
ÜRETİM YÖNETİMİNDE İLERİ ARAŞTIRMALAR

Editör: Prof.Dr. Hüseyin ŞENKAYAS

Üretim Yönetiminde İleri Araştırmalar

Editör

Prof. Dr. Hüseyin ŞENKAYAS

yaz
yayınları

2024

Üretim Yönetiminde İleri Araştırmalar

Editör: Prof. Dr. Hüseyin ŞENKAYAS

© YAZ Yayınları

Bu kitabın her türlü yayın hakkı Yaz Yayınları'na aittir, tüm hakları saklıdır. Kitabın tamamı ya da bir kısmı 5846 sayılı Kanun'un hükümlerine göre, kitabı yayınlayan firmanın önceden izni alınmaksızın elektronik, mekanik, fotokopi ya da herhangi bir kayıt sistemiyle çoğaltılamaz, yayınlanamaz, depolanamaz.

E_ISBN 978-625-5547-00-2

Aralık 2024 – Afyonkarahisar

Dizgi/Mizanpaj: YAZ Yayınları

Kapak Tasarım: YAZ Yayınları

YAZ Yayınları. Yayıncı Sertifika No: 73086

M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar/AFYONKARAHİSAR

www.yazyayinlari.com

yazyayinlari@gmail.com

info@yazyayinlari.com

İÇİNDEKİLER

Endüstri 4.0, Sürdürülebilirlik ve Verimlilik Üzerine Bir Sistematik Literatür Taraması.....	1
---	----------

Hüseyin ŞENKAYAS, Halil İbrahim AY, Bilgehan Serhat ÇINAR

Üretim Yönetiminde Talep Tahminlemede Derin Öğrenme Teknikleri.....	15
--	-----------

Gökhan TURGAY, Metin BAYRAM

"Bu kitapta yer alan bölümlerde kullanılan kaynakların, görüşlerin, bulguların, sonuçların, tablo, şekil, resim ve her türlü içeriğin sorumluluğu yazar veya yazarlarına ait olup ulusal ve uluslararası telif haklarına konu olabilecek mali ve hukuki sorumluluk da yazarlara aittir."

ENDÜSTRİ 4.0, SÜRDÜRÜLEBİLİRLİK VE VERİMLİLİK ÜZERİNE BİR SİSTEMATİK LİTERATÜR TARAMASI

Prof.Dr. Hüseyin ŞENKAYAS

Halil İbrahim AY

Bilgehan Serhat ÇINAR

1. GİRİŞ

Hayatta kalmak ve büyümeyi amaçlayan işletmeler, üretim faaliyetlerini yerine getirirken etkinlik ve tepkisellik faktörlerini dengelemek zorundadır. Müşterilere yönelik sürdürülebilir satışları en uygun maliyetle gerçekleştirmek için üretim süreçlerinin gelişmesi önem taşımaktadır. Üretim faaliyetlerinin dijitalleşmesi, Endüstri 4.0 kapsamındaki teknolojilerin uygulanması ve bu yolla tedarik zincirinde verimlilik ve sürdürülebilirlik sağlanması konuları üretim yönetimi alanında yaygınlaşmaktadır.

Çalışma, dijitalleşme, üretimde verimlilik ve sürdürülebilirlik anahtar kelimeleriyle başlıca hakemli dergilerin bulunduğu veri sitelerinde yapılmıştır. Literatürde Endüstri 4.0 teknolojileri ve sürdürülebilirlik alanlarında yapılan çalışmalara yer verilerek, bu konular hakkında açıklayıcı bilgiler ortaya konmuştur. Daha sonra, literatür taramasına dayanarak dijitalleşme ve sürdürülebilirlik hakkındaki bulgulara yer verilmiştir.

2. ENDÜSTRİ 4.0 TEKNOLOJİLERİ

Üretimde teknolojik yenilikler iki bakış açısında yapılır. Birincisi, maliyet unsuru olan girdileri düşürmek, ikincisi ise karlılığı arttıran çıktıları arttırmaktır. Bu kapsamda ilk kitle üretim sisteminden bu yana üretim süreçleri güncellenip gelişmektedir.

Endüstri 4.0 adı verilen programın amacı akıllı fabrikaları oluşturarak, verimliliği ve sürdürülebilirliği arttırmaktır (Schuh vd. 2015). Endüstri 4.0 ile talep kontrolü, ürünlerin kişiselleştirilmesi, satıştan sonra daha etkin müşteri ilişkileri, daha hızlı ürün dizaynı ve üretimi, daha karlı üretim sistemi, işletmenin her alanından gelen geri besleme bilgilerinin etkin bir şekilde analiz edilerek bilgi asimetrisinin düşürülmesi sağlanmaktadır (Vartolomei & Avasilcai, 2019).

Endüstri 4.0 teknolojileri, çeşitli kaynaklarda farklı kapsamlarda ele alınmakla birlikte genelde aşağıdaki bileşenlerden oluşmaktadır:

Akıllı Fabrikalar: Üretimde otomasyonun, mekanik üretim faktörlerinin soyut üretim faktörleri ile birleşimi sonucu ortaya çıkan fabrikaları ifade etmektedir.(Şekkeli&Bakan, 2018)

3-D yazıcılar: Farklı objelerin 3-D yazıcılar aracılığıyla fiziki olarak üretilmesidir.

Bulut Teknolojisi: İşletmenin faaliyetlerinden kaynaklanan verilerin depolanması, yedeklenmesi, paylaşılmasını sağlayan internet temelli teknolojilerdir(Çelik, 2021).

Arttırılmış Gerçeklik (AR): Gerçek dünya ile sanal dünyanın bir araya gelerek aynı ortamda ve bir arada algılanmasıdır. Fotoğraf, ses, görüntü, video, grafik, GPS gibi uygulamaların gerçek dünya ile bir araya gelerek canlandırılmasıdır (Tonga&Tonga, 2022).

Nesnelerin İnterneti (IoT): Geçmişte herhangi bir şekilde birbiri ile iletişim kullanamayan nesnelerin, gerektiğinde veriyi işleyerek servis eden, nesnelerin birbiri ile çift yönlü ve çok hızlı iletişime geçtiği, üzerinde bilgileri kaydeden ve analiz de edebilen nesneleri ifade eden bir kavramdır (Kablan, 2018). Nesnelerin interneti (Nİ), üretim süreçlerinde hangi unsurların kullanılacağını, hangi faktörlerin ölçülüp kontrol edilebileceğini, gerçek talep ile üretim ihtiyacının belirlenmesini, öngörülebilirliği ve hedeflerin ölçülebilirliğini mümkün kılar (Weckesser, 2021).

Yapay Zeka (AI): YZ makinelerin daha özerk ve daha akıllı hale gelmesidir. İnsana özel akıl yürütme, öğrenme ve iletişim kurma, geçmiş bilgileri kullanma gibi özelliklere sahip olmasıdır (Bayuk, 2019). YZ, geleneksel üretim süreçlerinde olmayan kesin kararlar verilmesini sağlar (Weckesser, 2021).

Otonom Robotlar (OR): Birbirleriyle iletişim kurabilen, kendi kendine yazılım güncellemesi yapabilen, gözlem ve analiz yeteneği olan, insanlardan talimat almadan yapay zeka ile güçlendirilmiş robotların üretim sürecine esneklik ve hız sunarak katkıda bulunacağı öngörülmektedir. Gelecekte gerçekleşmesi öngörülen Akıllı fabrikalar için önemli bir rol üstlenmektedir (İlhan, 2021)

Büyük Veri ve Analizi(BVA): BVA, bir veri uzayından değerli olabilecek verilerin çekilip, mantıksal ve analitik akıl yürütme süreçleri kullanılarak işlenmesine ve işletmeler için kullanışlı olabilecek bilgiler yaratmaktadır (Tonga&Tonga, 2024).

Endüstri 4.0 bileşenlerinin kullanılarak, üretim süreçlerine esneklik, çeviklik, kesinlik ve hız kazandırılarak, bütünleşik ve dijital akıllı fabrika-

lar oluşturulmaktadır. Otomasyon, insanların da üretim süreçlerine dahil olabildiği yarı otomasyon, insanların üretim sürecine hiç dahil olmadığı tam otomasyon olarak ikiye ayrılmıştır. Örneğin, birtakım üretim süreçlerinde YZ ile dizayn edilen (CAD ve CAE gibi programlar) ve 3-D yazıcılarla yapılan üretimler ile tam otomasyon sağlanabilirken, YZ ile dizayn edilip, üretim sürecinde insanların da katkı sağladığı üretim süreçleri de yarı otomasyon olarak örneklendirilebilir. Soft teknolojiler, yazılımlar aracılığıyla üretimlerin desteklenmesini ihtiva etmekteyken, hard-teknolojiler; yazılımlarla yönetilen fiziksel ortamdaki makinelerin üretim süreçlerini desteklemesidir.

Dijitalleşme, sadece üretim bandında değil, tedarikçi ilişkilerinin, müşteri yönetiminin, iletişim stratejilerinin, satış süreçlerinin ve dağıtım-cılar arası iletişimin düzenlenmesinde hızlı kararlar alınabilmesini sağlar (Vartolomei & Avasilcai, 2019). Dijitalleşme daha doğru, daha hızlı, daha kesin kararlar alınmasında önemli rol oynamaktadır (Weckesser, 2021).

