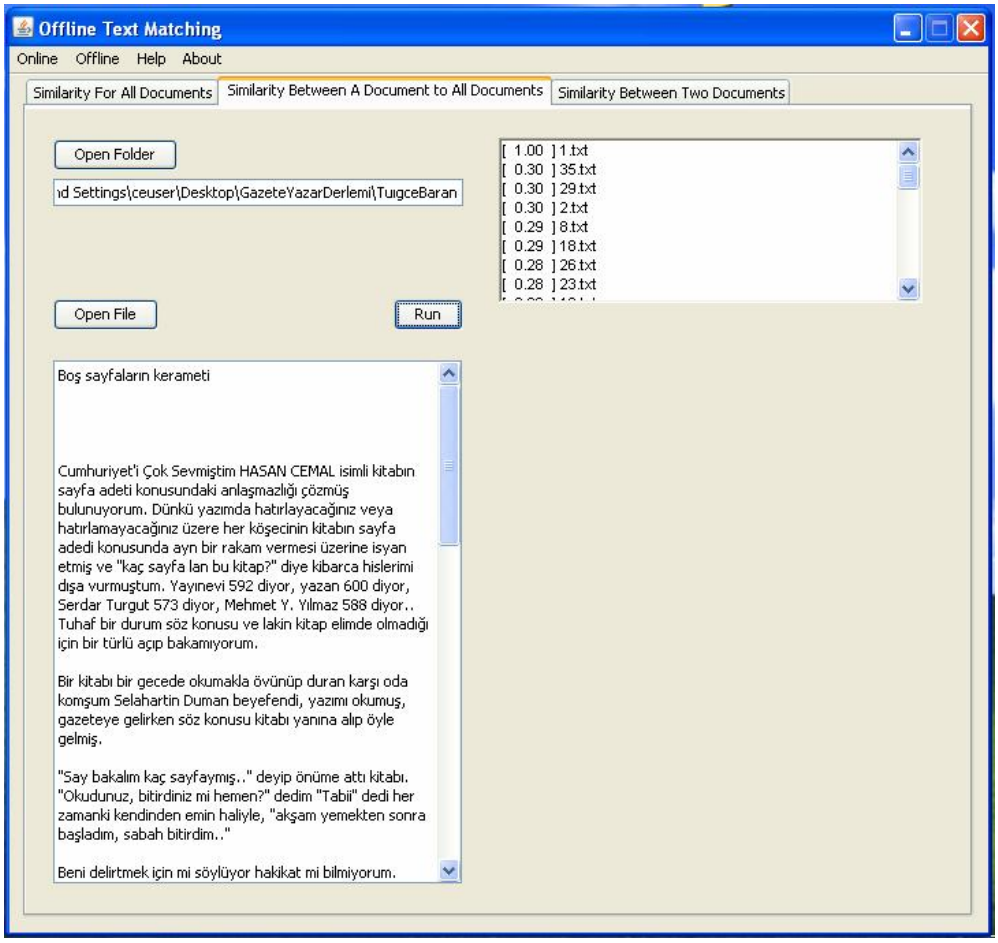

Şekil-3 Tek bir dokümanın tüm klasör içerisindeki dokümanlar ile benzerliği

Similarity Between Two Documents : Bu sekme ise “Open File-Dosya Aç” ile seçilmiş iki ayrı dosyanın birbirleri ile olan benzerliğini bulmaktadır. “Run-Çalıştır” düğmesi ile işlem başlatılır ve şekil-4’te ki ekran karşımıza gelir. Bu ekran bize karşılaştırılan bu iki dokümanın benzerliğinin 0.28 olduğunu söyler.

