CONFERENCE



ISBN: 978-625-5694-08-9

ISBN. : 978-625-5694-08-9

IKEA ENDONEZYA SANDALYE ÜRÜNÜ VERİ SETİNDE YAPAY SİNİR AĞLARIYLA SATIŞ MİKTARININ ANALİZİ

Öğr. Gör. Dr., Kenan KILIÇ

Yozgat Bozok Üniversitesi, kenan.kilic@bozok.edu.tr - 0000-0003-1607-9545

ÖZET

Bu çalışma, IKEA Endonezya'ya ait sandalye ürünlerinden oluşan bir veri seti kullanılarak, yapay sinir ağı tabanlı modellerle satış tahminleri yapmayı amaçlamaktadır. Veri setinde ürün adı, ürün açıklaması, kategori bilgisi ve fiyat gibi çeşitli öznitelikler yer almakta olup, bu değişkenler modelin satış miktarlarını tahmin etmesi için temel girdiler olarak değerlendirilmiştir. Çalışmanın temelinde, çok katmanlı algılayıcı (Multi-Layer Perceptron - MLP) mimarileri yer almakta ve farklı katman yapılarına sahip modeller karşılaştırmalı olarak incelenmiştir. Hedef, en düşük hata oranıyla en yüksek doğruluğu sağlayan mimariyi belirlemektir. Model eğitim sürecinde performansı değerlendirmek için RMSE (Kök Ortalama Kare Hatası), MAE (Ortalama Mutlak Hata), MAPE (Ortalama Mutlak Yüzde Hatası) ve R^2 (determinasyon katsayısı) gibi metrikler kullanılmıştır. Deneysel sonuçlar, dört katmandan oluşan MLP-4L (256-128-64-1) modelinin diğer modellere kıyasla daha başarılı olduğunu ortaya koymaktadır. Bu model, neredeyse hatasız tahminler yaparak R^2 değerini 1.0000 seviyesine çok yakın bir noktada tutmayı başarmıştır. Bu da modelin, karmaşık ilişkileri doğru biçimde öğrenme kapasitesinin oldukça yüksek olduğunu göstermektedir. Ayrıca, bazı modellerde Dropout gibi düzenlileştirici tekniklerin kullanılması sayesinde aşırı öğrenmenin (overfitting) önüne geçilmiş ve modelin genelleme kabiliyeti önemli ölçüde artırılmıştır. Basit yapılar düşük doğruluk sergilerken, aşırı karmaşık modellerin ise öğrenme süreci zorlaşmış ve bu durum tahmin başarısını olumsuz etkilemiştir. Dolayısıyla, model mimarisi tasarımı bu tür uygulamalarda büyük önem taşımaktadır. Sonuç olarak, yapay sinir ağı tabanlı yaklaşımların satış tahmininde oldukça etkili olduğu görülmektedir. Bu çalışma, e-ticaret platformlarında karar destek sistemlerinin daha doğru ve güvenilir şekilde geliştirilmesine katkı sunmaktadır. Ayrıca, bu yöntem sayesinde işletmeler ürün taleplerini daha isabetli öngörebilir, stok-planlama süreçlerini daha verimli ve stratejik şekilde yürütebileceği düşünülmektedir.

Anahtar kelimeler: Ağaç işleri endüstrisi, Yapay sinir ağları (YSA), Yapay zeka, Regresyon, Çok katmanlı algılayıcı (ÇKA)

ABSTRACT

This study aims to make sales forecasts using artificial neural network-based models using a dataset consisting of chair products from IKEA Indonesia. The dataset contains various attributes such as product name, product description, category information, and price, and these variables are considered as the main inputs for the model to predict sales quantities. The study is based on multi-layer perceptron (MLP) architectures, and models with different layer structures are comparatively examined. The goal is to determine the architecture that provides the highest accuracy with the lowest error rate. Metrics such as RMSE (Root Mean Square Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), and R^2 (Coefficient of Determination) were used to evaluate model performance during the training process. Experimental results reveal that the four-layer MLP-4L (256-128-64-1) model outperforms other models. This model achieved nearly error-free predictions, maintaining an R^2 value very close to 1.0000. This demonstrates the model's high capacity to accurately learn

ISBN. : 978-625-5694-08-9

complex relationships. Furthermore, the use of regularization techniques such as Dropout in some models prevented overfitting and significantly increased the model's generalization ability. While simple structures exhibited low accuracy, overly complex models had a more difficult learning process, negatively impacting their predictive success. Therefore, model architecture design is crucial in such applications. In conclusion, artificial neural network-based approaches are highly effective in sales forecasting. This study contributes to the development of more accurate and reliable decision support systems in e-commerce platforms. Furthermore, it is believed that this method allows businesses to more accurately forecast product demand and execute inventory planning processes more efficiently and strategically.

