

MAKİNE ÖĞRENMESİ VE PAZARLAMA: SCOPUS VERİTABANINDAKİ BİLİMSEL YAYINLARA İLİŞKİN BİBLİYOMETRİK ANALİZ

MACHINE LEARNING AND MARKETING: BIBLIOMETRIC ANALYSIS OF
SCIENTIFIC PUBLICATIONS IN THE SCOPUS DATABASE

İlkim Ecem EMRE*
Gözde Güsan KÖSE**

Öz

Veri çeşidi ve miktarı her geçen gün artarken, bu veriden anlamlı bilgiler elde edilmesi birçok araştırma alanı için önemli hale gelmiştir. Veri analizinde sıklıkla kullanılan makine öğrenmesi yöntemleri farklı araştırma alanlarında araştırmacılara fayda sağlamaktadır. Veri miktarının arttığı alanlardan biri olarak pazarlama alanı da makine öğrenmesi yöntemlerinin uygulanabileceği bir alandır. Bu çalışma kapsamında literatürdeki mevcut durumla ilgili olarak genel bir fikir sağlaması amacıyla, bibliyometrik analiz yöntemleri kullanılarak SCOPUS veri tabanında pazarlama ve makine öğrenmesi kavramlarının bir arada ele alındığı çalışmalar incelenmiştir. Böylece pazarlama alanında makine öğrenmesi yöntemlerinin kullanımına dair mevcut durum tespit edilmeye çalışılmıştır.

Anahtar Kelimeler: Pazarlama, Makine Öğrenmesi, Bibliyometri, Bibliyometrik Analiz.

Abstract

While the type and amount of data is increasing day by day, obtaining meaningful information from this data has become important for many research areas. Machine learning methods, which are frequently used in data analysis, provide benefits to researchers in different research areas. Marketing, as one of the areas where data amount has increased, is an area where machine learning methods can be applied. Within the scope of this study, in order to provide a general idea about the current situation in the literature, studies in which the concepts of marketing and machine learning are discussed together in the SCOPUS database were examined using bibliometric analysis methods. Thus, the current situation regarding the use of machine learning methods in the field of marketing has been tried to be determined.

Keywords: Marketing, Machine Learning, Bibliometrics, Bibliometric Analysis.

* Arş. Gör. Dr., Marmara Üniversitesi İşletme Fakültesi Yönetim Bilişim Sistemleri Bölümü, ecem.emre@marmara.edu.tr

** Arş. Gör., Marmara Üniversitesi İşletme Fakültesi İşletme Bölümü, gozde.gusan@marmara.edu.tr

1. GİRİŞ

Her geçen gün gelişen ve değişen teknolojiyle birlikte çok sayıda veri, hem farklı sektörlerde hem farklı araştırma alanlarında ortaya çıkmakta ve depolanmaktadır. Katlanarak artan bu verinin, faydalı olabilecek anlamlı bir bilgiye dönüşmesi ve bu bilgilerden içgörüler türetmeye duyulan ihtiyaç sonucunda makine öğrenmesi kavramı, 1950'li yıllarda ortaya çıkmıştır (Samuel, 1959). Bu kavram, bilgisayar bilimi ve istatistiğin kesiştiği noktada ve yapay zekâ ile veri biliminin merkezinde yer alan günümüzün en hızlı büyüyen teknik alanlarından biridir (Jordan & Mitchell, 2015). Makine öğrenmesinin Mitchell (1997) tarafından yapılan ve yaygın olarak kullanılan tanımı şu şekilde aktarılmıştır (Balaban & Kartal, 2018): “Eğer bir bilgisayar programının G görevlerinde P ile ölçülen performansı, deneyim D ile artıyorsa, o bilgisayar programının bazı G görevlerinin sınıflarına ve performans ölçüsü P 'ye göre deneyim D 'den öğrendiği söylenmektedir.” Basit bir ifadeyle, makine öğrenmesi verilerden öğrenebilen ve veriler üzerinde tahminler yapabilen algoritmaların incelenmesi ve oluşturulması olarak ifade edilmektedir (Robert, 2014).

Makine öğrenme teknikleri, çoğu zaman insanların varoluşundan beri biriktirdiği bilgi ve deneyime dayanarak insanların öğrenme şekillerini taklit ederek ve karar vermek için gereken tahminleri oluşturarak çalışır (Aylak vd., 2021; Min, 2015). Makine öğrenmesiyle birlikte veri bütünlüğünü geliştirme, süreç otomasyonu ile birlikte hem zamandan hem de kaynaktan tasarruf sağlanması amaçlanmaktadır. Bunlara ek olarak içgörülerini ortaya koyma, kullanıcı deneyimini geliştirme, müşteri davranışını tahmin ederek müşteri deneyimi iyileştirmeyi de hedeflemektedir. Bu noktada da makine öğrenmesinin pazarlama bilimindeki yeri büyük önem arz etmektedir (Brei, 2020; Choudhury vd., 2020; Ma & Sun, 2020). Teknolojik yeniliklere, bilgi ve becerilerdeki büyümelere bağlı olarak, tüketicilerin daha kişiselleştirilmiş, alakalı ve yardımcı deneyimler gibi farklılaşan beklentileri artmış; makine öğrenmesi de özünde tüketici istek ve ihtiyaçlarının belirlenmesi amacı yatan pazarlama bilimine bu talepleri karşılamaya yardımcı olacak bir araç haline gelmiştir (Hair & Sarstedt, 2021; Lu vd., 2016; Ordenes & Silipo, 2021). Pazarlama literatüründe ortaya çıkan çalışmalar, doğrudan pazarlamadan (Chui vd., 2006; Ha vd., 2005) stratejik pazarlamaya (Martínez-lópez & Casillas, 2013; Orriols-puig et al., 2013) kadar çeşitli alanlardaki sorunlara karar desteği sağlamak için makine öğrenmesi yaklaşımlarının dikkate değer kullanımını ortaya koymaktadır.