3. SÜRDÜRÜLEBİLİRLİK

İçinde bulunduğumuz çağın en önemli sorunu yenilenemeyen kaynaklar, üretim sonucu ortaya çıkan zehirli emisyonlar, atık miktarlarının artışı sonucu meydana gelen çevresel felaketlerdir. İklim krizi ile karşılaşabileceğimiz nedeniyle sıfır karbon emisyonlu üretim sistemlerinin ortaya çıkarılması gerekmektedir. Bazı büyük şirketlerin büyüklüklerinin, birçok ülkenin gayri safi milli hasılasından büyük olduğu değerlendirildiğinde, dünyamızın geleceği için önemli olan sürdürülebilirlik konusunda hassas davranmalarının önemi bir kez daha ortaya çıkacaktır.(KIRAY & KAPLAN, 2022)

Sürdürülebilirliğin üç temel bileşeni bulunmaktadır. Bunlar sosyal eşitlik, ekonomik büyüme ve çevresel sorunlardır. Brundtland raporu (1987) ile ilk defa gündeme gelmiştir. İklim kriziyle, çevresel kirlenme ve dünya nüfuslarının sosyal eşitsizliğine ortak alanda çare arayan Brundtland komisyonu tarafından BM gündemine getirilmiştir. (WCED (1987))

Dijitalleşme kurumlara rekabet avantajı sağlamakla birlikte, sürdürülebilirlik çalışmalarına en çok katkıyı sağlayan girdilerden birisidir. Sürdürülebilirlik işletmelerin birbirine rekabetini değil, ortak değerler yaratmasını savunur. Sürdürülebilirlik genel olarak karbon salınımının azaltılması, yenilenebilir enerji kaynaklarının kullanılması, üretimde verimliliğin artırılmasıdır. Teknolojik gelişmelerden faydalanılarak yukarıda bahsedilen yöntemlerin etkin bir şekilde kullanılması sürdürülebilirliği desteklemektedir. Sürdürülebilirlik ve Dijitalleşme ikiz dönüştürücüler olarak da adlandırılmaktadır. (Kıray & Kaplan, 2022)

Çevresel kirliliğe ve doğal kaynaklara zarar verilmesine en çok neden olan faktörlerden biri kimyasal ve fiziksel yöntemlerin kullanılarak ham madde işleyiciliği yapan üretim süreçleridir.(El-Halwagi, 2017). Sürdürülebilirliğin artmasının önündeki engellerden biri, özellikle gelişmekte olan ülkelerde faaliyet gösteren üretimlerden zararlı maddeler çıkan, küçük ve orta çaplı sanayi işletmelerinin yetişmiş işgücü bulunmamasından, yeterli teknik altyapı bulunmamasından, kaynakların yetersizliğinden dolayı kurulumamasından ötürü sürdürülebilirlik tam anlamıyla uygulanamamaktadır.

Dijitalleşme ile birlikte endüstri 4.0 bileşenlerinin çalışma alanlarında insanların yerini alması ile mavi yakalı kavramının yerini alacak ikame anlayış olarak robotların üretim süreçlerine dahil olacağı ve verimliliği arttırdığı literatürde çok kez gözlemlenmiştir. Graetz ve Michaels (2018), robot kullanımının toplam faktör ve toplam işgücü verimliliğini 0.36 oranında arttırdığını, Autor ve Salomons (2018) teknolojik yenileşmenin işgücünü ikame edeceğini, Bessen (2019) teknolojinin işgücü verimliliğini ve genel verimliliği arttırdığını, Melthyakhin vd. (2020) dijitalleşmenin verimliliği arttırdığını gözlemlemiştir. (Yılmaz, 2021) (Schuh, Reuter, & Hauptvogel, 2015)

4. ÇALIŞMA METODOLOJİSİ

Çalışma, dijitalleşme, üretimde verimlilik ve sürdürülebilirlik anahtar kelimeleriyle başlıca hakemli dergilerin bulunduğu veri sitelerinde yapılmıştır. Boolean teknikleriyle araştırmalarını belirli bir alana kısıtlamış, yalnızca 2010 sonrası yapılan akademik çalışmalar, dijitalleşmenin ve endüstri 4.0'ın miladı olarak tarif edilmesi nedeniyle bu tarihten sonra yapılan çalışmalar hedeflenmiştir. Tarım, inşaat, ulaştırma, sağlık sektörü gibi sektörlerin çalışmanın alanından çıkarılması için “excluding criteria” olarak belirlenerek çalışmalardan çıkarılmıştır. Taramalar genel olarak özet kısımlarda yapılmıştır, bunun nedeni direkt olarak konuyla ilgili makalelerin ortaya çıkarılabilmesidir.

Anahtar kelimelerle birçok uluslararası makalenin yayımlandığı Science direct, IEEEExplore gibi internet sitelerinde yapılan 2010 sonrası çalışmaların esas alındığı makaleler göz önünde bulundurulmuştur.

“Digitalisation”+“Digitalization”+“Sustainability”+“Productivity”+“Manufacture” anahtar kelimeleriyle hizmet sektörünün ve kamu sektörüyle ilgili çalışmalar çıkarılarak, 458 belirlenmiştir. Çalışmalar taranarak 25 çalışmanın konu ile ilgili olduğu belirlenmiştir. Yazarlarca yapılan çalışmaların özet kısımlarında yapılan inceleme sonucu 9 çalışmanın sistematik literatür taramasına dahil edilmesine karar verilmiştir.

Amaç mühendislik alanındaki gelişmeleri de çalışmaya dahil etmekte olduğundan mühendislik alanında yapılan çalışmaları barındırması nedeniyle bu veri sitesi seçilmiştir. “Digitalisation”+”Digitalization”+”Sustainability”+”Productivity”+”Manufacture” anahtar kelimeleriyle, hizmet sektörünün ve kamu sektörüyle ilgili çalışmalar çıkarılarak ile 342 çalışma belirlenmiştir. Yazarlarca yapılan çalışmaların özet kısımlarında yapılan inceleme sonucu 15 çalışmanın belirlendiği, konuyla direk ilgisi bulunan 11 çalışmanın sistematik literatür taramasına dahil edilmesine karar verilmiştir.

Çalışmaya ait Sistematik Litaretür Taraması tabloları sıra numaralarıyla aşağıda verilmektedir. Tabloda sırasıyla yazarlar, çalışmanın adı, yayınlanma tarihi, çalışmanın konusu ve bulgulara yer verilmiştir. Daha sonra tablodaki veriler ışığında sistematik tarama bulguları ortaya konarak yorumlanmıştır.

Tablo.1. IEEE endeksi kaynaklar

Yazarlar	Çalışmanın İsmi	Yıl	Çalışmanın Amacı	Bulgular
Olumide Olajide Ojo Stefan Zigan John Orchard Satya Shah	Advanced Technology Integration in Food Manufacturing Supply Chain Environment: Pathway to Sustainability and Companies' Prosperity	2019	İspanya’da bulunan bir tarım-hayvancılık işletmesinin tedarik zinciri ortamındaki sürdürülebilirliğine katkıda bulunmak için bir vaka çalışması gerçekleştirilmiş	İleri teknoloji ve tedarik zinciri yönetiminin bir arada kullanılması işletmelere olumlu yansımıştır.
Fernando Almeida Jose Duarte Santos Jose Augusto Monteiro	The Challenges and Opportunities in the Digitalization of Companies in a Post-COVID-19 World	2020	Covid-19 dönemi ve sonrasında işletmelerin dijitalleşme sürecinde gösterdikleri gelişmeler ele alınmıştır. Bu bağlamda üç alanda araştırma yapılmış: Emek ve sosyal ilişkiler, pazarlama ve satış, teknoloji.	Çalışmada işletmelerin Covid-19 ve sonrasında dijitalleşme değişimlerin etkili olacağı ifade edilmiştir. Çalışma işletmeler için rehber görevi görmektedir.

Konstantinos Georgiou Nikolaos Mittas Ioannis Mamalíkídis Athanasios Mitropoulos Lefteris Angelis	Analyzing the Roles and Competence Demand for Digitalization in the Oil and Gas 4.0 Era	2021	Petrol ve gaz endüstrisinin dijital kariyer fırsatları araştırılmıştır. Sonra, bu sektörlerin dijital iş rolleri ve ilgili becerileri incelenmiştir.	Araştırma sorularının cevapları bulunarak tartışılmış ve buradan elde edilen bulgular değerlendirilmiştir
Wan Ri Ho Naoum Tsolakis Tom Dawes Manoj Dora Mukesh Kumar	A Digital Strategy Development Framework for Supply Chains	2023	Dijital tedarik zinciri için yeni bir strateji geliştirme ve bunu formülize ederek operasyon yönetimine katkı sunmak	Çalışma sonucunda üç tipoloji ortaya çıkmıştır. Birincisi yukarıdan aşağıya, ikincisi aşağıdan yukarıya ve üçüncüsü karışık.
David Sjödin Anmar Kamalaldin Vinit Parida Nazrul Islam	Procurement 4.0: How Industrial Customers Transform Procurement Processes to Capitalize on Digital Servitization	2023	Amaç, endüstriyel müşteriler için dijital hizmetleştirmenin fırsatlarını ve zorluklarını ele almak için satın alma süreci modellerinin nasıl uyarlanabileceğini araştırmaktır.	Çalışma sonucunda tedarik 4.0 için model geliştirilmiş ve dijital hizmetler literatürüne katkıda bulunulmuş, üst düzey yöneticilerel öneriler sunulmuştur.
Clarissa Rocha , Carlos Quandt , Fernando Deschamps , Simon Philbin , and Giovani Cruzara	Collaborations for Digital Transformation: Case Studies of Industry 4.0 in Brazil	2023	İşletmelerin iş ortaklarıyla yaptıkları işbirliklerinin dijital dönüşüme katkısı araştırılmış. Bu kapsamda Brezilya’da faaliyet gösteren 3 işletme ile çalışılmış.	İşletmelerin dijital dönüşüm sürecinde yolun başında oldukları anlaşılmıştır. İşletmeler zihniyet, operasyonel süreçler ve iş modellerini yeniden şekillendirmeleri gerekir.

Manohar Mishra ,Monalisa Bıswal, Ramesh c. BANSAL Janmenjoy Nayak, Ajith Abraham and Om p. Malık	Intelligent Computing in Electrical Utility Industry 4.0: Concept, Key Technologies, Applications and Future Directions	2022	Endüstri 4.0'ın detaylı analizi yapılmış ve mevcut literatür gözden geçirilerek elektrik hizmetleri endüstrisindeki sonuçları, gelecekteki yeri ve uygulama basamağı özeti yapılmıştır.	Hazırlanan bu özetin endüstri 4.0 alanıyla ilgilenen kişilere ve elektrik hizmetleri endüstrisine rehber niteliği taşıyacağı ifade edilmiştir.
Francesco Arcidiaco-no; Ales-sandro An-carani; Car-mela Di Mauro; Flo-rian Schupp	Where the Rubber Me-ets the Road. Industry 4.0 Among SMEs in the Auto-motive Sector	2019	Otomotiv sektöründe faaliyet gösteren KOBİ'lerin en-düstri 4.0 sürecine geçiş uygulamala-rını kolaylaştıran stratejik kararlara ışık tutmak	Endüstri 4.0 uygulamada üç önemli faktöre dayanır: Yenili-ğe proaktif bir yaklaşım, tedarikçiler ile uzun vadeli ortaklıklar geliştirilmesi ve işçilerin tekno-lojik değişimlere katılımı.
Michele Compa-re; Piero Baraldi; En-rico Zio	Challenges to IoT-Enabled Predictive Ma-intenance for Industry 4.0	2020	Bahsedilen PDM (bakım paradigma-sının) güçlü ve za-yıf yönleri, zorluk-ları ve avantajları hakkında detaylı bilgi sunabilmek için ilgili literatür kapsamlı şekilde analiz edilmiştir.	Nesnelerin İnter-neti ve Endüstri 4.0 PDM üzerin-de olumlu etkisi yapar. Özellikle, Nesnelerin İn-terneti temeline dayanan PDM sistemlerinin önemli yatırımlara konu olduğu belirtilmiştir.