Keywords: Woodworking industry, Artificial neural networks (ANN), Artificial intelligence, Regression, Multilayer perceptron (MLP)

1. GİRİŞ

Sanayi alanındaki dönüşüm süreci, özellikle dördüncü sanayi devrimi (Endüstri 4.0) ile birlikte hız kazanmış ve üretim sistemlerinde dijitalleşmeyi temel bir gereklilik haline getirmiştir. Bu dönüşüm, Endüstri 5.0 ile birlikte daha insan merkezli, esnek ve özelleştirilmiş üretim anlayışını da beraberinde getirmiştir. Yapay zekâ, nesnelerin interneti (IoT), siber-fiziksel sistemler, büyük veri analitiği ve makine öğrenimi (ML) gibi teknolojiler, bu yeni endüstriyel yapının temel bileşenlerini oluşturmakta; üretim süreçlerinde karar alma, kalite kontrol, bakım planlaması ve teslimat sürelerinin öngörülmesi gibi pek çok alanda verimliliği artırmaktadır (Lingitz vd., 2018; Bender ve Ovtcharova, 2021).

Makine öğrenmesi algoritmaları, özellikle karmaşık yapıya sahip ve sürekli değişen veri setlerinde desenlerin keşfedilmesi, süreçlerin iyileştirilmesi ve çeşitli olayların öngörülmesi gibi görevlerde etkili bir çözüm yaklaşımı sunmaktadır. Bu tür algoritmalar, üretim süreçlerinde zamanın daha verimli kullanılması, kaynakların daha etkin planlanması ve müşteri beklentilerine daha çabuk cevap verilmesi gibi açılardan önemli avantajlar sağlamaktadır (Wuest vd., 2016; Lee vd., 2018). Özellikle ürün çeşitliliğinin fazla ancak üretim hacminin sınırlı olduğu sektörlerde, klasik yöntemlerin sınırlılıklarını aşmak adına makine öğrenmesi temelli yaklaşımlar daha işlevsel hale gelmektedir (Schuh vd., 2017; Mayr vd., 2019).

Mobilya endüstrisi, üretim süreçlerinde çok sayıda değişkenin etkili olduğu ve genellikle müşteriye özel üretimin ön planda olduğu bir alandır. Ürünlerin kesilmesi, zımparalanması, montajı ve paketlenmesi gibi aşamalar, işlenecek malzemenin türüne, ürünün boyutuna, tasarımına ve kullanılan ekipmanın özelliklerine bağlı olarak önemli ölçüde farklılık gösterebilir (Masoumi vd., 2022; Mirhoseini Taba vd., 2022). Bu nedenle işlem süresi tahmini gibi konular, hem üretim planlaması hem de maliyet kontrolü açısından kritik öneme sahiptir. Ayrıca, müşteri taleplerindeki çeşitlilik, klasik zaman etütlerinin doğruluğunu azaltmakta ve daha esnek yöntemlerin gerekliliğini ortaya koymaktadır.

Bu bağlamda, makine öğrenimi tabanlı modellerin üretim sürecine entegrasyonu, süreçlerin daha etkili yönetilmesini sağlamakta ve özellikle satış tahmini gibi karar destek alanlarında önemli avantajlar sunmaktadır. Literatürde bu tür tahminleme problemlerinde yapay sinir ağları (YSA), rastgele orman (Random Forest) ve gradyan artırma (Gradient Boosting) gibi yöntemler yaygın olarak kullanılmaktadır (Friedman, 2001; Chen ve Guestrin, 2016). Geleneksel regresyon teknikleri, üretim verilerinin doğrusal olmayan doğasını yeterince yansıtamayabilirken, derin öğrenme yaklaşımları, bu tür karmaşık ilişkileri daha doğru şekilde modelleyebilmektedir (Emmert-Streib vd., 2020; Alzubaidi vd., 2021).

