

T.C.
SELÇUK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**VETERİNERLİK ALANINDA YAPAY ZEKÂ ÇALIŞMALARININ
BİBLİYOMETRİK ANALİZİ**

Hakan SERİN

DOKTORA TEZİ

BİYOİSTATİSTİK ANABİLİM DALI

Danışman

Dr. Öğr. Üyesi Muslu Kazım KÖREZ

KONYA-2025

T.C.
SELÇUK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**VETERİNERLİK ALANINDA YAPAY ZEKÂ ÇALIŞMALARININ
BİBLİYOMETRİK ANALİZİ**

Hakan SERİN

DOKTORA TEZİ

BİYOİSTATİSTİK ANABİLİM DALI

Danışman

Dr. Öğr. Üyesi Muslu Kazım KÖREZ

KONYA-2025

ÖNSÖZ

Küresel çapta yapay zekâ konusu son yıllarda daha fazla ilgi görerek günlük hayattan sağlık alanına kadar birçok alanda kullanımının artmasıyla birlikte kıymetli ancak bir o kadar da zorlu bir çalışma alanıdır. Bu çalışma kapsamında bibliyometrik analiz ile veteriner hekimlikte yapay zekâ alanındaki literatürün genel haritasını çıkarmak ve kullanım alanlarını belirleyerek elde edilen sonuçların bu alanda çalışmaya devam eden veya henüz yeni başlayacak kıymetli araştırmacılara bir kaynak niteliğinde olmasını ve bilimsel literatüre katkı sağlamasını dilerim.

Doktora eğitimim boyunca her zaman yanımda olan, bilgi ve deneyimleriyle beni destekleyen ve akademik gelişimime katkı sağlayan, danışman hocam Dr. Öğr. Üyesi Muslu Kazım KÖREZ'e ve Anabilim Dalı başkanımız Prof. Dr. Mehmet Emin TEKİN'e ve Zootehni Anabilim Dalı öğretim üyesi Prof. Dr. Tamer ÇAĞLAYAN'a teşekkürü borç bilirim. Tez çalışmam süresince yardım ve desteklerinden dolayı Selçuk Üniversitesi Veteriner Fakültesi, Hayvan Sağlığı Ekonomisi ve İşletmeciliği Anabilim Dalı öğretim üyesi Prof. Dr. Aytekin GÜNLÜ'ye ayrıca teşekkür ederim.

Varlıklarıyla ve destekleriyle bugünlere gelmemde büyük emekleri olan sevgili annem, babam ve abime en içten duygularıyla teşekkür ederim. Lisans eğitimimden doktora sürecine kadar her aşamada beni motive eden değerli dostum Arş. Gör. Burak BARIT'a ve her daim desteğini hissettiğim, birlikte çalışıp geliştiğim kıymetli arkadaşım Diyetisyen Sinan SİREN'e ayrıca teşekkür ederim.

Hakan SERİN

Şubat / 2025

İÇİNDEKİLER

SİMGELER VE KISALTMALAR.....	v
ÖZET.....	vii
SUMMARY.....	viii
1. GİRİŞ.....	1
1.1. Yapay Zekâ.....	2
1.1.1. Yapay Zekânın Tarihi	3
1.1.2. Yapay Zekânın Kullanım Alanları	4
1.2. Bibliyometri.....	12
1.2.1. Bibliyometrik Analiz.....	13
1.2.2. Bibliyometrik Analiz Aşamaları	15
1.2.3. Bibliyometrik Yasalar	20
1.3. Konu İle İlgili Bilimsel Çalışmalar	22
1.3.1. Veteriner Hekimlikteki Bibliyometrik Analiz Çalışmaları	22
1.3.2. Veteriner Hekimlikteki Yapay Zekâ Çalışmaları	25
2. GEREÇ VE YÖNTEM.....	30
2.1. Gereç	30
2.2. Yöntem	31
2.2.1. Analiz Metodu ve Kullanılan Yazılımlar	31
2.2.2. Bibliyometrik Metodoloji.....	32
3. BULGULAR.....	36
3.1. Genel Yayın Eğilimleri.....	36
3.2. Dergiler.....	39
3.3. Yazarlar	44
3.4. Kurumlar	49
3.5. Ülkeler	51
3.6. Anahtar Kelimeler	55
3.7. Ortak Atıf	58
4. TARTIŞMA.....	63

5.	SONUÇ VE ÖNERİLER	67
6.	KAYNAKLAR	68
7.	EKLER	75
	EK-A: Etik Kurul Kararı.....	75
	EK-B: Turnitin Raporu	76
8.	ÖZGEÇMİŞ	77



SİMGELER VE KISALTMALAR

%: Yüzde

C: Sabit değer

f: Kelimenin görülme sıklığı

n: Toplam veri sayısı

r: Kelime sırası

R²: Determinasyon katsayısı

X: Dergi sıralaması

Y: Dergi sayısı

ABD: Amerika Birleşik Devletleri

AE: Atıf Etkisi

AI: Artificial Intelligence (Yapay Zekâ)

ANN: Artificial Neural Network (Yapay Sinir Ağları)

ASF: African Swine Fever (Afrika Domuz Ateşi)

AUC: Area Under the Curve (Eğri Altında Kalan Alan)

CNN: Convolutional Neural Network (Evrişimli Sinir Ağı)

DBN: Deep Belief Network (Derin İnanç Ağı)

DL: Deep Learning (Derin Öğrenme)

DT: Decision Tree (Karar Ağacı)

GİB: Grafiksel İşleme Birimi

IBM: International Business Machines

JIF: Journal Impact Factor (Dergi Etki Faktörü)

KBH: Kronik Böbrek Hastalığı

KNAE: Kategori Normalleştirilmiş Atıf Etkisi

KNN: K-Nearest Neighbours (K En Yakın Komşu)

LR: Logistic Regression

MCP: Multiple Country Publications (Çoklu Ülke Yayımları)

MD: Mavi Dil

MİB: Merkezi İşleme Birimi

ML: Machine Learning (Makine Öğrenmesi)

MLP: Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)

MMVD: Miksomatöz Mitral Kapak Hastalığı

NB: Naive Bayes (Naif Bayes)

RF: Random Forest (Rastgele Orman)

RNN: Recurrent Neural Network (Tekrarlayan Sinir Ağı)

ROC: Receiver Operating Characteristic (İşlem karakteristiği eğrisi)

RPP: Radyografik Pulmoner Patern

SCP: Single Country Publications (Tek Ülke Yayını)

SVM: Support Vector Machine (Destek Vektör Makine)

SÜVDAMEK: Selçuk Üniversitesi Veteriner Fakültesi Deney Hayvanları Üretim ve Araştırma Merkezi Etik Kurulu

WoS: Web of Science

ÖZET

T.C.

SELÇUK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

Veterinerlik Alanında Yapay Zekâ Çalışmalarının Bibliyometrik Analizi

Hakan SERİN

Biyoistatistik Anabilim Dalı

DOKTORA TEZİ / KONYA-2025

Yapay zekânın günümüzde veteriner hekimlik alanında kullanılması bu alandaki araştırmacılar için ilgi çekici bir yenilik olmuştur. Bu çalışmanın amacı, bibliyometrik analiz ile veteriner hekimlikte yapay zekâ alanındaki literatürün genel haritasını çıkarmak ve kullanım alanlarını belirlemektir.

Veteriner hekimlikte yapay zekâ üzerine mevcut literatürü keşfetmek için Web of Science veri tabanı kullanılmıştır. Araştırma verileri 397 adet makaleden oluşmuştur. Verilerin analizi için R istatistik programında mevcut olan “bibliometrix” kütüphanesi ile VOSviewer programı kullanılmıştır. Veri sorgusu 10 Kasım 2023 tarihinde “veterinary” OR “veterinary sciences” OR “animal sciences” AND “machine learning” OR “deep learning” OR “artificial intelligence” OR “data mining” kavramları ile gerçekleştirilmiştir. Dergiler, yayın ve atıf sayısı, yazar, kurum ve ülke gibi araştırma öğeleri bibliyometrik göstergeler ile incelenmiştir.

Genel yayın eğilimleri incelendiğinde veteriner hekimlikteki yapay zekâ çalışmalarına 65 farklı dergi ve 1758 yazar katkıda bulunmuştur. 2019 yılından itibaren yayın sayısı hızlı bir artış göstermiştir. Animals ve Preventive Veterinary Medicine dergileri alanın öncü dergileri olarak belirlenmiştir. Alanda önde gelen yazarlar Tommaso Banzato ve Ecevit Eydurhan olmuştur. En fazla yayın sayısına sahip kurum California Davis Üniversitesi olurken, uluslararası işbirliği düzeyi en yüksek kurum Bern Üniversitesi olmuştur. Çalışma sonucunda alanda önde gelen ülkeler Amerika Birleşik Devletleri ve Çin olmuştur. En sık kullanılan anahtar kelimelerin “deep learning”, “machine learning” ve “artificial intelligence” olduğu, “active learning” ve “computer-aided diagnosis” kelimelerinin ise yakın tarihli çalışmalarda daha fazla kullanıldığı belirlenmiştir.

Çalışmada ortaya konulan bulgular makine öğrenmesinin veteriner hekimlikte güncel çalışma alanı olduğunu göstermektedir. Gelecekte bu alandaki çalışmaların bilgisayar sistemleri ile destekleneceği öngörülmektedir. Bu alandaki çalışmaların geliştirilmesi için mali sorumluluk, yeterli altyapı (yazılım veya donanım) ve kaynak desteği, iyi veri yönetimi ilkelerinin oluşturulması ve eğitim-öğretim gibi sistemli bir yönetim oluşturulması önerilmektedir. Bu çalışma veteriner hekimlik alanında yapılacak yapay zekâ çalışmaları için alanın genel haritası hakkında bilgi vermesi açısından araştırmacılar için yol gösterici nitelik taşıyabilir.

Anahtar Sözcükler: Bibliyometrik analiz; Makine öğrenmesi; Sınıflandırma problemi; Veterinerlik bilimleri; Yapay zekâ

SUMMARY

REPUBLIC OF TURKEY
SELÇUK UNIVERSITY
HEALTH SCIENCES INSTITUTE

A Bibliometric Analysis of Research on Artificial Intelligence in Veterinary Medicine

Hakan SERİN

Department of Biostatistics

PhD THESIS / KONYA-2025

The use of artificial intelligence in veterinary medicine has been an interesting novelty for researchers in the field. With the application of artificial intelligence in the veterinary sciences, studies in this area have reached an important position in the literature. The aim of this study is to map the literature in the field of artificial intelligence in veterinary medicine using bibliometric analysis and to highlight areas of use.

The Web of Science database was used to explore the existing literature on artificial intelligence in veterinary medicine. The research data consisted of 397 articles. The “bibliometrix” library in the R statistical programme and the VOSviewer programme were used to analyse the data. The search was conducted using the keywords “veterinary” OR “veterinary sciences” OR “animal sciences” AND “machine learning” OR “deep learning” OR “artificial intelligence” OR “data mining” on 10 November 2023. Research elements such as journals, number of publications and citations, authors, institutions and countries were assessed using bibliometric indicators.

In terms of general publication trends, there have been 65 different journals and 1758 authors on AI studies in veterinary medicine. The number of publications has increased rapidly since 2019. Animals and Preventive Veterinary Medicine were identified as the leading journals in this area. The senior authors in this field were Tommaso Banzato and Ecevit Eydurhan. The institution with the highest number of publications was the University of California Davis, while the institution with the highest number of international collaborations was the University of Bern. The study found that the most productive countries in this area were the United States of America and China. The most frequently used keywords were “deep learning”, “machine learning” and “artificial intelligence”, while “active learning” and “computer-aided diagnosis” were more frequently used in recent studies.

The results of the study show that machine learning is a recent area of research in veterinary medicine. It is expected that studies in this area will be supported by computer systems in the future. For the development of studies in this area, it is recommended that systematic management is established, such as financial responsibility, adequate infrastructure (software or hardware) and resource support, establishment of good data management principles, and education and training. This study can be a guide for researchers in terms of providing information on the general map of the field for AI studies to be carried out in the field of veterinary medicine.

Key Words: Bibliometric analysis; Machine learning; Classification problem; Veterinary sciences
Artificial intelligence

1. GİRİŞ

Bibliyometri, belirli bir alandaki literatürü tanımak, değerlendirmek ve bilimsel etkileşimi ortaya çıkarabilmek için istatistiksel metotları kullanan bir analiz türüdür; bu analiz ile belirli bir çalışma alanındaki popüler konular belirlenebilmekte ve yakın gelecekte ortaya çıkması muhtemel konular tahmin edilebilmektedir (Yu ve ark 2020). h, g ve m indeksi, atıf sayısı ve yayın sayısı gibi bibliyometrik göstergeler kullanılarak araştırma ögeleri (kurum, yazar, dergi, anahtar kelime vb.) arasındaki etkileşim değerlendirilmektedir (Wang ve ark 2020). Ayrıca alanda yeni olan konuların literatür içerisindeki konumu ve nasıl bir gelişim gösterdiği de bibliyometrik analiz ile belirlenebilmektedir (Kurutkan ve Orhan 2018).

Son yıllarda sayısı hızla artan akademik dergi, kongre ve diğer yayın olanakları sebebiyle makale, tez, rapor ve olgu sunumu gibi akademik bilgi materyalleri yılda milyonları bulan sayılarla literatüre girmekte ve sayısı katlanarak artmaktadır. Bu durum araştırmacıların herhangi bir konuda araştırma yaparken mevcut literatüre ulaşabilmeleri için çok fazla zaman ve çaba harcamalarını zorunlu kıldığından, bilginin hızlı ve kolay bir şekilde elde edilebilmesinde bibliyometrik analiz büyük avantaj sağlamaktadır. Ayrıca bibliyometrik analiz yoluyla yakın geçmişte ortaya çıkan araştırma alanlarının gelişimi ortaya konulabilmektedir (Öztürk ve Gürlü 2021).

Günümüz teknolojisi ve bilgisayar sistemleri ile yeni bir araştırma alanı olarak yakın geçmişte ortaya çıkan Yapay Zekâ (AI: Artificial Intelligence) alanındaki çalışmaların farklı bilim dalları içerisindeki konumunu belirlemek için bibliyometrik analiz kullanımı literatüre önemli bir katkı sağlamaktadır.

AI, gelişen teknoloji ile hayatın her alanında olduğu gibi veteriner hekimlikte de uygulama alanı bulmakta, bu alan AI çalışmaları için büyük bir potansiyel olarak görülmektedir. AI bu alanda teşhis, hayvan bakımı, araştırma ve eğitim faaliyetleri dahil olmak üzere geniş bir uygulama yelpazesine sahiptir (Banzato ve ark 2021).


Veteriner hekimlik alanında AI çalışmalarını bibliyometrik analiz ile kapsamlı inceleyen bir çalışma olmaması bu çalışmayı değerli hale getirmektedir. Ayrıca bu çalışmada kapsamlı ve etik ilkelere uygun çalışmaları kapsayan bir veri tabanının kullanılmasıyla güvenilir sonuçlar elde edilmiştir. Veteriner hekimlik

alanındaki AI çalışmalarının yakın gelecekte hangi alanlarda daha fazla uygulama alanı bulacağı ve gelişim göstereceği belirlenmeye çalışılmıştır. Yazarlar, kurumlar ve ülkeler arasındaki işbirlikleri belirlenerek bu alandaki potansiyel büyümeye hangi ülkelerin liderlik edebileceği de tespit edilmeye çalışılmıştır. Bununla beraber veteriner hekimlik alanında yeni sayılabilecek bibliyometrik analiz ve AI konularının birlikte ele alınması çalışmayı farklı ve yenilikçi kılmaktadır.

1.1. Yapay Zekâ

AI terimi tarihte ilk olarak 1956 yılında John McCarthy tarafından kullanılmıştır. AI, bilgisayar programları aracılığıyla insan zekasının çalışma metodunu kavramayı amaçlayan disiplin olarak tanımlanmaktadır (Brooks 1991). Bu alanda, teorik çalışmalar olsa da bilgisayar ve yazılım teknolojilerinin ilerleme gösterdiği 2000’li yıllara kadar uygulama imkanı olmamıştır (Kaul ve ark 2020). Bu zamandan sonra hızla gelişen bilgisayar sistemleri ve teknoloji ile birçok alanda kullanım alanı bulmaya başlamıştır. Gelişen teknoloji ile yakın gelecekte birçok mesleğin artık AI desteğiyle yapılabileceği öngörülmektedir.

AI, Makine Öğrenmesi (ML: Machine Learning), Bilgisayarlı Görme, Doğal Dil İşleme, Yapay Sinir Ağları (ANN: Artificial Neural Network), Veri Madenciliği ve Genetik Algoritmalar gibi birçok bölüme ayrılmaktadır. ML algoritmaları, veriden öğrenen algoritmalarlardır. Derin öğrenme (DL: Deep Learning) algoritmaları ile görüntü analizi, özellik seçimi ve sınıflama işlemi yapılabilmektedir. Veri madenciliği ile büyük veri yığınlarından öz bilginin keşfi sağlanabilmektedir. Her bir AI alt dalı kendi algoritmalarına ait özellikler ile farklı alanlarda bilgi keşfi sağlamaktadır. Ayrıca AI veriden sonuç türettiğinden istatistikle de yakından ilişkilidir. İstatistik veriyi analiz ederek bilgi ortaya çıkardığından AI metotlarıyla bütünleşmiştir. Örneğin teorik istatistiğin önemli konularından regresyon analizi (doğrusal ve lojistik regresyon) ML’de sıklıkla kullanılan yöntemlerdendir (Köroğlu 2017, Altunkaynak 2019). AI yöntemleri, algoritmalar aracılığıyla öğrenme yeteneği kazanmaktadır. Algoritmalar, karmaşık sorunları analiz ederek, genelden birimlere ayırıştırıp çözmeye çalışan yapılardır. Bu sayede probleme özgü algoritma geliştirilebilmektedir (Şekil 1.1).



Şekil 1.1. Algoritma geliştirme süreçleri (Sayın 2022).

1.1.1. Yapay Zekânın Tarihi

AI çalışmalarının tarihi Cezeri'nin (1136 – 1206) robot çizimlerine kadar uzansa da modern anlamdaki çalışmalar İkinci Dünya Savaşı sonrasında gerçekleşmiştir (Coşkun ve Gülleroğlu 2021). AI ve eleştirel düşüncelerini bilgisayar aracılığıyla simüle etme çalışmaları ilk olarak 1950 yılında Alan Turing tarafından tanımlanmıştır (Holmes ve ark 2004). Turing, *Computers and Intelligence* (Bilgisayar ve Zeka) adlı kitabında bilgisayarlar ile insan zekasının kıyasını yapmak için “Turing testi” olarak bilinen bir test geliştirmiştir (Greenhill ve Edmunds 2020). Allen Newell ve Herbert Simon 1954 yılında bilgisayarları genel zeka için programlamaya başlayan ilk kişiler olmuşlardır (McCarthy 2007). 1956 yılına gelindiğinde John McCarthy AI terimini “akıllı makineler yapma bilimi ve mühendisliği” olarak tanımlamıştır (Malik ve ark 2019). AI, başlarda “eğer, o zaman kuralları” dizisi olarak bilinirken, ilerleyen yıllarda insan beynine benzer şekilde algoritmaları içerecek gelişmeler göstermiştir (Kutlusoy 2019, Kaul ve ark 2020).

İnsan benzeri robot çalışmaları sonucunda ilk akıllı robot, WABOT-1 adıyla

1972’de Japonya’da üretilmiştir. Ancak sonraki yıllarda AI konusunda olumsuz eleştiri barındıran birçok yayın yapılması devletlerin bu alana destek ve teşviklerini azaltmasına sebep olmuştur. Bu döneme “Yapay Zekâ Kışı” da denilmektedir. 1980 yılında İngiltere’nin de AI alanına kaynak ayırmasıyla bu alandaki çalışmalar tekrar hız kazanmıştır (Öztürk ve Şahin 2018). Bu dönemde artan hesaplama gücüne sahip cihazlar geliştirilmiştir. 11 Mayıs 1997’de IBM (International Business Machines) tarafından geliştirilen “Big Blue” adlı program dünya satranç şampiyonu Gary Kasparov’u yenmiştir. Bu durum AI adına dünyada büyük yankı uyandırmıştır (Hamet ve Tremblay 2017). 2000’li yıllara gelindiğinde “Roomba” isimli elektrikli süpürge ile AI günlük hayattaki yerini almaya başlamıştır. Sonraki yıllarda Facebook ve Twitter gibi büyük sosyal medya şirketleri de AI’yı platformlarında kullanmışlardır (Coşkun ve Gülleroğlu 2021). 2011’de IBM tarafından üretilen “Watson” adlı program Amerika Birleşik Devletleri (ABD)’nde “Jeopardy!”, Türkiye’de ise “Büyük Risk!” adlı oyunda insan olan rakiplerini mağlup etmiştir (Sariel 2017). 2018 yılında Google tarafından geliştirilen “Duplex” adlı program normal bir insan taklidi yaparak bir kuaförü arayıp randevu almıştır. Günümüzde ise AI, sağlık alanı da dahil olmak üzere hayatın her alanında aktif olarak kullanılmaktadır. AI, hastalık tahmininde bulunabilmekte, sürücüsüz araç kullanabilmekte ve bir problemin çözümünü açık bir şekilde anlatabilmektedir (Coşkun ve Gülleroğlu 2021). 2020’lerin başında ChatGPT’nin piyasaya sürülmesiyle AI hızlı bir büyüme yaşamıştır. ChatGPT dil çevirisi, metin özetleme, metin sınıflandırılması, bir problemin çözümünü sesli olarak anlatma, soru cevaplama, dil bilgisi denetimi, chatbot etkileşimi ve görüntü oluşturma gibi birçok görevi yerine getirebilmektedir. 2023 yılına Google’da kendi AI aracı Googe Bard’ı duyurmuş ve AI alanına dahil olmuştur (Al-Amin ve ark 2024).