Pazarlamada makine öğrenmesinin kullanımına yönelik yapılan ulusal ve uluslararası literatür taraması sonucunda temel çalışma konularının tüketici davranışları, müşteri bölümlendirme ve pazarlama stratejileri (Dibb & Meadows, 2010; Verhoef vd., 2002), dijital pazarlama uygulamaları (Arasu vd., 2020; Miklosik & Evans, 2020; Salminen vd., 2019; Wang, 2019) müşteri ilişkileri yönetimi-ilişkisel pazarlama (Chui vd., 2006; Dolgun & Ersel, 2014; Kushwaha & Kar, 2021; Verhoef vd., 2002) başlıkları altında toplandığı görülmüştür. Bunlara ek olarak, son yıllardaki teknolojik gelişmelerle birlikte önemli bir itici güç olarak dijital (büyük) verinin ortaya çıkması ve bunları analiz etmek için kullanılan yöntem olarak makine öğrenmesinin, pazarlama araştırmaları alanında büyük bir öneme ve değişime konu olabilecek katkısını konu alan çalışmalar da yer almaktadır (Ferrell vd., 2015; Hair & Sarstedt, 2021; Hakim vd., 2021).

Çok sayıda tüketici davranışı kapsamında *satın alma tahmini ve kararı* (Arandjelovic vd., 2018; Martínez vd., 2020), *satın alma modelleri* (Xia vd., 2019), *tüketim sonrası değerlendirmeler* (Dzyabura & Hauser, 2011) konuları incelenmiştir. Ayrıca, tüketici davranışları alanında sıklıkla kullanılan ve telekomünikasyon, bankacılık, sigorta, ve perakendecilik sektörü gibi birçok alanda uygulanabildiği görülen bir diğer konu ise *müşteri kayıp analizleridir* (Chinchanachokchai vd., 2021; Gordini & Veglio, 2017; Kaynar vd., 2017; Kisioglu & Topcu, 2011). Sadık müşterilerin işletmeler tarafından elde tutularak, düzenli bir gelir getirme potansiyellerinin bulunduğu yaygın olarak bilinmekle beraber (Mohammad vd., 2010), bu durum da müşteri kaybının tahminine ilişkin modellerin geliştirilmesini zorunlu kılmıştır.

Günümüzde online satış kanallarındaki ürün yorumları, tüketicilerin kararlarını şekillendiren önemli bir faktör haline gelmiştir. Yapılan ürün yorumlarında aldatıcı yorumların tespit edilmesinde makine öğrenmesi yöntemlerinin kullanıldığı görülmüştür (Dhaoui vd., 2017; Onan, 2017; Previtali vd., 2015; Sahni vd., 2017). Benzer şekilde, Twitter, Facebook gibi sosyal medya platformlarında paylaşılan mesajların güvenilirliği doğruluğu ve tüketiciler üzerindeki etkisi, makine öğrenme yöntemlerinden biri olan duygu analiziyle incelenmiştir (Arora vd., 2019; Aswani vd., 2020; Günçe & Arus, 2020; Kadiyala vd., 2019). Makine öğrenmesi yöntemlerinin kullanıldığı bir diğer alan ise, müşteri gruplarının doğru bir şekilde bölümlere ayrılması ve her bir pazar bölümüne kişiselleştirilmiş pazarlama faaliyetlerinin uygulanmasıdır. (Bulut, 2019; Dolgun & Ersel, 2014; Florez-Lopez & Ramon-Jeronimo, 2009; Kotras, 2020), bununla birlikte markalar/işletmeler hedef kitlelerine doğru zamanda, doğru yerde, doğru mesajla ulaşabilecek doğrudan pazarlama stratejilerinin kullanılması sağlanacaktır. Ayrıca işletmeler, müşteri deneyimlerini her alanda iyileştirirken daha çevik olabilmekte; müşteri etkileşimleri sırasında ilgili içerik ve teklifler ve/veya gerçek zamanlı yanıtlar sunabilmekteledir.

Makine öğrenmesinin günümüzde lojistik ve üretim, insan kaynakları, finans, sağlık hizmeti gibi pek çok farklı kullanım alanları söz konusudur. Bunlara ek olarak makine öğrenmesinin pazarlama ve satış alanlarında da kullanıldığı bilinmektedir. Ancak pazarlama literatürde ne kadar sıklıkla ve hangi alanlarda ele alındığının tespit edilmesi ise bu araştırmanın çıkış noktasını oluşturmaktadır. Bu noktada çalışma kapsamında, makine öğrenmesi yöntemleri ve pazarlama alanındaki çalışmaların genel olarak incelenmesi ve literatürdeki mevcut durumun ortaya konması amaçlanmıştır. Böylelikle bu çalışmanın, literatürdeki boşlukların tespit ederek, gelecekte yapılacak çalışmalar için katkı sağlaması beklenmektedir.