5. BULGULAR

Sistemantik literatür taraması bulgularına göre, Covid-19 ve sonrası dönemde dijitalleşmeye dönük değişimlerin etkili olacağı ifade edilmiştir (Almeida, 2020). Literatürde dijitalleşme çalışmalarının COVID-19 sonrası dönemde arttığı gözlemlenmiştir. İşletmeler, dijital dönüşüm sürecinde henüz yolun başında oldukları anlaşılmıştır (Rocha vd., 2021).

İşletmelerin dijitalleşmeye geçtiklerinde değer akışlarının tamamının uyum sağlaması gerektiği, işletmelerin zihniyetlerini, operasyonel

süreçlerini ve iş modellerini yeniden şekillendirmeleri gerektiği vurgulanmıştır (Rocha vd., 2021). İnovasyon ve müşterilerin talep dinamiğindeki değişikliklere bağlı olarak Akıllı Üretim anlayışına dayanan bir işletme içinde işbirliğine ihtiyaç olduğu belirtilmiştir (Davis vd. 2021). Dijital tedarik zinciri tipolojisinde, yukarıdan aşağıya, ikincisi aşağıdan yukarıya ve üçüncüsü karışık tipolojiyle, verimliliğin arttığı gözlemlenmiştir (Ho vd., 2023). Nesnelerin İnterneti ve Endüstri 4.0 gibi teknolojilerin önleyici bakım paradigması (PDM) üzerinde olumlu etkisi olduğu söylenmiştir (Compare vd., 2020).

Endüstri 4.0'ın başarıyla uygulanabilmesi için üç önemli faktöre değinilmiştir: Yeniliğe proaktif bir yaklaşım, Endüstri 4.0 teknolojilerinin tedarikçileri ile uzun vadeli ortaklıkların geliştirilmesi ve işçilerin teknolojik değişimlere katılımının teşvik edilmesi (Arcidiacono, 2019).

Endüstri 4.0'ın unsurlarından Nesnelerin İnterneti ve 3-D baskı teknolojilerinin, endüstriyel sektörde etkin olarak kullanıldığı ortaya çıkmıştır. Endüstri 4.0'ın kaynak verimliliği, sürdürülebilir enerji ve şeffaflık açısından sürdürülebilir kalkınmanın çevresel yönüne olumlu katkı sunduğu sonucu ortaya çıkmıştır (Ali vd., 2023).

Endüstri 4.0'ın ve sürdürülebilirliğin iki şekilde kullanılmaktadır. Bunlardan ilki bazı işletmelerin operasyonel verimliliği artırmak için Endüstri 4.0 teknolojisini kullanmasıdır. Bu sayede çevresel kazanımlar elde etmişlerdir. İkincisi ise bazı işletmelerin üretkenliği artırmayı amaçlamak için bu teknolojileri kullanmasıdır. Böylece çevresel ayak izini azaltmışlardır (Calabrese, A., Costa, R., Tiburzi, L., & Brem, A., 2023).

Endüstri 4.0'ın, dört sağlayıcısının sürdürülebilirliğe etkilerini arttırmak için ürün dizaynlarının artırılmış sanal gerçeklikten faydalanmaları gerekmektedir. Üretimin dikey ve yatay eksenleriyle olan iletişimi ve işbirliğini arttırabilmek için İşletme Kaynak Programlarının (ERP) dikey ve yatay entegrasyonunun sağlanmasıyla mümkün olabileceği, değer zincirlerinin azaltılmasının daha etkin sonuçlar doğuracağını, Geri besleme sisteminin, sistemde oluşan verilerin değerlendirilmesi yoluyla edinilebileceğini, bu sayede, süreç kalitesinin artırılabilceğini ve etkinlik sağlanabileceği saptanmıştır (Schuh vd., 2015). Sürdürülebilirliğe en çok katkısı bulunan Endüstri 4.0 bileşeni 3-D yazıcılardır (Calabrese, A., Costa, R., Tiburzi, L., & Brem, A., 2023).

Üretim süreçleri optimizasyonlarının MOO SMS teknikleri kullanılarak daha az karbon salınımına, üretkenliğin arttırılmasına, maliyetlerin düşürülmesini sağladığı gözlemlenmiştir. Üretim süreçlerinin planlanmadan önce simülasyon çalışmaları yapılmasıyla daha az karbon salınımı yapılabileceği gözlemlenmiştir. MOO optimizasyon çözümleri ile işletmelerin içinde bulunduğu üretim süreçlerini iyileştirirken aynı zamanda çevresel

zararları azaltmaları üzerine çözüm önerileri bulunmaktadır. (Nujoom, Mohammed, & Wang, 2019. Üretim süreci planlamasında, simülasyonlar ve nesnelerin internetini kullanan üretim girdilerinin gerçek zamanlı veri akışı sağlandığında sürdürülebilir üretim planlamasına katkı sunduğu ortaya çıkmıştır (Pirola vd., 2021)

Tehlikeli kimyasal maddelerle üretim yapılan tesislerde, dijital araçları kullanarak (CAD/CAM ve 3-D yazıcılar) işçilerin sağlığına olan olumsuz etkilerin azaldığı, verimliliğin yükseldiği, karbon salınımının azaldığı, enerji tüketiminin azaldığı, kalitenin arttığı, ürün süreçlerinin standartlaştığı gözlemlenmiştir (Jayawickrama, Dharmawardana, Kulatunga, Karunaratna, & Osadith, 2016). Enerji üretim tesislerinde yenilenebilir ve sürdürülebilir malzeme yönetimi için Endüstri 4.0 teknolojilerinin kullanımının önem arz ettiği sonucu ortaya çıkmıştır (Onu vd., 2023). Sürdürülebilirlik kaygısı ile hareket eden, petrol ve gaz endüstrisinin dijital kariyer fırsatlarını arttırdığı gözlemlenerek, dijitalleşmenin enerji sektörünün insan kaynakları potansiyelinde dikkate alındığı gözlemlenmiştir (Georgiou vd., 2021). Tarım-hayvancılık işletmesinin ileri teknoloji ve tedarik zinciri ortamındaki entegrasyonu sürdürülebilirliğe katkıda bulunmuştur.

Sürdürülebilirliğin arttırılabilmesi için yeni metodoloji olarak 6R (Materyal, enerji, su ve diğer kaynakların daha az kullanımı; ürünlerin yeniden değerlendirilmesi, geri dönüşüm, ürünlerin yeniden üretimi ve geri dönüştürülen materyallerden yeni ürünler üretilmesi) Metodolojisi kullanılarak, işletmelerin ekonomik, çevresel ve toplumsal açılardan sürdürülebilir bir üretim anlayışı geliştirmelerine yardımcı olmuştur (Hernandez vd., 2019).

6. Sonuç ve Öneriler

Genel olarak literatürde, uygulanan dijitalleşme ve otomasyon sonucunda israfların azaldığı, üretimin arttığı ve çevresel zararların azaltıldığı, böylece sürdürülebilirliğin ve verimliliğin arttığını, çevresel olumsuz etkilerin azaldığını ölçmek amacıyla yapılan vaka çalışmalarının ağırlıkta olduğu gözlemlenmiştir.

İşletmeler dijitalleşme süreçlerinde yatay ve dikey bütün süreçlerini göz önünde bulundurmalıdır. Üretim süreçlerinin planlamasında sürdürülebilirlik kaygısıyla simülasyon çalışmalarının önem kazandığı, Endüstri 4.0'ın kaynak verimliliği, sürdürülebilir enerji ve şeffaflık açısından sürdürülebilir kalkınmanın çevresel yönüne olumlu katkı sunduğu görülür.

Tehlikeli madde, kimyasal üretim yapan tesislerin, dijitalleşmeye giderek fazla önem verdiği yapılan çalışmalarda gözlemlenmiştir. Tehlikeli kimyasal maddelerle üretim yapılan tesislerde, dijital araçları kullanarak işçilerin sağlığına olan olumsuz etkilerin azaldığı, verimliliğin yükseldiği,

karbon salınımının azaldığı, enerji tüketiminin azaldığı, kalitenin arttığı, ürün süreçlerinin standartlaştığı gözlemlenmiştir.

Geleneksel üretim kullanan küçük işletmelerin çokça bulunduğu gelişmekte olan ülkelerde karlı olma kaygısının sürdürülebilirlik kaygısından daha fazla önemli olduğu, küçük ve atölye tipi üretim yapan işletmelerin sürdürülebilirliğe önem vermemeyi bir eğilim haline getirdikleri sonucu çıkmaktadır.

Bu sistematik literatür taraması çalışmasında uluslararası literatürde dijitalleşmenin sürdürülebilirliğe ve verimlilik üzerine olan etkileri alanında yapılan çalışmaları görmek, literatürün ne yönde yakınsadığını ortaya çıkarmak ve hangi alanda çalışmaların yoğunlaşması gerektiğini görme amacı gütmüştür.

Çalışmada, giderek artmakta olan endüstri 4.0 gelişmelerinin üretimde verimliliği arttıracığı ve tüm paydaşlara sürdürülebilir bir çevre sağlamak için bu alandaki yapılan çalışmalara bir katkı sağlanmayı amaçlamaktadır.

Türkiye'nin de içinde bulunduğu gelişmekte olan ülkelerin küçük orta ölçekli işletmelerin (SME) yapmış oldukları teknolojik gelişmelerin üretim verimliliğine ve sürdürülebilirliğe olan katkılarını inceleyen daha fazla çalışmanın ortaya çıkmasının, bu alandaki duyarlılığı artırılabilceği değerlendirilmektedir.