1.1.2. Yapay Zekânın Kullanım Alanları

AI, veri madenciliği algoritmalarının bilimsel çalışmalara ve günlük hayata uyarlanması sonucu ortaya çıkmıştır. AI’nın kökeni büyük veriye dayanmaktadır. Son 50 yılda verinin dijital ortamda depolanma düzeyinde inanılmaz artış gerçekleşmiştir. Böylelikle biriken verilerin işlenerek bilgiye dönüştürülme süreci AI’nın önünü açmıştır. AI, veri madenciliğinin bir alt dalıdır. Küçük farklılıklarla

birbirlerinden ayrılmasına rağmen günümüzde ML, DL ve AI gibi kavramlar birlikte sıklıkla kullanıldığından iç içe geçmiştir (Altunkaynak 2019).

Makine Öğrenmesi (ML)

Arthur Samuel ML'yi, bilgisayarlara açıkça programlanmadan öğrenme yeteneği kazandıran çalışma alanı olarak tanımlamaktadır. ML, makinelere verileri nasıl daha verimli kullanacaklarını öğretmek için kullanılır. Bazen eldeki verileri yorumlayacak kadar yeterli bilgi mevcut değildir. Bu durumda, ML kullanmak uygun bir seçenek olarak öne çıkmaktadır. (Bkassiny ve ark 2012, Mahesh 2020).

ML'nin bazı avantaj ve dezavantajları bulunmaktadır (Hiran ve ark 2021).

Avantajları:

- Eğilimleri ve örüntüleri kolayca tanımlar.
- İnsan müdahalesine gerek yoktur.
- Her türlü verinin verimli bir şekilde işlenmesini sağlar.
- Sürekli gelişmeye açıktır.

Dezavantajları:

- Yüksek hata olasılığı.
- Veri toplama.
- Zaman ve kaynaklar.
- Algoritma seçimi.

ML'de ilk adım veri kümesini toplamaktır. Daha sonra en ilgili özellikler belirlenir ki bu işlem özellik çıkarma olarak adlandırılır. Örneğin "Bruteforce" yöntemi, ölçümler yaparak en alakalı özellikleri ayıran bir yöntemdir. Ayrıca bu süreçte gereksiz ve alakasız özellikler belirlenerek ayıklanır. Veri kümesinde eksik ve aykırı değerler ile kukla değişkene dönüştürülmesi gereken kategorik veriler mevcut olabilir. Bundan dolayı dikkatli bir şekilde veri ön işlemlerden geçirilmelidir (De Mantaras ve Armengol 1998, Batista ve Monard 2003). Veri kümesi analiz için hazır hale geldiğinde eğitim ve test verisi olarak ikiye ayrılır. Eğitim veri kümesi, tahmin edilmesi veya sınıflandırılması gereken çıktı değişkenine sahiptir. Tüm algoritmalar eğitim veri setinden bir tür örüntü öğrenir ve bunları tahmin veya


sınıflandırma için test veri setine uygular.

ML, farklı algoritmalar kullanarak problemi çözmeye çalışır. Kullanılan algoritmalar problemin türüne, değişken sayısına ve uygun modele göre değişiklik gösterebilmektedir. ML amaçlarına ve öğretilme şekline göre Denetimli öğrenme, Denetimsiz öğrenme, Yarı-denetimli öğrenme olarak 3 alt kategoriye ayrılmaktadır (Marsland 2011).

Denetimli ML Algoritmaları

Denetimli ML algoritmalarında, kullanılan algoritmayı eğitmek için önce etiketli (bilinen / tanı konulmuş) bir eğitim veri kümesi kullanılır. Algoritma eğitildikten sonra benzer grupları ayırmak için etiketlenmemiş (bilinmeyen / tanı konulmamış) test veri kümesi ile test edilir (Uddin ve ark 2019).

Denetimli ML algoritmalarının regresyon ve sınıflandırma olarak iki türü vardır. Regresyon, eğitim veri kümesinden elde edilen ve algoritmaya verilen en son veri için sürekli değerli sonuçların tahmin edildiği yöntemdir. Bu yöntemde sayısal bir değer tahmin edilmeye çalışılır. Sınıflandırmadaysa amaç bireylerin o sınıflara düşme olasılıklarının tahmin edilmesidir. Sınıflar, “Evet/Hayır”, “Var/Yok”, “Doğru/Yanlış”, “Hatalı/Hatasız” vb. olacak şekilde kodlanmalıdır (Sharma ve ark 2020). Örneğin; Şekil 1.2’de kanser hastaları için özet bir veri seti kullanıldığında, kanser olan ve olmayan bireyleri denetimli ML algoritmalarının nasıl ayırdığına dair çalışma prensibi gösterilmektedir (Uddin ve ark 2019).




Şekil 1.2. Denetimli ML algoritmalarının kanser hastaları ve sağlıklı bireyleri kategorize etmek için nasıl çalıştığına dair bir örnek.

Bir sınıflandırma modeli, eğitim veri setinden bazı geçerli eşleme fonksiyonları çıkarır ve test veri setinde eşleme fonksiyonu yardımıyla sınıf etiketini tahmin eder. Araştırılan özelliğin verilen problem kümesinde bulunan ve doğru bir tahmin modeli oluşturma niteliğine sahip bir parametre olması gerekmektedir (Basak ve Kothari 2004). Sınıflandırma modeli aşağıdaki adımlarla oluşturulabilir (Mandal ve Bhattacharya 2020):

1. Verinin toplanması ve ön işlemlerden geçirilmesi.
2. Sınıflandırıcı modelin belirlenmesi.
3. Çapraz doğrulama kullanarak veri kümesinin bölünmesi ve sınıflandırıcı modelin eğitim verileriyle eğitilmesi.
4. Sınıflandırıcı model ile yeni bir gözlem verisi için etiket tahmini yapılması.
5. Test verisi üzerinde sınıflandırıcı modelin hata oranının değerlendirilmesi.

Denetimli ML algoritmalarının iş akış şeması Şekil 1.3'te verilmiştir (Mahesh 2020).



Şekil 1.3. Denetimli sınıflandırma modelinin çalışma akış şeması (Mandal ve Bhattacharya 2020).

Denetimsiz ML Algoritmaları

Denetimsiz öğrenme, herhangi bir dış denetim olmaksızın (denetimli öğrenmede olduğu gibi) verilerin doğal yapısını ortaya çıkarmaya yardımcı olan önemli bir öğrenme algoritmaları sınıfıdır. Tipik bir denetimsiz öğrenme probleminin amacı, öncelikle kümeleme olarak adlandırılan bir grup örnekteki benzerliği keşfetmek, yoğunluk tahmini olarak bilinen veri dağılımını belirlemek veya alt uzay öğrenme kategorisine giren bir boyutsal azaltma yapmaktır (Tyagi ve ark 2022). Denetimsiz öğrenme teknikleri etiketsiz veri kümeleri arasındaki benzerlikleri belirler ve örnek verileri arasındaki benzerliklere göre farklı kümelerde gruplandırır. Denetimli öğrenmenin aksine, denetimsiz öğrenmenin girdileri ve denetleyicileri ile ilişkili bir çıktısı yoktur. Denetimsiz öğrenmede performans, denetimli öğrenmeye kıyasla genellikle öznel ve alana özgüdür. Denetimsiz öğrenme teknikleri genel olarak benzer örnekleri kümeleme, boyut azaltma ve yoğunluk tahminini

kapsamaktadır (Yazici ve ark 2023).

Yarı-Denetimli ML Algoritmaları

ML genel olarak denetimli ve denetimsiz öğrenme olarak bilinmektedir (Bishop ve Nasrabadi 2006). Denetimli öğrenmede, bir girdi x ve buna karşılık gelen bir çıktı değeri y 'den oluşan bir dizi veri noktası ile daha önce bilinmeyen girdiler için çıktı değeri tahmin edilebilmektir. Öte yandan denetimsiz öğrenmede belirli bir çıktı değeri değil, girdilerden altta yatan bazı yapılar belirlenmeye çalışılmaktadır (Van Engelen ve Hoos 2020). Yarı denetimli öğrenme ise denetimli ve denetimsiz öğrenme metotlarını birleştirmeyi amaçlayan bir ML dalıdır (Zhou ve Li 2010). Tipik olarak, yarı denetimli öğrenme algoritmaları, genellikle diğeriyle ilişkili bilgileri kullanarak bu iki görevden birinde performansı arttırmaya çalışır. Örneğin, bir sınıflandırma problemi ele alınırken, sınıflandırma sürecine yardımcı olmak için etiketi bilinmeyen ek veri noktaları kullanılabilir. Öte yandan kümeleme yöntemleri için öğrenme prosedürü, belirli veri noktalarının aynı sınıfa ait olduğu bilgisinden faydalanabilir (Van Engelen ve Hoos 2020).

Derin Öğrenme (DL)

Son yıllarda teknolojik gelişmeler ışığında veri miktarlarının artmasıyla birlikte “Büyük Veri” olarak isimlendirilen veri yapılarının işlenmesi geleneksel yöntemlerle zor bir hale gelmiştir. Bu durum bilimdeki yeni gelişmelerle birlikte bir fırsat haline gelmiştir. Buna en iyi örnek yeterli büyüklükte veri bulmanın zor olduğu ANN için büyük veri kümelerinin kolaylıkla bulunur hale gelmesidir. Ayrıca Grafiksel İşleme Birimi (GİB) ve Merkezi İşleme Birimi (MİB) gibi teknolojik gelişmelerle birlikte sinir ve katman sayısı artırılarak ANN'nin geliştirilme çalışmaları hızlanmıştır (Çetin 2021).

DL, ML'nin bir alt dalıdır. Çok sayıda katman ve parametreye sahip bir sinir ağıdır. DL yöntemlerinin çoğu sinir ağı mimarilerini kullanır, bu nedenle derin sinir ağları olarak da adlandırılır (Shinde ve Shah 2018). DL, özellik çıkarma ve dönüştürme için doğrusal olmayan işlem birimlerinin çoklu katmanlarından oluşan bir basamak kullanır. Veri girişine yakın alt katmanlar basit özellikleri öğrenirken, üst katmanlar alt katman özelliklerinden türetilen daha karmaşık özellikleri öğrenir. Bu mimari hiyerarşik ve güçlü bir özellik temsili oluşturur. Bu DL'nin hem büyük

miktarda veriden hem de farklı kaynaklardan toplanan verilerden yararlı bilgileri analiz etmek ve çıkarmak için uygun olduğu anlamına gelir (Zhang ve ark 2018). DL algoritmalarının en önemli avantajı ön işleme, boyutsal indirgeme, öznelilik çıkarma ve sınıflandırma yöntemlerinin tek aşda birleştirilmesidir. DL, görüntü işleme ve sınıflandırmanın yanı sıra ses işleme ve sınıflandırma için de kullanılmaktadır (Çetin 2021).

DL'nin ML'ye kıyasla ayırt edici noktası, özellik mühendisliği olarak adlandırılan verilen verilerden üst düzey karakteristikler elde etme yeteneğidir. Böylece, derin öğrenme birçok alanda yeni uygulamalarla ortaya çıkmaktadır (Sharma ve ark 2021).

Günümüzde DL, görüntü işleme, video işleme, örüntü tanıma, nesne tanıma, ses tanıma, doğal dil işleme, sinyal tanıma ve fizyolojik fonksiyonları izleyerek takip etme gibi birçok alanda aktif olarak kullanılmaktadır (Çetin 2021). Sağlık alanında ise kanser, kemik hastalıkları, yaralanma ve akciğer hastalıklarının teşhisinde X-ray teşhis amaçlı kullanılmaktadır (Rachna 2020). Bunun yanı sıra Destek Vektör Makine (SVM: Support Vector Machine), göğüs röntgeni görüntülerinden özellik çıkarma işlemi ile görüntüyü sağlıklı veya enfekte olarak ayırmak için kullanılmaktadır (Shinde ve Shah 2018, Ramamurthy ve ark 2020). Bu alanda yapılan çalışmalarla birlikte algoritma sayısı da artış göstermiştir (Çetin 2021). Otomatik Kodlayıcı, Derin İnanç Ağı (DBN: Deep Belief Network), Evrişimli Sinir Ağı (CNN: Convolutional Neural Network) ve Tekrarlayan Sinir Ağı (RNN: Recurrent Neural Network) gibi birçok DL ağı mevcuttur (Shinde ve Shah 2018).

Diğer Yöntemler

Metin Madenciliği

Metin madenciliği, doğal dil metninden anlamlı bilgiler elde etmeye çalışan ve gelişmekte olan bir veri madenciliği yöntemidir. Belirli amaçlar için yararlı olan bilgileri çıkarmak için metni analiz etme sürecidir. Veri tabanlarında depolanan veri türleriyle karşılaştırıldığında, metin yapılandırılmamış, şekilsiz ve algoritmik olarak ele alınması zordur (Witten 2004).

Veri madenciliği, donanım ve yazılım teknolojisindeki önemli gelişmeler

nedeniyle son yıllarda hızlı ilerlemeler kaydeden bir alandır ve bu da farklı türde verilerin kullanılabilirliğine yol açmaktadır. Özellikle web, farklı kullanıcılar tarafından depolanması ve işlenmesi kolay bir biçimde büyük miktarda metin içeriğinin oluşturulmasını teşvik eden teknolojik bir olanaktır. Farklı uygulamalardan elde edilebilen metin verilerinin artan miktarı, verilerden ilginç örüntüleri dinamik ve ölçeklenebilir bir şekilde öğrenebilen algoritmik tasarımda ilerlemelere ihtiyaç duyulmasına neden olmuştur. Son zamanlarda, metin verisi bağlamında hızlı bir büyüme yaşanmaktadır. Özellikle modern kültürde metin, resmi bilgi alışverişi için en yaygın araç olarak kullanılmaktadır (Aggarwal ve Zhai 2012).

Görsel Madencilik

Görsel madencilik, dijital görüntülerin işlenmesine dayalı bir veri madenciliği metodudur (Altunkaynak 2019). Bu metot ile görsellerden istatistiksel veriye dayalı sayısal bilgiler elde edilebilmektedir (Friendly ve Denis 2001). Veri görselleştirme yardımıyla bir faaliyete yönelik hızlı bir değerlendirme yapılabilir. Böylece kullanıcılar veriler üzerinden istatistiksel olarak değer elde edebilirler. Ayrıca veri görselleştirmeyele soyutlanan veriler şematik formlarla incelenebilmektedir (Vanderplas ve ark 2020).

Gen Analizi

Gen analizi, genetik hastalıklara ya da belli bir hastalığa sebep olan baskın genlerin tespit edilmesine yönelik gen verilerinin analiz edilmesidir. Bu alanda yapılan çalışmalar biyoinformatik gibi alanların gelişmesine katkı sağlamıştır (Altunkaynak 2019). Gen analizinin sağlık alanında getirdiği yenilikler birçok hastalığın teşhis ve tedavisine imkan sağlamaktadır. Örneğin bazı hastalıkların doğumdan önce veya sonra teşhis ve tedavileri bu yöntemle yapılabilmektedir (Büyükcay 2005).

Web Madenciliği

Web madenciliği terimi Etzioni (1996) tarafından web belgelerini ve hizmetlerini otomatik olarak keşfetmek, web kaynaklarından bilgi çıkarmak ve web genel örüntüleri ortaya çıkarmak için veri madenciliği tekniklerinin kullanımını ifade etmek üzere ortaya atılmıştır. Yıllar geçtikçe Web madenciliği araştırmaları, web ve

web ile ilgili verilerden (web kullanım verileri veya web sunucusu günlükleri gibi) kaynak, örüntü ve bilgi keşfetmek için veri madenciliği ve benzer tekniklerin kullanımını kapsayacak şekilde genişletilmiştir (Chen ve Chau 2004). Öte yandan, ML ve bilgi erişimi alanındaki araştırmalar da Web madenciliği araştırmalarında çok önemli bir rol oynamıştır. ML çoğu veri madenciliği ve metin madenciliği tekniğinin temelini oluşturmakla birlikte bilgi erişim araştırmaları Web madenciliği uygulamalarının araştırma yönlerini büyük ölçüde etkilemiştir. Ayrıca ML teknikleri bilgi erişim ve metin madenciliği uygulamalarında da kullanılmaktadır. Web erişimi, ML, veri tabanları, veri madenciliği ve metin madenciliği dahil olmak üzere birçok yerleşik araştırma alanının kesişme noktasındadır. Günümüzde Web madenciliğine en iyi örnek arama motorlarıdır (Chen ve Chau 2004, Altunkaynak 2019).

Sosyal Ağ Analizi

Sosyal ağ analizi, sosyal bilimlerde giderek daha fazla uygulama alanı bulan bir yöntemdir ve psikoloji, sağlık, iş organizasyonu ve elektronik iletişim gibi çeşitli alanlarda uygulanmaktadır. Sosyal ağ analizin belirleyici özelliği, sıradan tanıdıklardan yakın bağlara kadar uzanan ilişkilerin yapısına odaklanmasıdır. Etkileşim halindeki birimleri birbirine bağlayan bilgi akışını neyin kolaylaştırdığını ya da engellediğini, yani kimin kimi tanıdığını ve kimin hangi iletişim aracıyla hangi bilgi ve enformasyonu kiminle paylaştığını anlamak için resmi ve gayri resmi ilişkileri haritalandırır ve ölçer. Facebook ve Instagram gibi uygulamaların bireylerin etkileşimlerini ölçmeye çalışması bu yönetime örnek verilebilir (Serrat ve Serrat 2017, Altunkaynak 2019).

1.2. Bibliyometri

Bibliyometri, belirli bir araştırma alanındaki veri tabanlarından elde edilen araştırma çıktılarının nicel analizi ve görselleştirilmesidir (Yu ve ark 2020). Bibliyometri terim olarak Yunanca kökenli olup kitap anlamı taşıyan “Biblion” ve ölçmek anlamı taşıyan “metricus” kelimelerinden oluşmaktadır (Sengupta 1992). Cole ve Eales tarafından anatomi alanında 1543 – 1860 yıllarındaki yayın ve kitapların sayısı ile ülke gruplandırması yapılarak gerçekleştirilen bir çalışma olmasına rağmen (Cole ve Eales 1917), bibliyometri teriminin ilk kullanımı Pritchard

tarafından yapılmış olup, matematiksel ve istatistiksel yöntemlerin kitaplara ve diğer iletişim ortamlarına uygulanması anlamına gelmektedir (Pritchard 1969).

1.2.1. Bibliyometrik Analiz

Bibliyometrik analiz, belirli bir araştırma alanındaki farklı bilimsel öğelerin (makaleler, yazarlar, anahtar kelimeler, dergiler, kurumlar ve ülkeler) bilimsel çıktılarını ölçmek ve bu öğeler arasındaki ilişkilere ve etkileşimlere dayanarak ilgili alanın entelektüel, sosyal ve kavramsal yapısının zaman içinde nasıl geliştiğini incelemek için önemli bir araç olarak ortaya çıkmıştır (Donthu ve ark 2021). Bibliyometrik analiz yoluyla araştırmacılar belirli bir araştırma alanındaki literatürü tanımayı, değerlendirmeyi ve anlamayı amaçlamaktadır (Ozturk 2021). Bibliyometrik göstergelere ilişkin istatistikler yardımıyla belirli bir alandaki yayınların sayısal analizi (yıllık makale sayısı, en çok çalışılan konular, en çok yayın yapan üniversiteler, alandaki en iyi dergiler, en çok makalesi olan yazarlar, atıf sayısı ve anahtar kelimeler gibi) yapılabilir (Ellegaard ve Wallin 2015). Bu bağlamda bibliyometrik analiz herhangi bir araştırma alanının entelektüel yapısının yanı sıra alanın evrimini ve yazar-konu-makale arasındaki ilişkileri haritalamak içinde kullanılan bir tekniktir (Osareh 1996, Fernandez-Alles ve Ramos-Rodríguez 2009).

