

İnsandan Daha İnsan? Arşivde Yapay Zekâ*

More human than human? Artificial intelligence in the archive

Gregory Rolan**, Glen Humphries, Lisa Jeffrey, Evanthia Samaras,
Tatiana Antsouпова, Katharine Stuart

(Çev.: HASAN ÖZTÜRK)***

öz

Görünen o ki hayatımızı dönüştürme potansiyeline sahip olan bazı Yapay Zekâ (YZ) gelişmelerinin olmadığı bir gün geçmiyor. Belge yöneticileri olarak ‘Peki ya biz?’ diye sorabiliriz. Sınıflama, değerlendirme ve imha işlemlerinde bize yardımcı olacak yapay zekâ veya otomasyon nerede? Dijital çağda belge yönetmenin zorluklarını aşacak – uygun beceri ve bilgilerle birlikte – bu tür bir teknoloji gerekli olacaktır. YZ, dijital belge yönetimi ve arşiv işlerini nasıl otomatikleştirebilir? Yazarlar bu makalede, Avustralya’daki belge yönetimi işlemlerinde yapay zekâ uygulamalarının değerlendirmesini yapmaktadır. Böyle bir teknolojinin aldatma karşısındaki gerçekliği nedir ve hâlihazırda neler yapıyor? Yazarlar bu soruları yanıtlarken, önce yapay zekâ tekniklerine ve bu tekniklerin belge yönetimi çalışmalarıyla ilgili özelliklerini sunmaktadır. Ardından YZ girişimlerine başlamış Avustralya arşiv ve kamu kurumlarından dört vaka çalışması sunulmaktadır. Her bir vakada, bugüne kadar olan faaliyeti, sonuçları ve gelecekleri açısından projenin gözden geçirilmesini sağlamaktadırlar. Makale, arşivdeki YZ’den öğrenilenler, sorunlar ve çıkarımlar hakkında bir tartışma ile sona ermektedir.

* Makalenin Künyesi: Gregory Rolan, Glen Humphries, Lisa Jeffrey, Evanthia Samaras, Tatiana Antsouпова, Katharine Stuart, “More human than human? Artificial intelligence in the archive”, *Archives and Manuscripts*, Vol. 47, No. 2, (2019), pp. 179-203.

Bu çalışma, “More human than human? Artificial intelligence in the archive” adlı makalenin yazarlarından alınan çeviri izni doğrultusunda hazırlanmıştır.

** Dr., Gregory Rolan, Centre for Organisational and Social Informatics, Faculty of Information Technology, Monash University, Australia, greg.rolan@monash.edu.

*** Arş. Gör., Bartın Üniversitesi Edebiyat Fakültesi, Bilgi ve Belge Yönetimi Bölümü, Bartın/Türkiye, hozturk@bartin.edu.tr. ORCID 

ABSTRACT

Not a day appears to go by without breaking news of some Artificial Intelligence (AI) advance that seemingly has the potential to transform our lives. As recordkeeping professionals, we can very well ask, ‘What about us?’ Where is the AI or automation to help us with our classification, appraisal and disposal work? If we are to meet the challenges of managing records in the digital age, such technology – together with appropriate skills and knowledge – will be necessary. How can AI automate our digital recordkeeping and archive work? In this article, the authors provide a snapshot of the practice of AI in Australian recordkeeping. What is the reality versus the hype of such technology, and what is actually being done now? In answering these questions, they first provide a brief introduction into AI techniques and their characteristics in relation to recordkeeping work. They then introduce four case studies from Australian archival and government institutions that have embarked on AI initiatives. In each case, they provide an overview of the project in terms of requirements, activities to date, outcomes and futures. The article concludes with a discussion of the lessons learnt, issues and implications of AI in the archive.

Giriş

GÖRÜNEN o ki hayatımızı dönüştürme potansiyeline sahip olan bazı Yapay Zekâ (YZ) gelişmelerinin veya en azından otomasyon ürünlerinin olmadığı bir gün geçmiyor. Telefon kameralarımızdaki yüz tanımasından, sürücüsüz araba vaatlerine, evlerimizdeki sesli asistanlara kadar günlük gereksinimlerimizin tümünde YZ bileşenleri var. Bilgi-eğlence ve reklam ağlarımızı oluşturan, çeşitli yayın ve akımları filtreleyen, bilgi gereksinimlerimizi tahmin eden, bir sonraki satın alma süreçlerini tahmin ve kontrol etmeye çalışan esrarengiz motorlar da aynı ölçüde yaygındır. Örneğin, istenmeyen e-postaları tanıyan ve yönlendiren, bize olası alıcıları bildiren ve e-posta sohbetlerine dayalı olarak takvime işleyen e-posta sistemleriyle iş hayatlarımızda değişimlere neden olmuştur. Ayrıca çeşitli bilgi çalışmalarında çığır açan gelişmeler olduğunu da duymaktayız; örneğin tıbbi teşhis, dilden dile çeviri, görüntü işleme, senaryo analizi (oyun oynama dâhil) ve istihbarat toplama gibi. Şüphesiz hayatımızın her alanında YZ destekli otomasyonun altın çağına giriyoruz.⁽¹⁾

Belge yöneticileri olarak ‘Peki ya biz?’ diye sorabiliriz. Sınıflama, değerlendirme ve imha işlemlerinde bize yardımcı olacak YZ veya otomasyon ne durumda? YZ, arabalarımızı sürmemize, hastalıklarımızı teşhis etmemize ve kişisel bilgi gereksinimlerimizi filtrelememize yardımcı oluyorsa, disiplinimizi yeniden şekillendiremezsek bile dijital belge yönetiminin gerçekleri doğrultusunda muhakkak bu tür teknolojileri, işimizin rutin yönlerinde ele almalı ve kullanmalıyız. Muhtemelen, dijital çağda⁽²⁾ belgeleri yönetmenin zorluklarını aşacak, bu tür teknolojik yardımlar – onları kullanmak için gereken beceri ve bilgi ile birlikte – gerekli olacaktır.⁽³⁾

Günümüzde artan veri hacimlerini içeren bilgi ortamları ‘vahşi sınır’⁽⁴⁾ hâline geldi; merkezî olmayan ve parçalanmış, ticari ve tescilli sistemlere olan güven, belge ve format biçimlerinin gelişmesiyle baskılara maruz kalıyor.⁽⁵⁾ Örneğin yakın tarihlerde Birleşik Krallık Ulusal Arşivlerinin yaptığı incelemede, kurumların

%30'unun Elektronik Doküman ve Belge Yönetimi Sistemi (EDRMS/EDBYS) içinde dijital belgeleri tutmasına rağmen genellikle aktif bir muhafaza/imha işlevlerinin olmadığı tespit edilmiştir. Rapor ayrıca e-postaların tutarsız bir şekilde yönetildiğini de vurgulamıştır. Kurumların sadece %10'u sosyal medya içeriklerini tutuyor ve değerlendiriyor, yüksek hacimli verileri depolamak için ortak sürücülerini kullanıyor – bir EDBYS'de tutulan her TB bilgi için ortak sürücülerde yaklaşık 10 TB veri vardır.⁽⁶⁾ Sürekli genişleyen “vahşi sınırın” evcilleştirilmesiyle [kontrol altına alınması problemi ile] karşı karşıya kalan kurumlar, dijital bilgilerin devasa hacmi karşısında sadece depolama ihtimaliyle yüzleşiyorlar, ‘dijital materyalleri ve onların izlerini çıkarma, yeniden kullanma ve iyileştirmeye yönelik yenilikçi teknikler’, sonunda büyük miktarda oluşan bilgi çamurundan belgelerin hakikatlerini ayırt etmeyi umuyorlar.⁽⁷⁾

Depolama maliyetlerindeki devam etmekte olan düşüş genellikle belgeler etrafında entelektüel sınırlar oluşturma ve karmaşık dijital alemde değer belirlemeye yönelik çabanın maliyetiyle karşılaştırılır. Ancak bugünün sorunlarını idealize edilmiş bir geleceğe kaydırmak yanlış bir ekonomidir. Bunun yerine dijital belgelerin ‘tasarım, göç ve tasfiye etme işlemlerindeki risk noktalarına’ müdahale etmek için pasif hizmet sunumundan proaktif sistem tasarımı ve izlemeye geçme zorunluluğu vardır.⁽⁸⁾ Basitçe söylemek gerekirse yeterli ilgi (ve uygun teknolojik yardımlar) olmazsa çamurda boğulacağız.⁽⁹⁾

Peki bu dijital belge yönetimi ve arşivleme işini otomatikleştirmek için hâlihazırda veya yakın gelecekte hangi teknolojiler mevcut? Bu makalede otomatikleştirilmiş hatların bazı yapı taşlarını oluşturabilecek dijital adli bilişim ve genel sistem yönetimi araçlarının (örneğin William P. Vinh-Doyle,⁽¹⁰⁾ Anthony Cocciolo,⁽¹¹⁾ Victoria Sloyan⁽¹²⁾ ve Ross Spencer⁽¹³⁾ tarafından tanımlandığı gibi) ötesine bakıyoruz. Bunun yerine YZ çözümlerinin değerlendirilmesi ve seçiminde yardımcı olmak için belge yönetiminde YZ literatürü ve uygulamasının anlık bir değerlendirmesi sunulmaya gayret edilecektir. Böyle bir teknolojinin aldatma karşısındaki gerçekliği nedir ve hâlihazırda neler yapılıyor? Belge yönetiminde Blade Runner tarzında ‘cevap veren’ belge yöneticilerinden çok uzak olsak da, belge yönetiminin tüm alanları için YZ mi yoksa aldatmacanın arkasında bir gerçeklik mi var?

Bu makalenin geri kalanı aşağıdaki gibi düzenlenmiştir. Öncelikle YZ tekniklerinin doğasına ve belge yönetimi çalışmalarıyla ilgili özelliklerine kısa bir giriş yapılacaktır. Ardından Avustralya kurumlarında yer alan YZ ile ilgili az sayıda güncel projeye genel bakış sunulacaktır. Son olarak, belge yönetimi çalışmalarında YZ teknolojilerinin kullanımına ilişkin kısa ve daha uzun vadeli tahminler hakkında bazı önerilerle sonuçlandırılacaktır.

Ama önce, YZ terimiyle ne demek isteniyor ve bilgi yöneticileri olarak mesleğimize ne gibi olanaklar getiriyor?

YZ Türleri: Uzman Sistemlerden Derin Öğrenmeye

YZ bilgi hesaplamasının ilk günlerinden beri (aslında insan bilgisinin çalışmasını otomatikleştirmeye yardımcı olan teknolojilere daha geniş bir bakış açısıyla

bakarsak, daha eski zamanlardan beri)⁽¹⁴⁾ zaman içinde gelişmiştir, ancak sürekli değişen doğası nedeniyle kolay tanımlamaya meydana okur. Sorunun bir kısmı da ‘insanlar bu teknolojiye alışkın hale gelir, YZ olarak görmeyi bırakır ve daha yeni teknolojiler ortaya çıkar’ şeklindedir.⁽¹⁵⁾ Bu devam eden karışıklık bir anlamda YZ'nin ‘YZ insanların yaptığı şeyler olarak görülmesiyle sonuçlanır’ anlamına gelir.⁽¹⁶⁾ Bu makalenin amaçları doğrultusunda YZ'yi ‘karar verme, problem çözme, öğrenme [ve] oluşturma gibi insan düşüncesiyle ilişkilendirilen faaliyetleri’ otomatikleştiren veya bunlara yardımcı olan dijital sistemler olarak kabul ediyoruz.⁽¹⁷⁾ Aslında YZ ile ilgili olarak ‘ölçek, hız, özerklik derecesi ve genellemeden oluşan [kapsayan] bir dizi otomasyon tekniği ve teknolojisini kapsayan çok boyutlu bir çeşitlilikte’ geniş bir görüşe sahibiz.⁽¹⁸⁾

Ayrıca, birçok teknoloji alanı gibi, YZ alanı da kendine has bir jargona sahiptir: uzman sistemler, kural motorları, makine öğrenimi, derin öğrenme, sinir ağları – liste devam eder. Ayrıca bu teknolojilerin etkinliği ve statüsü hakkındaki karışık; çeşitli teknikler ve teknolojiler gözden düşüp, yeniden keşfedildikçe, iniş çıkışlar (dolayısıyla araştırma finansmanı, geliştirme ve uygulama) ile aldatmaca döngülerinin⁽¹⁹⁾ art arda gelmesiyle şiddetlenir.⁽²⁰⁾ Bu bölümde, belge yönetimi gibi bilgi çalışmaları için bu teknolojiler ve teknikler perspektif olarak ele alınmaya çalışılacaktır. Bunu yapmanın bir yolu da, alan uzmanlığı ve otomatik bir sistemde somutlaştırılan bilginin derecesini ve biçiminin dikkate alınmasıdır. Böyle bir taksonomi; kural tabanlı sistemleri, istatistiksel modeli ve derin öğrenme sistemlerini kapsar. Çeşitli YZ tekniklerini anlamak için yararlı bir sınıflandırma olsa da gerçek dünya uygulamalarının çeşitli hibrit kombinasyonlarda bu tekniklerden birini içerebileceğine dikkat edilmelidir. Bu nedenle aşağıda kısa ve basitleştirilmiş bir şekilde açıklanmaya çalışılmıştır.