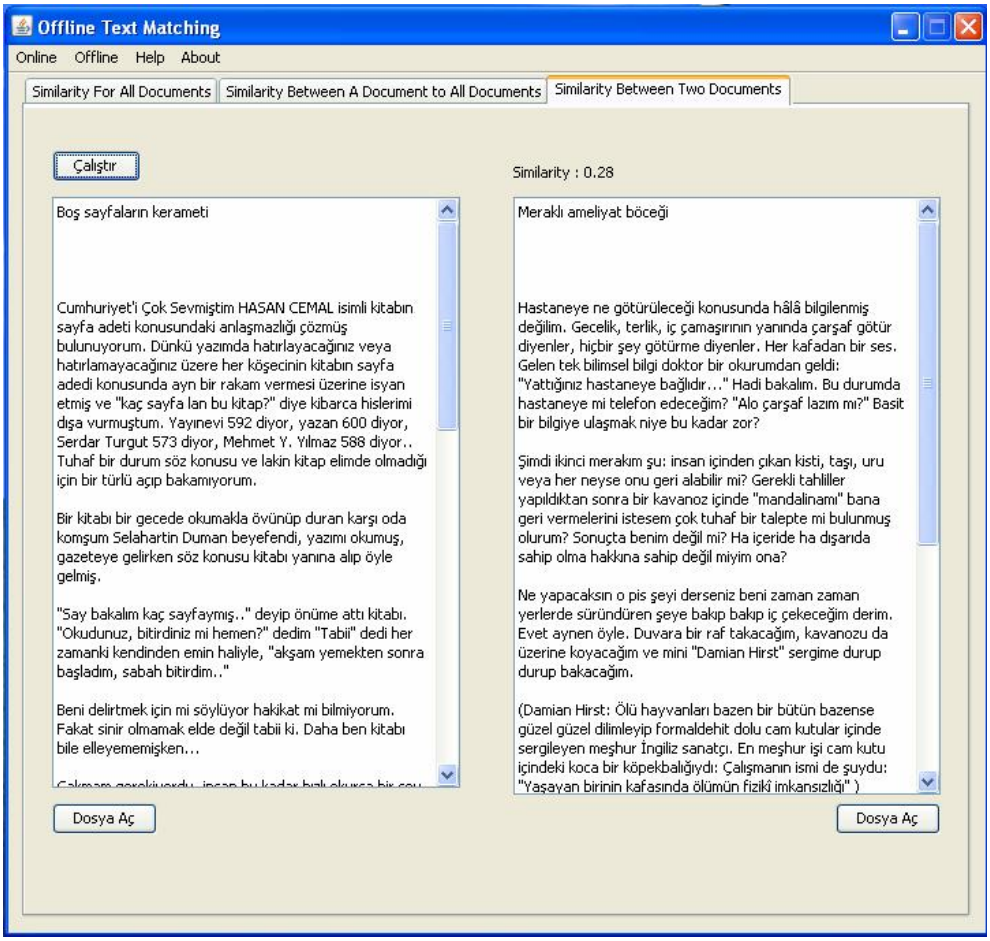

Şekil-4 İki dokümanın benzerliğinin çıkarılması

Online Mod

Şekil-5'te yer alan ekranın sol tarafında iki pencere yer almaktadır. Sol altta yer alan pencereden benzerleri aranacak olan doküman "Open File" düğmesi ile seçilir. Daha sonra "Analyse" düğmesi ile ilgili doküman analiz edilir. Ve en fazla sıklıkla kullanılan kelimeler çıkarılır (tek başlarına anlam ifade etmeyen=stop words ve fiiller hariç). Sol üstte yer alan pencerede Keyword ve Properties bilgileri yer almaktadır.

Properties altında bulunan:

Number Of Keywords : Dokümandan çıkarılan toplam anahtar kelime sayısı.

Keywords : Kaç tane anahtar kelime ile çalışmak istiyorsak seçme hakkını verir. Ayrıca Keywords penceresinde yer alan bir anahtar kelimeye çift tıklayarak silebilir ya da "Add" düğmesini kullanarak istediğimiz bir anahtar kelimeyi listeye ekleyebiliriz.

Search in : Seçilen dokümanın benzerlerinin html, doc ve pdf dosyalarının hangilerinde aranacağının seçilmesi için kullanılır.

Weighting : Kelimelerin ağırlıklandırılmasının hangi yönteme göre yapılacağını belirler.