Literatür taramaları, bir araştırma alanının genel durumunu incelemek, bu alana ilişkin bilgileri toplamak ve boşlukları belirlemek için akademik araştırmalarda önemli bir rol oynamaktadır (Snyder 2019). Herhangi bir bilimsel alandaki çalışmaların belli bir zaman aralığında incelenmesi o alandaki bilimsel çalışmaların zaman içinde hangi yönde gelişim gösterdiğinin tespit edilmesi açısından önem taşımaktadır. Bu tür çalışmalar belirli zaman aralıklarında yapılmadığında herhangi bir araştırma alanının bilgi birikimi büyük boyutlara ulaşmaktadır (Donthu ve ark 2021, Ozturk 2021). Bilimsel bilgi üretimindeki kayda değer büyüme, herhangi bir araştırma alanında bu tür incelemelere duyulan ihtiyacı arttırmaktadır (Kraus ve ark 2022).

Bilimsel bilgi birikiminin bu denli arttığı günümüzde yazarlar, daha geniş bir kanıt yelpazesini dikkate almaksızın, genellikle yüksek kaliteli dergilerden elde

edilen alıřmalara atıfta bulunmaktadır (Tranfield ve ark 2003). Bu nedenle, arařtırmacıların belirli bir alandaki durumu, geliřmeleri ve evrimi takip etmesi, boşlukları belirlemesi ve geleneksel literatür inceleme yöntemlerini (örneğin, anlatı, eleřtirel ve meta-analiz) kullanarak bilgi birikimini kategorize etmesi ok zor hale gelmektedir. Bu dođrultuda, herhangi bir arařtırma konusuyla ilgili tüm literatürü dikkate alan bir inceleme yapılmasını sađlayan bibliyometrik analiz daha fazla ilgi görmeye bařlamıřtır. Bibliyometrik alıřmalar sayesinde bilimsel alandaki alıřma boşlukları belirlenerek bu konularda alıřma planı hazırlanması sađlanabilmektedir (Öztürk ve ark 2024).

Genellikle literatür incelemeleri bibliyometrik analiz dıřında meta-analiz ve sistematik literatür incelemeleri ile yapılmaktadır. Meta-analiz, önceki arařtırmaların sonuçlarını sistematik olarak deđerlendirmek ve bu arařtırma gövdesi hakkında sonuçlar ıkarmak için kullanılan nicel, resmi ve epidemiyolojik bir alıřma tasarımıdır (Haidich 2010). Sistematik deđerlendirme ise arařtırmacı tarafından belirlenen kriterler dođrultusunda arařtırılan konudaki alıřmaların öznel ve yorumlayıcı bir deđerlendirilmesidir (Jesson 2011). Geleneksel literatür incelemelerinde özel bir alıřma alanı derinlemesine incelenirken, bibliyometrik analizde incelenilen alan ok daha fazla alıřma ile yüzeysel olarak incelenir. Bu bağlamda bibliyometrik analizden elde edilen sonuçlar sistematik derleme ve meta-analiz alıřmaları öncesinde alanın genel görünümü hakkında fikir sahibi olmak için kullanılabilir. Dolayısıyla bibliyometrik analiz ve geleneksel literatür incelemeleri birbirini tamamlayıcı rol oynamaktadır (Zupic ve Čater 2015, Öztürk ve Gürler 2021).

Bibliyometrik analiz, sistematik derleme ve meta-analiz yöntemleri ile kıyaslandığında birtakım avantajları mevcuttur. Bu yöntemlerde ilgilenilen alan ile ilgili alıřmaların tek tek ele alınarak incelenmesi gerektiđinden zaman kaybı ok fazladır. Ayrıca geleneksel literatür incelemelerinde alan ile ilgili tüm alıřmaların dahil edilmemesi ve alanı yansıtmayan alıřmaların dahil edilmesi ihtimali bulunmaktadır. Bibliyometrik analizde ise veri tabanlarında arařtırılan alandaki alıřmaları toplu olarak indirme imkanı olduđundan daha az zaman ve aba gerekmektedir (Block ve Fisch 2020, Öztürk ve Gürler 2021). Bundan dolayı veri seti daha kapsamlı bir niteliđe sahip olmaktadır. Ayrıca diđer yöntemlere kıyasla daha nicel ve objektif bir bakıř açısı sađlamaktadır (Zupic ve Čater 2015, Gutiérrez-

Salcedo ve ark 2018).

Bibliyometrik analiz farklı bilim dallarında kullanılmakla birlikte bibliyometrik araştırmanın türü ve standardı açısından önemli değişkenlikler mevcuttur. Buna, anlatı-edebiyat incelemeleri olmalarına rağmen bibliyometrik araştırma olarak değerlendirilenler, alanın yalnızca genel bir görünümünü sunanlar ve bibliyometrik analiz tekniklerini yalnızca “teknik olarak” kullananlar örnek verilebilir. Bu çalışmalarda ilgili araştırma alanıyla ilgili ortaya çıkan resimler / haritalar hakkında neredeyse hiçbir değerlendirme, tartışma veya tanımlama yapılmamaktadır (Block ve ark 2020). Bundan dolayı bibliyometrik analiz çalışmalarda bir araç olarak kullanılmalıdır. Sonuçlar alanın uzmanları tarafından yorumlanmalıdır. Aksi takdirde elde edilen bulgular alanın okuyucularına yeterince faydalı olamaz ve sadece istatistiksel bilgilerden ibaret kalır (Öztürk ve Gürler 2021). Bu nedenle, bibliyometrik bir çalışmadan önce araştırmacılar araştırma tasarımı, neleri içermesi gerektiği ve kalitesini neyin belirlediği gibi konularda bilgi sahibi olmalıdır (Punch 2013).

1.2.2. Bibliyometrik Analiz Aşamaları

Bibliyometrik analiz genel olarak şu 4 aşamadan oluşur (Öztürk ve ark 2024):

1. Araştırmanın amacının tanımlanması
2. İlgili literatür hakkında veri toplanması (Arama ve Filtreleme)
3. Analiz ve görselleştirme
4. Bulguların yorumlanması

Araştırmanın Amacının Tanımlanması

Araştırmanın amacı çalışmanın giriş bölümünde açık bir şekilde tanımlanmalıdır (Andres 2009). Araştırma amaçları ve soruları araştırmanın odağını ve kapsamını belirlemektedir. Bundan dolayı eldeki veri seti ve yapılacak analizler çalışmanın amacına göre farklılık gösterebilir. Araştırmanın amacı ile yapılacak analizlerin uyumlu olması çalışmanın kalitesi açısından önemlidir (Block ve ark 2020). Aksi halde çalışma amacından uzak ve uyumsuz bir hale dönüşebilir. Örneğin alandaki kavramsal gelişimi tarihsel süreç içinde ortaya koymayı amaçlayan bir

alıřma iin yazarlar, dergiler, kurumlar ve lkeler gibi yzeysel analizler yetersiz kalacak ve bulgular alıřmanın amacını yansıtmayacaktır. Dolayısıyla eksik ve yetersiz bulgular arařtırmacıya tartıřmak ve sonu ıkarmak iin yeterli bilgi saėlamayacaktır (Waltman ve Van Eck 2012).

İlgili Literatr Hakkında Veri Toplanması

Arařtırmanın amacı doėrultusunda sonraki adımda arařtırılan alana iliřkin veri seti oluřturulmalıdır. Bibliyometrik arařtırmalar tekrarlanabilir olduėundan literatr tarama sreci sistematik olarak yrtlmelidir. Ayrıca verinin elde edilme srecinde izlenen adımlar řeffaf ve aık bir řekilde aıklanmalıdır (Tranfield ve ark 2003, Block ve ark 2020). Arařtırılan alan hakkında veri setini oluřturmak iin ilk olarak uygun veri tabanı belirlenmelidir. Web of Science (WoS), Scopus, Google Scholar, PubMed, Microsoft Academic, Dimensions, EmBase, Springerlink gibi birok veri tabanı bibliyometrik analizde kullanılabilmektedir (Cobo ve ark 2011, Moral-Muñoz ve ark 2020). Ancak her veri tabanı uygun veri indirme imkanı saėlamamaktadır. WoS en byk, Scopus ise ikinci en byk dnya apında en kapsamlı atıf veri kaynaėıdır (Birkle ve ark 2020). Bu veri tabanları uygun formatta veri indirme imkanı saėladıėından arařtırmacılar tarafından sıklıkla tercih edilmektedir. Ayrıca veri tabanı seiminde arařtırılan alanla ilgili hangi veri tabanının daha fazla yayın ierdiėi de dikkate alınmalıdır (Van Raan 2014, Martnez ve ark 2015). Arařtırmacı, alıřmanın amacına ve arařtırmanın kriterlerine gre bir ya da daha fazla veri tabanı kullanabilir (ztrk ve ark 2024). Arařtırma alanına uygun veri tabanı belirlendikten sonra ilgilenilen alanı doėru bir řekilde yansıtacak kelimeler ile arama yapılmalıdır. Arama ařamasında kullanılan kelimeler arařtırma alanıyla ne kadar iliřkiliyse elde edilecek sonularda o kadar objektif ve gvenilir olacaktır. Ayrıca arama ařamasında kullanılacak semboller (* ve “...” gibi) ve kodlar da (“AND”, “OR” ve “NOT” gibi) ilgili literatr temsil eden alıřmaların seilmesine katkı saėlamaktadır. Ancak arama kelimelerindeki kk deėiřiklikler bile alıřma sayısında byk farklılıklara sebep olabilmektedir. Bu durum arařtırma alanıyla alakasız alıřmaların veri setine dahil olabılme ihtimalini doėurduėundan veri setinin arařtırma alanını temsil kabiliyetini olumsuz etkileyebilmektedir (Andres 2009, Zupic ve ater 2015, Linnenluecke ve ark 2020). Bundan dolayı elde edilen alıřmalar incelenerek alakasız olanlar hari tutulmalıdır. Filtreleme ařamasında alıřmanın amacına uygun olarak birtakım dıřlama ve dahil etme kriterleri veri setine

uygulanmalıdır. Örneğin sadece İngilizce dilindeki çalışmalar veya belli bir yıl aralığındaki çalışmalar dahil edilebilir (Snyder 2019, Block ve ark 2020). Sonuç olarak belirlenen filtrelemeler uygulandıktan sonra elde edilen veri seti örneklemi oluşturmaktadır. Elde edilen örneklem yazılım araçlarına aktarmak için indirme seçeneklerinden gerekli bilgiler işaretlenerek uygun formatta indirilmelidir (Dong ve ark 2023).

Analiz ve Görselleştirme

Bibliyometrik çalışmalarda analiz prosedürü performans analizi ve bilimsel haritalama bölümlerinden oluşmaktadır. Bibliyometrik performans analizinde, kelime sıklığı analizi, atıf analizi ve ülkeye, üniversitelere, araştırma grubuna veya yazarlara göre yayın sayımı dahil olmak üzere çok çeşitli teknikler kullanılır (Thelwall 2008). Bu bağlamda performans analizi veri setindeki bilimsel öğelerin (yazar, dergi, kurum ve ülke gibi) nitelik ve nicelik bakımından ölçülmesidir. Bu analiz ile bilimsel öğelerin yayın ve atıf performansına dayalı olarak değerlendirilmesi amaçlanmaktadır. Böylelikle bilimsel öğeler h, g ve m indeksi, makale başına ortalama atıf sayısı ve toplam atıf sayısı gibi birçok gösterge ile değerlendirilir (Öztürk ve Gürler 2021).

Bilimsel haritalama ise araştırma alanının entelektüel, sosyal, kavramsal ve evrimsel dinamiklerini görsel olarak ortaya koyan bir analiz türüdür. Bilimsel haritalama ile bilimsel öğelerin birbirleriyle nasıl ilişkili olduğu ortaya konulabilmektedir. Bilgisayar teknolojileri ve yazılımların gelişimi, bu metodolojinin mükemmelleştirilmesine ve bilimin yapılarını ve ağlarını değerlendirmek için farklı bir metodolojik seçenek olarak ortaya çıkmasına imkan tanımıştır (Börner ve ark 2003, Cobo ve ark 2012). Bu alandaki popüler yazılım araçlarından bazıları CiteSpace II (Chen 2006), VOSviewer (Van Eck ve Waltman 2010), SciMAT (Cobo ve ark 2012) ve R Project (Aria ve Cuccurullo 2017) programlarıdır. Bu yazılım programları farklı özelliklere ve algoritmalara sahip olsalar da farklı analiz birimlerinin ağ yapısını oluşturmak için aynı teknikleri kullanmaktadırlar (Small 1973).

Bulguların Yorumlanması

Analiz bulguları tamamlandıktan sonra son adım olarak elde edilen bulgular

literatür eşliğinde yorumlanmalıdır. Elde edilen sonuçlar ilgili literatürün durumunu yansıtmalı ve alanın genel eğilim ve yönelimlerini belirleyerek araştırmacılara yeni çalışmalar için fikir vermelidir (Block ve ark 2020). Araştırmacılar bibliyometrik görselleştirmeyi şekil ve tablolarda kullanarak betimsel tartışmalardan ziyade analitik tartışmalara yer vermelidir. Böylelikle içerik ve bağlam kavramlarının açıklanması daha kolay olacaktır (Donthu ve ark 2021).

1.2.3. Bibliyometrik Analiz Teknikleri


Bibliyometrik analiz gerçekleştirilirken kullanılan birçok teknik mevcuttur. Bunlardan başlıcaları atıf analizi, ortak atıf analizi, kaynakça eşleşmesi, ortak yazar analizi ve ortak kelime analizidir.

Atıf Analizi

Atıf analizi yazarların ortaya koydukları çalışmaların diğer yazarlar tarafından kaynak olarak gösterilmesidir. Bu analiz türü bilimsel bir çalışmanın etki gücü açısından fikir vermektedir (Osca-Lluch ve ark 2009). Bu teknikle mevcut veri seti dikkate alınarak araştırılan alandaki en etkili çalışma, yazar, dergi, kurum ve ülkeler belirlenebilmektedir. Bu teknikte atıf sayısı ölçüt olduğundan çok atıf alan çalışmaların araştırılan alanda daha fazla etkisi olduğu kabul edilir (Zupic ve Čater 2015).

Ortak Atıf Analizi


Ortak atıf analizi birbirinden farklı iki çalışmanın tek bir çalışmada alıntılanması olarak tanımlanmaktadır (Small 1973). Bu analiz tekniğine göre farklı iki çalışmanın birlikte atıf olarak verildiği çalışma sayısı arttıkça bu iki çalışma arasında ilişki olduğu kabul edilir (Şekil 1.4). Böylelikle bu iki çalışma arasındaki ortak atıf gücünün de yüksek olduğu söylenir. Ortak atıf analizi yardımıyla bir alanın entelektüel yapısı belirlenebilmektedir (Öztürk ve Gürler 2021).



Şekil 1.4. X çalışmasının Y ve Z çalışmalarına yaptığı ortak atıf (Öztürk ve Gürler 2021).

Kaynakça Eşleşmesi

Kaynakça eşleşmesi ilk olarak 1963'te Kessler tarafından öne sürülmüş ve araştırma alanları arasındaki ilişkiyi açıklayabilecek bir yöntem olarak tanımlanmıştır (Small 1973). Kaynakça eşleşmesi farklı iki dokümanın kaynakçaları arasındaki benzerliği tanımlamaktadır. Yani X ve Y çalışmalarının ikisi de Z makalesine atıfta bulunmuşsa, doğrudan birbirlerinden alıntı yapmasalar da bu iki çalışmanın ilişkili olduğu söylenebilir (Şekil 1.5). Diğer bir ifadeyle iki çalışma aynı yayınlara ne kadar fazla birlikte atıf yapmışsa aralarındaki ilişki o kadar fazladır. Kaynakça eşleşmesi araştırılan alandaki yeni ortaya çıkan çalışma alanlarının belirlenebilmesine imkan sağlamaktadır (Öztürk ve Gürler 2021).



Şekil 1.5. X ve Y çalışmalarının Z çalışmasına yaptığı atıf (Öztürk ve Gürler 2021).

Ortak Yazar Analizi

Bir çalışmaya birden fazla yazar katkıda bulunarak yayınladıklarında bu yazarlar arasında bilimsel bağlantı olduğu kabul edilmektedir. Bu durum yazarlar arasındaki işbirliği düzeyini göstermektedir. Ortak yazar analizi, birden fazla yazarın bir çalışmanın üretilmesine bilimsel katkı sağlayarak oluşturdukları sosyal ağları incelemektedir (Acedo ve ark 2006). Ortak yazar analizi ile yazarların kurumları ve ülkeleri arasındaki işbirliği ağları hakkında da bilgi edinilebilmektedir (Öztürk ve Gürler 2021).

Ortak Kelime Analizi

Ortak kelime analizi bir alandaki çalışmaların başlık, özet veya anahtar kelimelerindeki kelimeler arasındaki ilişkiyi incelemektedir. Kelimeler arasındaki ilişkinin boyutu değerlendirilerek alanın eğilimleri belirlenebilmektedir (Ronda-Pupo ve Guerras-Martin 2012).

1.2.3. Bibliyometrik Yasalar

Zipf, Bradford ve Lotka'nın bibliyometrik yasaları bibliyometrik yasaların temelini oluşturmaktadır (De Bellis 2009). Bununla birlikte Price ve Pareto yasaları gibi diğer bibliyometrik yasalar da mevcuttur.

Lotka Yasası

Lotka yasası temel olarak belirli bir alanda bilim insanları topluluğu içindeki yayınların dağılımını tanımlamak için kullanılır (Bookstein 2001). “Bilimsel üretkenliğin ters kare yasası” olarak da adlandırılır. Lotka yasası, belirli bir alanda çalışmaları bulunan yazarların o alana katkılarını kaç çalışma ile yaptıklarını belirleme imkanı sunmaktadır. Böylece yazarlara ait çalışmaların literatürdeki dağılımı ve verimlilik süreci hakkında tahminde bulunulabilmektedir (Yılmaz 2006). Bu yasaya göre yazar sayısı çalışma sayısının karesi ile ters orantılıdır (Bailón-Moreno ve ark 2005). Bilimsel formülü $1/n^2$ ile açıklanmaktadır (Öztürk ve Gürler 2021). Lotka yasası, zaman aralığı, değişen üretim oranları ve farklı sayım prosedürleri gibi çeşitli çalışmalarda yaygın olarak kullanılmaktadır (Kretschmer ve

Rousseau 2001).

Zipf Yasası

Bu yasa ilk olarak fizikçi Edward Uhler Condon tarafından önerilmesine rağmen günümüzde Zipf Yasası olarak bilinmektedir (Condon 1928). Bu yasaya göre araştırmacılar daha sık kullanılan kelimeleri nadir kullanılanlara tercih etme eğilimindedir (Zipf 1949). Zipf yasasına göre kelimenin tercih edilme düzeyi ile kelime uzunluğu arasında ilişki vardır. Bu bağlamda kelime uzunluğunun artması kullanım sıklığının azalmasına yol açmaktadır. " $r \times f = C$ " şeklinde ifade edilen formülde "r" kelimenin sırasını, "f" ise kelimenin görülme sıklığını (frekans) ve C ise metne göre değişebilen sabit bir değeri göstermektedir (Glanzel 2003, Zan 2012).

Bradford Yasası

İlk olarak 1934 yılında formüle edilen Bradford yasası belirli bir alandaki çalışmaların dergilerde nasıl dağıldığını ve dergi üretkenliğini belirlemektedir (Hood ve Wilson 2001, Andres 2009). Bu yasaya göre belirli bir alandaki dergiler yayın sayısına göre sıralanır ve eşit sayıda gruplar oluştururlar. Bu alandaki literatürün büyük bir kısmını oluşturan (üçte biri) küçük bir dergi grubu (çekirdek dergi), üçte birini kapsayan daha fazla sayıda ikinci dergi grubu ve son üçte birlik kısmı kapsayan en fazla sayıdaki üçüncü dergi grubu olacaktır (Garfield 1980, Al ve Coştur 2007, Barca ve Hızıroğlu 2009). Bu bağlamda çekirdek dergi grubu belirli bir alandaki yayınların büyük bölümünü kapsarken fazla sayıdaki dergi grubunun bu alanda az sayıdaki yayını kapsadığı söylenebilir (Andres 2009).