Kural-Tabanlı Sistemler

Özünde kural tabanlı bir sistem, alan uzmanı bilgisini ve bu bilginin karşılaşılabilecek durumlarda uygulanabileceği bir çalışma sisteminde dışsallaştırılmasını ifade eder.⁽²¹⁾ Kural tabanlı sistemlere, alan uzmanlığının ortaya çıkarılmasına ve eklenmesine dayandığı için bazen uzman sistemler de denir. Örneğin; arşiv uzmanlarının arşivsel değerlendirme tecrübelerinin kullanıldığı otonom bir elektronik iletişim (değerlendirme, ayıklama, tasfiye) sürecini yürüten bir uzman sistem kullanılmıştır.⁽²²⁾

Kurallar basit olabilir ‘Eğer öyleyse, bunu yap’ işlemsel ifadeleri, yeni girdi verileri ile sunulduğunda algoritmik olarak çalıştırılabilir. Aslında bir dizi belge arama terimi (‘bunu yap’ ifadesinin olduğu yerde ‘arama sonuçlarına uygula’) özellikle böyle bir arama kaydedilmişse ve sonuçları filtrelemek için rutin olarak kullanılıyorsa bu durumu önemsiz olarak kabul edebilir. Çünkü daha önce yapılan kaydedilmiş bir işlemde arama sonuçları tekrarlanmaktadır. Daha karmaşık sistemler, bilgi tabanı olarak adlandırılan olguları ve formel kuralları içeren bildirimsel ifade kümelerini içerebilir. Böyle bir bilgi tabanı daha sonra yeni olgulara dayalı kararlar veya çıktılara ulaşmak için bir çıkarım motoru aracılığıyla yeni vakalara uygulanabilir.⁽²³⁾

Kural tabanlı sistemlerin bir diğer özelliği de, dahili işlemlerin denetimini basitleştirmesidir. Bir karar veya çıktı sorgulanırsa veya yanlış olduğu belirlenirse, belirli bir girdi için kuralların ve olguların uygulanması izlenebilir. Hatalı olduğu tespit edilirse, gerektiği takdirde bilgi tabanı değiştirilebilir. Bu imkân, sistemlerin geliştirilmesine, hatalarının ayıklanmasına ve işlem sonuçlarının sonradan doğrulanmasına yardımcı olur.

Bununla birlikte kural tabanlı sistemler, 'öngörülemeyen ve uzmanlık alanlarının kısmen dışında kalan sorunlar çok başarısız olma' eğiliminde olabilir.⁽²⁴⁾ Koşullar değiştiğinde, bir bilgi tabanındaki kurallar ve/veya olgular gözden geçirilmeli veya yeniden yazılmalıdır. Bir uzman sistem, alan uzmanları ve uzman sistemde yetkin kişilerle birlikte oluşturulduğundan; bir bağlam için geliştirilmiş olan mevcut kural motorunu hedeflenen alana uyarlaması zaman alıcı ve pahalı bir uygulama olabilir. Bu kırılabilirliğin nedeni bilgi tabanına ek olgular ve çıkarım çıktıları eklense bile kural tabanlı sistemlerin kendi başına öğrenememesidir. Bu nedenle YZ'nin odağı bilgiyi biçimlendiren mekanizmalardan istatistiksel modeller ve derin öğrenme ağlarını içeren çeşitli makine öğrenimi tekniklerine kaymıştır.⁽²⁵⁾ Yine de iyi tanımlanmış kurallar ve/veya yavaşça değişen ortamlar olsa da bugün kural tabanlı uzman sistemler kullanılmaktadır.

İstatistiksel Modeller

Alan uzmanlığını ifade eden içine gömülü kodlama kurallarından ziyade, alternatif bir yaklaşım olarak girdi verilerindeki örüntüleri ve bu örüntülerin istenilen çıktılara eşlenmesini belirlemektir.⁽²⁶⁾ Yeterli sayıda nitelikli örnek verildiğinde, girdi ve çıktılar arasında istatistiksel bir ilişki geliştirilebilir ve bu istatistiksel model daha sonra yeni girdilere uygulanabilir. Girdilerin istatistiksel analiz için uygun bir şekilde temsil edilmesi, makine öğrenimi tasarımının temelini oluşturur; bir girdiden tanımlanan her bilgi parçası, bir özellik olarak bilinir ve bir dizi özellik, bir özellik vektörü olarak kabul edilir. Makine öğrenimi algoritmalarının geliştirilmesinde temsil tercihi ve özelliklerin seçimi, önemli bir görevdir. Örneğin, görüntü işlemede, özelliklerin tek veya piksel gruplarının (renk, parlaklık vb. veya daha yüksek bir ayrıntı düzeyinde, kenarlar ve şekiller vb.) özellikleri olması muhtemeldir. Belge analizinde sistem özellikleri, belirli kelimelerin, cümlelerin veya diğer dil bilgisi unsurlarının varlığını, göreceli konumlarını ve üst veri unsurlarını içerebilir. Tıbbî teşhislerde özellikler, semptom veya patolojilerin var olup olmasını içerebilir.

Böylelikle, bu tür istatistiksel modellerin görüntüleri, belgeleri veya tıbbî durumları tek başına 'anlayamadığı' vurgulanmalıdır. Daha doğrusu veriler, girdi görüntüsünü, belgeyi veya tıbbî vakayı istatistiksel yorumlamaya uygun bir dizi (sayısal) özellik olarak uygun karşılığa dönüştürmek için önceden işlenir.⁽²⁷⁾ Ayrıca, makine öğrenimi algoritması terimi kural tabanlı sistemlerde olduğu gibi, çıktılar tarafından türetilmiş herhangi bir anlamsal diziden çok özelliklerin istatistiksel model tarafından yorumlanması ile ilgilidir. Belirli bir çıktının nedenlerini araştırmak, modelin büyük ölçüde sayısal işlemeyle ilgili olan hesaplama mantığını takip


etmekten ziyade özelliklerin modele nasıl katkıda bulunduğunun anlaşılmasını içerir.

Makine öğrenimi; sınıflama, transkripsiyon (örneğin konuşmadan metne dönüştürme, optik karakter tanıma), çeviri, tahmin, anomali tespiti, anlamsız veri/aykırı değer azaltma ve yeni vakaların sentezi dahil olmak üzere bir dizi problem türü için kullanılabilir.⁽²⁸⁾ Sınıflama – belki de bugün belge yönetimi bilgisi çalışmasının en çok ilgilendiği görev – bir girdi durumuna olası sınıflamalardan hangisinin uygulanacağını belirlemeyi amaçlar. Böyle bir sınıflama ikili (örneğin, SPAM'dır/değildir, tıbbî prosedür uygulamak/uygulamamak, belgeyi muhafaza/imha etme) 1/N sınıfları veya çok değerli (örneğin, çalışma X konusundadır, belge M programı kapsamındadır, görüntü A, B ve C öğelerini içerir) olabilir.⁽²⁹⁾

Bu tür modellerde kullanılan gerçek istatistiksel mekanizmalar bu makalenin kapsamı dışındadır, ancak kavramsal olarak Şekil 1 (a) örneğinde gösterildiği gibi veri noktalarına uygun bir çizgi alıştırmasına benzerler, bundan dolayı matematiksel yöntemler, verilere en uygun formülün belirlenmesi için kullanılır. Modelin analiz ve inşası için makine öğrenmesi algoritmasına örnek veri sunulması, *eğitim* olarak adlandırılır. Bu örnekte, her bir eğitim veri noktası iki özellik ile ilgilidir (örneğin x ve y) ve elde edilen formül, yeni bir x girişi için “en iyi” y değeri sağlayabilen bir doğrusal ilişkidir. Aslında, genellikle ikiden fazla boyut vardır: özellik vektörü çok daha büyük, matematiksel ve daha karmaşık olmaktadır.

Örnek veri, hedef çıktıyı içeriyorsa algoritmanın ‘en uygun formülünü’ belirleyebilir – örneğin bir dizi belgeden ve ilişkili sınıflama terimlerinden türetilen özellik vektörü – bu durumda eğitim denetimli olarak adlandırılır.⁽³⁰⁾ Makine öğrenimi algoritmasının amacı, girdilerin hedef sonuçlarla nasıl eşleştirileceğini öğrenmektir. Bir defa eğitildikten sonra sistem – yeni bir vaka sunulduğunda bir özellik vektörü olarak temsil edilir – bu yeni sayısal verilere karşı eğitim sırasında geliştirilen ‘formülü’ çalıştırır ve sonrasında sonucu tekrar eşleşen hedef sonuca çevirir, yeni bir belgeyi eğitim verilerinde kullanılmış sınıflamalarla eşleştirmek örnek olarak gösterilebilir.

Farklı türde bir problem, özellikle her girdi birçok özellik içeriyorsa girdi verilerinin yapısal özelliklerinin modellenmesiyle ilgilidir. Bu durumda, örnek veriler hedef sonuçlarla etiketlenmez ve bu tür öğrenme denetimsiz olarak adlandırılır.⁽³¹⁾



Şekil 1. Matematiksel formülleri veri noktalarına yerleştirme örnekleri

Denetimsiz öğrenmeye verilebilecek örnek konu modellemedir, bundan dolayı girdi belgelerinin özellikleri daha sonra standart bir terim sözlüğüne göre konular olarak yorumlanan benzer metin kümelerini ayırt etmek için analiz edilir. Şekil 1 (b) örneğinde, iki boyutlu eğitim veri noktalarının kümelerini ayırt etmek için matematiksel teknikler kullanır. Bununla birlikte gerçek hayatta, özellik vektörleri ikiden fazla boyuta sahiptir.

Bu tür sistemlerin en uç noktaların biri, Jeopardy⁽³³⁾ bilgi yarışması oyununu oynamak (ve kazanmak) ansiklopediler, sözlükler, kavramsal dizinler, çevrimiçi dergi makaleleri, edebi eserler vb. dahi olmak üzere 600.000 kaynaktan 200 milyondan daha fazla sayfanın yüklendiği IBM Watson'dur.⁽³²⁾

İstatistiksel modellerle, ilk olarak uygun bir temsil ve özellik setinin tanımlanması ve sonrasında uygun eğitim verisinin hazırlanması yoluyla alan uzmanlığı somutlaştırılır. Özel görev ve problem alanıyla ilgili nitelikli eğitim verilerinin hazırlanması (ister denetimli ister denetimsiz), model oluşturmak için eğitim sırasında gerekli olan özellik ağırlıklarının ve diğer parametrelerin yinelemeli işlenmesi ve ayarlanması ile birlikte, bir makine öğrenimi uygulaması geliştirme çabasının ve maliyetinin önemli bir parçasıdır. Öte yandan, istatistiksel modellerin geliştirilmesi, hatalarının ayıklanması ve sorgulanması daha zor olsa da, belirli bir veriden elde edilen sonuçların güvenli olarak raporlanması için yapısal bir yararlılık sağlamaktadır. Örneğin çıktılar, sonuçların anlamının veya ilgililiğinin daha iyi anlaşılmasına katkıda bulunan bir doğruluk tahmini ile birlikte sıralanmış kararları veya sınıflandırmaları içerebilir. Bu, aşağıda daha ayrıntılı olarak ele alınmıştır.