2. YÖNTEM

Literatür taraması “araştırılan konuda diğer düşünür, araştırmacı ve uygulayıcıların ürettikleri bilgilerin bulunması, değerlendirilmesi ve sentezlenmesi ile mevcut durumun öğrenilmesi için yürütülen sistemli bir süreç” olarak aktarılmıştır (Karasar, 2016). Araştırma yaparken belirlenen veya araştırılan problemin tanımlanması araştırmanın kapsamının belirlenebilmek için önemlidir. Araştırmacının problem hakkındaki görüşlerinin düzene sokulabilmesi ve gelişigüzel olmaması

gerektiği yine Karasar (2016) tarafından belirtilmiştir. Bununla beraber, bibliyometri, TÜBİTAK ULAKBİM Cahit Arf Bilgi Merkezi tarafından, “belirli bir alanda belirli bir dönemde ve belirli bir bölgede kişiler ya da kurumlar tarafından üretilmiş yayınların ve bu yayınlar arasındaki ilişkilerin sayısal olarak analizi” olarak tanımlanmaktadır (ULAKBİM, 2021). Yani bibliyometri, sistemli bir literatür taraması yapılmasını ve mevcut yayınlar içerisindeki ilişkilerin incelenmesini sağlayan sayısal bir analiz olarak tanımlanabilir. Bu çalışma kapsamında da literatür taramasına temel sağlaması amacıyla nicel araştırma desenine dayalı bilimsel haritalama tekniklerinden bibliyometrik analiz yöntemi kullanılmıştır. Bibliyometrik analizde izlenen temel adımlar aşağıda belirtilmiştir (Zupic & Čater, 2015) :

1. Araştırma tasarımı (*research design*): Araştırma sorunun ne olduğu belirlenir.
2. Bibliyometrik veri toplanması (*compilation of bibliometric data*): Uygun veri tabanından veri çekilir.
3. Analiz (*analysis*): Uygun yazılım ile elde edilen veri analiz edilir.
4. Görselleştirme (*visualization*): Analiz edilen veri görselleştirilir.
5. Yorumlama (*interpretation*): Bulgular yorumlanır.

Analizlerin gerçekleştirilmesi için SCOPUS veri tabanından belirlenen kriterlere göre veri çekilmiştir. Başlık, özet ve anahtar kelime alanlarında, “*machine learning*” (makine öğrenmesi) ve “*marketing*” (pazarlama) anahtar kelimelerinin birlikte geçtiği çalışmalar filtrelenmiştir. 17.09.2021 tarihinde bu tarama sonucunda elde edilen toplam 1737 çalışma, sadece makale türünde çalışmalar filtrelenerek 743 çalışmaya indirgenmiştir. Çalışmaların filtrelenmesi SCOPUS’ta şu şekilde yapılmıştır:

TITLE-ABS-KEY (“machine learning” AND “marketing”) AND (LIMIT-TO (DOCTYPE , “ar”)).

Sonuç olarak 1991-2022 yılları arasında yayımlanan 743 makale türünde çalışmaya ait veri BibTex formatında indirilmiştir. Çalışma kapsamında “bibliometrix” (Aria & Cuccurullo, 2017) paketinden yararlanılmış ve analizler gerçekleştirilmiştir. Analizler R programlama dili ile R Studio programı ve biblioshiny web ara yüzünden yararlanılarak yapılmıştır.

3. BULGULAR

Bu çalışmada; genel betimsel bulgular, yıllara göre makale sayısı, makale sayısına göre en üretken yazarlar, en fazla atıf alan çalışmalar, sorumlu yazarın ülkesine göre en üretken ülkeler, en çok atıf alan ülkeler, en fazla yayın yapılan dergiler, en sık kullanılan ilk 20 anahtar kelimelerle ilgili göstergelere yer verilmiştir. Filtrelenen ve analizlere dahil edilen 743 çalışmanın (koleksiyon) genel durumu Tablo 1’de gösterilmiştir.


Tablo 1. Betimsel bulgular

Açıklama	İçerik
Zaman aralığı	1991-2022
Kaynaklar (<i>Journals, Books, etc</i>)	422
Makaleler	743
Çalışma başına ortalama atıf (<i>Average citations per documents</i>)	15,22
Çalışma başına yıllık ortalama atıf (<i>Average citations per year per doc</i>)	2,92
Referanslar	33409
Anahtar kelimeler (<i>Keywords Plus (ID)</i>)	3636
Anahtar kelimeler (<i>Author's Keywords (DE)</i>)	2262
Yazarlar	2350
Tek yazarlı çalışmalar (<i>Authors of single-authored documents</i>)	64
Çok yazarlı çalışmalar (<i>Authors of multi-authored documents</i>)	2286

1991-2022 yılı arasında yayımlanan çalışma sayıları Tablo 2'de verilmiştir. Buna göre yıllık bilimsel üretim büyüme oranı %2,7 olarak belirlenmiştir. Konunun son yıllardaki popülaritesi dikkat çekmekte olup, artış eğilimi görsel olarak sunulmuştur (Şekil 1).

Tablo 2. Yıllara göre makale sayısı

Yıl	Makale Sayısı	Yıl	Makale Sayısı
1991	1	2010	8
1994	1	2011	6
1995	1	2012	13
1996	1	2013	12
1999	2	2014	25
2001	2	2015	26
2002	3	2016	33
2003	5	2017	36
2004	3	2018	60
2005	6	2019	126
2006	6	2020	173
2007	4	2021	166
2008	12	2022	2
2009	10		




Şekil 1. Yıllara göre makale sayısı

Makale sayısına göre en üretken 20 yazarın hangi yazarlar olduğu tespit edilmiştir (Tablo 3). Aynı zamanda Şekil 2'de bu yazarlara ait hem makale sayısı hem de toplam atıf sayısına göre elde edilen görsel sunulmuştur.