Her sistematik literatür taramasında olduğu gibi yazarların eğilimi ve doğrulama yanlısaması ve sadece İngilizce makalelerin incelenmesi, bazı makalelerin henüz basım aşamasında oluşu, çalışmaların kendi önyargıları bu çalışmanın doğal bir kısıtıdır.

Yalın üretim süreçlerinin dijitalleşmesinin değer akışlarında, iç ve dış müşterilere değer katmayan gereksiz israfların azaltılmasının sürdürülebilirliğe ne gibi etkileri olacak araştırılmalıdır. Endüstri 4.0 uygulamalarının yalnızca bir bölümü uygulanarak, daha dar kapsamlı çalışmaların incelendiği literatür taramalarına ihtiyacın bulunduğu gözlemlenmiştir. Ortaya çıkardığımız literatür eksikliğinin literatürde ne yönde çalışmaların yapılması gerektiğini göstermesi açısından bu çalışmanın önemli bir sonucudur.

KAYNAKÇA

- Ali, M., Salah, B., & Habib, T. (2023). Utilizing industry 4.0-related technologies and modern techniques for manufacturing customized products – Smart yogurt filling system. *Journal of Engineering Research*, 100144. <https://doi.org/10.1016/j.jer.2023.100144>
- Almeida, F., Santos, J. D., & Monteiro, J. A. (2020). The challenges and opportunities in the digitalization of companies in a post-COVID-19 World. *IEEE Engineering Management Review*, 48(3), 97-103.
- Arcidiacono, F., Ancarani, A., Di Mauro, C., & Schupp, F. (2019). Where the rubber meets the road. Industry 4.0 among SMEs in the automotive sector. *IEEE Engineering Management Review*, 47(4), 86-93.
- Autor, D., & Salomons, A. (2018). Is Automation labor share–displacing? Productivity growth, employment, and the labor. *Brookings Papers on Economic Activity*, 1-63.
- Bayuk, m. (2019). Endüstri 4.0 Kapsamında Yapay Zekâ ve Pazarlamanın Geleceği. *Journal of Social, Humanities and Administrative Sciences*, 5(19), 781–799. <https://doi.org/10.31589/joshas.163>
- Bessen, J. (2019). Automation and jobs: when technology boosts employment, *Economic Policy*, 34(100), 589-626
- Calabrese, A., Costa, R., Tiburzi, L., & Brem, A. (2023). Merging two revolutions: A human-artificial intelligence method to study how sustainability and Industry 4.0 are intertwined. *Technological Forecasting and Social Change*, 188, 122265. doi:10.1016/j.techfore.2022.122265
- Compare, M., Baraldi, P., & Zio, E. (2019). Challenges to IoT-enabled predictive maintenance for industry 4.0. *IEEE Internet of Things Journal*, 7(5), 4585-4597.
- Çelik, K. (2021). Bulut Bilişim Teknolojileri. *Bartın Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. <https://doi.org/10.47129/bartiniibf.1019898>
- Davis, J., Edgar, T., Porter, J., Bernaden, J., & Sarli, M. (2012). Smart Manufacturing, manufacturing intelligence and demand-dynamic performance. *Computers & Chemical Engineering*, 47, 145–156. doi:10.1016/j.compchemeng.2012.06.037
- El-Halwagi, M. M. (2017). Introduction to sustainability, sustainable design, and process integration. *Sustainable Design Through Process Integration*, 1–14. doi:10.1016/b978-0-12-809823-3.00001-1
- Georgiou, K., Mittas, N., Mamalikidis, I., Mitropoulos, A., & Angelis, L. (2021). Analyzing the roles and competence demand for digitalization in the oil and gas 4.0 era. *IEEE Access*, 9, 151306-151326.
- Graetz, G., & Michaels, G. (2018). Robots at work. *The Review of Economics and Statistics*, 5, 753–768

- Hernández, A. E. B., Lu, T., Beno, T., Fredriksson, C., & Jawahir, I. S. (2019). Process sustainability evaluation for manufacturing of a component with the 6R application. *Procedia Manufacturing*, 33, 546-553.
- Ho, W. R., Tsolakis, N., Dawes, T., Dora, M., & Kumar, M. (2022). A digital strategy development framework for supply chains. *IEEE Transactions on Engineering Management*.
- İlhan, İ. (2019). Tekstil üretim süreçleri açısından endüstri 4.0 kavramı. *Pamukkale Univ Muh Bilim Derg*, 25(7), 810-823.
- Jayawickrama, H. M. M. M., Dharmawardana, M., Kulatunga, A. K., Karunarathna, K. G. S. P., & Osadith, S. A. U. (2016). Enhancement of productivity of traditional brass manufacturing industry using sustainable manufacturing concept. *Procedia CIRP*, 40, 562-567. doi:10.1016/j.procir.2016.01.134
- Kablan, A. (2018). Endüstri 4.0, “Nesnelerin İnterneti” - Akıllı İşletmeler Ve Muhasebe Denetimi. *Endüstri 4.0 ve Örgütsel Değişim Özel Sayısı*, 23, 1561-1579.
- Kıray, A., & Kaplan, M. (2022). *TEKNOLOJİK DÖNÜŞÜM, İŞLETME ve EKONOMİ*. Bursa: EKİN Basım Yayın Dağıtım.
- Nujoom, R., Mohammed, A., & Wang, Q. (2019). Drafting a cost-effective approach towards a sustainable manufacturing system design. *Computers & Industrial Engineering*, 133, 317-330. doi:10.1016/j.cie.2019.05.007
- Pirola, F., Zambetti, M., & Cimini, C. (2021). Applying simulation for sustainable production scheduling: a case study in the textile industry. *IFAC-PapersOnLine*, 54(1), 373-378.
- Porter, M. E. (1985). *Competitive advantage: Creating and sustaining superior performance*. Free Press.
- Rocha, C., Quandt, C., Deschamps, F., Philbin, S., & Cruzara, G. (2021). Collaborations for digital transformation: Case studies of industry 4.0 in Brazil. *IEEE Transactions on Engineering Management*.
- Ojo, O. O., Zigan, S., Orchard, J., & Shah, S. (2019, June). Advanced technology integration in food manufacturing supply chain environment: pathway to sustainability and companies' prosperity. In 2019 IEEE Technology & Engineering Management Conference (TEMSCON) (pp. 1-7). IEEE.
- Onu, P., Pradhan, A., & Mbohwa, C. (2023). The potential of industry 4.0 for renewable energy and materials development-The case of multinational energy companies. *Heliyon*, 9(10).
- Schuh, G., Reuter, C., & Hauptvogel, A. (2015). Increasing collaboration productivity for Sustainable Production Systems. *Procedia CIRP*, 29, 191-196. doi:10.1016/j.procir.2015.02.010
- Şekkeli, Z. H., & Bakan, İsmail. (2018). Smart Factories. *Journal of Life Economics*, 5(4), 203-220. <https://doi.org/10.15637/jlecon.270>

- Tonga, M., & Tonga, M. (2022a). Endüstri 4.0'a Genel Bir Bakış: Sanayinin Geleceği. *G. Ü. İslahiye İİBF Uluslararası E-Dergi*, 6(6), 40–60.
- Vartolomei, V. C., & Avasilcai, S. (2019). Challenges of digitalization process in different industries. before and after. *IOP Conference Series: Materials Science and Engineering*, 568(1), 012086. doi:10.1088/1757-899x/568/1/012086
- Voitsekh, V. O. (2023). Retrospective analysis of the word “digitalization.” *Business, Economics, Sustainability, Leadership and Innovation*, (9), 4–9. doi:10.37659/2663-5070-2022-9-4-9
- Yılmaz, Y. (2021). Dijital Ekonomiye Geçiş Süreci, Ölçümü ve Dijitalleşme Verimlilik İlişkisi. *Istanbul Journal of Economics / İstanbul İktisat Dergisi*, 71(1), 283–316. <https://doi.org/10.26650/istjecon2021-931788>
- WCED. (1987). Our common future. Oxford: Oxford University Press.
- Weckesser, P. (2021). Why sustainability and digitization go hand-in-hand. Retrieved from <https://blog.se.com/digital-transformation/2021/05/13/why-sustainability-and-digitization-go-hand-in-hand/>
- Digitalization and sustainability. (2023). *Strategic Direction*. <https://doi.org/10.1108/sd-06-2023-0078>

ÜRETİM YÖNETİMİNDE TALEP TAHMİNLEMEDE DERİN ÖĞRENME TEKNİKLERİ

Gökhan TURGAY¹

Metin BAYRAM²

1. GİRİŞ

İşletmeler varlıklarını sürdürebilmek için kaynaklarını verimli kullanmak zorundadır. İşletmeler, kaynaklarını doğru kullanabilmek, gelecek olaylara hazırlıklı olabilmek adına tahminleme yapmak durumunda kalırlar. Gelecek talepleri doğru tahmin edebilen firmalar, doğru zamanda doğru ihtiyaçları tedarik ederek, ihtiyaçlarını optimum kaynak kullanarak karşılayabilme yeteneğine sahip olur. Bu sayede firmalar kendilerini, gereksiz ve yanlış kaynak kullanması kaynaklı finans sorunları, talep karşılayamama, gereksiz stok maliyetleri gibi durumlardan koruyabilirler.

Gelecekte belirli bir zaman dilimi için bir şirketin ürün veya ürünleri için gelecek talep seviyesini tespit etme süreci olan talep tahmini, işletmelerin stratejik planlaması açısından da önemlidir. Özellikle; hammadde tedarik süresi uzun veya uzun üretim süreçlerine sahip işletmelerin, piyasa taleplerine zamanında cevap verebilmek, taleplere uygun tedarikte bulunmak, uygun hammadde stok seviyesinde kalmak işletmenin finansal yapısını koruyabilmesi için oldukça önem teşkil etmektedir.