Derin Öğrenme Modelleri

Makine öğrenimindeki zorluklardan biri, sonuçları doğrudan etkileyen özelliklerin belirlenmesidir. Genellikle, bu tür özellikler doğrudan ham verilerde bulunmaz, ancak daha yüksek seviyeli soyutlamalardır. Örneğin yüz tanıma, bir görüntüdeki tekil piksellerin doğasına değil göz rengi ve ayırımı, çene çizgisi açısı ve daha başka özelliklere bağlıdır. Bu tür özelliklerin manuel olarak tanımlanması, özetlenmesi ve ağırlıklandırılması – özellikle de görüntüler veya belgeler⁽³⁵⁾ gibi oldukça değişken girdi verileriyle uğraşırken alan uzmanları için bile çok zor⁽³⁴⁾ olabilir. Örnek verilere⁽³⁶⁾ dayalı örüntüleri sınıflandırmak için tasarlanmış derin öğrenme sistemleri, ham verilerden (örneğin bir görüntüdeki piksellerden veya bir belgedeki sözcüklerden) anlamlar çıkararak bu sorunu çözer.

Derin öğrenme sistemleri, işlemleri alt katmanda daha basit ve daha yüksek mertebeden özellikleri soyutlayan çok sayıda birbirine yüksek düzeyde bağlı katmanlar aracılığıyla yürütür, aslında verilerden ayırt edilebilecek soyut veya karmaşık özellikler öğrenir. Derin öğrenme sistemleri, genellikle sinir ağı (beynin yüksek düzeyde birbirine bağlı nöron yapısına benzerliklerinden dolayı) olarak adlandırılan yapıları kullanır. Örneğin basit bir derin öğrenme sinir ağı modeli, piksel dizisi olarak girdiye, piksellerin belirlenen kenarlarını algılayan bir birinci katmana, belirlenen köşe ve konturları algılayan ikinci bir katmana, belirlenen köşe ve kontur şekillerini tanıyan üçüncü bir katmana ve nesnelere etiketleyen bir çıktı

katmanına sahip olabilir.⁽³⁷⁾ Derin öğrenme, çok çeşitli alanlardaki sorunları çözmeye oldukça başarılı olmuştur.⁽³⁸⁾ Örneğin, Google yakın zamanda internet arama hizmetine mevcut kural ve istatistiksel tabanlı modellerin yanı sıra derin öğrenme algoritmalarını da eklemiş ve önceki YZ'den sorumlu başkanını arama bölümünün başına getirmiştir.⁽³⁹⁾ Buna karşın derin öğrenme yaklaşımlarının dezavantajları da vardır. İstatistiksel modellerde olduğu gibi, derin öğrenmede de alan uzmanlığının uygulanması, kaliteli eğitim verilerinin hazırlanmasına ve modelleri ayarlamak için derin öğrenme uzmanlarıyla çalışılmasına bağlıdır. Derin öğrenme modellerinin eğitimi, istatistiksel modellerde olduğu gibi denetimli veya denetimsiz olabilir, ancak derin öğrenme, istatistiksel modellerden daha fazla eğitim verisini gerektirir. Örneğin, 2016'da 'genel bir ifade ile denetimli bir derin öğrenme algoritmasının kategori başına yaklaşık 5.000 etiketli örnek ile kabul edilebilir bir performansa ulaşacağı ve en az 10 milyon etiketli örnek içeren bir veri kümesiyle eğitildiğinde insan performansı ile eşleşeceği veya onu aşacağı' rapor edilmiştir.⁽⁴⁰⁾ Google Street View'in cadde numaralarını tanıması başlangıçta 200.000 görüntüden oluşan bir küme ile deneyimlenmiştir.⁽⁴¹⁾ Derin öğrenme modelinin doğruluk seviyesi, eğitim setlerinin 1 milyondan 300 milyona yükseltilmesiyle daha da artmaktadır.⁽⁴²⁾

Ancak derin öğrenme sistemlerini şeffaf olmamaları nedeniyle diğer otomasyon türlerine göre geliştirmek, ayarlamak ve hata ayıklaması yapmak daha zor olabilir. Derin öğrenme sistemlerinin⁽⁴³⁾ sürekli artan katman (yüzlerce) ve düğüm (milyonlarca) sayısı, karmaşık iç bağlantıları ve parametreleri ile birlikte, yorumlaması zor işlere sahip 'kara kutu' sistemler ile sonuçlanmaktadır.⁽⁴⁴⁾ Derin öğrenme sistemlerinin başarısına ve yaygınlığına rağmen, bu önemli konunun; sosyal, metodolojik ve teknolojik bakış açısı ile etkileri yavaş yavaş ele alınıyor.⁽⁴⁵⁾ Daha da büyük bir sorun, çağdaş derin öğrenme sistemlerinin, özellikle metinsel verilerle uğraşırken çok kırılabilir olabilmeleridir.⁽⁴⁶⁾ Ancak araştırmalar, yeterli eğitim verisi örneği verildiğinde, bu ikinci sorunun zaman içinde çözülebileceğini öngörmektedir.⁽⁴⁷⁾

YZ'yi Belge Yönetimine Uygulama

YZ teknikleri, yukarıdaki taksonomi göz önüne alındığında, belge yönetimi bilgi çalışmasına nasıl uygulanabilir? YZ sistemleri, sınıflama ve imha gibi süreçleri otomatikleştirme potansiyeline sahiptir ve bu alanda bazı akademik araştırmalar yapılmıştır.⁽⁴⁸⁾ Bir EDBYS içinde belge kapatma zamanlamasını otomatikleştirmek için basit kural tabanlı tetikleyiciler kullanılabilir.⁽⁴⁹⁾ Dijital beşeri bilimlerde metinsel sınıflama ve analiz için daha karmaşık YZ'ler kullanılmaktadır, örneğin Cinsel İstismarı Soruşturma Komisyonu'nun Irish Ryan Report'u keşfetmek için yapılan çalışma.⁽⁵⁰⁾ Ayrıca, belge yönetimi bilgi çalışmasını geliştirmeyi amaçlayan otomatik sınıflandırma gibi makine öğrenimini kullanan ticari belge yönetimi ürünleri de mevcuttur.⁽⁵¹⁾ Belgeleri aktarırken değerlendirme, seçim ve duyarlılık incelemesi süreçlerinde doğuştan dijital belge koleksiyonlarına yardımcı olabilecek teknolojinin araştırılmasıyla ilgili Birleşik Krallık Ulusal Arşivleri tarafından dikkate değer bir girişim rapor edilmiştir. Bu girişim, eDiscovery araçlarına (dava amacıyla dijital bilgilerin keşfedilmesi veya ifşa edilmesi için tasarlanmış yazılım)

odaklanmıştır.⁽⁵²⁾ Rapor, eDiscovery yazılımının dijital transferlerin bir parçası olarak değerlendirme, seçim ve duyarlılık incelemesi sırasında kamu kurumlarını destekleyeceği ve yardımcı olabileceğini sonucuna varmaktadır. Fakat bu örneklerin ötesinde literatür temeli oldukça zayıf ve birkaç örnek vardır. Belge yönetimi alanında YZ kullanımının önündeki engeller aşağıdaki gibi açıklanabilir:

- Zorlayıcı vaka çalışmalarının eksikliği belki de bu aldatma döngüsü etkisidir, ancak yorumlar çok⁽⁵³⁾ olsa da akademik veya mesleki literatürde gerçek dünyadan çok sayıda örnek yoktur.
- Makine öğrenimi çözümlerini yapılandırmak için gereken maliyet ve zaman özellikle zaman içinde değişiklikler meydana geldikçe büyük, açık ve etiketli eğitim ve veri setleri geliştirmek (eğitildikten sonra sistemler, üretimde uygulanmadan önce farklı veriler üzerinde test edilmeye ihtiyaç duyar).⁽⁵⁴⁾ Büyük veri kümelerine ve yeterli hesaplama kaynaklarına duyulan gereksinim, daha küçük kuruluşlarda engel teşkil edebilir.
- Muhafaza ve imha yetkilileri gibi karmaşık, insana yönelik becerileri teknolojiye entegre etmenin zorluğu. Bu yetkileri muhafaza ve imha etmek amacıyla karar belgelerine uyguladığımızda, belgelerin içeriğini ve ilişkili bağlamlarını bilmek önemlidir.⁽⁵⁵⁾ Bazı belge grupları, bir belge sınıfında yer alan 'önemli' veya 'asıl' belgenin ne olduğunu deşifre etmeye ihtiyaç duyar. Ceza/mahkeme kayıtlarında sağduyu da bir etkenidir. Muhafaza ve imha süreçleri genellikle tarafsız biçimde yazılmıştır, ancak gerçekten öyleler mi?⁽⁵⁶⁾
- Dosyalar, seriler, koleksiyonlar ve kurumlar arasında belge yönetimi verilerinin (ve üst verilerinin) otomasyon girişimlerinin geliştirilmesinde zorluklar ortaya çıkaran heterojenliği (aşağıya bakın).

'Veriye erişim, alan uzmanlığına erişim ve algoritmaları geliştiren veri bilimcilerine erişimi birleştiren uygun bir makine öğrenimi uygulaması oluşturulduysa',⁽⁵⁷⁾ alanımızda çok fazla ilerleme olmaması şaşırtıcı olmayabilir. Belge yöneten kurumlar, YZ eğitimi için ayıklanmamış ve etiketlenmemiş doğru verilere sahip olsa da belki de eksik olan veri bilimi sektörüyle doğrudan bağlantıdır.

Doğru Sorular Sormak

Bir diğer sorun, doğru soruları sormanın zorluğu olabilir; sistem gereksinimlerini YZ'nin çözümüne uygun bir şekilde tanımlamak. Bir an için değerlendirme/karar verme süreci için 'basit' bir ikili sınıflandırmayı düşünün – muhafaza etmek mi yoksa imha etmek mi? Belge bağlamının⁽⁵⁸⁾ anlaşılmasını otomatikleştirmek, karmaşık bir durum olması sebebiyle, belki de en kolay olumsuz soru sormaktır: tamamen değeri olmayan belge nedir? Sorunun olumlu versiyonunu yanıtlamak için bağlamın değerlendirilmesini, bir temsil olarak çerçevelemek-1980'lerdeki İran/Kontra skandalındaki iki kelimelik 'well done' (aferin) e-postası örneği alındığında- daha zordur.⁽⁵⁹⁾

Ayrıca bir de belirtilen kırılma durumu var. Bedava öğle yemeği yok teoremi¹, mevcut YZ modellerinin⁽⁶⁰⁾ taşınabilirliğini, hatta görünürde benzer veri kümelerinin bile sınırlarını ifade ediyor. Google tarafından Afro-Amerikalıların görüntülerine atanan etiketler veya Microsoft ve Facebook tarafından atanan cinsiyetçi etiketler, rahatsızlık verici, önyargılı ve hatalı görüntü eğitim verilerinin olumsuz örnekleri arasında yer almaktadır.⁽⁶¹⁾ Bir bağlam için geliştirilen ikili bir sınıflandırıcı YZ modeli bile başka bir alana uygulanamayabilir (yakın olsa bile), anlam kayması veya bağlamda yapılacak anlaşılması zor değişikliklere maruz kalındığında, ortaya çıkan varsayımlar, önyargılar veya hatalar için hazırlıklı olunması gerekir.⁽⁶²⁾

Materyalin 1/N sınıflar içinde sınıflandırılması (örneğin program sınıf kimlikleri) daha karmaşıktır.⁽⁶³⁾ Bazı doğal dil işleme (NLP/DDİ) çalışmaları, kurumları ilgilendiren 'metinlerde ilgi çekici özellikler hakkında rapor oluşturmak, analiz etmek, özünü çıkartmak için kuruma özgü yazılım geliştirmeyi' amaçlayan Bitcurator-DDİ projesinin bir parçası olarak yapılmıştır.⁽⁶⁴⁾ Benzer şekilde, oldukça kısıtlı bilgi kaynaklarından basit bibliyografik üst verilerin özetlenmesi üzerine bazı çalışmalar da yapılmıştır.⁽⁶⁵⁾ Bununla birlikte, duyarlı, dinamik belgeler, karar verme ve erişim için belge yönetimi üst verilerinin oluşturulması, hala temel YZ araştırması alanında kalan karmaşık, birbirine bağımlı, çok aşamalı, derin öğrenme algoritmalarını gerektirebilir.