Tablo 3. Makale sayısına göre en üretken 20 yazar

Sıra	Yazarlar	Makale Sayısı	Sıra	Yazarlar	Makale Sayısı
1	Kar Ak	7	11	Kim Y	4
2	Chen Y	6	12	Li X	4
3	Wang Y	6	13	Liu X	4
4	Lessmann S	5	14	Nilashi M	4
5	Zhang W	5	15	Salas-Rueda Ra	4
6	Aswani R	4	16	Wang Q	4
7	Casillas J	4	17	Zhang J	4
8	Evgeniou T	4	18	Zhao J	4
9	Hauser Jr	4	19	Bai X	3
10	Kietzmann J	4	20	Cambria E	3



Şekil 2. En üretken yazarlara ait bulgular (makale sayısı ve toplam atıf sayısı bazında)

Atıf sayısına göre çalışmalar incelendiğinde en fazla atıf alan 20 makalenin listesi Tablo 4'te gösterilmiştir. En çok atıf alan Youyou et al. (2015) çalışmasında kişilerin başkaları hakkındaki kişilik yargılamalarında dijital ayak iz olan Facebook beğenileri dikkate alınmış ve makine öğrenmesindeki gelişmelerle birlikte bilgisayar modellerinin de geçerli ve doğru yargılarda bulunabileceğini sonucuna ulaşılmıştır. İlk 20'ye giren çalışmaların çoğunluğunun ana teması sosyal medya pazarlaması olmakla birlikte; sosyal medya platformlarındaki içeriklerin kategorize edilmesi ve kişilerin duygu durumları, kullanıcıların bölümlere ayrılması, bu mecralardaki reklamların tüketiciler üzerindeki etkisi takip etmektedir (Ghose et al., 2012; Lee et al., 2018; O'Mahony et al., 2004; Poria et al., 2014; Tripathy et al., 2016). Ek olarak işletmelerin müşteriler hakkında çok sayıda bilgiye kolayca ulaşabilmesiyle birlikte, makine öğrenmesi kullanılarak müşteri ilgi alanlarını ürünle ilgili bilgilerle eşleştirilmekte ve kişiye özel pazarlama stratejilerinin geliştirilmesini yönelik çalışmalar da yer almaktadır (Cheung et al., 2003; Kwok & Yu, 2013).

Tablo 4. En fazla atıf alan ilk 20 çalışma

	Çalışma	DOI	Toplam Atıf (Total Citations)	Yıllık Toplam Atıf (Total Citations per Year)
1	Youyou W, 2015, Proc Natl Acad Sci USA	10.1073/pnas.141.868.0112	418	59,71
2	Ghose A, 2012, Mark Sci	10.1287/mksc.1110.0700	315	31,50
3	Tripathy A, 2016, Expert Sys Appl	10.1016/j.eswa.2016.03.028	274	45,67
4	Enke D, 2005, Expert Sys Appl	10.1016/j.eswa.2005.06.024	265	15,59
5	O'mahony M, 2004, Acm Trans Internet Technol	10.1145/1031.114.1031116	233	12,94
6	Poria S, 2014, Knowl Based Syst	10.1016/j.knosys.2014.05.005	226	28,25
7	Lee D, 2018, Manage Sci	10.1287/mnsc.2017.2902	202	50,50
8	Mysln M, 2013, J Med Internet Res	10.2196/jmir.2534	200	22,22
9	Kwok L, 2013, Cornell Hosp Q	10.1177/193.896.5512458360	188	20,89
10	Cheung Kw, 2003, Decis Support Syst	10.1016/S0167-9236(02)00108-2	187	9,84
11	Buja A, 2008, J Comput Graph Stat	10.1198/106186008X318440	172	12,29
12	Giatsoglou M, 2017, Expert Sys Appl	10.1016/j.eswa.2016.10.043	166	33,20
13	Huang J, 2014, Tob Control	10.1136/tobaccocontrol-2014-051551	162	20,25
14	Chapelle O, 2014, Acm Trans Intell Syst Technolog	10.1145/2532128	160	20,00
15	Yu K, 2013, Jisuanji Yanjiu Yu Fazhan	NA	152	16,89
16	Mostafa Mm, 2009, Expert Sys Appl	10.1016/j.eswa.2009.02.088	128	9,85
17	Crone Sf, 2006, Eur J Oper Res	10.1016/j.ejor.2005.07.023	125	7,81
18	Kim Jw, 2001, Int J Elect Commer	10.1080/10864.415.2001.11044215	123	5,86
19	Kosinski M, 2014, Mach Learn	10.1007/s10994.013.5415-y	119	14,88
20	Zhao J, 2014, IEEE Trans Visual Comput Graphics	10.1109/TVCG.2014.234.6922	119	14,88

Makale sayısına göre en üretken 20 ülkeye ait bulgular elde edilmiştir. Sonuçlar yazarların aynı ülkeden (*single country publications-SCP*) veya farklı ülkelere (*multiple country publication-MCP*) olma durumlarına göre ayrı ayrı sunulmuştur (Aria & Cuccurullo, 2017). Bununla beraber benzer bir sıralama atıf sayılarına göre de Tablo 5'te gösterilmiştir.

Tablo 5. En üretken ilk 20 ülke (sorumlu yazarın ülkesine göre) ve en çok atıf alan ilk 20 ülke

	Ülke	Çalışma Sayısı	SCP	MCP		Ülke	Toplam Atıf (Total Citations)	Ortalama Makale Atıfı (Average Article Citations)
1	ABD	126	102	24	1	ABD	3511	27,865
2	Çin	82	60	22	2	Çin	697	8,5
3	Hindistan	40	37	3	3	Hindistan	627	15,675
4	İspanya	26	20	6	4	Hong Kong	422	38,364
5	Kore	25	17	8	5	Almanya	404	19,238

6	Almanya	21	12	9	6	İspanya	390	15
7	İtalya	16	11	5	7	Birleşik Krallık	375	23,438
8	Birleşik Krallık	16	11	5	8	Singapur	365	52,143
9	Hong Kong	11	4	7	9	Kore	312	12,48
10	Japonya	11	9	2	10	İrlanda	262	131
11	Suudi Arabistan	9	6	3	11	Yunanistan	179	35,8
12	Kanada	8	5	3	12	İtalya	159	9,938
13	Türkiye	8	7	1	13	İsveç	143	28,6
14	İran	7	5	2	14	Japonya	117	10,636
15	Hollanda	7	6	1	15	Hollanda	94	13,429
16	Pakistan	7	4	3	16	Fransa	89	17,8
17	Singapur	7	3	4	17	Suudi Arabistan	86	9,556
18	Tayland	7	7	0	18	Portekiz	76	15,2
19	Malezya	6	3	3	19	İran	74	10,571
20	Fas	6	6	0	20	Avusturya	72	14,4

Yayımlanan makale sayısına göre ilk 20 derginin listesi Tablo 6'da yer almaktadır. Dergiler incelendiğinde mühendislik ve bilgisayar teknolojileri dergilerine ek olarak, işletme ve özellikle pazarlama alanındaki dergilerin de yer alması dikkat çekmektedir.