Talep tahmini için geçmişten beri kullanılmış birçok yöntem bulunmakla beraber teknolojinin gelişmesiyle yapay zeka tabanlı tahminlemelerin geleneksel yöntemlere göre kolaylık sağlamaktadır. Çok fazla değişkene bağlı ve doğrusal bir modele uymayan problemlerin çözümünde, çoklu veri setleri ile çalışma için daha elverişli yapay zekaya

¹ İşletme Yüksek Lisans Öğrencisi, Sakarya Üniversitesi, İşletme Enstitüsü, İşletme Bölümü, gokhan.turgay@windowslive.com, ORCID: 0000-0003-0431-4448

² Dr. Öğr. Üyesi, Sakarya Üniversitesi, İşletme Fakültesi, İşletme Bölümü, metinbayram@sakarya.edu.tr, ORCID: 0000-0002-9483-7850

dayalı yöntemler, geleneksel yöntemlere göre daha etkili çözümler sunmaktadır (Yazıcıoğlu, N. 2010 s.71). Litaratür deki yapay zeka ile talep tahmini çalışmaları; gıda (Ünlü, 2019), tekstil (Eren ve Satoğlu, 2017) ve otomobil (Kaya ve Yıldırım, 2020) olmak üzere birçok alanda yapılmıştır.

Bu bölümde; talep tahmini kavramı ve talep tahmin yöntemleri genel hatları ile açıklanarak, talep tahmini çalışmalarında kullanılabilecek derin öğrenme teknikleri incelenecektir. Talep tahminleme de kullanılan derin öğrenme tekniklerinin avantaj ve dezavantajları incelenecek olup bu tekniklerin birbirlerine karşı hangi alanlarda üstünlük sağladığı araştırılacaktır.

2. TALEP TAHMİNİ VE TALEP TAHMİN YÖNTEMLERİ

2.1. Talep Tahmin Kavramı

Üretim yönetiminde talep, bir ürünün belirli miktar ve özellikler de istenilen zamanda satın alınması isteğidir. Talep tahmini ise, ürün veya hizmetlerin ne zaman ve ne miktarda isteneceğinin tahmin edilmesidir. Bu tahminleme, işletmelerin üretim planlamasında, işgücü planlamasında ve ihtiyacı olan hammaddelerin tedariğinin planlanmasında kritik bir rol oynar. İşletmelerin tahminlerindeki doğruluk, finans, işgücü, hammadde ve kapasite gibi kaynaklarını optimum seviyede kullanması ve işletme maliyetlerini en düşük seviyelerde tutarak faaliyet verimliliğini koruyabilmesini sağlar.

2.2. Talep Tahmin Süreçleri

Talep tahmin süreçleri 5 aşamada gerçekleştirilir. Bu 5 adım (Kobu, 2008) sırasıyla, hedefin belirlenmesi, tahmin zamanının belirlenmesi, tahmin zamanının belirlenmesi, bilgilerin toplanması, tahmin yönteminin belirlenmesi ve hatanın hesaplanması, tahmin yönteminin belirlenmesi ve hatanın hesaplanması süreçlerini içerir.

2.3. Talep Tahmin Türleri

2.3.1. Kalitatif Yöntemli Tahminler

Bu tür tahminler, bir veya birden fazla kişinin geçmiş deneyimlerini, sezgilerini ve kişisel değerlendirmelerini temel alarak, matematiksel modele dayanmadan gerçekleştirilir. Ancak, verilere dayanmadığından dolayı genellikle tahminlerin doğruluk düzeyi düşüktür.

2.3.1.1. Delphi Metodu

Tahmin sürecinde, karar verici kişi ya da kişiler bir araya gelmeden, uzmanlara sorular yöneltilir. Daha sonra alınan yanıtlar derlenerek raporlanır ve yeni sorular oluşturularak uzmanlara tekrar iletilir. Bu süreç, istenilen ve üzerinde uzlaşma sağlanmış sonuçlar elde edilinceye kadar sürdürülür. Tekniğin avantajı, kişilerin bir araya gelmemesi sebebiyle çatışmaların azalması ve herkesin bilgisinde istifade edilebilmesidir. Sistemin dezavantajı ise sistemin aşamalı olması sebebiyle yavaş işlemesidir. (Linstone & Turoff, 1975, s. 3)

2.3.1.2. Pazar Araştırması Yöntemi

Tüketici talepleri, telefon ve e-posta görüşmeleri ve anketler gibi yöntemlerin kullanılarak tüketicilerden bilgi toplayarak gerçekleştirilir. Pazar araştırmalarında sık kullanılan yöntemler genellikle anket uygulamalarıdır. Yeni bir ürünün piyasa koşullarındaki olası taleplerinin öngörülmesi aşamasında anketler düzenlenir. Ancak, katılımcı cevaplarının net olmaması, testlere rastgele cevaplar verilmesi gibi dezavantajları bulunmaktadır. (Malhotra, 2010, s. 45)

2.3.1.3. Satış Grupları Yöntemi

Satış ekipleri veya satış ve pazarlama alanında faaliyet gösteren personellerin, sürekli müşteri iletişimi kurarak geliştirdikleri gelecekle ilgili elde ettiği tahminler ve kendi deneyim ve görüşlerine dayanarak oluşturulan tahminlerdir. Bu personellerin, tüketicilerle yüz yüze görüşme fırsatları olduğundan satış tahminlerin yapılmasında aşamasında bu yaklaşım iyi bir rol oynar. Ancak, öznel özellikler taşıdığından güvenilirliği tartışılan bir yöntemdir. (Thomas, 2009, s. 24).

2.3.1.4. Yönetici Değerlendirmeleri Yöntemi

Bu tahmin yönteminde üst düzey yöneticilerin görüşleri esas alınır. Geçmiş verilere erişimin sınırlı olduğu durumlarda zaman ve maliyet açısından avantaj sağladığı için bu yöntem sıklıkla tercih edilir. Bununla birlikte, kararların kişisel değerlendirmelere dayanması, bazı dezavantajları beraberinde getirebilir ve yöneticilerin bireysel sorumluluklarını ön plana çıkarır.

2.3.1.5. Tarihsel Bilgilere Dayalı Yöntem

Geçmiş dönemlere ait aynı özellikleri içeren ürün veya ürün gruplarının verilerinin analiz edilmesiyle gerçekleştirilir. Yeni pazara

girecek veya değişiklik yapılacak ürün veya ürün gruplarında tüketicilerin talep ve ihtiyaçları göz önünde tutularak değerlendirilebilir.

2.3.2. Kantitatif Tahmin Yöntemleri

Geçmiş talep verilerinin istatistiksel yöntemlerle analiz edilerek gelecek dönem taleplerini belirlemeyi amaçlayan yöntemdir. Bu yöntem tipleri, verilere dayandığından dolayı tahmin performansında yüksek doğruluk sağlar ve tecrübe gerektirmeksizin kullanılabilir.

2.3.2.1. Zaman Serisi Analizi

Bu yöntem, geçmiş verilerin analiz edilmesiyle bir model oluşturulmasını ve bu modelin tahminlerde kullanılmasını içerir. Zaman dilimleri bağımsız değişkenleri oluştururken, stok miktarı, verim yüzdesi gibi değişkenler bağımlı değişkenlerdir. Ancak, öngörülemeyen değişimlerde bu yöntem yeterince etkili olmayabilir. Zaman serilerinde benzer yönde verilerin değişimini 'trend' olarak adlandırılır. Bu benzer değişimlere mevsimsellik örnek olarak gösterilebilir. Zaman serileri analizi için genellikle basit hareketli ortalama, ağırlıklı hareketli ortalama, üssel düzeltme, Holt'un lineer metodu, Holt-Winter yöntemi, Box-Jenkins yöntemi ve otoregresif modeller gibi çeşitli teknikler kullanılır (Salttürk, 2022).

Basit hareketli ortalama yöntemi, geçmiş n dönemdeki talep değerlerinin ortalamasını alarak tahmin yapar (Salttürk, 2022). Bu yöntem, hesaplanacak dönemin tahminini önceki dönem verilerinden etkilenmesini varsayar. Doğru bir tahmin elde etmek için n değeri deneysel olarak belirlenebilir. Aşağıdaki denklemde, F_t 'nin t dönemi için tahminini Y_t 'nin önceki dönemdeki gerçekleşen değerleri üzerinden ifade etmektedir. İfade denkliği (2.1) aşağıdaki gibidir.

$$F_t = \frac{-Y_{t-1} - 1 + Y_{t-1} - 2 + Y_{t-3} + \dots + Y_{t-n}}{n} \quad (2.1)$$

Bu formülde, F_t t dönemindeki tahmin değerini; Y_{t-1} ise önceki dönemde gerçekleşen değeri temsil eder. n , toplam dönem sayısını ifade eder (Salttürk, 2022).

Ağırlıklı hareketli ortalama yönteminde, talep dönemlerine ağırlık çarpanı eklenerek, benzer dönemlerin ortalamaya daha fazla etkiye bulunmasını sağlar. Bu yöntemde, dönemlere yakın olanlar daha yüksek ağırlığa sahiptir, uzak dönemler etkilerini daha az gösterir. Ağırlıkların toplamı her zaman '1' olmalıdır. Basit hareketli ortalama yönteminden

farkı, dönemlere farklı ağırlık değerleri atanmış olmasıdır. Basit hareketli ortalamada ise ağırlık değerleri dönemler arasında eşit kabul edilir, bu nedenle ağırlık çarpanı '1' olarak kalır. Aşağıdaki denklemdeki (2.2) gibi hesaplama yapılır.

$$F_t = \frac{W_1 * Y_{t-1} + \dots + W_n * Y_{t-n}}{W_1 + W_2 + \dots + W_n} \quad (2.2)$$

W_n , n dönemine ait gerçekleşen talebin W ağırlık değerleriyle çarpılması sonucunda elde edilir; burada W , ağırlık değerini temsil eder ve bağımsız değişkeni Y ifade eder.

Üssel düzeltme yöntemi, önceki dönem tahmin hatasına odaklanır. Tahmin edilen dönem, bir önceki dönem tahmin hatasının bir kısmıyla düzeltilir ve yeni bir tahmin oluşturulur. Pozitif hata değeri, tahminin gerçekleşen değerden yüksek olduğunu gösterir. α düzeltme sabiti kullanılarak tahmin hatası azaltılır ve bu sabitin genellikle 0.05 ile 0.30 arasında bir değer aldığı kabul edilir. Uygun bir α değeri belirleme önemlidir.

$$F_{t+1} = \alpha * Y_t + (1 - \alpha) * F_t \quad (2.3)$$

t periyodu, F_t tahmini F_{t+1} , önceki dönemin tahmini F_t , önceki dönemin talebini Y_t , ve α düzeltme sabitini ifade etmektedir.