Bulut Hizmetleri

Kural motorlarından derin öğrenme sinir ağlarına kadar YZ geliştirme ve uygulama için ücretsiz olarak kullanılabilen araçlar, motorlar ve sistemler olsa da YZ çözümlerinin donanım gereksinimleri kurumsal kullanım için uygun olmayabilir. Uygulamaya bağlı olarak, çalıştırma süresi donanım gereksinimleri oldukça verimli olabilir (örneğin, kameralı telefonlardaki yüz tanıma özelliği), ancak sistemin eğitimi, özellikle derin öğrenme sistemlerinde önemli kaynaklar gerektirebilir. Örneğin, Facebook'u çalıştıran motorlardan ve Google'ın hizmetlerinin yanı sıra 2880 çekirdekli ve 16 TB RAM'e⁽⁶⁶⁾ sahip 10 rafta 90 sunucudan oluşan IBM'in Watson gibi sistemleri var. Tabii ki, daha az işlem daha az hesaplama gücü gerektirir. İlginçtir ki masaüstü hatta taşınabilir bilgisayarlarda (örneğin oyun, animasyon veya video efektleri için) yoğun grafik işlemeyi desteklemek için geliştirilen grafik işlem birimi (GPU) donanımının türü, paralel matematiksel işlemler yapma kabiliyeti nedeniyle YZ iş yüklerine uygulanabilir.⁽⁶⁷⁾ Bu tür donanımların fiyatlarının uygun oluşu kolay erişilebilmesi, YZ tekniklerinin kabul edilebilir performans ve sonuçlar için gerekli ölçekte uygun maliyetli olarak ulaşılabileceği anlamına geliyordu.

Bununla birlikte, özellikle derin öğrenme durumunda kurumlar veri yönetimi için bazı riskleri olsa da (aşağıdaki NSW Eyalet Arşivleri vaka çalışmasına

¹ Genellikle NFL veya NFLT olarak kısaltılan teori, performanslarının tüm olası amaç fonksiyonlarının ortalaması alındığında optimizasyon algoritmalarının eşit derecede iyi performans gösterdiğini öne süren teorik bir bulgudur. Bk. <https://machinelearningmastery.com/no-free-lunch-theorem-for-machine-learning/>

bakın) YZ sistemleri geliştirmek ve kullanmak için bulut tabanlı platformlardan yararlanmayı tercih edebilir. Google, Microsoft, Amazon, IBM, Oracle gibi daha büyük bulut hizmetleri sağlayıcılarının çoğu bir dizi fiyatlandırma ve performans seçenekleri ile bulut-bilişim hizmetlerinin bir parçası olarak YZ geliştirme ve dağıtım platformlarını da sağlamaktadır. Müşteri odaklı pazarlar için isteğe özel hazırlanmış platformlar sağlayan bir dizi rakip start-up da vardır.

Ölçüm Sonuçları

Son olarak, bir YZ girişiminin başarısının (veya başarısızlığının) ölçülebileceği yollar tartışmaya değerdir. Belki de en basit ölçüm bir doğruluk metriğidir, örneğin: ‘insan (kararlarıyla) ile karşılaştırıldığında YZ'nin yapmış olduğu tespitler %85 oranında doğrudur’. Böyle bir metrik, sonuçların ölçümünden elde edilebilir olmalıdır. İnsan doğruluk oranlarının nadiren %10068 olduğunu ve bu nedenle gerçek dünyadaki insan performansına göre bilinen gerçekçi doğruluk eşiğinin YZ sistemi tasarımı ve/veya değerlendirmesinin temelini oluşturması gerektiği belirtmeye değerdir. Doğruluk (ve aslında aşağıda açıklanan diğer metrikler), eğitim kümesindeki veriler (modelin eğitim verilerine ne kadar iyi uyduğu) ve belirli bir test kümesindeki veriler (daha önce görmediği verilerle ne kadar iyi başa çıktığı) için belirlenmelidir.⁽⁶⁹⁾ Böyle bir doğruluk oranının nasıl belirlendiğini anlamak da önemlidir – özellikle Tip I (yanlış pozitif) ve Tip II (yanlış negatif) hataların oranı.⁽⁷⁰⁾ Belki de belge yönetiminde, neyin korunacağını/saklanacağını belirlerken, Tip I hata (yani, gerekmediği halde tutulan bir belge), Tip II hatadan (yani, gerekli bir belge imha edilmesi)⁽⁷¹⁾ daha az endişe vericidir ve bu sebeple her iki durum için de doğruluk ölçümleri rapor edilmelidir. Bilgiye erişimden elde edilen metrikler, hassas ölçü (‘doğru’ olan geri dönen sonuçların oranı) ve geri çağırma (geri dönen ‘doğru’ sonuçların oranı)⁽⁷²⁾ oranları sistemin ne kadar iyi performans gösterdiğine dair fikir verebilecektir.⁽⁷³⁾ Bazen bu hassas ölçü ve geri çağırma ölçümlerinin ortalaması (harmonik ortalama) F1 skoru olarak ifade edilir.

Ayrıca, birçok istatistiksel (ve bazı derin öğrenme) algoritmalar, çıktılarının güven düzeylerini sağlayabilir. İstatistiksel algoritmalar, mutlak sayılardan ziyade, bir kapsam göstergesi, hatırlama ve kesinlik sayılarıyla ilgili önlemlerin anlamı hakkında ek fikir verebilir. Kapsam, kabul edilebilir bir güven düzeyinde elde edilen kararların (veya çıktıların) oranı ile ilgilidir.⁽⁷⁴⁾ Örneğin, yukarıda açıklanan Google Street View projesi, %98 doğrulukta %95,64 kapsama elde etti (%98 insan operatörlerin performansıdır).⁽⁷⁵⁾ Sunulan seçenekler, çıktıların ve alternatiflerinin güven düzeyinin anlaşılmasına da yardımcı olabilir.⁽⁷⁶⁾

Avustralya Girişimleri

YZ'ye kısa bir arka plan ve onun belge yönetimi bilgi çalışmasına uygulanması için bazı değerlendirmeler yaptıktan sonra, bazı güncel girişimlerin vurgulandığı eyalet ve ulusal kurumlardan dört vaka çalışması sunulacaktır.

Viktorya Eyalet Arşivleri – Makine Destekli E-Posta Değerlendirmesi, Kavram Kanıtı

İlk vaka çalışması, Viktorya Eyalet Arşivleri'nin (PROV) e-posta değerlendirme sorununu nasıl ele aldığıyla ilgilidir. E-posta, kuruluşların nasıl fikir alışverişinde bulunduğu ve kararlarını nasıl uyguladıklarının anlaşılmasında önemli bir rol oynar. E-postanın hacmi ve yapılandırılmamış doğası yönetimini, ayıklanmasını ve duyarlılık incelemesini zorlaştırır. IBM Lotus Notes (LN), 1990'ların ortalarından beri Viktorya Hükûmeti genelinde e-postaları yönetmek için kullanılmaktadır. 20 yılı aşkın bir süredir yapılan rutin yedeklemeler, 67.000 kaset ve 28 petabayt² içerik yığını bir depolamaya neden olmuştur. Bu depolama bilgi taleplerine cevap vermek için artık verimli bir şekilde sorgulanamaz ve yerel hükûmetin şeffaflık ve hesap verebilirlik konusundaki itibarını tehlikeye atabilir.

Yaklaşım – eDiscovery

Kavram Kanıtı (PoC) projesinin amacı, büyük hacimli e-postaları değerlendirmek için bir eDiscovery aracının kullanımını ortaya koymaktır. eDiscovery araçları, 'bir koleksiyondaki ilişkili belgelerin mümkün olduğunca mantıklı bir çabayla bulmak amacıyla' çeşitli kural tabanlı, istatistiksel modeller ve derin öğrenme teknikleri kullanarak yasal açıdan belgelerin Teknoloji Destekli Gözden Geçirilmesini gerçekleştirmek için kullanılmaktadır.⁽⁷⁷⁾ Bu, daha önce açıklanan ikili sınıflandırmanın bir örneğidir.

eDiscovery yaklaşımları, belge yönetimi bağlamında başka yerlerde kullanılmış olsa da PoC, Nuix aracı,⁽⁷⁸⁾ veri hacmi (1,5 TB) ve e-posta dosya biçimine odaklanması bakımından benzersizdi. Teknik bir danışman ile işbirliği, eDiscovery aracının işlevselliğini uygulama ve yapılandırmada gerekli becerileri kazanmak için de hayati önem taşıyordu. Minimum personel ve programlama giderleri ile 6 aydan fazla süren bu ilk aşama ile yaklaşım tekrarlanması gerekirdi.

Normların dışında Nuix şunları yapmak için kullanıldı:

- teknik değerlendirme, veri setinin bileşimini daha iyi anlamak (sorumlular, format, hacim, oluşturma tarihi vb.); ve
- tekilleştirme, aynı e-postaları etiketlemek için bir MD5 karma uygulaması (veri kümesindeki 4,6 milyon e-postanın yaklaşık %40'ının kopya olduğu bulundu).⁽⁷⁹⁾

Muhafaza etmeye değer e-postaları bulmak için veri kümesinde Nuix ile uygulanan üç yaklaşım test edildi:

- (1) Pozitif – değerli e-postaları belirlemek için. Arama terimleri aşağıdakileri içerir:
 - (a) paydaş kurumların rol tanımları;
 - (b) eylem fiilleri/nesneleri ve
 - (c) fonksiyon/eylem terimleri.

² 1 Petabayt, 1024 Terabayt; 1 Terabayt 1024 gigabayttan oluşmaktadır.

- (2) Negatif – düşük değerli e-postaları belirlemek için:
 - (a) İlişkili olmayan adreslerden ve alanlardan gelen e-postalar hariç tutuldu.
- (3) Makro – e-posta oluşturucularının rollerini anlamak için organizasyon şemalarını kullanarak, fonksiyonel bağlamlarına göre e-postalara ek üst verileri değerlendirmek ve uygulamak.

Pozitif yaklaşım, yinelenen e-postaların %93'ünün iş ile ilgili belgeler olduğunu belirledi (birçok yanlış pozitif e-posta olmasına rağmen). Negatif yaklaşım, e-postaların %7'sini belge olmadığını belirlemiştir, bu durum muhtemelen negatif durumun yüksek hassasiyete sahip olduğunu ancak negatif durumun daha düşük hatırlandığını gösterir.

Sonuçlar

Proje ekibi, en düşük risk/en yüksek fayda yaklaşımının aşağıdakileri içeren çok katmanlı bir yaklaşım olduğu sonucuna varmıştır:

- e-posta hacmini azaltmak için tekilleştirme;
- değeri olmayan e-postaların Negatif yaklaşımla belirlenmesi ve
- makro yaklaşımının bir parçası olarak ek üst verilerin tanımlanması ve uygulanması.

PoC, Nuix eDiscovery aracının değerlendirme için PROV tarafından analiz edilmiş olması gereken e-posta hacminin etkin bir biçimde düşürmek için kullanılabilir olduğunu kanıtlamıştır. Ayrıca, teknoloji destekli bir iş akışının, geçmiş LN dosya formatları ve yedeklemeleri içinde işlenmesi zor olan e-postanın yönetilebilirliğini ve keşfedilebilirliğini geliştirebileceğini de göstermiştir.

Araç ayrıca değerlendirme görevlerini yerine getirmek, hassas ve korumalı bilgilerin varlığını tespit etmek için de kullanılabilir. Ancak, tamamen otomatikleştirme bir çözüm değildir; Geleneksel değerlendirmede olduğu gibi, anlamlı ara-malar oluşturmak için iş ve fonksiyonlar hakkında bilgi sahibi olmak ve doğruluğu değerlendirmek için manuel örnekleme yapmak çok önemlidir. İleriye dönük olarak, daha fazla işin oluşmasını önlemek için bu araç periyodik olarak çalıştırılabilir; daha geniş bir belge yelpazesine, yani ortak sürücülere ve diğer veri havuzlarına uygulanabilir; ve değerlendirmeye yönelik daha otomatik YZ yaklaşımlarını keşfetmek için kullanılabilir.

New South Wales Eyalet Arşivleri ve Belgeleri

İkinci vaka çalışması, Dijital Arşiv ekibinin 2017 Kasım ve Aralık aylarında yürüttüğü New South Wales Eyalet Arşivleri (NSWSAR)'nin yerel pilot uygulamasının belgeleri.⁽⁸⁰⁾ Bu pilot uygulamanın amacı, kullanıma hazır makine-öğrenmesi yazılımını bir muhafaza ve imha yetkilisi karşısında yapılandırılmamış veri der-lemine sınıflama sorunlarının çözümlenebilmesiydi. Temel amaç, daha önce bir

imha yetkilisince geleneksel yöntemlerle karar verilmiş belge topluluğu üzerinde makine öğrenimi algoritmalarını test etmektir. Belge topluluğunu aynı imha sınıflarına otomatik olarak eşleştirmek için birden çok yönlü sınıflama, hangi doğruluk düzeyinde gerçekleştirilebilir?