Tablo 6. En fazla yayın yapılan ilk 20 dergi

	Dergi	Makale Sayısı
1	Expert Systems with Applications	27
2	IEEE Access	15
3	International Journal of Advanced Computer Science and Applications	11
4	International Journal of Innovative Technology and Exploring Engineering	11
5	Journal of Business Research	11
6	Plos one	10
7	Marketing Science	9
8	Neurocomputing	9
9	Applied Marketing Analytics	8
10	European Journal of Operational research	8
11	Decision Support Systems	7
12	Journal of Medical Internet Research	7
13	Multimedia Tools and Applications	7
14	IEEE Transactions on Knowledge and Data Engineering	6
15	International Journal of Advanced Science and Technology	6
16	Journal of Marketing	6
17	Journal of Retailing and Consumer Services	6
18	Tourism Management	6
19	Computers and Electronics in Agriculture	5
20	International Journal of Recent Technology and Engineering	5

Seçilen makale koleksiyonunda en sık kullanılan ilk 20 anahtar kelimeye ait bulgular elde edilmiştir (Tablo 7). Bunlardan “*Author Keywords*” yazarların belirlediği anahtar kelimeler, “*Keywords-Plus*” ise SCOPUS ve Clarivate Analytics tarafından makale ile ilişkilendirilen anahtar kelimelerdir (Aria & Cuccurullo, 2017).

Tablo 7. En sık kullanılan ilk 20 anahtar kelime

Author Keywords (DE)	Makale	Keywords-Plus (ID)	Makale
Machine Learning	328	Marketing	214
Artificial Intelligence	65	Machine Learning	196
Data Mining	44	Learning Systems	183
Marketing	42	Artificial Intelligence	93
Social Media	42	Commerce	92
Deep Learning	37	Data Mining	84
Sentiment Analysis	37	Human	81
Big Data	36	Article	78
Classification	26	Forecasting	68
Natural Language Processing	25	Learning Algorithms	68
Text Mining	21	Social Media	67
Twitter	15	Social Networking (Online)	59
Clustering	13	Humans	57
Digital Marketing	13	Sales	54
Prediction	13	Decision Making	43
Feature Selection	11	Algorithm	40
Analytics	10	Classification (of Information)	36
E-Commerce	10	Machine Learning Techniques	36
Personalization	10	Internet	35
Support Vector Machine	10	Deep Learning	34

4. TARTIŞMA ve SONUÇ

Çalışmada belirlenen anahtar kelimelere göre SCOPUS veri tabanında yer alan çalışmalar filtrelenmiştir. Elde edilen koleksiyon betimsel olarak incelenerek literatürdeki mevcut durum (yapılan filtreleme kapsamında) ortaya konmaya çalışılmıştır. Bunu yaparken literatür taramasının sistemli bir şekilde yapılabileceği gösterilmeye çalışılmıştır. Bibliyometrik analiz araçları ve yöntemleri, herhangi bir konuda araştırma yapmak isteyen araştırmacılara literatür ile ilgili genel bakış açısı sağlayabilir. Bu ve benzer çalışmalar sayesinde bir araştırmacı literatür taramasını sistematik hale getirebilir ve hangi çalışmalara odaklanması gerektiğine daha kolay karar verebilir. Çalışmanın bulguları araştırmacılar bu kapsamda fayda sağlayabilir.

İncelenen çalışmalara göre makine öğrenmesi ve pazarlama alanlarında yapılan çalışmaların 1991’den günümüzde doğru genel olarak bir artış eğilimine olduğu görülmektedir. Bulgulara göre tespit edilen, daha üretken yazarların çalışmalarının tespit edilmesi araştırmacının inceleyeceği

yayınları belirlemesi açısından faydalı olabilir. Araştırma yapılan alandaki en fazla yayın yapan yazarların çalışmalarına odaklanılabilir. Bu alanda yapılacak bir literatür taramasında ilk olarak taranabilecek yayınlar bu yayınlar olarak seçilebilir. Bu aşamada yapılabilecek bir diğer şey ise araştırmacıların aldıkları h-indekslerine göre tarama yapmak da olabilir.

Bir literatür taramasında diğer araştırmacılar tarafından en çok atıf alan çalışmalar öncelikli olarak incelenebilir. Çalışmanın bulguları kapsamında en çok sayıda atıf alan çalışmalar ve bunların yıllık ortalama atıf sayıları ortaya konmuştur. Literatür taraması yapan bir araştırmacı bu bulguları dikkate alarak inceleyeceği yayınları seçebilir. En üretken 20 ülke ve en çok atıf alan 20 ülke bulgularına birlikte bakıldığında ilk üç sırada her iki listede de aynı ülkelerin yer aldığı görülmüştür. Amerika Birleşik Devletleri, Çin ve Hindistan hem yayın sayısı hem de atıf sayısı listelerinde ilk üç sırayı almıştır. Diğer ülkelerin sıralaması her iki listede değişiklik göstermektedir. Türkiye, en üretken 20 ülke arasında görülürken en çok atıf alan ülkeler listesinde ilk 20'de yer alamamıştır. Bu bulgular incelenerek ülkelerin araştırma yaptıkları alanların tespit edilmesi sağlanabilir. Özellikle araştırmalarına belli bir alanda devam etmek isteyen araştırmacılar hangi ülkelerdeki yayınlar takip etmeleri gerektiğine bu analiz sonuçlarına göre karar verebilir. Hatta araştırmacıların doktora sonrası araştırma veya proje başvurusu gibi uluslararası nitelik taşıyan akademik adımlarında benzer araştırma bulgularının faydası olabilir.