Holt lineer (İkili üssel düzeltme) yöntemi, tahmin yapmak için iki üssel düzeltme katsayısı (α ve β) kullanır. Holt, seriyi bir trende göre tahmin etmek amacıyla üssel düzeltme yöntemini geliştirmiştir ve bu nedenle Holt lineer yöntemi ortaya çıkmıştır. Her iki düzeltme sabiti, yalnızca 0 ile 1 arasında değer alabilir ve ilgili formülasyonlar (2.4), (2.5), (2.6) aşağıda gösterilmiştir

$$L_t = \alpha * Y_t + (1 - \alpha) * (L_{t-1} + b_{t-1}) \quad (2.4)$$

$$b_t = \beta * (L_t - L_{t-1}) + (1 - \beta) * b_{t-1} \quad (2.5)$$

$$F_{t+m} = L_t + b_t * m \quad (2.6)$$

L_t serinin t zamandaki değerini, b_t serinin t zamandaki eğim değerini belirtir, m tahmin edilecek dönem sayısını ifade eder (Salttürk, 2022).

Holt-Winter yöntemi, talebin doğrusal modele sahip olmadığı özellikle zaman serisine trend ve mevsimsellik eklenmiş durumda ise durumlarda kullanılır. Bu yöntemde üç farklı düzeltme bulunmakta olup α düzeltme, β trend düzeltme, γ ise mevsimsellik için düzeltme sabitleridir.

Bu üç sabit, sadece 0 ile 1 arasındaki değerleri alabilir. İlgili formülasyonlar (2.7), (2.8), (2.9), (2.10) aşağıdaki gibidir.

$$L_t = \alpha * (Y_t - S_t - s + (1 - \alpha) * (L_{t-1} + b_{t-1})) \quad (2.7)$$

$$b_t = \beta * (L_t - L_{t-1}) + (1 - \beta) * b_{t-1} \quad (2.8)$$

$$S_t = \gamma * (Y_t - L_t) + (1 - \gamma) * S_{t-s} \quad (2.9)$$

$$F_{t+m} = L_t + b_t * m + S_{t-s+f} \quad (2.10)$$

Box-Jenkins yöntemi, 1970-1976 yıllarında Box-Jenkins tarafından geliştirilmiştir (Salttürk, 2022). Kesikli serilerde, durağan serilerde ve tek değişkenli zaman serilerinin analizinde uygulanabilmektedir. Bu modeller, doğrusal ve durağan modeller olarak da bilinir. Herhangi bir döneme ait değeri, hata terimi ve zaman serisinin geçmiş değerlerinin doğrusal bir kombinasyonu ile ifade edilir. Yöntemin temel amacı, en uygun ve en az parametre içerecek doğrusal bir model oluşturmaktır. Box-Jenkins modeli, seriyi durağan hale getirmek için durağanlığı bozan unsurları belirler ve ardından da uygun modelleme yaparak tahmin gerçekleştirir. Bu yöntemin diğer yöntemlerde ayrıldığı özelliklerden birisi de herhangi bir belirgin eğilim göstermemesidir.

Yöntem sırasıyla, dönüştürme, model tanımı, tahmin, kontrol ve tahmin aşamalarıyla ilerler (Sarı, 2016). Dönüştürme aşamasında, verilere dönüştürme işlemi uygulanarak p ve q ifadelerinin derecelerinin bulunmasındaki adımdır. Bu dereceler, hareketli ortalama ve otoregresif özellikler ile bulunur. Model tanımı aşamasında, deneme olarak birden çok model tanımlanır. Bu modeller içerisinde uygun olanı öngörü olarak seçilir ve tahmin aşamasına geçilir. Tahmin aşamasında, modellerdeki tahminler yapılır ve en iyi olan model seçilir. Kişinin tecrübe ve bilgi seviyesi, en iyi olan modelin seçiminin kritik bir parçasıdır. Sonrasında parametre tahminleri gerçekleştirilir. Kontrol aşamasına gelindiğinde, model yetersiz bulunduğunda tekrar ikinci aşamaya dönülerek modeller tekrar değerlendirilir ve en uygun modeli belirlemek için adımlar tekrar edilir (Salttürk, 2022).

2.3.2.2. Nedensel Yöntemler

Talebin gelecek zamandaki değerinin ve onu etkileyen faktörler arasındaki neden-sonuç ilişkisini anlamaya yönelik bir metodolojidir. Nedensel yöntemler, regresyon ve korelasyon analizi olarak adlandırılan matematiksel modellerin geliştirilmelerini içerir.

Regresyon analizi, bağımlı ve bağımsız arasındaki ilişkiyi ölçen bir analiz metodudur. Tek bir bağımsız değişken bulunuyorsa, tek değişkenli regresyon analizi olarak adlandırılır. Daha fazla bağımsız değişken varsa, çok değişkenli veya çoklu regresyon analizi olarak adlandırılır. Bu analiz için kurulan matematiksel modeller regresyon modelleri olarak bilinir. Hatanın normal bir dağılım varsayımına dayandığı en büyük olasılık yöntemi veya varsayım olmadan en küçük kareler tekniği kullanılır.

Tek değişkenli regresyon analizi, bir bağımlı değişken ile tek bir bağımsız değişken arasındaki ilişkiyi analiz eden bir tekniktir (Salttürk, 2022). Bu analiz, ilişkide ve değişkenlerde doğrusal bir yapı olduğunu varsayar. Çok değişkenli regresyon analizi ise bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkiyi inceleyen bir tekniktir. İfade denklemi (2.11) aşağıdaki gibidir.

$$Y_i = \beta_i + \beta_0 + X_i + \varepsilon_i \quad i = 0,1,2 \dots n \quad (2.11)$$

Korelasyon analizi, değişkenler arasındaki ilişkinin gücünü gösterir (Özkaynar, 2024). Eğer değişkenler doğrusal bir ilişkiye sahipse, bu durum korelasyonu ifade eder. Korelasyon katsayısı, +1 ile -1 arasında değişen bir değeri temsil eder ve ilişkinin derecesini gösterir. Eğer korelasyon katsayısı 0'a yakınsa, bu durumda ilişki yoktur. Negatif bir korelasyon -1'e yakınsa, pozitif bir korelasyon +1'e yakındır. Aşağıdaki ifade (2.12) bu ilişkiyi ifade eder:

$$R = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{n \sum x^2 - (\sum x)^2 (n \sum y^2 - (\sum y)^2)}} \quad (2.12)$$

2.3.2.3. Yapay Zeka Çözümlü Yöntemler

Yapay zeka terimi, 1956 yılında John McCarthy'nin Dartmouth Konferansı'nda tanıtıldı (Salttürk, 2022). Yapay zeka, insan zekasının öğrenme, akıl yürütme, anlam keşfetme ve karar verme gibi yeteneklerini taklit eden bir teknolojidir. Bu alan, insan davranışlarını simüle ederek birçok alanda daha hızlı ve etkili kararlar almayı mümkün kılar. Günlük yaşamda yaygın olarak kullanılan yapay zeka, giderek gündelik hayatın vazgeçilmez bir parçası haline gelmektedir.

3. TALEP TAHMİNİNDE KULLANILABİLECEK DERİN ÖĞRENME TEKNİKLERİ

Derin öğrenme, yapay zeka ve makine öğreniminin bir alt dalı olarak, çok katmanlı yapay sinir ağlarını kullanarak, büyük ve karmaşık veri setlerinde anlamlı desenler öğrenir (LeCun et al., 2015). Talep

tahminlemede derin öğrenme teknikleri çok tercih edilebilir durumdadır. Talep planlamada kullanılan tekniklerin kendilerine özgü özellikleri bulunmaktadır. Bu özellikler bu tekniklerin sektörel olarak kullanımlarının farklılaşmasına yol açmıştır. Bu çalışmada, talep tahmininde en çok tercih edilen derin öğrenme tekniklerini tanıyacağız. Bu tekniklerin diğerlerinden farklılıklarını ve bu farklılıkların avantaj ve dezavantajlarını inceleyeceğiz.

3.1. Yapay Sinir Ağları (ANN)

Yapay sinir ağlarının temelleri, McCulloch ve Pitts tarafından 1943 yılında tanımlanmıştır (Irmak, 2022). 1958 yılında Rosenblatt'ın geliştirdiği “Perceptron” modeliyle önemli bir gelişme göstermiştir. Son yıllarda, talep tahminlemedeki başarısı fark edilmiş ve birçok çalışma da ve akademik incelemede yerini almıştır. Yapay sinir ağları ile perakendeden, otomotive kadar birçok sektöre özgü akademik çalışmalar yapılmıştır.

Yapay sinir ağları, insan beyninin sinir ağlarının çalışma prensinden esinlenilerek oluşturulmuş bir tekniktir (Taşar, 2023). Veri analizi ve modelleme süreçlerinde sık kullanılan bir yapay zeka yaklaşımıdır. Yapay sinir ağları, birden fazla gizli katman kullanarak karmaşık veri kümelerindeki doğrusal ve doğrusal olmayan ilişkileri öğrenebilir ve bu yetenekleriyle karmaşık ve çok parametrelili veri kümeleri için oldukça etkili sonuçlar sunmaktadır. Girdi ve çıktı arasındaki ilişkiyi modellemek amacıyla sıklıkla ileri beslemeli sinir ağları tercih edilir. Özellikle geçmiş satış, üretim, tüketim gibi verilerden eğilim ve desenlerin öğrenilmesi gibi talep tahminlemeye yönelik işlerde yaygın olarak kullanımı bulunmaktadır.

3.2. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağlarının teorik temelleri 1986 yılında David Rumelhart ve Geoffrey Hinton tarafından atılmış olup özellikle zaman serisi analizleri ve ardışık veri modelleme süreçlerinde kullanılan bir yapay zeka yaklaşımıdır. Zaman serisi analizinde devrim niteliği taşıyan bu ağlar, ardışık verilerin analizine yönelik önemli avantajlar sağlamaktadır. Bu ağlar, zaman serilerinde ardışık bilgiyi öğrenmek için içsel bir bellek mekanizması kullanır ve her bir zaman adımındaki bilgiyi ağıın durumunda tutarak sonraki tahminlerde değerlendirir (Lipton et al., 2015). Günlük, haftalık veya aylık satış tahminleri gibi sıralı veri analizine dayalı

uygulamalarda tekrarlayan sinir ağları modelleri önemli bir çözüm sunmaktadır. Örneğin, Patel ve ekibi (2018), enerji sektöründe RNN kullanarak elektrik talebinin tahmininde yüksek doğruluk oranları elde etmiştir.