Ön Kurulum

Yerel pilot uygulama, sınırlı kaynağa sahipti ve proje için özel bir bütçe yoktu. Ancak (ve ne mutlu ki) makine öğrenimi alanında yakın zamanda üniversite deneyimine sahip olan bir bilgi ve iletişim teknolojileri mezunu istihdam edildi ve pilot uygulamada uygun teknolojileri belirlemek için proje ekibi, düşük maliyetli, kullanıma hazır çözümleri araştırdı.

Bulunan ilk ürün, Microsoft Azure bulut tabanlı YZ ve Bilişsel Hizmetleriydi. Bu platform, önceden oluşturulmuş algoritmalara, sınıflandırıcılara ve harika bir arayüze sahiptir: ‘Makine Öğrenmesi Tezgâhı’. Bu seçenek çok umut verici görünse de nihayetinde platforma gönderilen verilerin saklanması ve yönetimiyle ilgili belirsizlikler nedeniyle iptal edilmek zorunda kaldı. Birçok Microsoft Azure hizmeti NSW’de yerel olarak mevcut olsa da YZ ve Bilişsel Hizmetler yalnızca açık sunucularda mevcuttu.⁽⁸¹⁾ İlginç bir şekilde, pilot uygulamanın gerçekleştirilmesinden bu yana Microsoft Azure Bilişsel Hizmetleri’nin sözleşme hüküm ve koşulları, diğer Azure depolama hizmetleriyle daha uyumlu ve kabul edilebilir bir biçimde güncellendi.

Ancak pilot uygulama sırasında bu koşullar, Eyalet Dışındaki Hizmet Sağlayıcılar tarafından Depolama ve Bakım Belgelerini NSW dışına aktarılması (GA35) gerekliliklerini karşılamak için bir risk analizinin gerekli olduğu anlamına geliyordu.⁽⁸²⁾ Bu analizde, hizmette depolanan belgelerin 1998 Eyalet Belgeleri Yasası (NSW) standartlara göre yönetilmesini sağlamak önemli bir adımdı. Ayrıca sözleşme düzenlemelerinin güvenlik incelemesinin yapmak, belgelerin mülkiyetinin eyalet tarafından tutulmasını sağlamak ve proje sonuçlandıktan sonra tüm belgelerin iade edilmesini sağlamak önemlidir. – bk. *NSW Dışındaki Hizmet Sağlayıcıları; Eyalet Belgelerinin Depolanması*.⁽⁸³⁾

Yerel pilot uygulama, Eyalet Arşivleri’ne devredilen erişime kapalı belgelerden oluşan bir derlem içerdiğinden ve proje için ayrılan zamanın daha ayrıntılı bir risk değerlendirmesini engellediğinden (bu, daha ayrıntılı bilgi için satıcıları takip etmeyi veya yasal tavsiye aramayı gerektiriyor olabilir), herhangi bir bulut tabanlı yazılımlara yönelik karar alamadı bunun yerine yerel ölçekte çalıştırılacak hazır yazılımlar aradı.

Proje, Python programlama dili için ücretsiz ve açık kaynaklı bir makine öğrenimi kitaplığı olan Scikit-learn⁽⁸⁴⁾ kullanılmasına hızla karar verdi. Bu, çok çeşitli kural tabanlı, istatistiksel modeller ve derin öğrenme algoritmaları sağlayan basit ve erişilebilir bir araç setidir. Microsoft’un Bilişsel Hizmetleri gibi, scikit-learn de önceden oluşturulmuş sınıflandırıcıları içerir. Bulut tabanlı hizmetlerden ayrılma kararı, çeşitli YZ test vakalarını eğitmek ve çalıştırmak için yeterli bilgi işlem gücü bulma sorusunu gündeme getirmiştir⁽⁸⁵⁾

Derlem³

Yerel pilot uygulama için seçilen belgeler, 2016 yılında merkezi bir kamu da-iresi tarafından Dijital Eyalet Arşivi'ne aktarılmıştır. Bu derlem, objektif bir ED-BYS'den çıkarılan eksiksiz kurumsal klasör yapısı içermesi bakımından olağan-dışıydı. Derlem 7561 klasördeki 42.653 dosyadan oluşan 30 GB'lik veriden oluş-maktaydı ve dosyalar için bir imha işlemi uygulanmamıştı. Kamu dairesi iş birliği ile derlem, Genel Muhafaza ve İmha Yetkilisi İdari Belgeleri'ne (GA28)⁽⁸⁶⁾ manuel olarak (klasör düzeyinde) karar verildi ve bu da Eyalet Arşivleri'nde toplam 12.369 dosyanın oluşmasına sebep oldu.

Yerel pilot uygulama için aşağıdaki seçenekler göz önünde bulundurulmuştur:

- GA28'den (toplam 75 klasör) Eyalet Arşivleri için gerekli sınıfların tü-münü uygulayın. Bu sınıflara uymayan klasörler tasnif dışı kalacaktır.
- Derlemde manuel olarak tanımlanmış (toplam 23 klasör) Eyalet Arşiv-leri için gerekli sınıfların alt kümesine uygulayın. Bu sınıflara uymayan klasörler derleminde dışında tutulacaktır.
- Tüm GA28 sınıflarını uygulayın (toplamda 686 klasör). Bu, tüm klasör-lerin tamamının bir testini gerektirir.
- Normal İdari Uygulama (NAP) kapsamında olacak, örneğin kopyalar veya resmi olmayan/özel belgeler gibi tüm klasörleri kaldırarak derle-mi ön işlemde geçirin.

Derlemi ön işleme tabi tutularak NAP kapsamında bulunan tüm klasörleri çıkarılmasına ve yalnızca 23 GA28 sınıfında yer alan Eyalet Arşivleri için gerekli 12.369 dosyanın alt kümesinin alınmasına karar verildi. Bu işlem için alt kümenin manuel olarak hazırlanması, sınıflandırmanın tek tek dosyalar düzeyinde klasör seviyesinden atanması gerekiyordu. Ayrıntılar için Tablo 1'e bakın.

Metin Ayıklama Adımları

Metin ayıklama. Analiz amacıyla seçilen belgelerin kullanılabilir olması için kolayca özetlenebilir olması gerekir. Özetlenebilir olması daha sonraki süreçte, metin manipülasyonunun uygulanabilme performansını ve kolaylığını sağlamak içindir. Eyalet Arşivleri için gerekli olarak sınıflandırılan 12.369 dosyadan sadece 8784'ü dosya türleri basit metin ayıklamaya olanak sağladığı için seçilebilmiştir

Tablo 1. NSW derleminin dökümü

Veri Kümesi	Dosya Nu.
Toplam derlem	42,653
NAP	25,643
Kurumsal Dosya Planı	17,307
Eyalet Arşivleri için Gerekli	12,369
Kullanılabilir örnek küme: Eyalet Arşivleri için Gerekli ve uygun format	8784

³ Dil bilimde ve günümüz doğal dil işleme çalışmalarında corpus (derlem) kelimesi ile kastedilen, çok sayıdaki metnin düzenli ve yapısal olarak bir arada bulunmasıdır. Bk. <https://bilgisayarkavramlari.com/>

Örnek kümeyi sıraladıktan sonra PDF, DOCX ve DOC dosya türlerinden metin ayıklamak için çeşitli kütüphaneleri kullanan bir Python programı geliştirildi. Belgelerden özetlenen metin daha sonra Virgüllerden Ayrılmış Değer (CSV) dosyasına yerleştirildi. CSV dosyası dosya adı (benzersiz tanımlayıcı), sınıflama (GA28 sınıfı) ve son olarak metin ayıklama olarak üç sütuna bölündü.

Veri temizleme. Veri temizlemede temel bir yaklaşım esas alındı. Sırasıyla filtreler uygulandı: belge biçimlendirmesinin kaldırılması; gereksiz kelimelerin çıkarılması; gerekli olmayan belgelerin kaldırılması ve tüm harflerin küçük harfe dönüştürülmesi.

Metin vektörleştirme ve özellik çıkarma. Metin vektörleştirme, metni sayısal özellik vektörlerine dönüştürme işlemidir. Bu pilot uygulamada metin vektörleştirme için Kelime Torbası (bag-of-words) yaklaşımı kullanıldı. Kelime Torbası, kelimelerin belge içindeki yerlerinden ziyade tek tek kelime varlığına ve sıklığına odaklanan ve her benzersiz kelimeyi bir özellik olarak gören basit bir modeldir. Bu yaklaşım herhangi bir belgeyi, özellikler sözlüğü olarak bilinen benzersiz kelimeler kümesine karşılık gelen sabit uzunlukta bir vektör olarak temsil edebilir. Özellik vektöründeki benzer kelimenin her konumu, o belgede görünen belirli kelimenin sıklığı ile doldurulur, böylece bir belge koleksiyonunda yer alan terimlerin sıklığını tanımlayan bir belge terim matrisi oluşturulur.

Bir kelime dizgesinin aşağıdaki kelimeleri içerdiğini varsayalım:

- Kahverengi, köpek, tilki, atladı, tembel, atladı, hızlı, zebra
- Ardından, bir giriş belgesi verildi:
- Hızlı kahverengi tilki tembel köpeğin üzerinden atladı
- Elde edilen özellik vektörü Tablo 2'de gösterilmektedir

Özellik vektörlerinde basit kelime sıklıklarının kullanılmasıyla ilgili sorun, büyük sıklık değerlerine sahip sık sık yinelenen bazı sözcüklerin, belgelerin vektör temsilleri için anlamlı olmayışıdır. Alternatif bir ölçü olan Terim Frekans Ters Belge Frekansının (bir belge içindeki belirli bir kelimenin sıklığı) hesaplanması ve Ters Belge frekansı ile çarpılmasıyla çalışır.⁽⁸⁷⁾

Tablo 2. Özellik vektörü örneği.

	Kahverengi	köpek	tilki	atladı	tembel	üzerinden	hızlı	the	zebra
Belge 1	1	1	1	1	1	1	1	2	0

Sınıflama

Projede, makine öğrenmesi algoritmaları arasından yaygın olarak tercih edilen iki sınıflama algoritmanın test verilerinin karşılaştırılması tercih edilmiştir: Çok Terimli Naive Bayes ve Çok Katmanlı Algılayıcı.

- (1) Çok Terimli Naive Bayes (MNB), basit olasılık tabanlı sınıflandırıcılar ailesinin bir parçası olan istatistiksel bir model algoritmasıdır. Bu

sınıflandırıcı, özellikler arasında güçlü bir şekilde bağımsızlığı varsayan Bayes teoremine dayanmaktadır.

- (2) Çok Katmanlı Algılayıcı (MLP), sınıflandırma veya regresyon için kullanılabilir bir derin öğrenme ağı biçimidir.

Her iki durumda da modelleri eğitmek için denetimli öğrenme kullanılmıştır.

Algoritmaların her biri ile derlemin iki versiyonu kullanıldı: temizlenmiş bir versiyon ve orijinal bir versiyon. Derlem eğitim ve test verileri için %75 ve %25 oranında bölünmüş, başlangıç olarak, her bir algoritmayı eğitmek için önceden sınıflandırılmış, Eyalet Arşivleri için gereken içeriğin %75'i kullanılmıştır.

Bulgular

Dört vakadan (temiz/orijinal derlem, MNB/MLP algoritması) elde edilen, özellik vektörü; boyutunu, eğitim süresini, doğruluk ölçüsünü ve her bir durum için F1-Skorunu içeren bulgular Tablo 3'te gösterilmektedir. Elde edilen istatistikler, derlemin test kısmında maksimum %84 başarı oranıyla, temizlenmiş verilere sahip Çok Katmanlı Algılayıcı algoritmasının daha başarılı olduğunu göstermektedir. Bu bulgular, bu teknolojinin sınıflandırılmamış, yapılandırılmamış verilerin sınıflandırılmasına ve tasfiyesine yardımcı olabileceğini ortaya koymaktadır. %84 oranı muhtemelen henüz insan yeteneği seviyesinde olmasa da (bu durumda gerçek insan doğruluk oranı bilinmemekle birlikte) nispeten kısa bir uygulamadan ve yaklaşık 100 satırlık kod içeren basit modellerden elde edildiği için iyi bir sonuçtu. Kullanılan derlem yalnızca tekil belgelerin örneklenmesi ile klasör düzeyinde manuel olarak karar verebilirken model doğrudan belge düzeyinde daha hızlı karar verebiliyordu. Bununla birlikte karar verme sırasında eğitim verilerine tanıtılan herhangi bir hata veya sapma, modelde zamanla sonucun temsiline ve eğitimin doğruluğuna bağımlılığı artıracağını göstermektedir.

