

WWW Tarama Araçları

Internet kullanıcının en büyük sorunu yüzbinlerce farklı arşivde tutulan gigabaytelere biliye nasıl ulaşabileceğidir. Sayısız arşivdeki bilgilere tek tek bakmak sadece insanın sabır sınırlarını zorlamakla kalmaz, aynı zamanda mümkün de değil. Bu amaçla Internet'in ilk günlerinden itibaren arşivlerde tutulan bilgilerin sorgulanabilmesi için onları indeksleyen, Tarama Araçları (Search Engines) adı verilen yazılımlar üretilmiştir. Örneğin, herkesin kullanımına açık FTP arşivlerinde yer alan dosyaları ARCHIE adlı bir program aracılığı ile öğrenebilirsiniz. Dosyanın tam adını ya da adında geçtiği düşünülen sözcükleri verip, ARCHIE aracılığı ile hangi FTP arşivlerinde tutulduğunu öğrenmek mümkün. Benzer şekilde Gopher servislerinde tutulan bilgilerin fihristini tutan VERONICA (Very Easy Rodent Oriented Network Information for Computerized Archives) adlı bir program var. VERONICA, belirli aralıklarla kendisinde kayıtlı bulunan Gopher servislerindeki dizinlerin ve bu dizinlerin içinde yer alan dosyaların listesini çıkarır. Bu liste aracılığı ile yarattığı veritabanıyla da sorgulayıcılarla hizmet verir. ARCHIE ve VERONICA dışında WAIS (Wide Area Information Service, Geniş Alan Bilgi Servisi) adında başka bir yazılım var. ARCHIE ve VERONICA'dan farklı olarak, WAIS, sabit bir veritabanı üzerinden sorgulamayı gerçekleştirir. Bu veritabanını WAIS kendisi güncellemez; güncellemenin sistem sorumlusu tarafından gerçekleştirilmeli gerekir.


Internet'in gelişimine koşut olarak, tarama araçları da gelişti. Yukarıda adı belirtilen bazı tarama araçları bir çok yönden kullanıcının istediği esnekliği sağlamıştı. Özellikle WWW yayıldıktan sonra, kimse VERONICA ya da WAIS gibi karakter tabanlı arayüzlü eski tarama araçlarını kullanmak istemedi. Bu noktadan sonra, WWW üzerindeki bilgilerin sorgulanmasını sağlayan WWW tarama araçları devreye girdi.

WWW'deki tarama araçları, önceliği kuşak tarama araçlarına göre çok daha esnek. Tarama için birden fazla sözcük verilebiliyor. Tarama yapılacak alanlar belirlenebiliyor.

Ve/veya gibi mantıksal bağclar kullanılıyor. Tarama sonunda kaç yani istendiği belirtilebiliyor. Sorgulamalar için grafik ortam kullanıldığından işlemler de çok daha rahat. WWW'deki Lycos, WebCrawler, WWW Worm gibi ilk tarama araçları akademik araştırma projeleri olarak ortaya çıktı. Ancak ortaya çıkan sonuçlar böyle tammin ediciydi ki, tarama servisleri bir anda Internet üzerindeki en önemli uğrak yerleri haline geldiler.

Şak tarama araçları tüm metni indeksine alıyor. Digital firmasının, Alta Vista adlı tarama aracı, aynı anda 1000 tane WWW servisini tarayıp, bulduğu tüm metni veritabanına kaydediyor.

Alta Vista'nın veritabanında yaklaşık 22 milyon WWW sayfası yer almıyor. Bu sayfalarda ise yaklaşık 10 milyar sözcük var. Tüm indeks ise 33 gigabyte tutuyor. Bu devasa veritabanı, Digital firmasının en güvenli bilgisayarlarından birinde tutuluyor.