Çalışma sayılarına göre elde edilen dergi bulgularına bakılarak hangi yayınların takip edilmesinin araştırmacıya fayda sağlayacağı belirlenebilir. Bilimsel dergiler bazında belli başlı yayınlar takip edilebilir. Pazarlama alanındaki Q1 kategorisindeki dergilerin de listede yer alması da, makine öğrenmesi yöntemlerinin pazarlama içerisindeki yeri ve önemini göstermektedir.

Tespit edilen ve incelenen koleksiyondaki anahtar kelimelerin çoğunluğunun makine öğrenmesi yöntemleri veya bu konu ile ilgili kavramlarla ilgili olduğu görülmüştür. Kullanılan anahtar kelimelerin bir kısmının pazarlama ile ilgili olması, yapılan literatür taramasına da benzerlik göstermekte ve makine öğrenmesinin kullanıldığı pazarlamanın alt dallarını göstermektedir. Bundan sonraki yapılacak çalışmalarda bu konularla ilgili çalışmalar geliştirilebileceği gibi, diğer pazarlama karması elemanlarından fiyat, ürün geliştirme gibi alt dallarında da makine öğrenmesi yöntemleri kullanılarak literatüre katkı sağlanabilir. Bulgular sunulan anahtar kelimelerin tespitinin, araştırmacılara çalışmalarının kapsamını belirlemede faydası olabilir. Araştırmanın kapsamının daraltılması ve genişletilmesi amacıyla mevcut koleksiyondaki anahtar kelimeler incelenebilir veya bu alanda bir eksik olduğu düşünülüyorsa mevcut anahtar kelimelere ek olarak başka kelimeler kullanılabilir.

Sonuç olarak bu çalışmanın bulgularından yola çıkarak, bibliyometrik analiz yönteminin SCOPUS, Web of Science (WOS) veya PUBMED gibi veri tabanlarında araştırma yapmak isteyen araştırmacılara sistematik bir literatür taraması yapma imkânı sağlayabileceği söylenebilir. Bu ve benzer çalışmalar araştırmaların literatür taraması aşamasında bir başlangıç noktası olabilir.

KAYNAKLAR

- Arandjelovic, O., Stubseid, S., & Arandjelovi 'c, O. A. (2018). Machine Learning Based Prediction of Consumer Purchasing Decisions: The Evidence and Its Significance Surveillance. *Workshops at the Thirty-Second AAAI ...*, 100–106. <https://www.researchgate.net/publication/323393890>
- Arasu, B. S., Seelan, B. J. B., & Thamaraiselvan, N. (2020). A machine learning-based approach to enhancing social media marketing. *Computers and Electrical Engineering*, 86. <https://doi.org/10.1016/j.compeleceng.2020.106723>
- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959–975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Arora, A., Bansal, S., Kandpal, C., Aswani, R., & Dwivedi, Y. (2019). Journal of Retailing and Consumer Services Measuring social media influencer index – insights from facebook , Twitter and Instagram. *Journal of Retailing and Consumer Services*, 49(January), 86–101. <https://doi.org/10.1016/j.jretconser.2019.03.012>
- Aswani, R., Satish, S. P. G., Arpan, C., & Kar, K. (2020). A hybrid evolutionary approach for identifying spam websites for search engine marketing. *Evolutionary Intelligence*, 012.345.6789. <https://doi.org/10.1007/s12065.020.00461-1>
- Aylak, B. L., Oral, O., & Yazici, K. (2021). Using artificial intelligence and machine learning applications in logistics. İçinde *El-Cezeri Journal of Science and Engineering* (C. 8, Sayı 1, ss. 74–93). TUBITAK. <https://doi.org/10.31202/ecjse.776314>
- Balaban, M. E., & Kartal, E. (2018). *Veri Madencilği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları* (2. baskı). Çağlayan Kitapevi.
- Brei, V. A. (2020). Machine learning in marketing. *Foundations and Trends in Marketing*, 14(3), 173–236. <https://doi.org/10.1561/170.000.0065>
- Bulut, F. (2019). Bankacılık Sektöründe Makine Öğrenmesi Yöntemleriyle Müşteri İlişkileri Yönetiminin Zenginleştirilmesi. *European Journal of Science and Technology*, 382–394. <https://doi.org/10.31590/ejosat.520295>
- Chinchanachokchai, S., Thontirawong, P., & Chinchanachokchai, P. (2021). Journal of Retailing and Consumer Services A tale of two recommender systems : The moderating role of consumer expertise on artificial intelligence based product recommendations. *Journal of Retailing and Consumer Services*, 61(March), 102528. <https://doi.org/10.1016/j.jretconser.2021.102528>
- Choudhury, P., Starr, E., & Agarwal, R. (2020). Machine Learning and Human Capital Complementarities : Experimental Evidence on Bias Mitigation. *Strategic Management Journal*, 41(8), 1381–1411.
- Chui, G., Wong, M. L., & Lui, H.-K. (2006). Machine Learning for Direct Marketing Response Models : Bayesian Networks with Evolutionary Programming. *Management Science*, 42(4), 597–612. <https://doi.org/10.1287/mnsc.1060.0514>
- Dhaoui, C., Webster, C., & Tan, L. P. (2017). Social media sentiment analysis: lexicon versus machine learning. *Journal of Consumer Marketing*, 34(6), 480–488.
- Dibb, S., & Meadows, M. (2010). Relationship marketing and CRM : a financial services case study Relationship marketing and CRM : a financial services case study. *Journal of Strategic Marketing ISSN:*, 12(2), 111–125. <https://doi.org/10.1080/096.525.4042000215177>
- Dolgun, M. Ö., & Ersel, D. (2014). Doğrudan Pazarlama Stratejilerinin Belirlenmesinde Veri Madencilği Yöntemlerinin Kullanımı. *İstatistikçiler Dergisi: İstatistik&Aktüerya* 7, 7, 1–13.
- Dzyabura, D., & Hauser, J. R. (2011). Active machine learning for consideration heuristics. *Marketing Science*, 30(5), 801–819. <https://doi.org/10.1287/mksc.1110.0660>