Tablo 3. NSW bulguları

Çok Terimli Naive Bayes		Çok Katmanlı Algılama					
Veri Temizleme Yok		Temizlenmiş Veri		Veri Temizleme Yok		Temizlenmiş Veri	
Özellikler:	5000	Özellikler:	5000	Özellikler:	5000	Özellikler:	5000
Doğruluk:	%65,4	Doğruluk:	%69	Doğruluk:	%77	Doğruluk:	%82,7
F1 Skoru:	0,624	F1 Skoru:	0,648	F1 Skoru:	0,767	F1 Skoru:	0,812
Eğitim süresi:	109ms	Eğitim süresi:	108ms	Eğitim süresi:	2dk 23s	Eğitim süresi:	2dk 43s
Özellikler:	10,000	Özellikler:	10,000	Özellikler:	10,000	Özellikler:	10,000
Doğruluk:	%64	Doğruluk:	%68	Doğruluk:	%78	Doğruluk:	%84
F1 Skoru:	0,622	F1 Skoru:	0,638	F1 Skoru:	0,777	F1 Skoru:	0,835
Eğitim süresi:	111ms	Eğitim süresi:	109ms	Eğitim süresi:	3dk 28s	Eğitim süresi:	4dk 02s

Avustralya Ulusal Arşivleri

Üçüncü vaka çalışması, Avustralya Hükûmetinde dijital işletmeyi destekleyen bir formatta imha ve muhafaza yetkilerinin nasıl oluşturulacağı ve yayınlana-
cağını araştırmak için Avustralya Ulusal Arşivleri'nde (NAA) gerçekleştirilen bir
araştırma projesidir. Ulusal Arşivler, Avustralya ve dünyadaki diğer birçok arşivde
olduğu gibi muhafaza ve imha kararlarını genel ve kuruma özgü yetki dokümanla-
rını oluşturur. Bu geleneksel arşiv dokümanları, kâğıt ortamında olup, yetkililerin
durumla ilgili karar alabilmelerine yardımcı olması amacıyla hazırlanmışlardır.
Aslında dijital imha yetkileri, belge üreticilerinin bu tür kararları otomatikleş-
tirmesini sağlamalı ve bilgileri yöneten dijital sistemlerin insanların minimum
katılımıyla yürütmesine izin vermelidir.

2015'ten beri 4 kişilik bir ekip bu projede yarı zamanlı olarak çalışmakta ve
süreç boyu öğrenmeye devam etmektedir. Farklı danışmanlar ve tedarikçiler, farklı
zamanlarda ekibin mevcut teknolojiye aşına olmasına ve değerlendirmeye yönelik
teorik ve metodolojik yaklaşımları test etmesine yardımcı olacak çalıştaylar yürüt-
müştür. Arşiv ekibi varlık ve otomatik üst veri çıkarma, semantik analiz, sınıfla-
ma ve ontoloji kurma, bağlantılı veri yaklaşımlarını incelemiştir. W3C tarafından
PROV Veri Modeli ve Uluslararası Arşiv Konseyi tarafından 'Bağlamdaki Belgeler
– Kavramsal Model'⁽⁸⁸⁾ üzerine uluslararası alanda yapılan çalışmalar da ekibin
motive olmasına yardımcı olmuştur.

Projenin ilk aşaması, imha yetkilerinin kavramsal modeli ve semantik analizi
ile sonuçlanmıştır. Şema XML'de temsil edilir ve mevcut muhafaza ve imha prog-
ramlarına benzer birçok unsur içerir:

- (1) İmha yetkisi ve sorumlu kamu kurumu veya kurumları hakkında bağ-
lamsal bilgileri içeren bir başlık.
- (2) İlgili faaliyetleri belgelemek ve desteklemek için oluşturulan belgele-
rin/dokümanların bağlamını oluşturan en üst düzeyindeki işlemler.
- (3) İmha sınıfları ve bu sınıfların içinde teorik olarak, bir belgenin uygun
imha sınıfı ve eylemi ile otomatik olarak bağlanmasına izin verecek
kriterler.

Bu kriterler, sözde test gruplarından oluşur ve mevcut imha sınıflarında for-
müle edilmesinde kullanılan dili analiz etmek için kullanılmıştır. Bir sonraki adım,
bu teorik varsayımları, Ulusal Arşivlerin 10 yıldan daha eski ve revizyona gidecek
olan ana faaliyet belgeleri yetkili personeli ile uygulamada test etmek olacaktır.
Proje, makine öğrenmesi ve YZ uzmanlarının tavsiyeleriyle varsayımları test ede-
cek, kanıtlayacak veya çürütecektir. Projeden, otomatik sınıflandırma, kümeleme
ve dizinleme araçları dahil olmak üzere çeşitli makine öğrenmesi türlerinin oluş-
turulması ve uygulanması beklenmektedir. Bu aşamanın, tüm kurum belge üre-
timinden sorumlu kişilere gelecekte dijital bir yaklaşım için pilot/örnek olması
bekleniyor.

Avustralya Maliye Bakanlığı

Son vaka çalışması, Avustralya Maliye Bakanlığı (DoF) tarafından yürütülen PoC projesidir. Belge yönetimini otomatikleştirmek için mikro hizmet mimarisi ve bağlantılı veri teknolojilerinin uygulamasını test etmek amacıyla Şubat 2018'de başlayan 12 haftalık bir araştırmadır. Bu örnekte bir kurumun e-posta sunucusundan veri toplanmaya çalışılmıştır.

Projede, toplanan e-posta verilerinin faaliyetlere ilişkin değerini otomatik olarak tanımlayacak tahmin modelleri oluşturması ve Australian Government Records Interoperability Framework özellikleri kullanarak bu belgeleri birbiri ile ilişkilendirilmesi amaçlanmaktadır.⁽⁸⁹⁾ Yakalanan veriler, saklama planlarına göre sınıflandırılacaktır. Sınıflama sonuçlarının test edilmesi, doğru imha sınıflarının/kategorilerinin uygulandığını onaylayacak olan kurum belge yöneticileri tarafından gerçekleştirilecektir.

Bunun PoC sisteminin kullanılabilirliğinin ispatına yönelik bir araştırma girişimi olduğu vurgulanmalıdır. Projeden kamu kurumları için gelecekte bir belge yönetimi çözümü sunması beklentisindeyiz.

Uygulama

Pilot kurumun ticari faaliyetleri ve mevcut belgeleri analiz edilecek iş süreçleri ve insan eliyle yapılan faaliyetlere tanımlanacaktır.

Kullanıcı hikâyeleri, pilot/örnek kurumun modellenmesine yardımcı olacak ve bu da keşifleri kategorize etmek ve desteklemek için gösterim hizmetleri tarafından kullanılacak yeniden kullanılabilir makine ve insan tarafından okunabilir eserler ile sonuçlanacaktır. Gösterim özellikleri olarak oluşturulan ürünler ile modellemenin gerektiğinde genişletilebilir olması beklenmektedir.

Mikro hizmetler, Amazon web hizmetlerine dağıtılacak ve pilot kurumun Exchange sunucusu ve Office örnekleriyle 'hafif bir dokunuş' etkileşimine sahip olacak. Bu hafif dokunuş ile kurum belge yöneticilerine yönelik yönetim faaliyetlerini desteklemesinin yanı sıra genel olarak kullanıcıların belgelere erişim için bir web arayüzüne sahip olacaktır. Mikro hizmetlerin kullanımı, orijinal gösterim kapsamında olmayan bir hizmete gereksinim olması durumunda mikro hizmet bileşenlerinden yeni hizmetler oluşturmanın mümkün olduğu anlamına gelir.

Gösterim sistemi aşağıdaki teknolojileri içerecektir:

- Mikro hizmetler için Netflix açık kaynak teknoloji kümesi,
- Makine öğrenimi için Apache Spark ve Scala gibi büyük veri teknolojileri,
- Kullanıcı arayüzü implantasyonu için Facebook açık kaynak teknolojisi REACT; ve
- Bulut hizmeti sağlanması için Amazon web hizmetleri.

Sonuç – Arşivde YZ

Bu vaka çalışmalarıyla birlikte anekdot niteliğindeki kanıtlar, YZ teknolojileri ve uygulamalarına gözle görülür bir ilgi olduğunu ve belge yönetimi bilgi çalışması üzerinde etki oluşturacak faydalar üretebileceğini göstermektedir. YZ, dijital değerlendirme, belgeleme ve imha desteğinde verimlilik vaat ederken, henüz sorunlara tam olarak çözüm sunabilecek bir sihirli değnek özelliğinde değildir, halen gelişim safhasında olduğu görülmektedir. Buna rağmen YZ, arşiv ve belge yönetimi alanında da etkisini göstermeye başlamış ve ilerleyen yıllarda bu alanda etkisini gösterecektir. Belki de bu Amara Kanunu⁴ olarak da bilinen ‘aldatma-döngüsü’ etkisinin bir belirtisidir: bizler ‘bir teknoloji etkisini kısa vadede abartma ve uzun vadede hafife alma eğilimindeyiz’.⁽⁹⁰⁾

Vaka çalışmalarının ortaya çıkardığı ortak sonuç, YZ teknolojilerinin tanıtılmasının çaba gerektirdiği ve hedeflere bağlı olarak önemli altyapı çalışmaları gerektirebileceğidir. Örneğin Hem PROV hem de NSW SAR, veri temizleme, veri tekilleştirme, araç zincirleri ve iş akışları geliştirme gibi veri hazırlamanın gerekliliğini göstermiştir.⁽⁹¹⁾ Bitcurator Konsorsiyumu tarafından uygun eğitim ve test verilerinin tanımlanması ve hazırlanması için bir araya getirilenler ile Spencer tarafından otomatikleştirilmiş iş akışındaki veriler için ön işleme adımı kullanılabilir yazılımlar burada önemli bir rol oynayabilir.⁽⁹²⁾ Ayrıca, NAA, teknolojinin arşiv iş ve işlemlerine ilişkin bilgilerin tanımını, keşfini ve birlikte çalışabilirliğini geliştirmesi için arşiv süreçlerinin değişebileceğini gerekebileceğini ortaya koymuştur. Benzer şekilde DoF girişimi, hizmetlerinin sunulması için esnek bir mikro hizmet mimarisinin temel analizinin ve yeniden tasarımının gerekli olduğunu belirlemiştir.