3.3. Uzun Kısa Süreli Bellek Ağları (LSTM)

Hochreiter ve Schmidhuber (1997) tarafından geliştirilen LSTM, zaman serisi verilerinin uzun vadeli analizinde çığır açmıştır. Örneğin, Amazon gibi büyük e-ticaret platformları, LSTM modellerini kullanarak stok yönetiminde yıllık talep döngülerini tahmin etmektedir.

RNN'nin bir varyasyonu olan LSTM, özellikle uzun dönemli bağımlılıkları öğrenme yeteneğiyle dikkat çeker. Geleneksel RNN modellerinde görülen "unutma" problemini çözmek amacıyla geliştirilmiştir. Bellek hücreleri ve kapı mekanizmaları sayesinde LSTM, mevsimsellik ve trend gibi uzun vadeli ilişkileri başarılı bir şekilde analiz edebilir (Hochreiter & Schmidhuber, 1997).

Google, dil modelleme, arama sonuçlarının sıralaması ve kullanıcı etkileşimini analiz etmek için LSTM ağlarını kullanır. LSTM'ler, dil bağımlılıklarını öğrenmede ve anlama görevlerinde etkilidir, bu nedenle metin verilerini işlemek için idealdir.

3.4. Gated Recurrent Unit (GRU)

2014 yılında Cho ve arkadaşları tarafından önerilen GRU, lojistik sektörden e-ticaret platformlarına kadar birçok alanda uygulanmıştır. Örneğin, Zhang ve ekibi (2021), GRU kullanarak lojistik sektörde dinamik rota tahmini yapmış ve düşük maliyetli bir çözüm sağlamıştır. GRU, üretim hatlarında ihtiyaç duyulan hammaddelerin ve bitmiş ürünlerin talebini tahmin etmek için de kullanılır. Yang ve arkadaşları (2020), otomotiv sektöründe GRU tabanlı talep tahmininin stok maliyetlerini %20 oranında düşürdüğünü belirtmiştir (Yang, Li, Chen, & Zhao, 2020). Benzer şekilde Erol ve İnkaya (2024) da hem LSTM hem de GRU'nun doğru tahminlerde bulunduğunu ortaya koymuştur.

GRU, LSTM'nin daha basitleştirilmiş bir versiyonu olarak tasarlanmıştır ve daha az parametre içerir. Bu özellik, GRU'nun daha hızlı çalışmasını ve daha az hesaplama gücü gerektirmesini sağlar. GRU, özellikle düşük işlem kapasitesine sahip cihazlarda veya gerçek zamanlı uygulamalarda kullanılmaktadır (Zhang & Li, 2021).

3.5. Konvensiyonel Sinir Ağları (CNN)

CNN, ilk olarak 1980’lerde Fukushima tarafından geliştirilmiş, ardından 1990’larda LeCun’un katkılarıyla modern formunu kazanmıştır. Başlangıçta görüntü işleme için kullanılan bu yapı, son yıllarda zaman serisi verilerinde de uygulanmaktadır. CNN, veri içindeki yerel desenleri tespit etme yeteneği sayesinde talep tahmini gibi karmaşık problemlerde kullanılmaktadır. Çok boyutlu talep verilerinde, CNN’in desen tanıma kapasitesi önemli bir avantaj sağlamaktadır. Örneğin, Amazon’un global tedarik zincirinde stok yenileme ve müşteri talebini tahmin etmek için kullanılmaktadır. Firma Satış geçmişine ve kullanıcı davranışlarına göre ürün önerisi yaparken CNN’lerden yararlanır. Talep tahminlerinde %30’a varan doğruluk artışı ile stok fazlası ve eksikliklerini optimize ettiği bilinmektedir. CNN, Walmart’ın günlük satış verilerini analiz ederek belirli ürünler için talep tahminlerinde kullanılır. CNN modelleri ile müşterilerin talebine ve piyasa koşullarına göre fiyat stratejileri belirlenir. Bu modeller sayesinde lojistik maliyetlerini %20 oranında azalttığı bildirilmiştir (LeCun, 1990).

3.6. Zaman Serisi Transformer Modelleri (TST)

Transformer modelleri, uzun dönem bağımlılıkların olduğu zaman serisi verilerinde dikkate değer bir performans sunar (Vaswani et al., 2017). Dikkat mekanizmaları sayesinde büyük veri setlerinde yüksek doğruluk ve hız sağlar.

Transformer modelleri, 2017 yılında Vaswani ve ekibi tarafından geliştirildi. Özellikle uzun süreli bağımlılıkları ve büyük veri setlerini hızlıca analiz etme kapasitesiyle dikkat çeker. Zaman serisi uygulamalarında, Transformer modelleri örneğin e-ticaret sektöründe hızlı değişim gösteren müşteri taleplerinin tahmininde kullanılmaktadır. Netflix, kullanıcı izleme alışkanlıklarını ve tercihlerini analiz ederek öneri sistemlerini geliştirmek için Transformer modellerinden yararlanır. Bu sayede, kullanıcılara kişiselleştirilmiş içerikler sunulur. Google, arama trendleri, reklam harcamaları ve kullanıcı etkileşimi gibi konuları tahmin etmek amacıyla Transformer modellerini kullanır. Bu modeller, kullanıcıların arama eğilimlerini ve ilgilerini doğru bir şekilde öngörerek, kullanıcı deneyimini kişiselleştirir (Vaswani et al., 2017).

3.7. Otomatik Kodlayıcılar (Autoencoders)

İlk olarak 1980’lerde Hinton tarafından önerilen Otomatik Kodlayıcılar, düşük boyutlu temsillerin öğrenilmesi ve anormallik tespiti konularında geniş bir uygulama alanına sahiptir. Otomatik Kodlayıcılar, veri setlerindeki bilgiyi daha düşük boyutlu temsillerde sıkıştırarak önemli özellikleri öğrenir. Bu yöntem, özellikle veri gürültüsünün azaltılması ve anormallik tespiti gibi görevlerde etkilidir. Talep tahmini alanında, eksik verinin olduğu durumlarda veri zenginleştirme amacıyla kullanılmaktadır. Talep tahmininde, az veriyle çalışan sektörlerde veri zenginleştirme için kullanılabilir (Hinton, 1980).

3.8. Derin İnanç Ağları (DBN)

DBN, 2006 yılında Hinton tarafından tanıtılmıştır. Bu yapı, çok katmanlı veri analizlerinde üstünlük sağlamaktadır. Örneğin, Li ve ekibi (2018), üretim hatlarında DBN kullanarak tedarik zinciri verilerinde kritik desenleri tespit etmiş ve tahmin doğruluğunu artırmıştır (Li, Wang, & Zhang, 2018).

Derin İnanç Ağları (DBN), birden fazla gizli katmandan oluşur ve her katman, girdideki özellikleri öğrenerek verinin daha karmaşık temsili oluşturur. Bu hiyerarşik öğrenme yapısı, bu tekniği özellikle karmaşık tedarik zincirlerinde talep tahmini için uygun hale getirir.

DBN’ler, üretim hatlarında kalite kontrol ve tedarik zinciri yönetiminde kullanılmaktadır. Örneğin, H&M gibi moda markaları, ürün taleplerini tahmin etmek ve stok yönetimini optimize etmek amacıyla bu ağları kullanır. Finansal hizmetler, hisse senedi fiyatları ve piyasa eğilimlerini analiz etmek için ise, Morgan Stanley gibi büyük bankalar, müşteri davranışlarını analiz etmek ve yatırım stratejilerini optimize etmek amacıyla bu ağları uygular (Morgan Stanley).

3.9. Generative Adversarial Network (GANs)

2014 yılında Goodfellow ve ekibi tarafından geliştirilen GAN modelleri, veri üretiminde devrim yaratmıştır. Örneğin, GAN’ler moda sektöründe yeni ürünlere yönelik talebi analiz etmek için sentetik veri üretimi amacıyla başarıyla kullanılmıştır.

Generative Adversarial Networks (GANs), bir üreten ve bir ayırt eden olmak üzere iki ağdan oluşur. Bu ağlar, veri üretimi ve doğrulama süreçlerinde birbirini geliştirerek öğrenir. Talep tahmininde, sentetik veri

üretimi ve veri genişletme gibi görevlerde önemli bir araçtır (Goodfellow et al., 2014).

Moda markaları, GAN'leri yeni ürünler ve koleksiyonlar tasarlamak amacıyla kullanır. Örneğin, Nike ve Adidas gibi büyük spor giyim markaları, yeni tasarımlar için sentetik görseller oluşturmak ve müşteri taleplerini analiz etmek için bu ağlardan yararlanır. Talep tahmininde ve risk analizinde GAN'leri kullanır. JPMorgan gibi büyük finansal kuruluşlar ise, müşteri taleplerini analiz etmek ve kredi değerlendirme süreçlerini iyileştirmek amacıyla bu ağlardan yararlanır (Goodfellow et al., 2014).

3.10. Attention Mekanizmaları

Attention mekanizmaları, ilk kez 2014 yılında Bahdanau ve ekibi tarafından önerilmiştir. Günümüzde Transformer modellerinin temel bileşeni olan bu mekanizma, talep tahmini gibi karmaşık süreçlerde yaygın olarak kullanılmaktadır. Örneğin, Liu ve arkadaşları (2021), lojistik sektöründe attention mekanizmalarını kullanarak dinamik talep tahmini gerçekleştirmiştir. Bu mekanizmalar, verilerdeki kritik bilgileri seçici bir şekilde işleyerek modelin daha anlamlı sonuçlar üretmesini sağlar. Özellikle önemli veri noktalarının önceliklendirilmesini mümkün kılar ve talep tahmini uygulamalarında etkili bir şekilde kullanılabilir (Liu et al., 2021).

4. DERİN ÖĞRENME TEKNİKLERİNİN FARKLILIKLARI VE ÜSTÜNLÜKLERİ

Derin öğrenme teknikleri, farklı veri yapılarına ve uygulama alanlarına özgü avantajlar sunar. Bu özellikler, özellikle üretim yönetiminde talep tahmini gibi karmaşık ve dinamik bir problemi çözmek için kritik öneme sahiptir. Her bir teknik, belirli sektörlerde ve kullanım senaryolarında öncelikli tercih edilme sebeplerine ve sağladığı özel avantajlara sahip olduğu anlaşılmaktadır.