- Ferrell, O. C., Jr, J. F. H., Marshall, G. W., Tamlia, R. D., Jr, J. F. H., Marshall, G. W., & Tamlia, R. D. (2015). Understanding the History of Marketing Education to Improve Classroom Instruction Classroom Instruction. *Marketing Education Review*, 25(2), 159–175. <https://doi.org/10.1080/10528.008.2015.1038963>
- Florez-Lopez, R., & Ramon-Jeronimo, J. M. (2009). Marketing segmentation through machine learning models: An approach based on customer relationship management and customer profitability accounting. *Social Science Computer Review*, 27(1), 96–117. <https://doi.org/10.1177/089.443.9308321592>
- Ghose, A., Ipeiotis, P. G., & Li, B. (2012). Designing Ranking Systems for Hotels on Travel Search Engines by Mining User-Generated and Crowdsourced Content. *Marketing Science*, 31(3), 493–520. <https://doi.org/10.1287/mksc.1110.0700>
- Gordini, N., & Veglio, V. (2017). Industrial Marketing Management Customers churn prediction and marketing retention strategies . An application of support vector machines based on the AUC parameter-selection technique in B2B e-commerce industry. *Industrial Marketing Management*, 62, 100–107. <https://doi.org/10.1016/j.indmarman.2016.08.003>
- Günçe, E., & Arus, A. (2020). Twitter Platformunda Makine Öğrenmesi Algoritmalarıyla Cinsiyet ve İlgi Analizi. *European Journal of Science and Technology*, November, 187–194. <https://doi.org/10.31590/ejosat.819722>
- Ha, K., Cho, S., & Maclachlan, D. (2005). Response models based on bagging neural networks. *Journal of Interactive Marketing*, 19(1), 17–30. <https://doi.org/10.1002/dir.20028>
- Hair, J. F., & Sarstedt, M. (2021). Data, measurement, and causal inferences in machine learning: opportunities and challenges for marketing. *Journal of Marketing Theory and Practice*, 29(1), 65–77. <https://doi.org/10.1080/10696.679.2020.1860683>
- Hakim, A., Klorfeld, S., Sela, T., Friedman, D., Shabat-simon, M., & Levy, D. J. (2021). International Journal of Research in Marketing Machines learn neuromarketing : Improving preference prediction from self-reports using multiple EEG measures and machine learning. *International Journal of Research in Marketing*, 38(3), 770–791. <https://doi.org/10.1016/j.ijresmar.2020.10.005>
- Jordan, M. I., & Mitchell, T. M. (2015). *Machine learning: Trends, perspectives, and prospects*. 349(6245).
- Kadiyala, B., Özer, Ö., & Simsek, S. (2019). Value of Promotions with Delayed Incentives: An Empirical Investigation of Gift Card Promotions. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3499711>
- Karasar, N. (2016). *Bilimsel Araştırma Yöntemi: Kavramlar İlkeler Teknikler* (33. baskı). Nobel.
- Kaynar, O., Fatih Tuna, M., Görmez, Y., & Ali Deveci, M. (2017). Makine Öğrenmesi Yöntemleriyle Müşteri Kaybi Analizi. *C.Ü. İktisadi ve İdari Bilimler Dergisi*, 18(1).
- Kisioglu, P., & Topcu, Y. I. (2011). Applying Bayesian Belief Network approach to customer churn analysis: A case study on the telecom industry of Turkey. *Expert Systems with Applications*, 38(6), 7151–7157. <https://doi.org/10.1016/j.eswa.2010.12.045>
- Kotras, B. (2020). Mass personalization: Predictive marketing algorithms and the reshaping of consumer knowledge. *Big Data and Society*, 7(2). <https://doi.org/10.1177/205.395.1720951581>
- Kushwaha, A. K., & Kar, A. K. (2021). MarkBot – A Language Model-Driven Chatbot for Interactive Marketing in Post-Modern World. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796.021.10184-y>
- Kwok, L., & Yu, B. (2013). Spreading Social Media Messages on Facebook: An Analysis of Restaurant Business-to-Consumer Communications. *Cornell Hospitality Quarterly*, 54(1), 84–94. <https://doi.org/10.1177/193.896.5512458360>