Pareto Yasası

Vilfredo Pareto tarafından 1897'de ortaya konulan Pareto yasası 80/20 kuralı olarak ta bilinmektedir (Koch 2011). Bu yasaya göre belirli bir alandaki çalışmaların %80'ini o alandaki dergilerin %20'si, aynı alandaki çalışmaların %80'ini de o alandaki yazarların %20'si yayınlamaktadır. Bradford yasası ile karşılaştırıldığında Pareto yasasında çekirdek dergi grubu %20'lik kısma karşılık gelmektedir (Egghe ve Rousseau 1990, Egghe 1991).

Price Yasası

Price yasası karekök yasası olarak ta bilinmektedir. Bu yasaya göre belirli bir alanda önde gelen yazarların sayısı o alandaki toplam yazar sayısına kıyasla düşük seviyededir. Bu yasaya göre belirli bir alandaki toplam çalışma sayısının yarısı aynı alandaki toplam yazar sayısının karekökü ($\sqrt{N}$) kadar yazar tarafından üretilmiştir (Price 1976). Örneğin belirli bir alanda toplam 100 yazar olduğu belirlenmişse o alandaki toplam çalışma sayısının yarısı en üretken ilk 10 yazar tarafından üretilmiştir (Yılmaz 2008).

1.3. Konu İle İlgili Bilimsel Çalışmalar

1.3.1. Veteriner Hekimlikteki Bibliyometrik Analiz Çalışmaları

Veteriner hekimlik alanındaki bibliyometrik analiz çalışmaları incelendiğinde farklı disiplinlerden bibliyometrik çalışmalar olduğu belirlenmiştir. Uluslararası alanda veteriner hekimlik alanında yapılmış mevcut bibliyometrik çalışmalar:

Manuelian ve ark (2020), son zamanlarda organik hayvancılığa olan ilgi arttığından bibliyometrik analiz ile bu araştırma alanına genel bir bakış sağlamayı amaçlamışlardır. Sonuçlar incelendiğinde, 2018 yılına kadar organik hayvancılıkla ilgili toplam 320 belge yayınlandığını ve yıllık büyüme oranının %9,33 olduğunu belirlemişlerdir. En fazla yayınlanmış makaleye sahip ülke Almanya, en çok kullanılan anahtar kelimeler; hayvan refahı (29 kez), hayvan sağlığı (22 kez), sığır (15 kez), otlatma (10 kez) ve koyun (10 kez) olarak rapor edilmiştir. Bu çalışmada ülkelerin organik hayvancılık üretim araştırmalarını ana üretim alanlarına odakladığı ve sığır ve koyun dışındaki türlerde daha fazla araştırmaya ihtiyaç duyulduğu bildirilmiştir.

Banchi ve ark (2022), WoS veri tabanını kullanarak küçük hayvan üremesi ile ilgili son on yıllık literatürün bibliyometrik analizini yürütmeyi amaçlamışlardır. Bu çalışmada, belge ve atıf sayısına göre en üst sıradaki ülkeler Brezilya, ABD, İtalya, Polonya ve Kore olarak bildirilmiştir. Yazar anahtar sözcükleri, kategoriler ve son literatür incelemelerine göre yapılan analizler incelendiğinde, köpek türleri üzerindeki araştırmaların kedi türleri üzerindeki araştırmalardan daha fazla olduğu ve üreme biyoteknolojilerinin ana araştırma odağı olduğu rapor edilmiştir.

Sofyantor ve ark (2022), 1933 – 2022 yıllarında Scopus veri tabanında dizinlenen yılan zehri arařtırmalarındaki küresel literatür profilini analiz etmeyi amaçlamıřlardır. Çalışma sonucunda küresel ölçekte yayınlanan toplam belge sayısı 2999, yıllık ortalama belge sayısı ise 34 olarak rapor edilmiřtir. En fazla belge üreten ölkeler sırasıyla Brezilya (n=729), ABD (n=548), Avustralya (n=240) ve Kosta Rika (n=235) olarak bildirilmiřtir. Sonuçlar incelendiğinde, antivenom, proteomik ve transkriptomik gibi konuların bu alandaki arařtırmacılar için giderek daha fazla ilgi çekici hale geleceđi rapor edilmiřtir.

Yu ve ark (2023), son yirmi yılda toplanan Afrika Domuz Ateři (ASF: African Swine Fever) hakkındaki bilimsel yayınları düzenlemek, analiz etmek ve özetlemek için bibliyometrik yöntemleri kullanmayı amaçlamıřlardır. *Transboundary and Emerging Diseases* bu alanda en fazla yayını olan dergi, *Virus Research* makale başına en fazla atıf alan dergi olarak rapor edilmiřtir. En fazla makaleye sahip kurumun Çin Tarım Bilimleri Akademisi olduđunu, “transmission”, “identification”, “virulence”, “replication” ve “gene” anahtar kelimelerinin arařtırma sahasını yansıttığını bulmuřlardır. Sonuç olarak ASF patojenlerinin ve epidemiyolojisinin bu alandaki arařtırma noktaları ve arařtırma içeriđinin moleküler biyoloji ve immünoloji ile yakından iliřkili olduđu bildirilmiřtir.

Gonzalez-Alcaide ve ark (2023), sistiserkoz ve nörosistiserkoz ile ilgili arařtırmaların gelişimini, endemik yapılarına ve gelir düzeylerine göre, sađlanan bilimsel kanıt düzeyini ve farklı ölkelerin arařtırmalara katkısını göz önünde bulundurarak karakterize etmek için bibliyometrik analizi kullanmıřlardır. 1928 – 2021 yılları arasında yayınlanan toplam 7860 makale analiz etmiřlerdir. En verimli dergilerin Parazitoloji ve Tropikal Tıp kategorilerine ait olduđunu belirlemiřlerdir. Arařtırma çıktılarının hayvanlarda temel arařtırma, parazitizm, hayvan sađlığı ve zoonozlar ve sistiserkoz ve nörosistiserkoz ile iliřkili hastalıklarda tanı ve tedavi yaklařımı olmak üzere üç tematik kümede toplandıđı bildirilmiřtir. Sistiserkoza iliřkin bilgi üretiminin, yalnızca bazı endemik ölkelerin olađanüstü katkısı ve kapsamlı arařtırma yaklařımlarının (hayvan ve insan sađlığı) uygunluđu gibi konularda diđer arařtırma alanlarından farklı özellikler sunduđu sonucuna ulařmıřlardır.

Manasa ve ark (2024), dimension.ai veri tabanından elde edilen veriler ile

Ocak 2015'ten Haziran 2024'e kadar hayvancılık yayın arařtırmalarındaki eęilimleri arařtırmak amacıyla bibliyometrik analizi kullanmıřlardır. Bulgular, yıllar içinde bilimsel yayınlarda %51,55'lik kayda deęer bir artış ve hayvancılık verimlilięine, sürdürülebilirlięine ve sosyoekonomik sonuçlarını artırmaya yönelik artan ilgi olduęunu bulmuřlardır. Çalışmada ayrıca, 2016 yılında yayınlanan "Climate change vulnerability, adaptation and risk perceptions at farm level in Punjab, Pakistan" başlıklı makaleye en çok atıfta bulunulan yaklaşık 294 atıf tespit edilerek bu alandaki bilgi ve uygulamaların ilerletilmesindeki önemli rolleri rapor edilmiřtir.

Avcı ve ark (2023), köpek brusellozu üzerine yapılan arařtırmalardaki yayın eęilimlerini arařtırmayı ve bibliyometrik analiz kullanarak hastalıęın tarih boyunca geęirdięi deęiřimleri ve genel özelliklerini belirlemeyi amaçlamıřlardır. Bu amaçla, 1980 – 2022 yılları arasında Scopus ve WoS veri tabanlarında yayınlanan 316 makaleyi çalışmaya dahil etmiřlerdir. ABD (n=55), Brezilya (n=40) ve Arjantin'i (n=25) en fazla sayıda makale yayınlayan ülkeler olarak belirlemiřlerdir. Yayıının ilk yıllarında, "brucellosis", "infection", "abortion" ve "Brucella canis" gibi hastalık aęırlıklı ve "diagnosis", "serodiagnosis", "vaccine" ve "agar gel" gibi tanı ve tedaviyle ilgili anahtar kelimelerin önem kazandıęını ve giderek daha alakalı hale geldięini rapor etmiřlerdir. Bu çalışma ile belirlenen temalar ve alt temaların, daha fazla arařtırma ve bilimsel sorgulama için bir temel oluřturma potansiyeli ile ilgili arařtırmacılara yeni arařtırma sorularının ve fırsatlarının geliřtirilmesinde katkıda bulunabileceęini bildirmiřlerdir.

Miao ve ark (2022), ketamin kullanımı üzerine yapılan çalışmaların nicelięi ve nitelięi hakkında bilgi sahibi olmak için 2001'den 2020'ye kadar ketamin üzerine yapılan arařtırmaların bibliyometrik analizini yapmayı amaçlamıřlardır. ABD'nin ketamin hakkında en fazla sayıda makale yayınlayan ülke olduęunu ve ketamin hakkındaki makalelerin çoęunun *Anesthesia and Analgesia* dergisinde yayımlandıęını belirlemiřlerdir. Ayrıca, ketaminin antidepresan etkisinin son 20 yıldır bir arařtırma merkezi olduęunu bildirmiřlerdir. Bu çalışma ile ketamin üzerine yapılan arařtırmaların kapsamlı bir analizinin sunulduęu ve ketaminin antidepresan üzerine olan etkilerine artan ilgi olduęu rapor edilmiřtir.

Amado-Fuentes ve ark (2024), At Destekli Müdahaleler üzerine geleneksel bibliyometrik yasalar ve öneriler kullanarak bibliyometrik bir analiz

gerçekleştirmişlerdir. Yıllık yayın sayısında katlanarak artan bir eğilim ($R^2 = \%86$) ve bu konuya araştırmacılar, yayıncılar ve dergiler arasında giderek artan bir ilgi olduğu bildirilmiştir. ABD'yi dünya çapında en üretken ülke, Jeong-yi Kwon ve Ji Lee'yi üretken ortak yazarlar, en fazla makaleye sahip WoS kategorisini ise Rehabilitasyon ($n=84$) olarak belirlemişlerdir. Ayrıca en fazla yayına sahip dergileri *Journal of Alternative and Complementary Medicine* ve *Pediatric Physical Therapy* ve en fazla atıf alan makaleyi “State of the Evidence Traffic Lights 2019: Systematic Review of Interventions for Preventing and Treating Children with Cerebral Palsy” olarak bulmuşlardır. En fazla kullanılan yazar anahtar sözcüklerinin rehabilitation, balance ve Cerebral Palsy and Autism Spectrum Disorder gibi belirli popülasyonlarla ilgili olduğu rapor edilmiştir.

1.3.2. Veteriner Hekimlikteki Yapay Zekâ Çalışmaları

Bradley ve ark (2019), rutin veterinerlik uygulamaları sırasında okunan elektronik sağlık kayıtlarından elde edilen verileri kullanarak kronik böbrek hastalığı (KBH) olan kedilerde hastalık gelişme riskini tahmin etmek için bir model türetmeyi amaçlamışlardır. Verileri ikiye ayırarak %67'sini özellik seçimi ve en uygun sinir ağı türü ve mimarisinin belirlenmesini içeren bir tahmin modeli oluşturmak için, %33'ünü ise model performansını değerlendirmek için kullanmışlardır. Nihai modeli 4 özellikli (kreatinin, kan üre nitrojeni, idrar özgül ağırlığı ve yaş) bir RNN modeli olarak belirlemişlerdir. Model tanı noktasına yakın KBH'yi öngörürken, %90,7 duyarlılık ve %98,9 özgüllük gösterdiği ve ML tabanlı modellerin kullanımının, KBH'nin erken teşhisini kolaylaştırarak veteriner karar verme sürecini destekleyebileceği bildirilmiştir.

Shahinfar ve ark (2021), Naive Bayes (NB), Random Forest (RF) ve Multi-Layer Perceptron (MLP) olmak üzere üç ML algoritmasının süt üretimi ve konformasyon özelliklerini kullanarak topallık vakalarını tahmin etme kabiliyetini araştırmışlardır. Daha sonra bu algoritmaların performansını, ikili sınıflandırma için altın standart yaklaşım olarak Logistic Regression (LR) ile karşılaştırmışlardır. Topallık vakalarını tahmin etmek için Avustralya'daki dokuz sütçü işletmeden toplam 2535 topallık skoru (2248 sağlam ve 287 total) ve 29 tahmin edici özellik elde etmişlerdir. Eğitim için her bir sürüdeki verilerin %80'ini ve geri kalanını

doğrulama seti olarak kullandıklarını bildirmişlerdir. Sonuçlarda, alıcı işlem karakteristiği eğrisi (ROC: Receiver Operating Characteristic) altındaki alanı açısından LR (0,67) ve NB (0,66) arasında ihmal edilebilir farklar olduğunu, MLP (0,62) ve RF'nin (0,61) diğer iki yöntemle kıyasla daha düşük performans gösterdiğini rapor etmişlerdir. Bununla birlikte, NB'deki F1-skorunun (%27) LR'den (%1) daha iyi performans gösterdiğini bildirmişlerdir.

Kim ve ark (2023), miksomatöz mitral kapak hastalığı (MMVD) olan köpekler için ML tabanlı kalp yetmezliği riski tahmin modelleri geliştirmeyi amaçlamışlardır. Risk tahmin modelleri geliştirmek için dört makine öğrenme algoritması (RF, KNN, NB ve SVM) kullanmışlardır. Model performansını, ROC eğrisinin çizilmesi ve eğri altında kalan alanın (AUC: Area Under the Curve) hesaplanmasıyla belirlemişlerdir. RF modelinin diğer modellere göre üstün performans gösterdiği (AUC = 0,88) ve K-Nearest Neighbours (KNN) modelinin ise en düşük performans gösterdiği (AUC = 0,69) rapor edilmiştir. Bu ML modellerinin klinisyenlerin MMVD hastalarının prognozunu tahmin etmede karar alma süreçlerini destekleyeceğini bildirmişlerdir.

Huma ve Iqbal (2019), Pakistan'ın Balochi koyun ırkının koçlarının vücut ağırlığını modellemek ve tahmin etmek için regresyon ağaçları, SVM ve RF yöntemlerini kullanmışlardır. Bağımsız değişkenleri (girdiler) 2 – 36 aylık 131 erkek koyunun vücut (vücut uzunluğu, göğüs çevresi, cidago yüksekliği) ve testis (skrotal çap, skrotal çevre, skrotal uzunluk ve testis uzunluğu) ölçümlerinden elde etmişlerdir. Modellerin performansını, ortalama mutlak hata, ortalama mutlak yüzde hata, gözlenen ve uydurulan değerler arasındaki korelasyon, belirleme katsayısı ve kök ortalama karesel hata değerlendirme kriterlerine göre değerlendirilmişlerdir. RF modelinin hem eğitim hem de test veri kümeleri için en iyi sonuçları sağladığı, ML yöntemlerinin geleneksel modellerden daha iyi sonuçlar sağlayabileceği ve uygulayıcılar ile araştırmacıların çiftlik hayvanlarının vücut ağırlığı için en iyi tahmin edicileri seçmelerine yardımcı olabileceği bildirilmiştir.

Dumortier ve ark (2022), kedi toraks radyografi görüntülerinden özellikle Radyografik Pulmoner Patern'i (RPP) tespit etmek için bir CNN geliştirmeyi amaçlamışlardır. Sınıflandırma performanslarını iyileştirmek için 200 ağ, eğitim seti ve doğrulama setinin rastgele karıştırılmasıyla eğitildiği bildirilmiştir. Toraks

radıyografı g r nt leri  zerinde eęıtılen bu 200 aę  zerinden test setinde sırasıyla %82, %85, %75, %81 ve %88 ortalama Doęruluk, F1-Skoru,  zg ll k, Pozitif Tahmin Deęeri ve Duyarlılık elde etmiřlerdir. Son olarak,  nerilen yaklařımın veteriner hekimler i in yararlı olduęunun doęrulandıęı rapor edilmiřtir.

Fragoso-Garcia ve ark (2023), yaygın 7 k pek deri t m r n n (trikoblastom, skuam z h creli karsinom, periferik sinir kılıfı t m r , melanom, histiyositom, mast h cre t m r  ve plazmasitom) otomatik teřhisi i in ML tabanlı bir algoritma kullanmıřlardır.  alıřmada 350 hematoksilen ve eozin boyalı slayt (t m r tipi bařına 50) se ilmiř ve bir CNN eęitmek i in kullanmıřlardır. Daha sonra, tespit edilen t m r b lgelerini b lgesel olarak 7 t m r sınıfından 1'ine sınıflandırmıřlardır. Aę slayt d zeyinde %95'lik bir t m r sınıflandırma doęruluęuna ve b lge d zeyinde %85'lik bir doęruluęa ulařmıřlardır. Aynı  rnekler tanı i in 6 deneyimli patoloęa verilmiř ve bu patologlar da %98'lik benzer bir slayt seviyesi doęruluęu bildirmiřlerdir. Sonu  olarak AI tabanlı y ntemlerin tanısall onkolojik patolojide bir destek aracı olarak uygulanabilirlięini ve gelecekte dięer t rlerde ve t m r tiplerinde de uygulanabileceęini rapor etmiřlerdir.

Awaysheh ve ark (2016), noninvaziv tanı testlerinden elde edilen verileri kullanarak kedilerde inflamatuvar baęırsak hastalıęı ve sindirim sistemi lenfoması arasında ayırım yapmak i in denetimli ML algoritmalarının kullanımını test etmiřlerdir. NB, Decision Tree (DT) ve ANN olmak  zere    ML algoritması kullanılarak    tahmin modeli geliřtirmiřlerdir. Modelleri, normal, iltihaplı baęırsak hastalıęı veya sindirim sistemi lenfoması olan 3 kedi grubu i in tam kan sayımı ve serum kimyası sonu larından elde edilen veriler  zerinde eęitmiř ve test etmiřlerdir. NB ve ANN'nin, DT algoritmasından (%63, $p < 0,0001$) daha y ksek sınıflandırma doęruluęu (sırasıyla %70,8 ve %69,2 duyarlılıklar) elde ettięini bildirmiřlerdir. ML kullanan tahmin modellerinin normal, inflamatuvar baęırsak hastalıęı ve sindirim sistemi lenfoması olan kediler arasında ayırım yapmak i in bir y ntem ve hastalıklı ve hastalıksız kediler arasında ayırım yapma konusunda yardımcı olacak bařka bir noninvaziv tanı aracı saęlayabileceęini bildirmiřlerdir.

Kiouvrekis ve ark (2024), s t koyunu iřletmelerinde mastitisin yaygınlık d zeyine iliřkin tahminlerin yapılabileceęi bir hesaplamalı model geliřtirmeyi ama lamıřlardır. Verileri 18 deęiřkene ( iftliklerde uygulanan saęlık y netimi

uygulamalarıyla ilgili 17 bağımsız değişken, çiftliklerin bulunduğu yerlerdeki iklimsel veriler ve hedef değer olarak subklinik mastitis yaygınlık düzeyi) dayalı olarak iki kümeye ayırmak için denetimsiz öğrenme metodolojisi uygulamışlardır. K-ortalamların, hesaplama modelinin oluşturulması için çiftliklerin iki kümeye sınıflandırılmasında en yüksek önemi gösterdiğini belirlemişlerdir. Daha sonra enfeksiyonun yaygınlık düzeyini tahmin etmek için DT, KNN, SVM ve sinir ağı gibi denetimli öğrenme araçları kullanmışlardır. K-ortalamlar algoritması tarafından sunulan sonuçlar için modelin genel doğruluğu %94,1; çiftliklerdeki yaygınlık düzeyinin tahmini için ise %96,3 olarak bulmuşlardır. Sonuç olarak ML algoritmalarının süt koyunu çiftliklerinde subklinik mastitis seviyesinin tahmin edilmesinde faydalı bir şekilde kullanılabileceğini bildirmişlerdir.

Gouda ve ark (2022), Mısır'daki beş farklı eyaletten 233 hayvanın (125 koyun ve 108 keçi) seroprevalans çalışması verilerini kullanarak ML algoritmaları ile Mavi Dil (MD) riskini tahmin etmek ve algoritmaların performansını karşılaştırmayı amaçlamışlardır. Bunun için LR, DT, RF ve ANN algoritmaları kullanmışlardır. Model performansını, AUC, doğruluk, gerçek pozitif oranı, yanlış pozitif oranı, yanlış negatif oranı, kesinlik ve F1 puanı ile değerlendirmişlerdir. Sonuçlarda, RF'nin %81, ANN'nin %79,6 ve DT'nin %72,85 AUC skoru ile diğer modellerden daha iyi performans gösterdiğini rapor etmişlerdir.