Yapay Sinir Ağları (ANN), genel amaca yönelik esnek yapıları sayesinde çeşitli sektörlerde kullanılabilirler. Ancak, büyük miktarda veriyi işlerken hız konusunda sınırlıdır. ANN'ler genellikle mevsimsel talep trendlerinin tespit edilmesinde perakende sektöründe kullanılır. Tekrarlayan Sinir Ağları (RNN), ardışık verilerle çalışarak sürekli olarak talep edilen ürünlerin tahmininde etkili olabilirken uzun vadeli bağımlılıkları tam olarak yakalayamayabilirler ve tütün veya yiyecek gibi

ürünlerin talep tahmininde kullanılabilir. Uzun Kısa Süreli Bellek (LSTM), uzun vadeli bağımlılıkları etkili bir şekilde işleyerek mevsimsellik veya trendlerin önemli olduğu endüstrilerde (perakende ve tarım) tercih edilir. Örneğin, hasat tahminlerinde başarılı sonuçlar elde eder. Gated Recurrent Unit (GRU), LSTM'ye benzer şekilde performans gösterirken daha az hesaplama gücü gerektirir. Bu nedenle, gerçek zamanlı tahmin gereksinimlerinin olduğu alanlarda, örneğin lojistikte dinamik rota optimizasyonunda öncelikli bir tercihtir. Konvolüsyonel Sinir Ağları (CNN): CNN, yerel desenleri çok iyi öğrenir, bu nedenle büyük ölçekli üretim hatlarında kalite kontrolü optimize eden tahmin modellerinde faydalıdır.

Zaman Serisi Transformer Modelleri (TST): Transformer modelleri, büyük veri setlerini hızlı bir şekilde analiz ederek e-ticaret sektöründe ani talep artışlarını etkili şekilde tahmin eder. Otomatik Kodlayıcılar (Autoencoders): Veri ön işlemlerinde ve eksik veri tamamlama işlemlerinde kullanılabilir. Özellikle nadir satılan ürünlerin detaylı talep tahmininde etkili olabilirler. Derin İnanç Ağları (DBN): Karmaşık sistemlerde çok katmanlı verileri etkili bir şekilde öğrenir, bu nedenle tedarik zinciri sistemlerinin optimize edilmesinde kritik bir rol oynar. Generative Adversarial Networks (GANs), sentetik veri oluşturma yetenekleri sayesinde yeni ürünlere olan potansiyel talebin test edilmesinde kullanılabilir. Attention Mekanizmaları, kritik veri noktalarını işleyebilme yeteneği, dinamik sektörlerdeki uygulamalar için ideal olmakla birlikte lojistik ve dağıtım şirketlerinde rotalar ve talep arasındaki karmaşık ilişkileri anlamak için kullanılabilir.

5. SONUÇ

Derin öğrenme teknikleri, üretim yönetiminde talep tahmini sürecinde geleneksel yöntemlere göre önemli avantajlar sunmaktadır. Geleneksel yöntemler, zaman serisi verilerindeki karmaşık desenleri ve uzun dönemli bağımlılıkları tam olarak analiz edemezken, derin öğrenme teknikleri bu tür sorunları çözme kapasitesine sahiptir. Yapay sinir ağları, zaman serisi verilerindeki doğrusal ve doğrusal olmayan ilişkileri öğrenirken, uzun kısa süreli bellek ağları (LSTM) ve kapalı döngülü sinir ağları (GRU), uzun vadeli bağımlılıkları işleyebilme yetenekleri ile dikkat çekmektedir. Özellikle, LSTM ve GRU, mevsimsel döngüler ve uzun vadeli talepler gibi dinamikleri başarılı bir şekilde modelleyebilme yetenekleri ile öne çıkmaktadır. Konvolüsyonel sinir ağları (CNN) ve zaman serisi transformer modelleri (TST), büyük ölçekli veri setlerinde yerel desenleri tanıyıp, büyük veri analitiği ve ani taleplerin tahmininde yüksek doğruluk sunarken, otomatik kodlayıcılar ve derin inanç ağları

(DBN) veri önışleme ve veri eksikliđi sorunlarını çözmek için kritik bir rol oynamaktadır. Attention mekanizmaları ise, kritik veri noktalarını öne çıkararak daha anlamlı tahminler yapılmasına olanak tanır ve özellikle dinamik lojistik gibi alanlarda verimli kullanılmaktadır.

Sonuç olarak, derin öğrenme tekniklerinin sektörel uygulamalardaki üstünlükleri, farklı endüstrilerde talep tahmini süreçlerini iyileştirmeye yönelik çeşitli avantajlar sunar. Uygulama senaryoları ve tekniklerin sektörel seçilme sebepleri göz önünde bulundurulduğunda, derin öğrenme tekniklerinin üretim yönetiminde verimliliđi artırmak, maliyetleri optimize etmek ve hassas talepleri doğru bir şekilde tahmin etmek adına kritik bir rol oynadıđı anlaşılmaktadır.

KAYNAKÇA

- Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *Proceedings of the International Conference on Learning Representations (ICLR)*.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- Eren, U., & Satoğlu, Ş. I. (2017). Perakende giyim sektöründe yapay sinir ağları ile talep tahmini. *Endüstri-İşletme Kurultayı*.
- Erol, B. & İnkaya, T. (2024). Satış Tahmini İçin Derin Öğrenme Yöntemlerinin Karşılaştırılması. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 29(2), 535-554.
- Es, H. Ü. S. E. Y. İ. N., KALENDER ÖKSÜZ, F. A. T. M. A., & Hamzacebi, C. (2014). Forecasting the net energy demand of Turkey by artificial neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(3).
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.
- Hinton, G. E. (1980). Autoencoders: Learning useful representations in a deep network with a locally connected network. *Proceedings of the International Conference on Neural Networks (ICNN)*, 1, 5-8.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Hochreiter, S. (1997). Long Short-term Memory. *Neural Computation MIT-Press*.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Irmak, B. (2022). Yapay Sinir Ağlarının Eğitimi İçin Kelebek Optimizasyonu Algoritmasının İyileştirilmesi (Basılmamış Yüksek Lisans Tezi). Konya: Necmettin Erbakan Üniversitesi
- Kaya, S. K., & Yıldırım, Ö. (2020). A prediction model for automobile sales in Turkey using deep neural networks. *Endüstri Mühendisliği*, 31(1), 57-74.

- Kobu, B. (2008). *Üretim Yönetimi*, Beta Basım, 14. Baskı, İstanbul.
- LeCun, Y. (1990). The Handwritten Digit Recognition Experiment: A Case Study in Using Neural Networks. *Neural Computation*, 2(1), 1-39.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Li, Y., Dai, W., & Wu, D. (2018). Application of deep belief networks in supply chain data mining. *Journal of Systems Science and Complexity*, 31(3), 767-779.
- Li, Y., Wang, X., & Zhang, Z. (2018). Using Deep Belief Networks for Predictive Analysis in Production Lines. *International Journal of Production Research*, 56(10), 3535-3550.
- Linstone, H. A., & Turoff, M. (1975). *The Delphi method: Techniques and applications*. Addison-Wesley Pub. Co.
- Lipton, Z. C., Berkowitz, J., & Elhadad, N. (2015). A critical review of recurrent neural networks for sequence learning. *IEEE Transactions on Neural Networks and Learning Systems*, 26(5), 1019–1039.
- Liu, Y., Wang, Z., Zhang, X., & Li, T. (2021). Dynamic demand forecasting with attention mechanisms in logistics. *Journal of Operations Management*, 37, 123-135.
- Liu, Y., Zhang, Y., & Liu, Y. (2021). Dynamic demand forecasting with attention mechanism in logistics. *IEEE Transactions on Industrial Informatics*, 17(5), 3469-3479.
- Malhotra, N. K. (2010). *Basic marketing research: Integration of marketing concepts with techniques*. Pearson Education.
- Morgan Stanley. (n.d.). Demand forecasting and inventory management using deep learning techniques. Morgan Stanley Research Report, 1-7.
- Nasuhoğlu, H. (2019). *Eczacılık sektöründe yapay sinir ağları ve zaman serileri analizi ile talep tahmini* (Master's thesis, Fen Bilimleri Enstitüsü).
- Özkaynar, G. K. (2024). Bir dijital bağımlılık sendromu phubbing: işgören kariyer başarısı ve iş tatminine etkisi açısından araştırılması. *Yönetim Bilimleri Dergisi*, 22, 1807-1840.

Salttürk, B. (2022). Yapay sinir ağları ile ürün satış miktarlarının tahmini: Mobilya sektöründe bir uygulama (Master's thesis, Sakarya Üniversitesi (Turkey)).

Sarı, M. (2016). Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.

Sönmez, O., & Zengin, K. (2019). Yiyecek ve içecek işletmelerinde talep tahmini: yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma. Avrupa Bilim ve Teknoloji Dergisi, 302-308.

Taşar, D. E. (2023). Organizasyonel Gelişim İçin Otomatik Konuşma Tanıma Sistemi Önerisi. İzmir: Dokuz Eylül Üniversitesi.

Thomas, J. C. (2009). Sales forecasting management. John Wiley & Sons.

Ünlü, R. (2019). Zaman serileri tahminlenmesinde makine öğrenimi ve derin öğrenme tekniklerinin kıyaslanması: Türkiye elektrik üretimi için en iyi tahmin modelinin seçilmesine yönelik bir vaka çalışması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 23(2), 359-370.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. Advances in Neural Information Processing Systems, 30, 5998–6008.

Yang, X., Li, Y., Chen, Z., & Zhao, H. (2020). GRU-based demand forecasting in the automotive industry: Reducing inventory costs by 20%. Journal of Supply Chain Management and Artificial Intelligence Applications, 15(3), 45-58.

Yazıcıoğlu, N. (2010). Yapay zeka ile talep tahmini (Master's thesis, Bursa Uludağ University (Turkey)).

Zhang, W., & Li, Y. (2021). Dynamic Route Prediction Using GRU Networks: A Case Study in the Logistics Industry. Journal of Transportation Technologies, 11(2), 1-9.

ÜRETİM YÖNETİMİNDE İLERİ ARAŞTIRMALAR

yaz
yayınları

YAZ Yayınları

M.İhtisas OSB Mah. 4A Cad. No:3/3

İscehisar / AFYONKARAHİSAR

Tel : (0 531) 880 92 99

yazyayinlari@gmail.com • www.yazyayinlari.com