- Lee, D., Hosanagar, K., & Nair, H. S. (2018). Advertising Content and Consumer Engagement on Social Media: Evidence from Facebook. *Management Science*, 64(11), 5105-5131. <https://doi.org/10.1287/mnsc.2017.2902>
- Lu, L., Gou, Q., Tang, W., & Zhang, J. (2016). Joint pricing and advertising strategy with reference price effect. *International Journal of Production Research*, 7543, 1-21. <https://doi.org/10.1080/00207.543.2016.1165878>
- Ma, L., & Sun, B. (2020). Machine learning and AI in marketing – Connecting computing power to human insights. *International Journal of Research in Marketing*, 37(3), 481-504. <https://doi.org/10.1016/j.ijresmar.2020.04.005>
- Martínez-lópez, F. J., & Casillas, J. (2013). Industrial Marketing Management Artificial intelligence-based systems applied in industrial marketing : An historical overview , current and future insights. *Industrial Marketing Management*, 42(4), 489-495. <https://doi.org/10.1016/j.indmarman.2013.03.001>
- Martínez, A., Schmuck, C., Pereverzyev, S., Pirker, C., & Haltmeier, M. (2020). A machine learning framework for customer purchase prediction in the non-contractual setting. *European Journal of Operational Research*, 281(3), 588-596. <https://doi.org/10.1016/j.ejor.2018.04.034>
- Miklosik, A., & Evans, N. (2020). Impact of Big Data and Machine Learning on Digital Transformation in Marketing: A Literature Review. İçinde *IEEE Access* (C. 8, ss. 101284-101292). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.299.8754>
- Min, H. (2015). Artificial intelligence in supply chain management : Theory and applications. *International Journal of Logistics Research and Applications*, 13(1)(February 2010), 13-39. <https://doi.org/10.1080/136.755.60902736537>
- Mitchell, T. M. (1997). Does Machine Learning Really Work ? *AI Magazine*, 18(3), 11-20. <https://doi.org/10.1609/aimag.v18i3.1303>
- Mohammad, S., Hosseini, S., Maleki, A., & Gholamian, M. R. (2010). Expert Systems with Applications Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty. *Expert Systems With Applications*, 37(7), 5259-5264. <https://doi.org/10.1016/j.eswa.2009.12.070>
- Offergeld, T., Martinez, L. F., & Ferreira, A. I. (2020). A train of thought in product experientiality: Working memory, distraction, and inconsistencies in cue order effects. *Journal of Retailing and Consumer Services*, 53(October 2019), 101971. <https://doi.org/10.1016/j.jretconser.2019.101971>
- O'Mahony, M., Hurley, N., Kushmerick, N., & Silvestre, G. (2004). Collaborative recommendation: A robustness analysis. *ACM Trans. Internet Technol.*, 4(4), 344-377. <https://doi.org/10.1145/1031.114.1031116>
- Onan, A. (2017). SENTIMENT ANALYSIS ON TWITTER MESSAGES BASED ON MACHINE LEARNING METHODS. *Yönetim Bilişim Sistemleri Dergisi*, 3(2), 1-14.
- Ordenes, V. F., & Silipo, R. (2021). Machine learning for marketing on the KNIME Hub : The development of a live repository for marketing applications. *Journal of Business Research*, 137(August), 393-410. <https://doi.org/10.1016/j.jbusres.2021.08.036>
- Orriols-puig, A., Martínez-lópez, F. J., Casillas, J., & Lee, N. (2013). A soft-computing-based method for the automatic discovery of fuzzy rules in databases : Uses for academic research and management support in marketing. *Journal of Business Research*, 66(9), 1332-1337. <https://doi.org/10.1016/j.jbusres.2012.02.033>
- Poria, S., Cambria, E., Winterstein, G., & Huang, G.-B. (2014). Sentic patterns: dependency-based rules for concept-level sentiment analysis. *Know.-Based Syst.*, 69(1), 45-63. <https://doi.org/10.1016/j.knosys.2014.05.005>

- Previtali, F., Arrieta, A. F., & Ermanni, P. (2015). Double-walled corrugated structure for bending-stiff anisotropic morphing skins. *Journal of Intelligent Material Systems and Structures*, 26(5), 599–613. <https://doi.org/10.1177/1045389X14554132>
- Robert, C. (2014). Machine Learning, a Probabilistic Perspective. *CHANCE*, 27(2), 62–63. <https://doi.org/10.1080/09332.480.2014.914768>
- Sahni, T., Chandak, C., Chedeti, N. R., & Singh, M. (2017). Efficient Twitter sentiment classification using subjective distant supervision. *2017 9th International Conference on Communication Systems and Networks, COMSNETS 2017*, 548–553. <https://doi.org/10.1109/COMSNETS.2017.794.5451>
- Salminen, J., Yoganathan, V., Corporan, J., Jansen, B. J., & Jung, S. G. (2019). Machine learning approach to auto-tagging online content for content marketing efficiency: A comparative analysis between methods and content type. *Journal of Business Research*, 101, 203–217. <https://doi.org/10.1016/j.jbusres.2019.04.018>
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3), 210–229.
- Tripathy, A., Agrawal, A., & Rath, S. K. (2016). Classification of sentiment reviews using n-gram machine learning approach. *Expert Systems with Applications*, 57, 117–126. <https://doi.org/10.1016/j.eswa.2016.03.028>
- ULAKBİM, T. C. A. B. M. (2021). *Bibliyometri nedir?* <https://cabim.ulakbim.gov.tr/bibliyometrik-analiz/bibliyometrik-analiz-sikca-sorulan-sorular/>
- Verhoef, P. C., Spring, P. N., Hoekstra, J. C., & Leeflang, P. S. H. (2002). The commercial use of segmentation and predictive modeling techniques for database marketing in the Netherlands. *Decision Support Systems*, 34(4), 471–481. [https://doi.org/10.1016/S0167-9236\(02\)00069-6](https://doi.org/10.1016/S0167-9236(02)00069-6)
- Wang, Q. (2019). *Machine Learning Applications in Operations Management and Digital Marketing* [University of Amsterdam]. <https://pure.uva.nl/ws/files/35645398/Thesis.pdf>
- Xia, F., Chatterjee, R., & May, J. H. (2019). Using conditional restricted boltzmann machines to model complex consumer shopping patterns. *Marketing Science*, 38(4), 711–727. <https://doi.org/10.1287/mksc.2019.1162>
- Youyou, W., Kosinski, M., & Stillwell, D. (2015). Computer-based personality judgments are more accurate than those made by humans. *Proceedings of the National Academy of Sciences*, 112(4), 1036–1040. <https://doi.org/10.1073/pnas.141.868.0112>
- Zupic, I., & Čater, T. (2015). Bibliometric Methods in Management and Organization. *Organizational Research Methods*, 18(3), 429–472. <https://doi.org/10.1177/109.442.8114562629>