Sotola ve Sotola (2024), inekleri sağlıklı ve subklinik mastitis riski altında olarak sınıflandırmak için kullanılabilecek modeller oluşturmak amacıyla ML yöntemlerini kullanmışlardır. Bu amaçla 3 sürüden 2227 Polonya Holstein-Friesian ineğine ait 19856 kayıt ve SVM, LR, NB, KNN ve DT algoritmalarını sınıflandırmada kullanmışlardır. Modelleri, sürü 1 için kaydedilen bilgilere ve hayvan kimliğine göre 80:20 eğitim-test bölünme oranı kullanılarak eğitmiş ve değerlendirmişlerdir. Sürü 2 ve 3 için kaydedilen bilgileri yalnızca sürü 1 veri kümesi kullanılarak geliştirilen görülmemiş veri modellerini değerlendirmek için kullanmışlardır. Tekli ML modelleri arasında SVM modeli, hem eğitim seti (ortalama F1-skoru 0,760) hem de sürü 1, 2 ve 3'e ait verileri içeren test setleri (sırasıyla F1-skoru 0,778, 0,790 ve 0,741) için kullanıldığında sonraki test gününde subklinik mastitisi tahmin etmede en doğru model olarak bulmuşlardır.

Veteriner hekimlik özelinde AI konusu yeni olduğundan çalışmaların hangi yönde gelişme gösterdiği, alanın entelektüel ve sosyal yapısı ile araştırmacılar arasındaki ilişkilere yönelik çalışmalar değer atfetmektedir. Bundan dolayı bu alandaki gelişimi takip etmek ve geleceğe yönelik popüler olması beklenen konuları tespit için literatüre geniş bakış açısı kazandıracak bir çalışmanın mevcut olmadığı tespit edilmiştir. Bu çalışmada, veteriner hekimlikte AI alanındaki literatürün genel haritasını çıkarmak ve en çok hangi alanlarda kullanıldığının bibliyometrik analiz ile belirlenmesi amaçlanmıştır. Bu amaç çerçevesinde alanda önde gelen araştırma ögelerinin ve alandaki işbirliklerinin belirlenerek alana katkıları değerlendirilecektir. Böylelikle ilgili araştırmacılara alanın genel bir çerçevesi sunularak literatür hakkında bilgi sahibi olmaları sağlanabilir. Ayrıca AI'nın veteriner hekimlik alt dalları arasındaki etkileşimini inceleyerek, multidisipliner bir yaklaşımın alana katkısı ortaya koyulmaya çalışılacaktır. Çalışma, tüm veteriner bilimlerinde AI yöntemleri kullanılarak yayınlanan makalelerin ilk bibliyometrik analizidir.

2. GEREÇ VE YÖNTEM

2.1. Gereç

Bu çalışmada veteriner hekimliği alanında AI ile ilgili güncel literatürü keşfetmek için Clarivate Analytics'in veri tabanı WoS (Philadelphia, PA, United States) kullanılmıştır. WoS ve Elsevier'in Scopus'u en büyük veri tabanlarıdır. Her iki veri tabanı da yayın etiğine uygun çalışmaları kapsamaktadır (Merigó ve Yang 2017). Bu veri tabanlarında veteriner hekimlik alanında AI çalışmaları için yapılan literatür taramasında Scopus ve WoS'ta filtreleme ile sırasıyla 212 ve 467 yayın elde edilmiştir. Bu doğrultuda, daha geniş bir literatüre ulaşma imkanı sağladığı için WoS tercih edilmiştir. Veri sorgusu 10 Kasım 2023 tarihinde gerçekleştirilmiştir. WoS'ta “veterinary” OR “veterinary sciences” OR “animal sciences” AND “machine learning” OR “deep learning” OR “artificial intelligence” OR “data mining” kavramları ile yapılan arama sonucu veteriner bilimleri alanında 531 çalışma tespit edilmiştir. Doküman türü (research article) ve dil (ingilizce) sınırlamaları yapıldığında açık erişim olan ve olmayan toplam 467 çalışmaya ulaşılmıştır. Bu 467 makale üzerinde yapılan incelemede, 70 makalenin kelime benzerliği nedeniyle arama sonuçlarına dahil edildiğini ve AI ile veterinerlik alanını içermediğini ortaya koymuştur. Sonuç olarak, bibliyografik veri seti, gerekli kriterleri karşılayan toplam 397 araştırma makalesini içermektedir (Şekil 2.1).



Şekil 2.1. Bu çalışma için yayın seçim süreci.

Bu araştırma için etik kurul onayı, 30.03.2023 tarihli ve 2023/027 sayılı karar ile Selçuk Üniversitesi Veteriner Fakültesi Deney Hayvanları Üretim ve Araştırma Merkezi Etik Kurulu (SÜVDAMEK)’ndan (EK-A) alınmıştır.

2.2. Yöntem

2.2.1. Analiz Metodu ve Kullanılan Yazılımlar

Veriler WoS’den “Full record and cited references” seçeneği ile “plain text” ve “bib text” formatında dışa aktarılmıştır. Veri setinde yer alan yayınlara ilişkin yıl, ülke, kurum, yazar ve atıf sayısı gibi göstergeler yer almaktadır. Çalışmada verilerin bibliyometrik analizi için R version 4,2,3 (R Foundation for Statistical Computing, Vienna, Austria) istatistik programında mevcut olan “bibliometrix” kütüphanesi ve Biblioshiny arayüzü ile VOSviewer 1,16,20 programı kullanılmıştır (Aria ve Cuccurullo 2017, Van Eck ve Waltman 2017). Akademisyen, dergi, kurumlar ve ülkelerin performans analizleri “bibliometrix” kütüphanesi yardımıyla

gerçekleştirilmiştir. Ortak atıf analizleri, bibliyografik eşleşme, kurumların ağ haritası ve kelime ağ analizleri VOSviewer yardımıyla gerçekleştirilmiştir. Ağ görselleştirmesinde, esas olarak her bir ögenin etiketine, boyutuna ve rengine odaklanılmıştır.

Araştırma nicel olarak alanın yapısını objektif olarak yansıtsa da bazı sınırlılıkları mevcuttur. WoS veri tabanı geniş bir dergi ağına sahip ve bibliyometrik çalışmalarda sıklıkla kullanılan bir veri tabanıdır. Ancak Scopus ve ScienceDirect gibi veri tabanları birbirinden farklı içerikler sunduğu için bu durum çalışmanın tekrar edilebilirliğini azaltacak, farklı veri tabanından kaynak sağlayan araştırmacılar farklı sonuçlarla karşılaşabilecektir. Bu durumu ortadan gidermek adına çalışmada kullanılan tek bir veri tabanı oluşu aynı zamanda çalışmanın kısıtlılığı olarak da değerlendirilebilir.

İngilizce dili dışında bu alanda yapılan çalışmaların kapsam dışı tutulması da sonuçları etkilemektedir. Ancak veri tabanlarında veri sorgulama aşaması anahtar kelimeler üzerinden yapıldığından aynı kelimenin farklı dillerde kullanımı dil karışıklığına sebep olmaktadır. Bundan dolayı sadece İngilizce çalışmalar analize dahil edilmiştir.

2.2.2. Bibliyometrik Metodoloji

Veteriner hekimlik alanında AI konulu çalışmalar bibliyometrik analiz ile incelenmiştir. Bibliyometrik analiz genel olarak performans analizi ve haritalama teknikleri olarak 2 bölümden oluşmaktadır. Performans analizi sayısal hesaplamalara ilişkin metrikleri verirken haritalama teknikleri çalışma ögeleri arasındaki ilişkiyi görsel olarak değerlendirme imkanı sunmaktadır (Donthu ve ark 2021). Bu çalışmada performans analizine yönelik h, g, m indeks, toplam makale sayısı, toplam atıf sayısı, Dergi Etki Faktörü (JIF: Journal Impact Factor) ve JIF Quartile göstergeleri kullanılmıştır. Ayrıca bibliyometrik yasalardan Lotka ve Bradford yasası kullanılmıştır.

Bibliyometrik yasalardan Bradford yasası, belli bir konudaki literatürün önemli bir kısmını (üçte biri) içerisine alan küçük bir dergi grubunu belirlemekte

kullanılmaktadır (Garfield 1980). Lotka yasası ise belirli bir alandaki yazarların o alana katkılarının nasıl dağıldığını tespit ederek bilimsel üretkenliği ölçmeye çalışan bir yasadır. Lotka yasasına göre yazarların %60'ının bir makale, %15'inin iki makale ve %7'sinin üç makale ile alana katkıda bulunması beklenmektedir (Sudhier 2013).

Bibliyometrik Çalışmada Kullanılan Göstergeler

h indeksi: h indeksi, Jorge E. Hirsch tarafından bulunan çalışma ve atıf sayısını dikkate alan bir performans indeksidir. h indeksi, en az h atıf alan bir yazarın makale sayısıdır ve dolayısıyla araştırmacının yayınlarının sayısına ve bunların etkisine bağlıdır. h indeksi günümüzde önemli etki ölçülerinden biridir. Ancak zamanın etkisinde kalması, atıf ve makale sayısı yüksek araştırmacılarda düşük çıkması gibi bazı dezavantajlarından dolayı eleştirilmektedir (Hirsch 2005, Bornmann ve Daniel 2007).

g indeksi: h indeksinin eleştirilerinin sonucu olarak Leo Egghe tarafından g indeksi geliştirilmiştir. g indeksi, yayınlara yapılan atıf sayılarını azalan bir şekilde sıraladığında g kadar çalışmanın toplam atıf sayısını en az g^2 'ye eşitleyen en büyük sayıdır. g indeksi yüksek atıf alan çalışmalara daha fazla ağırlık verirken h indeksi bu durumu dikkate almaz (Egghe 2006).

m indeksi: h indeksi, atıf almak için yeterli süre olmadığından genç araştırmacılar için uygun değildir. Bundan dolayı Hirsch, h indeksini araştırmacının aktif olduğu yıl sayısına bölerek m indeksini oluşturmuştur (Harzing 2012).

Atıf Etkisi (AE): Bir araştırma alanına ait yayınların almış oldukları atıf sayısına bölünmesiyle atıf etkisi elde edilmektedir (Waltman 2016).

Kategori Normalleştirilmiş Atıf Etkisi (KNAE): KNAE, konu odağı, yaş ve belge türü için normalleştirilmiş bir etki göstergesidir. KNAE değerinin 1 olması dünya ortalamasıyla eşit performansı temsil ederken, 1'in üzerindeki değerler ortalamanın üzerinde, birin altındaki değerler ise ortalamanın altında kabul edilir. KNAE değerinin iki olması dünya ortalamasının iki katı olarak kabul edilir. Örneğin 2014 yılında Plant Sciences kategorisinde yayınlanan bir makaleye 46 kez atıf yapılmışsa, bunun performansını belirlemek için öncelikle, makaleyi karşılaştıracak bir referans alıntı oranı hesaplamamız gerekir. Plant Sciences Kategorisi için Beklenen Atıflar =

Aynı belge türü, yıl (2014) ve kategori için ortalama atıf = 2,32 bulunur. Buna göre;

$$KNAE = \frac{\text{Gerçek Atıflar}}{\text{Kategori Beklenen Atıflar}}$$

$$KNAE = \frac{46}{2,32} = 19,82 \text{ olarak hesaplanır (Center 2024).}$$

Uluslararası İşbirliği: Bir makalede iki veya daha fazla farklı ülkeden ortak yazarların varlığıyla tanımlanır (Jiang ve ark 2018).

Dergi Etki Faktörü: Bir dergide yayınlanan makalelerin önceki iki yıl içerisinde atıf alma sayısının, aynı aralıkta o dergi tarafından yayınlanan makale sayısına bölünmesiyle hesaplanır (Kumar ve ark 2009).

DEF Çeyreklik: Etki faktörüne göre sıralandığında derginin kategorideki sırası aynı kategoride yer alan toplam dergi sayısına bölünerek hesaplanır. $Z = (X/Y)$ formülü ile hesaplanır. Burada X kategorideki dergi sıralaması, Y ise kategorideki dergi sayısıdır. Örneğin bir dergi bir kategoride 314 dergi arasında 78. sıradaysa, $Z=(78/314)=0,248$, yani Q1 dergisidir (Support 2024).

Akademik-Kurumsal İşbirliği: Akademik ve kurumsal bağlantıları olan belgelerin yüzdesini gösterir (Guides 2024).

Bağlantılar: Bir araştırmacının diğer araştırmacılarla olan ortak yazarlık bağlantılarının sayısını göstermektedir. Örneğin anahtar kelime analizi için bir kavramın kaç anahtar kelimeyle bağlantılı olduğunu göstermektedir (Van Eck ve Waltman 2022).

Toplam Bağlantı Gücü: Bir araştırmacının diğer araştırmacılarla ortak yazarlık bağlantılarının toplam gücünü ifade eder. Örneğin anahtar kelime analizi için toplam bağlantı gücü diğer tüm kavramlarla birlikte kaç kez kullanıldığını göstermektedir (Van Eck ve Waltman 2022).

Yazar Ayak İzi İndeksi: Bir makaleye katkıda bulunan yazar sayısı ile bu yazarların isimlerinin geçme sıklığı arasındaki ilişki analiz edilir. Yazar sayısı makalelerde yer alan toplam isim sayısına bölünür ve elde edilen değer 1'den çıkarılarak yazar ayak izi indeksi hesaplanır (Atabay ve ark 2019).

İşbirliği İndeksi: Birden fazla yazarın alandaki yayınlarıyla ilgili bir göstergedir. Bu indeks çok yazarlı makalelerin yazar sayısının çok yazarlı makale sayısına bölünmesiyle hesaplanır (Ajiferuke ve ark 1988).



3.BULGULAR

3.1. Genel Yayın Eğilimleri


AI ilgili temel istatistikler Tablo 3.1’te verilmiştir. Veteriner hekimlikte AI’nın kullanımı ile ilgili bibliyometrik verilere ilişkin genel bilgiler incelendiğinde 1995 – 2023 döneminde 65 farklı dergiden çalışmalar analize dahil edilmiştir. 28 yıllık zaman aralığında bu alanda toplam 397 adet makale yazılmıştır. Yazar sayısı 1758 olup, tek yazarlı çalışma sayısı 9’dur. Makale başına düşen atıf sayısı 6,25 ve toplam referans sayısı 13958’dir. Bibliyografik veriler 1127 keywords plus ve 1437 yazar anahtar kelimesi içermektedir. Yazarların işbirliğine ait istatistikler incelendiğinde, yazar başına makale sayısı 0,23, makale başına yazar sayısı 4,42, makale başına ortak yazar sayısı 5,45, uluslararası ortak yazarlık oranı %27,46 ve işbirliği indeksi 4,53’tür. Bu çalışmalara 1758 yazarın katkıda bulunduğu ve yazarların isimlerinin 2163 kez geçtiği tespit edilmiştir. Yayınların büyük çoğunluğu (%97,22) birden fazla yazara sahiptir. Yazar ayak izi indeksi değeri 0,18 olarak elde edilmiştir.

Tablo 3.1. AI ilgili temel istatistikler.

Tanım	Sonuçlar
Veri Hakkında Temel Bilgiler	
Zaman aralığı	1995; 2023
Kaynaklar (dergiler, kitaplar, vb.)	65
Belgeler	397
Yıllık büyüme oranı %	17,88
Belge ortalama yaşı	2,71
Doküman başına ortalama atıf	6,25
Referanslar	13958
Doküman Türleri	
Makale	378
Makale; erken erişim	8
Makale; bildiri metni	11
Doküman İçeriği	
Anahtar kelimeler plus	1127
Yazarın anahtar kelimeleri	1437
Yazarlar	
Yazarlar	1758
Yazar görünümleri	2163
Tek yazarlı belgelerin yazarları	9
Çok yazarlı belgelerin yazarları	1749
Yazar İşbirliği	
Tek yazarlı belgeler	11
Çok yazarlı belgeler	386
Yazar başına belge	0,23
Belge başına yazar	4,42
Belge başına ortak yazarlar	5,45
İşbirliği indeksi	4,53
Yazar ayak izi indeksi	0,18
Uluslararası ortak yazarlıklar %	27,46


Veteriner hekimlikte AI alanındaki çalışmaların yayın eğilimleri incelendiğinde 1995 – 2023 yıllarında makale sayısında önemli bir artış gerçekleşmiştir. Yıllık büyüme oranı %17,88’dir. Ancak büyüme doğrusal bir eğilim

göstermemektedir. Genellikle 2018 yılına kadar yayın sayısı durağan seyrederken 2018 yılından itibaren keskin bir artış gerçekleşmiş ve yayın sayısı sürekli artma eğilimi göstermiştir. 2018 yılında bu alanda sadece 7 makale yayınlanmışken bu sayı 2019 yılında 27, 2020 yılında 36, 2021 yılında 70 ve 2022 yılında 105'e çıkmıştır. Kasım 2023 itibari ile de şu ana kadar 2023 yılında 100 makale yayınlanmıştır (Şekil 3.1).



Şekil 3.1. Veteriner hekimlikte AI üzerine yıllık bilimsel üretim.

Şekil 3.2’deki üç alan grafiğinde alanda öne çıkan “kaynaklar (SO), “yazarlar (AU)” ve “anahtar kelimeler (DE)” arasındaki ilişkiler görülmektedir. Analiz sonucunda, Animals ile Frontiers in Veterinary Science dergileri alanda öne çıkan kaynaklar olarak dikkat çekmektedir. Jayon Kim ile Guoming Li alandaki etkili yazarlardan ikisidir. Alanda önde gelen araştırmacılar çalışmalarında yazar anahtar kelimeleri olarak çoğunlukla “deep learning” ve “artificial intelligence” kullanmayı tercih etmişlerdir.



Şekil 3.2. AI üç alan grafiği, kaynaklar (solda), yazarlar (ortada) ve anahtar kelimeler (sağda)

3.2. Dergiler

En çok yayın yapan dergiler ve h, g ve m indeksleri Tablo 3.2’de verilmiştir. AI ile ilgili çalışmalarda alanda önde gelen dergiler bilimsel metrikler göz önünde bulundurularak değerlendirilmiştir. h, g indeks, toplam yayın ve atıf sayısına göre ilk iki sırada Animals ve Preventive Veterinary Medicine dergileri yer almaktadır. Alanda ilk sırada gelen Animals dergisinin amaç ve kapsamı yakından incelendiğinde hayvan etiği başta olmak üzere hayvanları içeren herhangi bir alandaki önemli çalışmalara yer verdiği belirlenmiştir. Dergideki AI çalışmaları incelendiğinde çalışmaların çoğunlukla hayvan davranışları, hayvan refahı ve hayvan

takip sistemleri gibi konular olduđu belirlenmiřtir. Preventive Veterinary Medicine dergisi incelendiğinde hayvan saėlıėı, veteriner epidemiyolojisi ve hastalık kontrolü gibi konularda alıřmalar olduđu belirlenmiřtir. Dergideki AI alıřmaları incelendiğinde hastalıkların sınıflandırılması, hastalık tespiti ve salgın tahmini gibi konularda ML ve DL alıřmalarına rastlanmaktadır. m indeksi en yüksek iki dergi Animals ve Frontiers in Veterinary Science dergileridir. Dergilerin AE incelendiğinde en yüksek AE deėerine sahip iki dergi Transboundary and Emerging Diseases ve Veterinary Journal dergileridir. AI alanındaki en iyi 10 derginin 8'inin KNAE'si 1'in (dünya ortalaması) üzerindedir. Dergilerin uluslararası iřbirliėi yüzdesi incelendiğinde en yüksek iřbirliėi oranının Transboundary and Emerging Diseases ve Preventive Veterinary Medicine dergilerinde olduđu görölmektedir.



Tablo 3.2. En çok yayın yapan dergiler ve h, g ve m indeksleri (ilk 10 dergi).