NSW SAR vaka çalışması, özellikle, bu tür girişimlere yeterince kaynak sağlanması gerekliliğini vurgulamış: yalnızca test verileri üzerinden sonuçlara ulaşmak için sınıflandırılmış veriden oluşan büyük eğitim setleri ile değil, aynı zamanda modeli işlemek için yerel makinelerde yeterli hesaplama gücüne sahip olması gerektiğini göstermiştir. Bu proje ayrıca, özellikle bireylerin kişisel mahremiyeti ve işlenen verilerin yasal mülkiyeti gibi konularda bulut hizmetlerini kullanmanın potansiyel riskleri olmasının yanı sıra bu tür hizmetlerin hızla değişen/gelişen doğası olduğunu da kanıtlamıştır. Belki de böyle bir girişimi düşünürken atılacak ilk adım, Carlton Sapp tarafından tanımlandığı gibi YZ'nin tanıtımına hazırlanmaktır.⁽⁹³⁾

Daha da önemlisi, gelecekte belge yönetimi gereksinimlerinin karşılanması için bilgi yönetimi/arşivcilik alanında YZ kavramlarına ilişkin bir anlayışın oluşturulması kaçınılmazdır. Arşivcilerin, YZ'nin etkisini keşfetmek, başarıları ve öğrenmelerini daha geniş mesleki topluluğa sunmak için bu yeni teknoloji grubunun sağladığı fırsattan yararlanmaları gerekiyor. Daha önceki teknolojik araçların

⁴ Stanford Üniversitesi'nde bilgisayar bilimcisi olan ve aynı zamanda Gelecek Enstitüsü başkanlığı görevini yürütmüş Roy Amara adındaki bir bilim insanı tarafından ortaya atılmıştır. 1960 veya 1970'li yıllarda dile getirilen bu ifade zamanla bir deyiş niteliği kazanmıştır. Bk. <https://www.rationaloptimist.com/blog/amaras-law/>

(veri modelleme, Web, Semantik Web vb.) mesleğimiz üzerindeki etkisinde olduğu gibi, bu tür kavramlara aşina olmayan bilgi yöneticileri ve arşivciler için bilgi ve beceri eksikliğini gidermek amacıyla yeni eğitim programlarının hazırlanması gerekmektedir.⁽⁹⁴⁾ Özetle bu tür bir aşinalık, başka bir bakış açısından daha önemlidir. YZ algoritmalarının şeffaf olmayışı, bu tür teknolojiler tarafından yönlendirilen işlemlerle ilgili olarak yapılabilecek belge yönetimi türlerini doğrudan etkiler. Şüphesiz ki kararların sonuçları kaydedilebilir, ancak en önemlisi iş belgelerinin bir parçasını oluşturan bu tür kararlar için ayrıntılı bir gerekçe değildir. YZ teknolojilerini kullanan altyapı tasarımı, güçlü bir belge yönetimini prosedürünü içermelidir, aksi takdirde kriz daha da kötüleşecektir.⁽⁹⁵⁾ YZ ve belge yönetimi hakkındaki tartışmalara katkıda bulunulacak ise uyumsuz teknolojik argümanları engellemek için bilgili ve tercihen YZ teknolojisinde deneyimli olmamız gerekir. Bu aynı zamanda kendi kurumumuz için de önemli ve geçerlidir. Belgelerimizin dokümantasyon gereksinimlerini karşılamak için ISO 23081'de tanımlandığı gibi belge yönetimi işinin dokümantasyonuna katkıda bulunan YZ'den nasıl faydalanabileceğimizi anlamamız gerekecek.⁽⁹⁶⁾

Hedefimiz iyi bir belge yönetimi olmalı ve bunu başarmak için yeni teknolojilerle hareket etmeli ve öğrenmeliyiz. Bu teknolojileri uygun yerlerde kullanmalı, sistemlerimizin ve süreçlerimizin hesap verebilirliğinin tehlikeye atılmadığından emin olmalıyız. Biz insan olabiliriz ama YZ tartışması başladı ve hepimizin katılımı gerekiyor.

Notlar

1. Stanford University, 'Artificial Intelligence and Life in 2030: One Hundred Year Study on Artificial Intelligence; Report of the 2015 Study Panel', 2016, available at <https://ai100.stanford.edu/sites/default/files/ai_100_report_0916fnl_single.pdf>, accessed 14 February 2018.
2. National Archives of Australia and Council of Australasian Archives and Records Authorities, 'Digital Archiving in the 21st Century: Archives Domain Discussion Paper', Collections Council of Australia, 2006; Frank Upward, Barbara Reed, Gillian Oliver and Joanne Evans, 'Recordkeeping Informatics: Re-Figuring a Discipline in Crisis with a Single Minded Approach', Records Management Journal, vol. 23, no. 1, 2013, pp. 37–50, doi:10.1108/09565691311325013.
3. Ross Harvey and Dave Thompson, 'Automating the Appraisal of Digital Materials', Library Hi Tech, vol. 28, no. 2, 2010, pp. 313–22, doi:10.1108/07378831011047703.
4. John McDonald, 'Managing Records in the Modern Office: Taming the Wild Frontier', Archivaria, no. 39, Spring 1995, pp. 70–9.
5. Kate Cumming and Anne Picot, 'Reinventing Appraisal', Archives and Manuscripts, vol. 42, no. 2, 2014, pp. 133–45, doi:10.1080/01576895.2014.926824
6. The National Archives UK, 'Digital Strategy', available at <<https://www.nationalarchives.gov.uk/documents/the-national-archives-digital-strategy-2017-19.pdf>>, accessed 14 February 2018.
7. Anne Gilliland, 'Archival Appraisal: Practising on Shifting Sands', in Caroline Brown (ed.), Archives and Recordkeeping: Theory into Practice, Facet, London, 2014, p. 50. Attributed to Clive Humby and, perhaps, first quoted in Michael Palmer, 'Data is the New Oil', ANA Marketing Maestros, 2006, available at <http://ana.blogs.com/maestros/2006/11/data_is_the_new.html>, accessed 14 February 2018; Upward et al., 'Recordkeeping Informatics'.

8. Cassie Findlay, 'Appraisal: An Essential Tool for Digital Recordkeeping', August 2015, available at <<http://www.informationstrategy.tas.gov.au/Publications/Documents/Cassie-Findlay-Appraisal-Essential-tool-for-digital-recordkeeping-Aug-2015.pptx>>, accessed 14 February 2018.
9. Frank Upward, Barbara Reed, Gillian Oliver and Joanne Evans, Recordkeeping Informatics for a Networked Age, Social Informatics, Monash University Publishing, Clayton, Vic., 2018, pp. xix–xx.
10. William Vinh-Doyle, 'Appraising Email (Using Digital Forensics): Techniques and Challenges', Archives and Manuscripts, vol. 45, no. 1, 2017, pp. 18–30, doi:10.1080/01576895.2016.1270838.
11. Anthony Cocciolo, 'Finding Inactive Records on Institutional Networks: An Evaluation of Tools', Practical Technology for Archives, June 2016, available at <https://practicaltechnologyforarchives.org/issue6_cocciolo/>, accessed 14 February 2018.
12. Victoria Sloyan, 'Born-Digital Archives at the Wellcome Library: Appraisal and Sensitivity Review of Two Hard Drives', Archives and Records, vol. 37, no. 1, 2016, pp. 20–36, doi:10.1080/23257962.2016.1144504.
13. Ross Spencer, 'Binary Trees? Automatically Identifying the Links Between Born-Digital Records', Archives and Manuscripts, vol. 45, no. 2, 2017, pp. 77–99, doi:10.1080/01576895.2017.1330158.
14. Pamela McCorduck, Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence, AK Peters, Natick, MA, 2004, p. 523.
15. Stanford University, p. 12.
16. Edward Feigenbaum as quoted in McCorduck, p. 326.
17. Richard Bellman, An Introduction to Artificial Intelligence: Can Computers Think? Boyd & Fraser, San Francisco, 1978, p. 3.
18. Stanford University.
19. Gartner, 'Hype Cycle Research Methodology Gartner Inc.', 2018, available at <<https://www.gartner.com/technology/research/methodologies/hype-cycle.jsp>>, accessed 14 February 2018
20. McCorduck, Machines Who Think, 423.
21. Ikujiro Nonaka and Hirotaka Takeuchi, The Knowledge-Creating Company: How Japanese Companies Create the Dynamics of Innovation, Oxford University Press, New York, 1995, pp. 86, 154.
22. Anne J Gilliland. 'Designing Expert Systems for Archival Evaluation and Processing of Computer-Mediated Communications', in Anne J Gilliland, Sue McKemish and Andrew J Lau (eds), Research in the Archival Multiverse, Monash University Publishing, Clayton, Vic., 2016, pp. 686–722. For more detail, seek access to Anne Jervois Gilliland-Swetland, 'Development of an Expert Assistant for Archival Appraisal of Electronic Communications: An Exploratory Study', PhD dissertation, University of Michigan, 1995.
23. Daniel G Bobrow, Sanjay Mittal and Mark J Stefik, 'Expert Systems: Perils and Promise', Communications of the ACM, vol. 29, no. 9, 1986, pp. 880–94.
24. Craig Stanfill and David Waltz, 'Toward Memory-Based Reasoning', Communications of the ACM, vol. 29, no. 12, 1986, pp. 1213–28.
25. Herbert Gelerntner, 'Realization of a Geometry-Theorem Proving Machine', in Edward A Feigenbaum and Julian Feldman (eds), Computers and Thought: A Collection of Articles, McGraw-Hill, New York, 1963, pp. 134–52.
26. Ian Goodfellow, Yoshua Bengio and Aaron Courville, Deep Learning, MIT Press, 2017, p. 2, available at <<http://www.deeplearningbook.org/>>, accessed 14 February 2018.

27. *ibid.*, p. 3.
28. *ibid.*, p. 98
29. Steven Bird, Ewan Klein and Edward Loper, *Natural Language Processing with Python*, O'Reilly Media, Sebastopol, CA, 2016, p. 221
30. Goodfellow, Bengio and Courville, p. 103
31. *ibid.*
32. The following names mentioned in this article are registered trademarks (TM): IBM Watson, Jeopardy, Google Street View, Facebook, IBM Lotus Notes, Nuix, Microsoft Azure, Microsoft Azure Cognitive Services, Python, Objective, Amazon Web Services, Microsoft Exchange, Microsoft Office, Netflix, Apache Spark and Scala
33. David Ferrucci et al., 'Building Watson: An Overview of the DeepQA Project', *AI Magazine*, vol. 31, no. 3, 2010, pp. 59–79; Jo Best, 'IBM Watson: The Inside Story of How the Jeopardy-Winning Supercomputer Was Born, and What It Wants to Do Next', *Tech Republic*, September 2013, available at <<https://www.techrepublic.com/article/ibmwatson-the-inside-story-of-how-the-jeopardy-winning-supercomputer-was-born-and-whatit-wants-to-do-next/>>, accessed 14 February 2018.
34. Goodfellow, Bengio and Courville, p. 3.
35. Ian Goodfellow et al., 'Multi-Digit Number Recognition from Street View Imagery Using Deep Convolutional Neural Networks', *arXiv Preprint arXiv:1312.6082*, 2013; Li Deng and Dong Yu, 'Deep Learning: Methods and Applications', *Foundations and Trends in Signal Processing*, vol. 7, nos. 3–4, 2013, p. 219, doi:10.1561/20000000039.
36. Gary Marcus, 'Deep Learning: A Critical Appraisal', *arXiv Preprint arXiv:1801.00631*, January 2018.
37. Goodfellow, Bengio and Courville, *Deep Learning*, 6.
38. Stanford University; Goodfellow, Bengio and Courville, pp. 22–5.
39. Cade Metz, 'AI is Transforming Google Search. The Rest of the Web Is Next', *WIRED*, February 2016, available at <<https://www.wired.com/2016/02/ai-is-changing-the-technology-behind-google-searches/>>, accessed 14 February 2018.
40. Goodfellow, Bengio and Courville, p. 20.
41. Goodfellow et al.
42. Chen Sun et al., 'Revisiting Unreasonable Effectiveness of Data in Deep Learning Era', paper presented at *IEEE, Venice*, 22–29 October 2017.
43. Goodfellow, Bengio and Courville, pp. 21–3.
44. Davide Castelvecchi, 'Can We Open the Black Box of AI?' *Nature News*, vol. 538, no. 7623, October 2016, pp. 20–3, doi:10.1038/538020a.
45. For a discussion of the effects of these issues, see Joanna Redden and Jessica Brand, 'Data Harm Record', December 2017, available at <<https://datajusticelab.org/data-harm-record>>, accessed 14 February 2018; and Cathy O'Neil, *Weapons of Math Destruction*, Penguin Books, New York, 2017. For initiatives that are looking at ways of addressing these problems, see FAT/ML, 'Home:: FAT ML', *Fairness, Accountability, and Transparency in Machine Learning*, 2017, available at <<https://www.fatml.org/>>, accessed 14 February 2018; Paul VoosenJul, 'How AI Detectives Are Cracking Open the Black Box of Deep Learning', *Science AAAS*, July 2017, available at <<http://www.sciencemag.org/news/2017/07/how-ai-detectives-are-cracking-open-black-box-deep-learning/>>, accessed 14 February 2018.
46. Robin Jia and Percy Liang, 'Adversarial Examples for Evaluating Reading Comprehension Systems', *arXiv Preprint arXiv:1707.07328*, 2017.
47. Marcus.