Tarama araçlarını yaratmak kuramsal açıdan pek zor gözükmede de, pratikte pek böyle olmadığı görülmüyor. Başlangıçta programcının veritabanında tanımladığı adreslere bakın tarama aracı bu adreslerdeki sayfalarda bulunan metnin indeksini tutuyor. Yine, uğradığı sayfalardaki yeni sayfaların adreslerin -kendi veritabanında yer almıyor- kaydediyor. Daha sonra bu yeni adreslere de uğrayıp, aynı işlemleri tekrarlıyor. İlk başta 10 adresle işe başlayan tarama araçları kısa süre içerisinde on binler ulaşıyor.

İlk tarama araçları, uğradıkları her sayfadan başlık ya da konu olarak seçikleri birkaç sözcüğü fihristlerine katmakla yetinmişken; yeni ku-

Alta Vista'nın çalıştığı bilgisayarın 6 gigabyte belleği, 10 ana işlemci, 210 gigabyte da sabit disk kapasitesi var. Alta Vista bir günde 2 milyonu aşkın tarama isteğine yanıt veriyor. 33 gigabytelik fihrist üzerinde yapılan her bir tarama yarınlı sanıyeden az sürüyor. Tüm bu işlem haemine

Bazı WWW Tarama Araçlarının Adresleri
<http://altavista.digital.com>
<http://www.inktomi.com>
<http://guide-p.infoseek.com>
<http://webcrawler.com>
<http://www.cs.colorado.edu/www.html>
<http://www.lycos.com>
<http://www.yahoo.com>
<http://cuwww.unige.edu/w3catalog>
<http://www.psu.edu/search.html>

karşılık Alta Vista'nın (ve diğer WWW tarama araçlarının) çözemediği önemli bir sorun var. WWW'nin inanılmaz büyürme hızı.

Şu anda 100 000 WWW servisinin tutulan 50 milyon sayfa olduğu sanılıyor. Bu sayı, her 9 ayda iki katına çıkarıyor. Alta Vista bile, duyurulduğu 15 Aralık 1995 tarihinden bu yana, WWW'nin yarısından azını taramayıp.

WWW tarama araçlarının çözemediği tek sorun bu da değil. WWW üzerinde yet alen her türlü bilginin indeksini tutmak olanak dışı. Şu an için sadece metin dokümanları indekslenebiliyor. World Wide Web'in yeni uzantıları olan VRML ya da JAVA dillerinde hazırlanan belgelerin, ses, görüntü ve canlılandırma dosyalarının tarama araçları veritabanlarına alamıyorlar. Aslında, bütün metin dosyalarının da veritabanlarına alınabilindiğinden bahsedemeyiz. İsteğiniz üzerine, bir sorgu sonucunda dinamik olarak üretilen bilgiyi indekslemenin yolu yok. Zaten böyle veritabanları WWW tarama araçlarının "kara listesinde".

Tarama araçları ile ilgili sorunun en önemli bir boyutu da, kullanıcıyı doğrudan ilgilendiriyor. Verdiğiniz anahtar sözcüğe göre, bir taramadan on ile onbin arasında değişen miktarada yanıt almanız mümkün. Yanıtların sayısı 25-30'lu geçiyorsa, gerçekten aradığınız bilgiye ulaşmak bir sorun haline gelebilir.

Tarama araçları ile ilgili önceliği kuşak tarama araçlarına da, bu servislerin an için Internet ve WWW'nin vazgeçilmez parçaları. Daha iyi algoritmalarla çalışan, hızlı araçların yaratılması durumunda daha da iyi hale gelmeyecekler. Ancak özel Internet şirketlerinin tarama servislerini daha ne kadar "amme hizmeti" olarak götürecekleri de tartışılmaktadır. Kuşkusuz, tarama servisleri bugün Internet'in en çok ziyaret edilen sayfalar arasında yer alıyor. Bu sayede tarama servisi veren şirketler de WWW sayfalarına aldıkları reklamlardan çok fazla kâr ediyorlar. Ancak taramalardan da sözcük başına para almayı düşünebilirler. Bekleyip, göreceğiz.

Kaynaklar:
New Scientist, 6 Nisan 1996
<http://altavista.digital.com>