Kaynak	h indeksi	g indeksi	m indeksi	TA	YS	AE	KNAE	Uİ (%)	DEF	DEF Çeyrek	Ülke
Animals	11	15	2,200	405	106	3,82	1,37	32,36	3	Q1	İsviçre
Preventive Veterinary Medicine	9	14	0,474	236	32	7,38	1,38	40,89	2,6	Q1	Hollanda
Animal	6	10	0,429	109	12	9,08	1,68	38,73	3,6	Q1	İngiltere
Frontiers in Veterinary Science	6	11	0,667	178	49	3,63	1,41	34,41	3,2	Q1	İsviçre
Bmc Veterinary Research	5	10	0,313	110	10	11	1,33	29,52	2,6	Q1	İngiltere
Veterinary Journal	5	6	0,227	85	6	14,17	1,13	33,22	2,2	Q2	İngiltere
Veterinary Radiology & Ultrasound	5	9	0,455	92	16	5,75	0,86	20	1,7	Q2	ABD
Journal of Veterinary Internal Medicine	4	6	0,800	37	7	5,29	1,28	29,62	2,6	Q1	ABD
Kafkas University Journal of Veterinary Faculty	4	6	0,400	41	9	4,56	0,39	10,62	0,7	Q3	Türkiye
Transboundary and Emerging Diseases	4	4	0,308	58	4	14,50	1,82	43,54	4,3	Q1	Almanya

TA: Toplam Atıf, YS: Yayın Sayısı, AE: Atıf Etkisi, KNAE: Kategori Normalleştirilmiş Atıf Etkisi, Uİ: Uluslararası İşbirliği, DEF: Dergi Etki Faktörü

Bradford yasası dikkate alındığında, alana kaynaklık yapan dergilerden Animals ve Frontiers in Veterinary Science dergilerinin önemli ve temel dergiler olduđu belirlenmiştir (Şekil 3.3).



Core Sources by Bradford's Law



Şekil 3.3. Bradford's yasası.

3.3. Yazarlar

Veterinerlik alanındaki AI çalışmalarında ilk 10 sıradaki yazarların AI çalışmalarıyla sınırlandırılmış h, g, m indeksi ve kendi alanlarında literatüre katkısı ve işbirliklerini belirten metrikler Tablo 3.3'te verilmiştir. h ve g indeksleri açısından en yüksek puana sahip ilk 3 yazar Tommaso Banzato (İtalya), Ecevit Eydurur (Türkiye) ve Alessandro Zotti (İtalya)'dır. m indeksine göre en yüksek puana sahip yazar Jayon Kim (Güney Kore) olurken onu Tommaso Banzato (İtalya) takip etmektedir. Bu alanda en fazla yayına sahip olan ve atıf alan yazarlar incelendiğinde ilk sırada Ecevit Eydurur, ikinci sırada Tommaso Banzato ve üçüncü sırada Alessandro Zotti gelmektedir. AE incelendiğinde ilk 3 sırada Ecevit Eydurur, Lilong Chai ve Tommaso Banzato gelmektedir. Yazarların KNAE değerlerine göre 10 yazardan 7'sinin 1'in üzerinde olduğu görülmektedir. Yazarların çalışmalarının uluslararası işbirliği oranı incelendiğinde Ecevit Eydurur, Guoming Li ve Lilong Chai öne çıkmaktadır. Uluslararası işbirliği olmayan tek yazar ise Jayon Kim'dir.

Tablo 3.3. Yazarların h, g ve m indeksleri (ilk 10 yazar).


Yazarlar	h indeksi	g indeksi	m indeksi	TA	YS	AE	KNAE	AKİ (%)	Uİ (%)	Ülke
Banzato, Tommaso	5	8	0,833	85	8	10.63	1.32	12.2	20	İtalya
Eyduran, Ecevit	4	8	0,500	96	8	12.00	1.22	0	77.78	Türkiye
Zotti, Alessandro	4	7	0,667	58	7	8.29	1.28	10.6	20.83	İtalya
Brunton Lucy, A.	3	3	0,750	26	3	8.67	1.55	7.7	37.50	İngiltere
Celik, Senol	3	7	0,375	64	7	9.14	0.87	0	25	Türkiye
Chai, Lilong	3	4	0,750	45	4	11.25	2.26	5.8	56.52	ABD
Chang, Yu-Mei Ruby	3	3	0,750	26	3	8.67	0.95	7.7	25	İngiltere
Drewe, Julian, Ashley	3	3	0,750	26	3	8.67	1.64	4.2	40	İngiltere
Kim, Jayon	3	3	1	13	7	1.85	0.68	0	0	Güney Kore
Li, Guoming	3	5	0,750	25	5	5	1.37	0	60.87	ABD

TA: Toplam Atıf, YS: Yayın Sayısı, AE: Atıf Etkisi, KNAE: Kategori Normalleştirilmiş Atıf Etkisi, AKİ: Akademik-Kurumsal İşbirliği, Uİ: Uluslararası İşbirliği

Lotka yasası ve yazar sayıları ile yayınladıkları makale sayıları Tablo 3.4’de verilmiştir. Buna göre makale ve yazar sayıları incelendiğinde yazarların %85,7’sinin bir makale, %9,2’sinin iki makale, %3,2’sinin üç makale ile katkıda bulunduğu görülmektedir. Dağılımın Lotka yasasına uymadığı görülmektedir. Gelişen bilgisayar ve yazılım teknolojileri ile beraber ilerleyen yıllarda ilgili ihtiyaç duyduğundan dağılım sapma gösterebilir. Ancak 5’ten fazla yayına sahip yazarların AI alanında derinleştiği ve çekirdek yazar olarak değerlendirilmesi gerektiği söylenebilir (Şekil 3.4).


Table 3.4. Lotka yasası ve yazarların makale sayısı.

Makale sayısı	Yazar sayısı	Yazar oranı
1	1507	0,857
2	162	0,092
3	56	0,032
4	19	0,011
5	4	0,002
6	2	0,001
7	6	0,003
8	2	0,001



Şekil 3.4. Lotka yasası.

Şekil 3.5'te AI ortak yazarlık ağ haritası verilmiştir. AI alanında önde gelen yazarlar arasındaki işbirliğini tespit etmek için alanda yayın sayısı sınırlaması olmadan yazarlar arasındaki bağlantılar görselleştirilmiştir. Şekil incelendiğinde aralarında en fazla bağlantı bulunan yazarlar arasındaki analize göre 4 kümede birleşen 46 yazar ve toplam 385 bağlantı görülmektedir. En çok atıf alan yazarların 96 atıf ile Ecevit Eydur, 78 atıf ile Andres Martin Perez ve 66 atıf ile Zhanjiang Liu olduğu görülmektedir.



Şekil 3.5. AI ortak yazarlık ağ haritası.


3.4. Kurumlar

Kurumlar veya üniversitelerin yayın sayılarına ilişkin bilgiler Tablo 3.5'te verilmiştir. 397 makaleye ait 663 kurum belirlenmiştir. Kurum sayısının makale sayısına göre fazla olması alandaki işbirliği yüzdesinin yüksek olması ile açıklanabilmektedir. Kurumların veterinerlik alanında AI çalışmaları yönünden üretkenlikleri incelendiğinde en fazla yayın sayısına sahip 3 kurum California Davis Üniversitesi (ABD), Padua Üniversitesi (İtalya) ve Çin Tarım Üniversitesi (Çin) şeklindedir. Ayrıca bu kurumlar, üniversitelere ait h indeksi sıralamasında da ilk 3 sırada gelmektedir. Kurumların KNAE değerleri incelendiğinde ilk 10 kurumdan 8'inin üretkenliğinin 1'in üzerinde olduğu tespit edilmiştir. Kurumların uluslararası işbirliği oranı incelendiğinde ilk sırada Bern Üniversitesi, ikinci sırada Padua Üniversitesi ve üçüncü sırada Guelph Üniversitesi gelmektedir (Şekil 3.6).

Tablo 3.5. Üniversitelerin yayın sayıları (ilk 10).

Kurum/Üniversite	MS	h indeksi	KNAE	Uİ (%)	Ülke
University of California Davis	37	213	1,55	42,14	ABD
University of Padua	32	222	1,57	52,20	İtalya
China Agricultural University	30	132	1,42	31,75	Çin
University of Guelph	26	116	1,21	49,16	Kanada
Iğdir University	24	38	0,87	20,67	Türkiye
University of Georgia	19	133	1,21	32,27	ABD
University of Tennessee Knoxville	17	169	1,36	41,70	ABD
Kangwon National University	16	83	0,85	26,71	Güney Kore
University of Bern	16	233	1,74	68,26	İsviçre
University of Minnesota Duluth	16	57	1,23	38,82	ABD

MS: Makale Sayısı, KNAE: Kategori Normalleştirilmiş Atıf Etkisi, Uİ: Uluslararası İşbirliği



Şekil 3.6. Kurumlar arası iş birliği haritası.

3.5. Ülkeler

Tek ve çoklu ülke yayını oranları Tablo 3.6’da verilmiştir. Coğrafi olarak veri setindeki en yüksek yayın ve atıf sayısına sahip ülke ABD olurken, onu Çin ve Türkiye takip etmektedir. Ayrıca bu 3 ülke Dünya’da veteriner hekimlikteki AI çalışmalarının %41,1’ini oluşturmaktadır. Alana özgü atıf etkisine bakıldığında en yüksek AE değerine sahip ülke Güney Kore olmuştur. Çoklu ülke yayını (ÇÜY; MCP: Multiple Country Publications) %50 oranını yakalayan tek ülke olan Avustralya uluslararası işbirliğinin en yüksek olduğu ülke olmuştur. Tek ülke yayını (TÜY; SCP: Single Country Publications) en fazla olan ülke ise ABD olmuştur. Ülkelere ait KNAE değerleri incelendiğinde ilk 10 ülkeden 8’inin bilimsel üretkenliğinin 1’in üzerinde olduğu tespit edilmiştir.




Tablo 3.6. Tek ve çoklu ülke yayını oranları.

Ülke	TA	YS	AE	Sıklık	TÜY	ÇÜY	ÇÜY Oranı	KNAE	Bağlantılar	TBG
ABD	537	72	7,46	0,181	45	27	0,375	1,29	33	75
Çin	276	63	4,38	0,159	51	12	0,19	1,14	14	24
Türkiye	242	28	8,64	0,071	25	3	0,107	0,86	3	5
Güney Kore	236	23	10,26	0,058	18	5	0,217	1,08	8	9
Birleşik Krallık	167	23	7,26	0,058	18	5	0,217	1,47	19	40
İtalya	124	19	6,53	0,048	16	3	0,158	1,33	12	18
Almanya	101	18	5,61	0,045	11	7	0,389	1,29	20	42
Kanada	74	15	4,93	0,038	8	7	0,467	1,39	18	28
Brezilya	68	14	4,86	0,035	12	2	0,143	0,81	5	8
Avustralya	66	10	6,60	0,025	5	5	0,5	1,50	8	11

TA: Toplam Atıf, YS: Yayın Sayısı, AE: Atıf Etkisi, TÜY: Tek Ülke Yayını, ÇÜY: Çoklu Ülke Yayını, KNAE: Kategori Normalleştirilmiş Atıf Etkisi, TBG: Toplam Bağlantı Gücü


Şekil 3.7’de AI alanında ülkelere ait işbirliği ağı verilmiştir. Ağdaki düğümlerin büyüklüğü ülkelerin yayın sıklığını göstermektedir. Ağdaki 48 ülke 12 kümeli bir yapı oluşturmaktadır. Aynı kümedeki ülkeler birlikte daha fazla yayın yapma eğilimindedir. Ağ incelendiğinde en fazla işbirliğinin ABD ve Çin’in bulunduğu kümelerde olduğu görülmektedir. Ayrıca bu 2 kümedeki en etkin ülkelerin yine ABD ve Çin olduğu tespit edilmiştir. Bağlantı sayısı ve toplam bağlantı gücü dikkate alındığında ABD, Çin, Birleşik Krallık ve Kanada işbirliği ağının etkin ülkeleri olarak karşımıza çıkmaktadır.





Şekil 3.7. Ülkeler arası işbirliği haritası.

Şekil 3.8’de sorumlu yazarların ülkelerine ait işbirliği grafiği verilmiştir. En fazla uluslararası işbirliğine sahip ülke ABD olurken, MCP oranı toplam yayının %37,5’ini oluşturmaktadır. Avustralya ise yayın sayısına göre onuncu sırada yer alırken, MCP oranına göre ilk sırada yer almaktadır.



Şekil 3.8. Sorumlu yazarların ülkeleri.

3.6. Anahtar Kelimeler

Yazarların anahtar kelimelerinin ağ analizi Şekil 3.9’da verilmiştir. Alandaki anahtar kelimelerin eğilimi incelendiğinde AI çalışmalarında kullanılan önemli kavramların yıllar içinde nasıl değiştiği ve hangi kavramların güncel olduğu belirlenebilmektedir. Bu bağlamda kelime ağı incelendiğinde machine learning, artificial intelligence, deep learning ve convolutional neural network kavramlarının sıklıkla kullanıldığı görülmektedir. Image processing, classification, data mining algorithm, active learning ve computer-aided diagnosis kavramlarının ise yakın tarihli çalışmalarda daha fazla tercih edildiği görülmektedir.



Şekil 3.10. Kelime ağaçları; a) Makale başlığı, b) Özet, c) Kaynakça, d) Anahtar kelimeler


3.7. Ortak Atıf

Ortak atıf analizi, iki çalışmanın birlikte alıntılanma sıklığını göstermektedir. Dergilerin ortak atıf analizi incelendiğinde, minimum atıf sayısı 20 olarak belirlendiğinde 102 dergi elde edilmiştir. Dergilerin ortak atıf ilişkisi ve ağ haritasındaki düğümleri Şekil 3.11’de görülmektedir. Tablo 3.7’de, alandaki ortak atıf yapılan ilk 10 dergiye ait atıf sayıları listelenmektedir. Computers and Electronics in Agriculture en çok atıf alan dergi olurken (439 atıf, JIF 2023 = 8,3, Q1), onu Journal of Dairy Science (412 atıf, JIF 2023 = 3,5, Q1) ve Plos One (249 atıf, JIF 2023 = 3,7, Q2) takip etmektedir. Ayrıca, Scientific Reports en yüksek etki faktörüne sahip ikinci dergi olup (JIF 2023 = 4,6), multidisipliner alandaki en iyi dergilerden biri olmakla birlikte profesyonel alanda yüksek bir otoriteye sahiptir.

Tablo 3.7. AI ile ilgili ortak atıf yapılan ilk 10 dergi.

Dergiler	Atıflar	DEF	DEF Çeyrek	Kategori	Ülke
Computers and Electronics in Agriculture	439	8,3	Q1	Agriculture, Multidisciplinary; Agronomy; Computer Science, Interdisciplinary Applications	İngiltere
Journal of Dairy Science	412	3,5	Q1	Agriculture, Dairy & Animal Science; Food Science & Technology	ABD
Plos One	249	3,7	Q2	Biology; Multidisciplinary Sciences	ABD
Animals	243	2	Q1	Agriculture, Dairy & Animal Science; Veterinary Sciences	İsviçre
Preventive Veterinary Medicine	228	2,6	Q1	Veterinary Sciences	Hollanda
Scientific Reports	150	4,6	Q2	Multidisciplinary Sciences	İngiltere
Journal of Animal Science	145	3,3	Q1	Agriculture, Dairy & Animal Science	ABD
Applied Animal Behaviour Science	144	2,3	Q1	Agriculture, Dairy & Animal Science; Behavioral Sciences; Veterinary Sciences	Hollanda
Veterinary Journal	141	2,2	Q2	Veterinary Sciences	İngiltere
Journal of Veterinary Internal Medicine	139	2,6	Q1	Veterinary Sciences	ABD

DEF: Dergi Etki Faktörü




Şekil 3.11. AI ile ilgili ortak atıf alan dergilerin görselleştirme ağ haritası.

Çalışmada analiz nesnesi olarak 13925 referans kullanılmış ve atıf yapılan makalelerin minimum atıf sayısı 5 olarak belirlenmiştir. Böylece ortak atıf analizi için 136 referans elde edilmiştir. En fazla atıf yapılan 145 makalenin görsel analizi 4 küme oluşturmuştur. Küme 1’de yer alan çalışmalar incelendiğinde hayvanlarda yüz tanıma, hayvan davranış tahmini ve yüz görüntüleriyle koyunların biyometrik tahmini gibi DL algoritmalarının kullanıldığı çalışmalar olduğu belirlenmiştir. Küme 2’deki çalışmalar veri madenciliği algoritmaları kullanılarak hayvanlarda canlı ağırlık tahmini yapılması ve algoritmaların tahmin performanslarının karşılaştırılması ile ilgilidir. Küme 3’deki çalışmaların DL’ye dayalı hayvanlarda hastalık tespiti ile evrimsel sinir ağlarına dayalı DL çalışmalarının olduğu belirlenmiştir. Küme 4’deki çalışmalar ise genellikle istatistiksel öğrenme, ANN, LR ve RF gibi ML algoritmalarının tıp ve veteriner bilimlerinde kullanımının avantaj ve dezavantajlarına değinen çalışmalar olduğu tespit edilmiştir. Bu 136 referans içerisinde en çok ortak atıf yapılan ilk 10 referans Tablo 3.8’de verilmiştir.

Tablo 3.8. Ortak atıf yapılan ilk 10 referans.


Küme	Başlık	Yıl	Atıflar
1	<i>R</i> Core Team (2020) <i>R</i> : A Language and Environment for Statistical Computing. <i>R</i> Foundation for Statistical Computing, Vienna.	2020	30
1	Deep Residual Learning for Image Recognition	2016	29
4	Random forests	2001	25
3	Very deep convolutional networks for large-scale image recognition	2015	19
2	Comparison of Artificial Neural Network and Decision Tree Algorithms used for Predicting Live Weight at Post Weaning Period From Some Biometrical Characteristics in Harnai Sheep	2015	18
1	Faster r-cnn: Towards real-time object detection with region proposal networks	2015	18
2	Comparison of the Predictive Capabilities of Several Data Mining Algorithms and Multiple Linear Regression in the Prediction of Body Weight by Means of Body Measurements in the Indigenous Beetal Goat of Pakistan	2017	17
2	Examples of the use of data mining methods in animal breeding	2012	17
2	You only look once: Unified, real-time object detection	2016	17
4	Building predictive models in <i>R</i> using the caret package	2008	16

R Core Team (2020) *R: A Language and Environment for Statistical Computing*. *R* Foundation for Statistical Computing, Vienna en fazla atıfta bulunulan çalışmadır. *R* programının özellikleri hakkında ayrıntılı bilgi verir. Deep Residual Learning for Image Recognition en fazla atıfta bulunulan ikinci çalışmadır. Bu çalışma DL ve kullanılan algoritmalar hakkında bilgi verir. RF ise en fazla atıfta bulunulan üçüncü çalışmadır. Bu çalışma ML algoritmalarından olan RF hakkında ayrıntılı bilgi vermektedir. İlk 10 sıradaki çalışmaların genel olarak AI metotları ve algoritmalar hakkında olduğu söylenebilir (Şekil 3.12).



Şekil 3.12. AI ile ilgili ortak atıf alan referansların görselleştirme ağ haritası.

Şekil 3.13'teki eserlerin bibliyografik eşleşmesi incelendiğinde, en az 1 atıf almak kriteri ile seçilen ve aralarında bağlantı bulunan 287 eser ile yapılan analize göre, 11 küme, 2342 bağlantı ve 4116 toplam bağlantı gücü elde edilmiştir. En fazla bibliyografik eşleşme olan yayınlar 207 alıntı ile Douglas (2003), 59 alıntı ile Tong (2015) ve 54 alıntı ile Benaissa (2019) olmuştur.



Şekil 3.13. Belgelerin bibliyografik eşleşmesi.

4. TARTIŞMA

Veteriner hekimlikte AI alanındaki çalışmalar 1995 yılında başlamasına rağmen 2019 yılına kadar kayda değer bir artış gerçekleşmemiştir. Bilgisayar ve yazılım teknolojisindeki gelişmelerle birlikte AI algoritmalarının veteriner hekimlikte kullanımı son yıllarda önemli derecede artış göstermiştir (Owens ve ark 2023). Bu alandaki ilgili yayınların 1995 yılında yayınlanmaya başlanmasına rağmen yayınların %85'inin son 5 yıla ait olması ve yayınların kısa bir dönemde gerçekleşmesi dağılımın farklılaşmasına sebep olmaktadır. Tüm disiplinlerdeki bilimsel çalışma sayıları son 30 yılda ortalama %3 oranında büyüme gerçekleştirmiştir (Bornmann ve Mutz 2015). Veteriner hekimlik alanındaki AI çalışmaları ise %17,88'lik bir büyüme gerçekleştirmiştir. AI çalışmalarındaki hızlı büyümenin gelecek yıllarda araştırmacıları daha fazla çekmesi muhtemel görülmektedir. AI alanındaki çalışmaların yeni ülkelerinde bu alana dahil olmasıyla yayın sayısındaki doğrusal artışın yakın gelecekte daha hızlı gerçekleşeceği öngörülmektedir. AI alanında yapılan çalışmalar teorik sonuçlarının yanı sıra pratik olarak da hayvan sağlığını tehdit eden unsurların tahmini, önlenmesi ve kontrolünde faydalı sonuçlar sağlamaktadır (Kour ve ark 2022). Ayrıca AI ve gelişen teknolojik sistemlerin hayvancılık alanına entegre edilmesiyle birlikte iş gücü ve insan kaynaklı hatalar azalmakta, hayvanlardan optimum verim sağlanmaktadır. Ayrıca görüntü işleme, karar verme ve tahmin etme gibi özellikleriyle insan müdahalesi minimuma inmektedir.