48. André Vellino et al., 'Assisting the Appraisal of E-Mail Records with Automatic Classification', *Records Management Journal*, vol. 26, no. 3, 2016, pp. 293–313, doi:10.1108/RMJ-02-2016-0006; Floriana Esposito et al., 'Machine Learning Methods for Automatically Processing Historical Documents: From Paper Acquisition to XML Transformation', paper presented at IEEE, Palo Alto, CA, 23–24 January 2004, doi:10.1109/DIAL.2004.1263262.
49. Kye O'Donnell, 'Taming Digital Records with the Warrior Princess: Developing a Xena Preservation Interface for TRIM', *Archives and Manuscripts*, vol. 38, no. 2, 2010, pp. 37–60.
50. Susan Leavy, Emilie Pine and Mark Keane, 'Mining the Cultural Memory of Irish Industrial Schools Using Word Embedding and Text Classification', paper presented at DH2017, Montreal, Canada, 8–11 August 2017, available at <<https://dh2017.adho.org/abstracts/098/098.pdf/>>, accessed 14 February 2018.
51. IBM, 'Auto-Classification Models', IBM, 2014, available at <https://www.ibm.com/support/knowledgecenter/SSDUBN_7.5.1/Administrator/cpt/cpt_autoclassificationmodel.html>, accessed 14 February 2018; Open Text, 'Auto-Classification for Records Management', Open Text, 2018, available at <<https://www.opentext.com.au/what-we-do/products/discovery/auto-classification>>, accessed 14 February 2018; Integro, 'Auto-Classification – Integro: Experts in Information Governance and Enterprise Content Management', 2017, available at <<https://www.integro.com/ecm-solutions/auto-classification>>, accessed 14 February 2018; Concept Searching, 'Auto-Classification, Taxonomy Management, Metadata Generation', Concept Searching, 2017, available at <<https://www.conceptsearching.com/>>, accessed 14 February 2018.
52. Jason R Baron, 'Toward a Federal Benchmarking Standard for Evaluating Information Retrieval Products Used in E-Discovery', *Sedona Conference Journal*, vol. 6, Fall 2005, pp. 237–9.
53. Nicholas Fripp, 'Is Machine Learning the Future of Records Management?' *IQ: The RIM Quarterly*, vol. 33, no. 1, 2017, pp. 22–3; George Parapadakis, 'A Clouded View of Records and Auto-Classification', *For What It's Worth*. . ., June 2013, available at <<https://4most.wordpress.com/2013/06/26/clouded-view-of-records-and-classification/>>, accessed 14 February 2018; Ronald Layel, 'Auto-Classification for RM – Beginning to See It as Possible – Association for Information and Image Management International', February 2012, available at <<http://community.aiim.org/blogs/ron-layel/2012/02/16/auto-classification-for-rm---beginning-to-see-it-as-possible>>, accessed 14 February 2018.
54. Tim Shinkle, 'Automated Electronic Records Management? Are We There yet? *IDM Magazine*', *Image and Data Manager*, December 2016, available at <<http://idm.net.au/article/0011369-automated-electronic-records-management-are-we-there-yet>>, accessed 14 February 2018.
55. Parapadakis.
56. For example, see Department of Corporate and Information Services, 'Guidelines for the Development of a Functional Records Disposal Schedule – Records Policy and Standards – NTG IT and Communications – Department of Corporate and Information Services', Northern Territory Government, 2014, available at <http://www.nt.gov.au/dcis/info_tech/records_policy_standards/records_disposal/index.shtml>, accessed 16 April 2018; Public Record Office Victoria, 'Retention and Disposal Authorities (RDAs)', PROV, 2018, available at <<https://www.prov.vic.gov.au/recordkeeping-government/how-long-should-records-be-kept/retention-and-disposal-authorities-rdas>>, accessed 16 April 2018; Queensland State Archives (Department of Science, Information Technology and Innovation), 'Use a Retention and Disposal Schedule', Queensland Government, 2017, available at <<https://www.for.gov.qld.gov.au/use-retention-and-disposal-schedule>>, accessed 16 April 2018; State Archives and Records, 'Disposal Authorisation Procedures', State Archives and Records NSW, 2015,

- available at <<https://www.records.nsw.gov.au/recordkeeping/rules/procedures/disposal-authorisation>>, accessed 16 April 2018.
57. Erika Morphy, 'How to Differentiate Machine Learning from Dressed-up BI', CMSWire.com, January 2018, available at <<https://www.cmswire.com/digital-experience/how-to-differentiate-machine-learning-from-dressed-up-bi/>>, accessed 14 February 2018.
 58. Parapadakis.
 59. Harold Greene, 'United States V. Poindexter, 725 F. Supp. 13 (D.D.C. 1989)', Justia Law, October 1989, available at <<https://law.justia.com/cases/federal/district-courts/FSupp/725/13/1406938/>>, accessed 14 February 2018.
 60. Goodfellow, Bengio and Courville, p. 141.
 61. Tom Simonite, 'Machines Learn a Biased View of Women', WIRED, August 2017, available at <<https://www.wired.com/story/machines-taught-by-photos-learn-a-sexist-view-ofwomen/>>, accessed 14 February 2018.
 62. Brian d'Alessandro, Cathy O'Neil and Tom LaGatta, 'Conscientious Classification: A Data Scientist's Guide to Discrimination-Aware Classification', Big Data, vol. 5, no. 2, 2017, pp. 120–34, doi:10.1089/big.2016.0048.
 63. Shinkle; Parapadakis
 64. Bitcurator Consortium, 'BitCurator NLP', Bitcurator, 2018, available at <<https://bitcurator.net/bitcurator-nlp/>>, accessed 14 February 2018.
 65. Hui Han et al., 'Automatic Document Metadata Extraction Using Support Vector Machines', paper presented at IEEE, Houston, TX, 27–31 May 2003.
 66. Tami Deedrick, 'It's Technical, Dear Watson', IBM Systems Magazine, February 2011, available at <<http://ibmsystemsmag.com/ibmi/trends/whatsnew/its-technical,-dear-watson/>>, accessed 14 February 2018.
 67. And not just AI. GPUs are also being employed in cryptographic applications, most notoriously in the mining of virtual currencies
 68. Layel; Vellino et al.; Goodfellow et al.
 69. Goodfellow, Bengio and Courville, p. 108.
 70. Judy Sheard, 'Quantitative Data Analysis', in Kirsty Williamson and Graeme Johanson (eds), Research Methods: Information, Systems and Contexts, Tilde University Press, Prahran, Vic., 2013, p. 408.
 71. Baron; Richard J Cox, 'The Documentation Strategy and Archival Appraisal Principles: A Different Perspective', Archivaria, vol. 38, Fall 1994, pp. 11–36.
 72. Philip Hider and Ross Harvey, Organising Knowledge in a Global Society: Principles and Practice in Libraries and Information Centres, Topics in Australasian Library and Information Studies 29, Centre for Information Studies, Charles Sturt University, Wagga Wagga, 2008, p. 191.
 73. Goodfellow, Bengio and Courville, p. 418.
 74. *ibid.*, p. 419.
 75. Goodfellow et al.
 76. Eugene Yang, David Grossman, Ophir Frieder and Roman Yurchak, 'Effectiveness Results for Popular E-Discovery Algorithms', paper presented at the 16th International Conference on Artificial Intelligence and Law, London, 12–16 June 2017.
 77. Gordon V Cormack and Maura R Grossman, 'Evaluation of Machine-Learning Protocols for Technology-Assisted Review in Electronic Discovery', ACM, 2014, pp. 153–62, doi:10.1145/2600428.2609601. Also see Baron; Yang et al.

78. See Nuix, 'Electronic Discovery', Investigation, Cybersecurity, Information Governance and eDiscovery Software, 2017, available at <<https://www.nuix.com/problems-we-solve/electronic-discovery>>, accessed 14 February 2018.
79. For discussion of this method, see Spencer
80. Glen Humphries, 'Machine Learning and Records Management', 14 September 2014, 2017, available at <<http://futureproof.records.nsw.gov.au/machine-learning-and-records-management/>>, accessed 2 March 2018.
81. At the time of the pilot, Microsoft's Trust Center included the following advice about use of its Cognitive services: 'Data that is sent to Cognitive Services is treated differently than other customer data. Microsoft may use Cognitive Services data to improve Microsoft products and services. For example, we may use content that you provide to the Cognitive Services to improve our underlying algorithms and models over time. To do that, we may retain Cognitive Services data after you are no longer using the services.' An additional clause, under the Privacy tab, stated: 'Cognitive Services collect and use many types of data, such as images, audio files, video files, or text, all of which may be retained by Microsoft indefinitely to improve Microsoft products and services, without a means for you to access or delete that retained data. Unless otherwise stated in documentation for a particular service, these services provide no means for you to store, access, extract, or delete customer data.'
82. State Records Authority of New South Wales, 'Transferring Records Out of NSW (GA35)', State Archives and Records NSW, November 2015, available at <<https://www.records.nsw.gov.au/node/649>>, accessed 14 February 2018.
83. State Records Authority of New South Wales, 'Storage of State Records with Service Providers Outside of NSW', State Archives and Records NSW, November 2015, available at <<https://www.records.nsw.gov.au/recordkeeping/advice/storage-and-preservation/service-providers-outside-nsw>>, accessed 14 February 2018.
84. Scikit-learn developers, 'Scikit-Learn: Machine Learning in Python', 2017, available at <<http://scikit-learn.org/stable/>>, accessed 14 February 2018. Also see Fabian Pedregosa et al., 'Scikit-Learn: Machine Learning in Python', *Journal of Machine Learning Research*, vol. 12, October 2011, pp. 2825–30.
85. The actual machine specifications were: HP Z440 Workstation, CPU: 2x Intel® Xeon® E5-1650 v3 (12 cores total), RAM: 64 GB DDR4, Storage: 2x Micron M600 1 TB SSD.
86. State Records Authority of New South Wales, 'Administrative Records (GA28)', State Archives and Records NSW, November 2015, available at <<https://www.records.nsw.gov.au/recordkeeping/rules/gdas/ga28>>, accessed 14 February 2018.
87. Formally, the Inverse Document Frequency = $\text{Log}(\text{Total number of documents} / \text{Number of documents having the particular word})$.
88. W3C, 'PROV-DM: The PROV Data Model', 2013, available at <<http://www.w3.org/TR/2013/REC-prov-dm-2013043>>, accessed 2 March 2018. International Council on Archives, 'Records in Contexts: A Conceptual Model for Archival Description', 2016, available at <<https://www.ica.org/sites/default/files/RiC-CM-0.1.pdf>>, accessed 2 March 2018.
89. Available at <<https://www.finance.gov.au/archive/policy-guides-procurement/interoperability-frameworks/information-interoperability-framework>>, accessed 15 July 2018.
90. Matt Ridley, 'Amara's Law', November 2017, available at <<http://www.rationaloptimist.com/blog/amaras-law/>>, accessed 14 February 2018.
91. The identification and classification of 'duplicates' is not without its tensions. See Geoffrey Yeo, 'Nothing Is the Same as Something Else: Significant Properties and Notions of Identity and Originality', *Archival Science*, vol. 10, no. 2, 2010, pp. 85–116, doi:10.1007/s10502-010-9119-9.

92. BitCurator Consortium; Spencer.
93. 'Preparing and Architecting for Machine Learning', Gartner, January 2017, available at <https://www.gartner.com/binaries/content/assets/events/keywords/catalyst/catus8/preparing_and_architecting_for_machine_learning.pdf>, accessed 14 February 2018.
94. Richard Marciano et al., 'Archival Records and Training in the Age of Big Data', in Johnna Percell, Lindsay Sarin, Paul Jaeger and John Bertot (eds), Re-envisioning the MLS: Perspectives on the Future of Library and Information Science Education, Advances in Librarianship 44, Emerald Group Publishing, Bingley, UK, 2017, p. 210.
95. Upward et al., 'Recordkeeping Informatics'.
96. International Organization for Standardization, ISO 23081 Information and Documentation – Records Management Processes – Metadata for Records – Principles, International Organization for Standardization, 2006.

Teşekkürler

Yazarlar proje çalışanlarına teşekkür etmek isterler, onlar olmasaydı bu girişimler mümkün olmazdı: Richard Lehane ve Malay Sharma NSW Eyalet Arşivleri ve Kayıtları; David Header, Marian Kearney ve Sean Wright Avustralya Ulusal Arşivleri ve John Machin ve Wicka Simet Commonwealth Hükûmeti, Maliye Bakanlığı.

Açıklama Bildirimi

Yazarlar tarafından potansiyel bir çıkar çatışması bildirilmemiştir.