Pages to Search : Aramanın kaç sayfada yapılacağı.

Aynı bölümde "Find the Original File" seçeneğinin seçilmesi ile dokümanın birebir aynısının web üzerinde aranması istenebilir. Sağ taraftaki bölümde ise benzer dosyaların link adresleri ve benzerlik oranları verilmektedir.

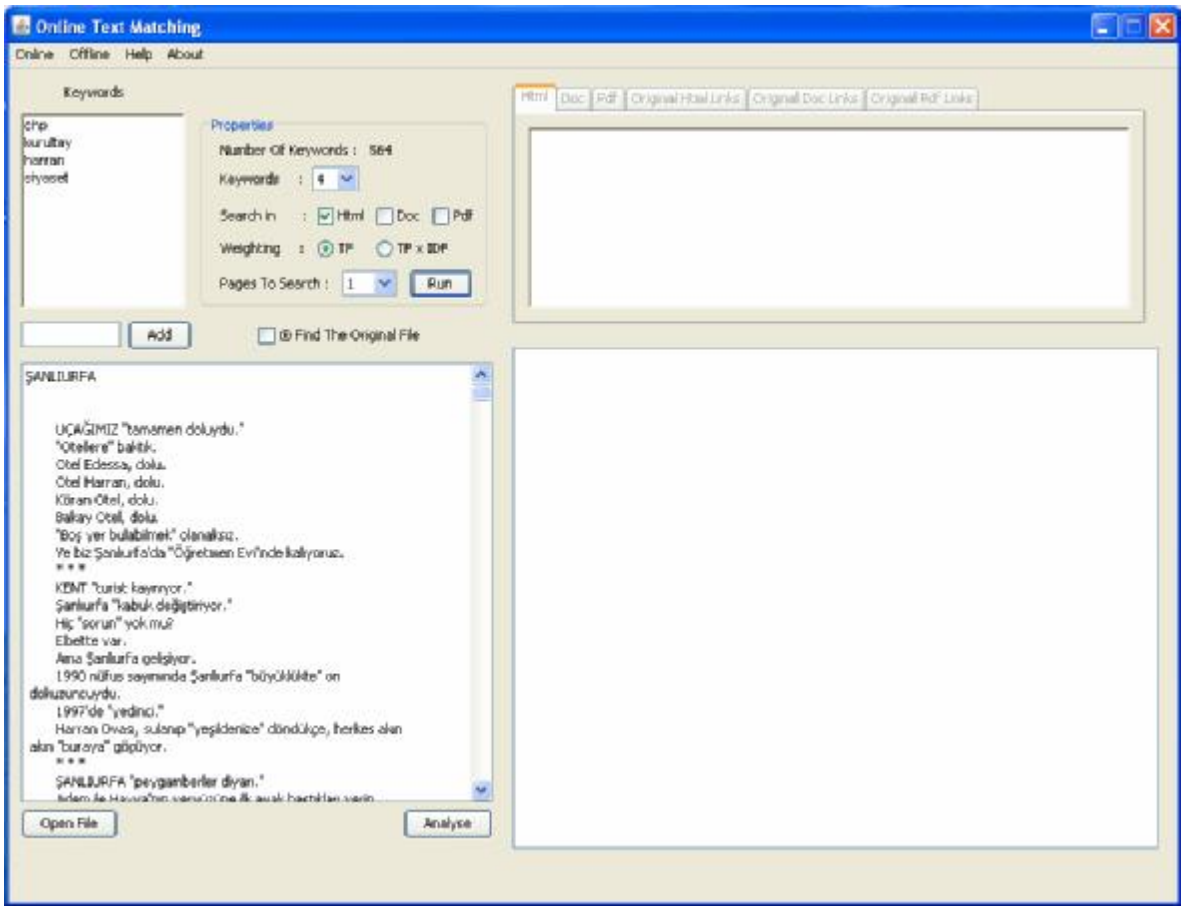

Şekil – 5 Online çalışma ekranı