Veteriner hekimliğin bazı alt dallarında AI çalışmalarına ilişkin bibliyometrik analiz çalışmaları literatürde mevcuttur. Mitsunaga ve ark (2024) yaptıkları çalışmada 2011 ile 2021 yılları arasında sığır mastitisindeki AI uygulamalarının evrimini Scopus veri tabanını kullanarak değerlendirmeyi amaçlamışlardır. Bulgularda “makine öğrenimi” ve “mastitis” terimlerinin en çok atıfta bulunulan terimler olduğunu ve 2018 ile 2021 yılları arasında önemli bir artış olduğunu belirlemişlerdir. Sığır mastitisinin süt üretimi ve ekonomik getiri üzerindeki önemli etkileri göz önüne alındığında, AI'nın mastitisin tespitinde kullanılmasının bu hastalığın önlenmesinde önemli bir araç olarak kullanılabileceği sonucuna varmışlardır. Bu çalışmada da ML sık kullanılan terimler arasında yer almıştır. Mastitis kelime olarak öne çıkmasa da süt sığırcılığı ve hayvan sağlığı gibi konular güncel çalışma alanı olarak belirlenmiştir. Oliveira ve ark (2024), bilimsel literatürdeki araştırmanın kapsamını keşfetmek ve haritalamak için çiftlikte süt üretimiyle ilgili içeren teknolojilere

odaklanan bir bibliyometrik analiz çalışması sunmayı amaçlamışlardır. Yazarların, davranışsal izleme, süt sığırtı tanımlama ve bu hayvanlardaki termal stresin yönetimi için ML, DL ve bilgisayar görüşü gibi ortaya çıkan teknolojilere odaklandıkları görülmüştür. Bu konuda ilgi çekici ana dergilerin “Computers and Electronics in Agriculture” ve “Journal of Dairy Science” olduğunu belirlemişlerdir. Çalışmada gelişmiş dijital araçların benimsenmesinin süt sığırcılığında sürü yönetimi, sürdürülebilirliği, verimliliği ve hastalıkların erken tespitinde önemli bir etkisi olduğu sonucuna ulaşılmıştır. Sonuçlar bu çalışmada elde edilen bulguları (önde gelen dergiler, yazarlar ve sık kullanılan anahtar kelimeler gibi) destekler niteliktedir.

Hennessey ve ark (2022), veterinerlik alanında tanısal görüntüleme AI'nın kullanımı ile ilgili yapmış oldukları çalışmada, literatürde veteriner klinik araştırmalarında birden fazla anatomik bölgede görüntüleme ile ilişkili görevleri gerçekleştirmek için ML'nin kullanıldığını belirlemişlerdir. Bu alandaki başlıca zorluklar arasında, yeterli görüntü verisinin toplanması ve düzenlenmesi, yüksek kaliteli temel gerçek etiketlerinin seçilmesi, veterinerlik ve ML uzmanları arasında ilişkilerin kurulması ve AI'nın akademik kullanımları ile mevcut ticari ürünler arasındaki boşluğa dikkat çekmişlerdir. Bu çalışmada deep learning en sık kullanılan anahtar kelimelerde yer almış ve bu alana ilişkin çalışmaların literatürde arttığı belirlenmiştir. AI'ya ilişkin çalışmaların artmasıyla birlikte pratisyen hekimler ve radyologlar için iş akışı, kalite kontrol ve görüntü yorumlama uygulamaları yoluyla radyolojik hizmetlere yönelik artan ihtiyacın karşılanmasında yakın gelecekte görüntü işlemenin daha büyük bir paya sahip olacağı öngörülmektedir. Ayrıca AI'ya ilişkin çalışmalar, radyolojik görüntülemenin yanı sıra farklı alanlardaki hekimlik uygulamalarında da kullanılmaktadır. DL ile köpek torasik radyolojisinde sol atriyal genişlemenin tespiti (Li ve ark 2020), kolikli atlarda hayatta kalma ve ameliyat ihtiyacının tahmin edilmesi (Fraivan ve Abutarbush 2020), ML yardımıyla ineklerde subklinik mastitis tespiti (Ebrahimie ve ark 2018), köpek MR'larında CNN ile meningiom ve gliom ayrımının yapılması (Banzato ve ark 2018), osteosarkomlu köpeklerde rezidüel hastalığı tespit etmek için ML kullanılması (Makielski ve ark 2021), K-ortalama algoritması ile büyükbaş hayvanlardan alınan eğim sensörü ve sıcaklık verileriyle kızgınlık tahmini yapılması (Shahriar ve ark 2016), ANN ile kuzularda hastalık teşhisi (Cihan ve ark 2017) ve RF algoritması ile ineğin yürüyüşünün akustik analizinin yapılması (Volkmann ve ark 2021) gibi birçok alanda uygulama örneği bulmak mümkündür.

Çalışma sonucunda elde edilen bulgulara alanda en sık kullanılan kelimelerin machine learning, artificial intelligence ve deep learning olduğu belirtilmiştir. Bouchemla ve ark (2023) yaptıkları sistematik derlemede veteriner hekimlikte AI çalışmaları için arama terimi olarak machine learning, deep learning ve convolutional neural network kelimelerini kullanmışlardır. Bu çalışma kelime analizinde elde edilen bulguları destekler niteliktedir. Literatürdeki çalışmalar (Cavero ve ark 2006, Ebrahimi ve ark 2019, Rao ve ark 2020) incelendiğinde araştırmaların çoğunlukla görüntü işleme, ML algoritmaları ile hastalık tahmini ve sınıflandırma çalışmaları olduğu görülmektedir. Bu sonuçlar anahtar kelimelerden elde edilen kelime ağının doğruluğunu desteklemektedir. Ayrıca kelime ağı tür bazında incelendiğinde genellikle kedi-köpek hekimliğinde görüntü işleme, kanatlı ve ruminant hekimliğinde ise sınıflandırma ve tahmin yapma çalışmaları olduğu tespit edilmiştir.

AI alanında çalışma yapan araştırmacıların Açık Erişim yayıncılığı daha fazla tercih ettiği görülmektedir. Ancak alandaki popüler dergiler için ödeme yapamayan yazarların çalışmalarını açık yayıncılığı karşılayabilen yazarlar kadar geniş bir alana ulaştıramayacağı bilinmelidir. Bu durum gelişmemiş ve gelişmekte olan ülkelerdeki AI çalışmalarının sayısının az olmasının ana nedenlerinden biridir. Veteriner hekimlik alanında AI konulu orijinal araştırma makalesi yapabilmek için veteriner hekimliğin yanı sıra aynı zamanda istatistik, bilgisayar ve yazılım gibi farklı alanlarda da uzmanlaşmaya ihtiyaç duyulmaktadır. Bundan dolayı inceleme ve orijinal araştırma makalelerinin yazarları çok fazla farklılık gösterebilmektedir. Bu durum alandaki çalışmalarda akademik işbirliğinin yüksek olma durumunu açıklamaktadır. Bir araştırma alanındaki çekirdek araştırmacıların belirlenmesi o alanla ilgili bakış açılarının ve danışmanlık için uygun araştırmacıların tespit edilmesinde önem taşımaktadır (Boyack ve ark 2013). AI alanında çekirdek yazarlardan ikisinin Ecevit Eyduran ve Tommaso Banzato olduğu tespit edilmiştir. Bu yazarların uluslararası işbirliği %20 ve üzerinde yer almaktadır. Ayrıca önde gelen ilk 10 yazardan Alessandro Zotti ve Tommaso Banzato'nun birçok AI çalışmasında ortak yazarlığı bulunmaktadır. Bu yazarların çalışmalarının büyük bölümünün görüntü işleme üzerine olduğu tespit edilmiştir. Bu iki yazar arasındaki işbirliği hem kurumlarının hem de ülkelerinin bu alanda öne çıkmasına katkı sağlamaktadır. Bu alandaki çalışmaları destekleyen kurumlar incelendiğinde, California Davis Üniversitesi ve Padua Üniversiteleri alandaki ana yayıncılar ve en fazla atıf yapılan kuruluşlar olarak belirlenmiştir.

Yayınlara yapılan atıf sayıları o alana olan ilginin bir göstergesidir. Bu açıdan değerlendirildiğinde ABD’den yapılan yayınlar en fazla atıf alan yayınlar olurken (537) onu Çin (276) ve Türkiye (242) takip etmektedir. Ecevit Eydur n ve Őenol  elik’in bu alandaki  alıřmaları T rkiye’nin ilk 3  lke arasında yer almasını saėlamıřtır. Literat r taramasının yapıldıėı 10 Kasım 2023 tarihi ile bu alandaki  alıřma sayısı sınırlı olduėundan bu alanda  alıřmaları olan birkaç arařtırmacı kendi kurumlarını veya  lkelerini  ne  ıkarabilmektedir.



5. SONUÇ VE ÖNERİLER

Veteriner hekimlik alanında AI çalışmaları, şimdi ve gelecekte hastalıkların teşhis ve tedavi süreçlerinde daha hızlı ve doğru tanı ile tedaviye başlanması için büyük önem taşımaktadır. Bu bağlamda AI alanındaki çalışmalar daha fazla dikkat çekmeye başlamıştır. Bu bibliyometrik çalışmada, WoS veri tabanında 28 yıllık süreçte veteriner hekimlikteki AI alanındaki çalışmaların gelişimi, farklı disiplinlerdeki eğilimleri ve öne çıkan yazarlar, ülkeler, kurumlar, dergiler ve popüler konular araştırılmıştır. Toplam 397 akademik çalışma 1995 – 2023 yıllarındaki yayınlar analiz edilerek sonuçlar haritalama metotları ile birlikte istatistiksel olarak raporlanmıştır.

Genel olarak incelendiğinde veteriner hekimlikte AI alanındaki çalışmalar, yazarlar ve dergilerin gelişmiş ülkelere ait olduğu görülmektedir. Ancak bu durumun oluşmasında gelişmemiş ve gelişmekte olan ülkelerin yazarlarının makale işleme ücreti sebebiyle yüksek kalitede dergilere çalışmalarını ulaştırmamalarının da etkili olduğu düşünülmektedir. Bundan dolayı dergilerin bu ülkelerin yazarlarına makale işleme ücreti konusunda daha fazla destek vermeleri önerilmektedir. Güncel olarak alanda en popüler konuların hastalık teşhisi üzerine ML ve görüntü işleme çalışmaları olduğu belirlenmiştir. Gelecekte ise bu çalışmaların bilgisayar sistemleri ile destekleneceği öngörülmektedir. AI çalışmalarının en fazla olduğu ülke ABD olurken onu Çin ve Türkiye takip etmektedir. Bu durumun oluşmasında Avrupa ülkeleri ve ABD’de veteriner kliniklerinde tıbbi cihazların kullanımının etkili olduğu düşünülmektedir. Türkiye ise bu alanda öne çıkan 2 araştırmacının katkılarıyla gelişmiş ülkeler arasında yer almıştır. Öte yandan AI alanındaki çalışma sayısının az olduğu Nepal, Gana, Sri Lanka, Arjantin, Portekiz, Litvanya ve Hindistan gibi ülkelerde ise tıbbi cihazların kullanım oranının düşük olduğu belirlenmiştir. Bu durum yüksek kaliteli tıbbi verilerin eksikliğine ve AI alanında yapılan çalışmaların yavaş ilerlemesine sebep olmaktadır. Bu ülkelerde kayıtların düzenli tutulması ve araştırmacılar ve kurumlar arasında uluslararası işbirliklerinin geliştirilmesi önerilmektedir. Ayrıca bu alandaki çalışmaların geliştirilmesi için mali sorumluluk, yeterli altyapı (yazılım veya donanım) ve kaynak desteği, iyi veri yönetimi ilkelerinin oluşturulması ve eğitim ve öğretim gibi sistemli bir yönetim oluşturulmalıdır.

Bu çalışma veteriner hekimlik alanında yapılacak AI çalışmaları için alanın genel haritası hakkında bilgi vermesi açısından araştırmacılar için yol gösterici nitelikte olabilir.

6. KAYNAKLAR

- Acedo FJ, Barroso C, Casanueva C, Galán JL, 2006. Co-authorship in management and organizational studies: An empirical and network analysis. *J Manag Stud*, 43, 957-83.
- Aggarwal CC, Zhai C, 2012. An introduction to text mining. In: *Mining text data*. Eds: Springer, p. 1-10.
- Ajiferuke I, Burell Q, Tague J, 1988. Collaborative coefficient: A single measure of the degree of collaboration in research. *Scientometrics*, 14, 5-6, 421-33.
- Al U, Coştur R, 2007. Türk Psikoloji Dergisi'nin bibliyometrik profili. *Türk kütüphaneciliği*, 21, 2, 142-63.
- Altunkaynak B, 2019. Veri madenciliği yöntemleri ve R uygulamaları, Seçkin Yayıncılık, Ankara, p.
- Amado-Fuentes M, Denche-Zamorano A, Barrios-Fernandez S, Gozalo M, 2024. Bibliometric Analysis on Equine-Assisted Interventions. *Animals*, 14, 12, 1776.
- Andres A, 2009. *Measuring Academic Research: How to Undertake a Bibliometric Study*, Chandos Publishing, p.
- Aria M, Cuccurullo C, 2017. bibliometrix: An R-tool for comprehensive science mapping analysis. *JOI*, 11, 4, 959-75.
- Atabay E, Çizel B, Ajanovic E. Akıllı şehir araştırmalarının R programı ile bibliyometrik analizi. 20. Ulusal Turizm kongresi, Bildiri Özet Kitabı: p. 1130-7 16 – 19 Ekim 2019, Eskişehir, Türkiye.
- Avcı H, Kırally-avcı E, Karagül MS, Metiner K, 2023. Canine brucellosis: A bibliometric analysis based on scopus and web of science databases. *Journal of Istanbul Veterinary Sciences*, 7, 89-98.
- Alwaysheh A, Wilcke J, Elvinger F, Rees L, Fan W, Zimmerman KL, 2016. Evaluation of supervised machine-learning algorithms to distinguish between inflammatory bowel disease and alimentary lymphoma in cats. *J Vet Diagn Invest*, 28, 679-87.
- Al-Amin M, Ali MS, Salam A, Khan A, Ali A, Ullah A, Alam MN, Chowdhury K, 2024. History of generative Artificial Intelligence (AI) chatbots: past, present, and future development. *arXiv preprint arXiv:2402.05122*.
- Bailón-Moreno R, Jurado-Alameda E, Ruiz-Baños R, Courtial JP, 2005. Bibliometric laws: Empirical flaws of fit. *Scientometrics*, 63, 209-29.
- Banchi P, Rota A, Bertero A, Domain G, Ali Hassan H, Lannoo J, Van Soom A, 2022. Trends in Small Animal Reproduction: A Bibliometric Analysis of the Literature. *Animals*, 12, 336.
- Banzato T, Bernardini M, Cherubini GB, Zotti A, 2018. A methodological approach for deep learning to distinguish between meningiomas and gliomas on canine MR-images. *BMC Vet Res*, 14, 1-6.
- Banzato T, Wodzinski M, Burti S, Osti VL, Rossoni V, Atzori M, Zotti A, 2021. Automatic classification of canine thoracic radiographs using deep learning. *Sci Rep*, 11, 3964.
- Barca M, Hızıroğlu M, 2009. 2000'li Yıllarda Türkiye'de Stratejik Yönetim Alanının Entellektüel Yapısı. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 4, 113-48.
- Basak J, Kothari R, 2004. A classification paradigm for distributed vertically partitioned data. *Neural computation*, 16, 1525-44.
- Batista GE, Monard MC, 2003. An analysis of four missing data treatment methods for supervised learning. *Appl Artif Intell*, 17, 519-33.
- Birkle C, Pendlebury DA, Schnell J, Adams J, 2020. Web of Science as a data source for research on scientific and scholarly activity. *Quant Sci Stud*, 1, 363-76.
- Bishop CM, Nasrabadi NM, 2006. *Pattern recognition and machine learning*. 4, New York: Springer, p. 738.
- Bkassiny M, Li Y, Jayaweera SK, 2012. A survey on machine-learning techniques in cognitive radios. *IEEE Commun Surv Tut*, 15, 1136-59.
- Block J, Fisch C, Rehan F, 2020. Religion and entrepreneurship: a map of the field and a bibliometric analysis. *Manag Rev Q*, 70, 591-627.

- Block JH, Fisch C, 2020. Eight tips and questions for your bibliographic study in business and management research. *Manag Rev Q*, 70: 307-12.
- Bookstein A, 2001. Implications of ambiguity for scientometric measurement. *JASIST*, 52, 74-9.
- Bornmann L, Daniel HD, 2007. What do we know about the h index? *JASIST*, 58, 1381-5.
- Bornmann L, Mutz R, 2015. Growth rates of modern science: A bibliometric analysis based on the number of publications and cited references. *JASIST*, 66, 2215-22.
- Bouchemla F, Akchurin SV, Akchurina IV, Dyulger GP, Latynina ES, Grecheneva AV, 2023. Artificial intelligence feasibility in veterinary medicine: A systematic review. *Vet World*, 16, 2143-9.
- Boyack KW, Klavans R, Sorensen AA, Ioannidis JP, 2013. A list of highly influential biomedical researchers, 1996–2011. *EJCI*, 43, 1339-65.
- Börner K, Chen C, Boyack KW, 2003. Visualizing knowledge domains. *Annual review of information science and technology*, 37, 179-255.
- Bradley R, Tagkopoulos I, Kim M, Kokkinos Y, Panagiotakos T, Kennedy J, De Meyer G, Watson P, Elliott J, 2019. Predicting early risk of chronic kidney disease in cats using routine clinical laboratory tests and machine learning. *JVIM*, 33, 2644-56.
- Brooks RA, 1991. Intelligence without representation. *Artificial intelligence*, 47, 139-59.
- Büyükcay Y, 2005. Gen analizleri ve mukayeseli hukuktaki düzenlemeler. *Erzincan Binali Yıldırım Üniversitesi Hukuk Fakültesi Dergisi*, 9, 355-82.
- Cavero D, Tölle K-H, Buxadé C, Krieter J, 2006. Mastitis detection in dairy cows by application of fuzzy logic. *Livestock Science*, 105, 207-13.
- Indicators and Calculations, Normalized Indicators, Category Normalized Citation Impact (CNCI), 2024. Erişim tarihi 02.12.2024. Erişim adresi, <https://incites.zendesk.com/hc/en-gb/articles/25087312115601-Category-Normalized-Citation-Impact-CNCI>.
- Chen C, 2006. CiteSpace II: Detecting and visualizing emerging trends and transient patterns in scientific literature. *JASIST*, 57, 359-77.
- Chen H, Chau M, 2004. Web mining: Machine learning for web applications. *ARIST*, 38, 289-329.
- Cihan P, Gökçe E, Kalipsiz O, 2017. Veteriner hekimlik alanında makine öğrenmesi uygulamaları üzerine bir derleme. *Kafkas Univ Vet Fak Derg*, 23, 673-80.
- Cobo MJ, López-Herrera AG, Herrera-Viedma E, Herrera F, 2011. Science mapping software tools: Review, analysis, and cooperative study among tools. *JASIST*, 62, 1382-402.
- Cobo MJ, López-Herrera AG, Herrera-Viedma E, Herrera F, 2012. SciMAT: A new science mapping analysis software tool. *JASIST*, 63, 1609-30.
- Cole FJ, Eales NB, 1917. The history of comparative anatomy: Part I.—A statistical analysis of the literature. *Science Progress (1916-1919)*, 11, 578-96.
- Condon EU, 1928. Statistics of vocabulary. *Science*, 67, 1733, 300-.
- Coşkun F, Gülleroğlu HD, 2021. Yapay zekânın tarih içindeki gelişimi ve eğitimde kullanılması. *JFES*, 54, 947-66.
- Çetin E, 2021. Yapay Zekâ Uygulamaları: Yapay Sinir Ağı-Makine Öğrenmesi-Derin Öğrenme-Derin Ağlar-Bulanık Mantık-Sinirsel Bulanık Mantık-Genetik Algoritma. Seçkin Yayıncılık, Ankara.
- De Bellis N, 2009. *Bibliometrics and citation analysis: from the science citation index to cybermetrics*, Toronto: Scarecrow press, p. 450
- De Mantaras RL, Armengol E, 1998. Machine learning from examples: Inductive and Lazy methods. *DKE*, 25, 99-123.
- de Oliveira FM, Ferraz GAeS, André ALG, Santana LS, Norton T, Ferraz PFP, 2024. Digital and Precision Technologies in Dairy Cattle Farming: A Bibliometric Analysis. *Animals*, 14, 1832.

- Dong J, Dong S, Buckingham L, 2023. How does a research topic evolve into a research field?—a bibliometric analysis of metadiscourse research. *ibérica*, 45, 163-89.
- Donthu N, Kumar S, Mukherjee D, Pandey N, Lim WM, 2021. How to conduct a bibliometric analysis: An overview and guidelines. *J Bus Res*, 133, 285-96.
- Dumortier L, Guépin F, Delignette-Muller M-L, Boulocher C, Grenier T, 2022. Deep learning in veterinary medicine, an approach based on CNN to detect pulmonary abnormalities from lateral thoracic radiographs in cats. *Sci Rep*, 12, 11418.
- Ebrahimi M, Mohammadi-Dehcheshmeh M, Ebrahimie E, Petrovski KR, 2019. Comprehensive analysis of machine learning models for prediction of sub-clinical mastitis: Deep Learning and Gradient-Boosted Trees outperform other models. *Comput Biol Med*, 114, 103456.
- Ebrahimie E, Ebrahimi F, Ebrahimi M, Tomlinson S, Petrovski KR, 2018. Hierarchical pattern recognition in milking parameters predicts mastitis prevalence. *Comput Electron Agric*, 147, 6-11.
- Egghe L, 1991. The exact place of Zipf's and Pareto's law amongst the classical informetric laws. *Scientometrics*, 20, 93-106.
- Egghe L, 2006. Theory and practise of the g-index. *Scientometrics*, 69, 131-52.
- Egghe L, Rousseau R, 1990. Introduction to informetrics. Quantitative methods in library, documentation and information science, Elsevier Science Publishers, p. 450.
- Ellegaard O, Wallin JA, 2015. The bibliometric analysis of scholarly production: How great is the impact? *Scientometrics*, 105, 1809-31.
- Etzioni O, 1996. The World-Wide Web: quagmire or gold mine? *Communications of the ACM*, 39, 65-8.
- Fernandez-Alles M, Ramos-Rodríguez A, 2009. Intellectual structure of human resources management research: A bibliometric analysis of the journal *Human Resource Management*, 1985–2005. *JASIST*, 60, 161-75.
- Fragoso-Garcia M, Wilm F, Bertram CA, Merz S, Schmidt A, Donovan T, Fuchs-Baumgartinger A, Bartel A, Marzahl C, Diehl L, 2023. Automated diagnosis of 7 canine skin tumors using machine learning on H&E-stained whole slide images. *Vet Pathol*, 60, 865-75.
- Fraiwan MA, Abutarbush SM, 2020. Using artificial intelligence to predict survivability likelihood and need for surgery in horses presented with acute abdomen (colic). *JEVS*, 90, 102973.
- Friendly M, Denis DJ, 2001. Milestones in the history of thematic cartography, statistical graphics, and data visualization. URL <http://www.datavis.ca/milestones>, 32, 13.
- Garfield E, 1980. Bradford law and related statistical patterns. *Current contents*, 19, 5-12.
- Glanzel W, 2003. Bibliometrics as a research field a course on theory and application of bibliometric indicators, p.
- Gonzalez-Alcaide G, Sosa N, Shevy L, Belinchon-Romero I, Ramos-Rincon J-M, 2023. Global research on cysticercosis and neurocysticercosis: A bibliometric analysis. *Front Vet Sci*, 10, 1156834.
- Gouda HF, Hassan FA, El-Araby EE, Moawed SA, 2022. Comparison of machine learning models for bluetongue risk prediction: a seroprevalence study on small ruminants. *BMC Vet Res*, 18, 394.
- Greenhill AT, Edmunds BR, 2020. A primer of artificial intelligence in medicine. *TIGE*, 22, 85-9.
- Research Metrics, Academic-Corporate Collaboration and Impact, 2024. Erişim tarihi 02.12.2024. Erişim adresi, <https://libguides.usc.edu.au/c.php?g=508927&p=3480482>.
- Gutiérrez-Salcedo M, Martínez MÁ, Moral-Munoz JA, Herrera-Viedma E, Cobo MJ, 2018. Some bibliometric procedures for analyzing and evaluating research fields. *Appl Intell*, 48, 1275-87.
- Haidich A-B, 2010. Meta-analysis in medical research. *Hippokratia*, 14, Suppl 1, 29.
- Hamet P, Tremblay J, 2017. Artificial intelligence in medicine. *Metabolism*, 69, 36-40.
- Harzing A-W, 2012. Reflections on the h-index. *Business & Leadership*, 1, 101-6.
- Hennessey E, DiFazio M, Hennessey R, Cassel N, 2022. Artificial intelligence in veterinary diagnostic imaging: A

- literature review. *Veterinary Radiology & Ultrasound*, 63, 851-70.
- Hiran KK, Jain RK, Lakhwani K, Doshi R, 2021. *Machine Learning: Master Supervised and Unsupervised Learning Algorithms with Real Examples (English Edition)*, BPB Publications, p.
- Hirsch JE, 2005. An index to quantify an individual's scientific research output. *Proceedings of the National academy of Sciences*, 102, 16569-72.
- Holmes J, Sacchi L, Bellazzi R, 2004. Artificial intelligence in medicine. *Ann R Coll Surg Engl*, 86, 334-8.
- Hood WW, Wilson CS, 2001. The literature of bibliometrics, scientometrics, and informetrics. *Scientometrics*, 52, 291-314.
- Huma ZE, Iqbal F, 2019. Predicting the body weight of Balochi sheep using a machine learning approach. *Turk J Vet Anim Sci*, 43, 500-6.
- Jesson J, 2011. *Doing your literature review: Traditional and systematic techniques*, Sage, p.192.
- Jiang L, Zhu N, Yang Z, Xu S, Jun M, 2018. The relationships between distance factors and international collaborative research outcomes: A bibliometric examination. *JOI*, 12, 618-30.
- Kaul V, Enslin S, Gross SA, 2020. History of artificial intelligence in medicine. *Gastrointestinal endoscopy*, 92, 807-12.
- Kim Y, Kim J, Kim S, Youn H, Choi J, Seo K, 2023. Machine learning-based risk prediction model for canine myxomatous mitral valve disease using electronic health record data. *Front Vet Sci*, 10, 1189157.
- Kiouvrekis Y, Vasileiou NG, Katsarou EI, Lianou DT, Michael CK, Zikas S, Katsafadou AI, Bourganou MV, Liagka DV, Chatzopoulos DC, 2024. The Use of Machine Learning to Predict Prevalence of Subclinical Mastitis in Dairy Sheep Farms. *Animals*, 14, 2295.
- Koch R, 2011. *The 80/20 Principle: The Secret of Achieving More with Less: Updated 20th anniversary edition of the productivity and business classic*, Hachette UK, p.
- Kour S, Agrawal R, Sharma N, Tikoo A, Pande N, Sawhney A, 2022. Artificial Intelligence and its Application in Animal Disease Diagnosis. *J Anim Res*, 12, 1-10.
- Köroglu Y, 2017. Yapay zeka'nın teorik ve pratik sınırları. *Boğaziçi Üniversitesi Yayınevi*, 26-30.
- Kraus S, Breier M, Lim WM, Dabić M, Kumar S, Kanbach D, Mukherjee D, Corvello V, Piñeiro-Chousa J, Liguori E, 2022. Literature reviews as independent studies: guidelines for academic practice. *Rev Manag Sci*, 16, 2577-95.
- Kretschmer H, Rousseau R, 2001. Author inflation leads to a breakdown of Lotka's law. *JASIST*, 52, 610-4.
- Kumar V, Upadhyay S, Medhi B, 2009. Impact of the impact factor in biomedical research: its use and misuse. *Singapore Med J*, 50, 752-5.
- Kurutkan MN, Orhan F, 2018. Sağlık Politikası Konusunun Bilim Haritalama Teknikleri İle Analizi, p.
- Kutlusoy Z, 2019. Felsefe açısından yapay zeka. *Yapay zeka ve gelecek: Doğu Kitabevi*, p. 25-43.
- Li S, Wang Z, Visser LC, Wisner ER, Cheng H, 2020. Pilot study: application of artificial intelligence for detecting left atrial enlargement on canine thoracic radiographs. *Veterinary radiology & ultrasound*, 61, 611-8.
- Linnenluecke MK, Marrone M, Singh AK, 2020. Conducting systematic literature reviews and bibliometric analyses. *Aust J Manag*, 45, 175-94.
- Mahesh B, 2020. Machine learning algorithms-a review. *IJSR*, 9, 381-6.
- Makielski KM, Donnelly AJ, Khammanivong A, Scott MC, Ortiz AR, Galvan DC, Tomiyasu H, Amaya C, Ward KA, Montoya A, 2021. Development of an exosomal gene signature to detect residual disease in dogs with osteosarcoma using a novel xenograft platform and machine learning. *Laboratory Investigation*, 101, 1585-96.
- Malik P, Pathania M, Rathaur VK, 2019. Overview of artificial intelligence in medicine. *J Family Med Prim Care*, 8, 2328-31.
- Manasa K, Sidharth S, Saifuddin M, Surya K, Srishailam B, 2024. Trends and Collaborations in Livestock

- Extension Research: A Bibliometric Analysis (2015-2024). *Journal of Scientific Research and Reports*, 30, 448-56.
- Mandal JK, Bhattacharya D, 2020. Emerging technology in modelling and graphics, Springer, p.
- Manuelian CL, Penasa M, da Costa L, Burbi S, Righi F, De Marchi M, 2020. Organic Livestock Production: A Bibliometric Review. *Animals*, 10, 618.
- Marsland S, 2011. Machine learning: an algorithmic perspective, New York: Chapman and Hall/CRC, p. 406.
- Martínez MA, Cobo MJ, Herrera M, Herrera-Viedma E, 2015. Analyzing the scientific evolution of social work using science mapping. *Res Soc Work Pract*, 25, 257-77.
- McCarthy J, 2007. From here to human-level AI. *Artificial Intelligence*, 171, 1174-82.
- Merigó JM, Yang J-B, 2017. A bibliometric analysis of operations research and management science. *Omega*, 73, 37-48.
- Miao H, Yu K, Gao D, Lin X, Cao Y, Liu X, Qiao H, Li T, 2022. A Bibliometric Analysis of Research on Ketamine From 2001 to 2020. *Front Mol Neurosci*, 15, 839198.
- Mitsunaga TM, Garcia BLN, Pereira LBR, Costa YCB, da Silva RF, Delbem ACB, Dos Santos MV, 2024. Current Trends in Artificial Intelligence and Bovine Mastitis Research: A Bibliometric Review Approach. *Animals: an Open Access Journal from MDPI*, 14, 14.
- Moral-Muñoz JA, Herrera-Viedma E, Santisteban-Espejo A, Cobo MJ, 2020. Software tools for conducting bibliometric analysis in science: An up-to-date review. *Profesional de la Información*, 29, 1.
- Osareh F, 1996. Bibliometrics, citation analysis and co-citation analysis: A review of literature I.
- Osca-Lluch J, Mollá CC, Ortega MP, 2009. Consecuencias de los errores en las referencias bibliográficas. El caso de la revista *Psicothema*. *Psicothema*, 300-3.
- Owens A, Vinkemeier D, Elsheikha H, 2023. A review of applications of artificial intelligence in veterinary medicine. *Companion Animal*, 28, 78-85.
- Ozturk O, 2021. Bibliometric review of resource dependence theory literature: an overview. *Management Review Quarterly*, 71, 525-52.
- Öztürk K, Şahin ME, 2018. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6, 25-36.
- Öztürk O, Gürlü G, 2021. Bir literatür incelemesi aracı olarak bibliyometrik analiz. Ankara: Nobel Yayınevi.
- Öztürk O, Kocaman R, Kanbach DK, 2024. How to design bibliometric research: an overview and a framework proposal. *Rev Manag Sci*, 18, 1-29.
- Price DdS, 1976. A general theory of bibliometric and other cumulative advantage processes. *JASIST*, 27, 292-306.
- Pritchard A, 1969. Statistical bibliography or bibliometrics. *Journal of documentation*, 25, 348.
- Punch KF, 2013. Introduction to social research: Quantitative and qualitative approaches, p. 408.
- Rachna C, 2020. Difference between X-ray and CT scan. Rahman, T., Chowdhury, M., & Khandakar, A.(2020). COVID-19 radiography database. Kaggle. Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., & Shpanskaya, K.(2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *ArXiv Preprint ArXiv*, 1711, 2352-449.
- Ramamurthy R, Sifa R, Bauckhage C, 2020. NLPgym--A toolkit for evaluating RL agents on Natural Language Processing Tasks. *arXiv preprint arXiv:2011.08272*.
- Rao Y, Jiang M, Wang W, Zhang W, Wang R, 2020. On-farm welfare monitoring system for goats based on Internet of Things and machine learning. *Int J Distrib Sens Netw*, 16, 1550147720944030.
- Ronda-Pupo GA, Guerras-Martin LÁ, 2012. Dynamics of the evolution of the strategy concept 1962–2008: a co-word analysis. *SMJ*, 33, 162-88.
- Sariel S, 2017. Günümüzde yapay zeka. İnsanlaşan makineler ve yapay zekâ içinde İstanbul: İstanbul Teknik Üniversitesi Vakfı Dergisi. 21-25

- Satoła A, Satoła K, 2024. Performance comparison of machine learning models used for predicting subclinical mastitis in dairy cows: Bagging, boosting, stacking, and super-learner ensembles versus single machine learning models. *JDS*, 107, 3959-72.
- Sayım F, 2022. *İşletmelerde ve Yönetimde Yapay Zeka*, Ankara, Seçkin Yayıncılık, p. 276.
- Sengupta IN, 1992. Bibliometrics, informetrics, scientometrics and librametrics: an overview. *Libri*, 42, 75-98.
- Serrat O, Serrat O, 2017. Social network analysis. Knowledge solutions: Tools, methods, and approaches to drive organizational performance. Springer Natura, 39-43.
- Shahinfar S, Khansefid M, Haile-Mariam M, Pryce JE, 2021. Machine learning approaches for the prediction of lameness in dairy cows. *Animal*, 15, 100391.
- Shahriar MS, Smith D, Rahman A, Freeman M, Hills J, Rawnsley R, Henry D, Bishop-Hurley G, 2016. Detecting heat events in dairy cows using accelerometers and unsupervised learning. *Comput Electron Agric*, 128, 20-6.
- Sharma N, Sharma R, Jindal N, 2021. Machine learning and deep learning applications-a vision. *Global Transitions Proceedings*, 2, 24-8.
- Sharma R, Sharma K, Khanna A, 2020. Study of supervised learning and unsupervised learning. *IJRASET*, 8, 588-93.
- Shinde PP, Shah S. A review of machine learning and deep learning applications. 2018 Fourth international conference on computing communication control and automation (ICCUBEA), 1-6, 25 Nisan 2019, Pune, India.
- Small H, 1973. Co-citation in the scientific literature: A new measure of the relationship between two documents. *JASIST*, 24, 265-9.
- Snyder H, 2019. Literature review as a research methodology: An overview and guidelines. *J Bus Res*, 104, 333-9.
- Sofyantoro F, Yudha DS, Lischer K, Nuringtyas TR, Putri WA, Kusuma WA, Purwestri YA, Swasono RT, 2022. Bibliometric Analysis of Literature in Snake Venom-Related Research Worldwide (1933–2022). *Animals*, 12, 2058.
- Sudhier KP, 2013. Lotka's law and pattern of author productivity in the area of physics research. *DESIDOC Journal of Library & Information Technology*, 33, 6, 457-64.
- Journal Citation Reports: Quartile rankings and other metrics, 2024. Erişim tarihi 02.12.2024. Erişim adresi, https://support.clarivate.com/ScientificandAcademicResearch/s/article/Journal-Citation-Reports-Quartile-rankings-and-other-metrics?language=en_US.
- Thelwall M, 2008. Bibliometrics to webometrics. *J Inf Sci*, 34, 605-21.
- Tranfield D, Denyer D, Smart P, 2003. Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *Br J Manag*, 14, 207-22.
- Tyagi K, Rane C, Sriram R, Manry M, 2022. Unsupervised learning. In: Artificial intelligence and machine learning for edge computing. Eds: Elsevier, p. 33-52.
- Uddin S, Khan A, Hossain ME, Moni MA, 2019. Comparing different supervised machine learning algorithms for disease prediction. *BMC Med Inform Decis Mak*, 19, 1-16.
- Van Eck N, Waltman L, 2010. Software survey: VOSviewer, a computer program for bibliometric mapping. *Scientometrics*, 84, 523-38.
- Van Eck N, Waltman L, 2022. *VOSviewer Manual Versi 2.6*. 18. Leiden: Univeristeit Leiden.
- Van Eck NJ, Waltman L, 2017. Citation-based clustering of publications using CitNetExplorer and VOSviewer. *Scientometrics*, 111, 1053-70.
- Van Engelen JE, Hoos HH, 2020. A survey on semi-supervised learning. *Machine learning*, 109, 373-440.
- Van Raan A, 2014. Advances in bibliometric analysis: research performance assessment and science mapping. *Bibliometrics Use and Abuse in the Review of Research Performance*, 87, 17-28.
- Vanderplas S, Cook D, Hofmann H, 2020. Testing statistical charts: What makes a good graph? *Ann Rev Stat Appl*, 7, 61-88.

- Volkman N, Kulig B, Hoppe S, Stracke J, Hensel O, Kemper N, 2021. On-farm detection of claw lesions in dairy cows based on acoustic analyses and machine learning. *JDS*, 104, 5921-31.
- Waltman L, 2016. A review of the literature on citation impact indicators. *JOI*, 10, 365-91.
- Waltman L, Van Eck NJ, 2012. A new methodology for constructing a publication-level classification system of science *JASIST*, 63, 2378-92.
- Wang C, Lim MK, Zhao L, Tseng M-L, Chien C-F, Lev B, 2020. The evolution of Omega-The International Journal of Management Science over the past 40 years: A bibliometric overview. *Omega*, 93, 102098.
- Witten IH, (2004). *Text Mining*, Citeseer.
- Yazici İ, Shayea I, Din J, 2023. A survey of applications of artificial intelligence and machine learning in future mobile networks-enabled systems. *Eng Sci Technol Int J*, 44, 101455.
- Yılmaz M, 2006. Lotka yasası ve Türkiye’de kütüphane ve bilgi bilimi literatürü. *Türk Kütüphaneciliği*, 16, 61-9.
- Yılmaz M, 2008. Price Yasası ve Türkiye’de Fikri Mülkiyet Hakları Literatürü. *Bilgi ve Belge Araştırmaları*, 1, 23-38.
- Yu Y, Li Y, Zhang Z, Gu Z, Zhong H, Zha Q, Yang L, Zhu C, Chen E, 2020. A bibliometric analysis using VOSviewer of publications on COVID-19. *Ann Transl Med*, 8, 13.
- Yu Z, Xie L, Shuai P, Zhang J, An W, Yang M, Zheng J, Lin H, 2023. New perspective on African swine fever: a bibliometrics study and visualization analysis. *Front Vet Sci*, 10, 1085473.
- Zan BU, 2012. Türkiye’de bilim dallarında karşılaştırmalı bibliyometrik analiz çalışması, Doktora Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.
- Zhang L, Wang S, Liu B, 2018. Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8, 1253.
- Zhou Z-H, Li M, 2010. Semi-supervised learning by disagreement. *Knowledge and Information Systems*, 24, 415-39.
- Zipf GK, 1949. *Human behaviour and the principle of least effort*, adisson. Wesley Press, Cambridge, 6, 306.
- Zupic I, Čater T, 2015. Bibliometric methods in management and organization. *Organizational research methods*, 18, 429-72.

7.EKLER

EK-A: Etik Kurul Kararı



EK-B: Turnitin Raporu

VETERİNERLİK ALANINDA YAPAY ZEKÂ ÇALIŞMALARININ BİBLİYOMETRİK ANALİZİ.pdf

ORJİNALLİK RAPORU

% 12	% 11	% 5	% 4
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	dergipark.org.tr İnternet Kaynağı	% 1
2	www.researchgate.net İnternet Kaynağı	% 1
3	acikbilim.yok.gov.tr İnternet Kaynağı	<% 1
4	www.scribd.com İnternet Kaynağı	<% 1
5	www.pressacademia.org İnternet Kaynağı	<% 1
6	Submitted to Karadeniz Teknik University Öğrenci Ödevi	<% 1
7	www.uyik.org İnternet Kaynağı	<% 1
8	eskiweb.harran.edu.tr İnternet Kaynağı	<% 1
9	akademikbirikimdergisi.com İnternet Kaynağı	<% 1

8.ÖZGEÇMİŞ