ISBN. : 978-625-5694-08-9

Bu çalışmada, Endonezya IKEA'ya ait sandalye ürünleri veri seti kullanılarak, ürün satış miktarlarının tahmini yapılması amaçlanmıştır. Veri setinde yer alan ürün adı, açıklama ve fiyat gibi sayısal ve metinsel öznitelikler, makine öğrenimi modellerinin eğitimi için işlenmiş ve modele dâhil edilmiştir. İlk aşamada satış miktarı sürekli bir değişken olarak ele alınarak, YSA tabanlı regresyon modeli ile tahminleme yapılmış ve modelin doğruluğu çeşitli hata metrikleriyle değerlendirilmiştir. Bu araştırma mobilya alanında ithalat ve ihracat konularında yönlendirici bilgiler sağalmaktadır.

2. MATERYAL VE METOT

2.1. Veri Seti

Bu çalışmada kullanılan veri seti, Endonezya pazarına yönelik IKEA Endonezya web sitesinden web scraping yöntemiyle elde edilmiştir. Veri seti, IKEA'nın Endonezya'daki yemek sandalyesi ürünlerine ait çeşitli özellikleri içermekte olup, toplamda yaklaşık 400 ürün kaydını kapsamaktadır. Veri kaynağı, https://www.ikea.co.id/in/produk/kursi-makan adresinde yer alan resmi IKEA Endonezya ürün sayfasıdır.

Veri setinde yer alan temel sütunlar; ürün adı (product_name), ürün markası (merk_product), ürün açıklaması (product_description), fiyat bilgisi (price) ve satılan ürün adedi (sold) şeklindedir. Ürün açıklamaları Endonezce dilinde sağlanmış olup, ürün fiyatları Endonezya Rupiah (IDR) cinsindendir. Satılan ürün miktarı, her ürünün satış performansını yansıtan sayısal bir değerdir. Fiyat aralıkları genel olarak 170.000 IDR ile 225.000 IDR arasında yoğunlaşmakla birlikte, bazı ürünlerde bu aralık daha geniş olabilmektedir. Satış miktarları ise bazı ürünlerde 0'a yakın seyrederken, bazı ürünlerde 3.000'e yakın değerlere ulaşmaktadır (Nuhrija, 2020).

Bu veri seti, IKEA Endonezya'nın sandalye ürün gamına ilişkin marka tercihleri, fiyatlandırma stratejileri ve satış performansları hakkında önemli bilgiler sunmaktadır. Endonezya pazarına özgü ekonomik ve tüketici eğilimlerini anlamak için uygun bir örnek teşkil etmektedir. Veri seti üzerinde yapılan analizler, hem ürün bazlı satış trendlerinin incelenmesini hem de fiyat ve marka ilişkilerinin değerlendirilmesini mümkün kılmaktadır. Ancak veri setine dair lisans ve güncelleme bilgileri açıkça belirtilmemiştir; bu nedenle çalışmada kullanılan veri statik ve tek zamanlı bir çekim olarak değerlendirilmiştir (Nuhrija, 2020). Çizelge 1'de IKEA Endonezya sandalye ürünleri veri setine ait 10 satır ürün bilgisi verilmektedir. Veri setine ait sayısal sütunlara ait istatistikler Çizelge 2'de verilmektedir.

Çizelge 1. IKEA Endoneyza sandalye ürünleri veri setine ait 10 satır ürün bilgisi

product_name	product_description	price	sold
ÄPPLARÖ	Meja+6 kursi dg sndrn lgn, luar rg, diwarnai cokelat	225000	2
ÄPPLARÖ	Meja+8 kursi recliner, l.ruang, diwarnai cokelat/kuddarna krem	225000	0
ÄPPLARÖ	Meja+4 kursi lipat, luar ruang, diwarnai cokelat/kuddarna abu-abu	225000	2
ÄPPLARÖ	Bangku, luar ruang, diwarnai cokelat, 114 cm	225000	123
ÄPPLARÖ	Meja+4 kursi recliner, l.ruang, diwarnai cokelat/kuddarna biru muda	225000	0
ÄPPLARÖ	Meja+4 kursi dg sndrn tgn, l rg, diwarnai cokelat/järpön/duvholmen antrasit	225000	0
ÄPPLARÖ	Meja+6 kursi dg sndrn lgn, luar rg, diwarnai cokelat/frösön/duvholmen krem	225000	0
ÄPPLARÖ	Meja+8 kursi recliner, l.ruang, diwarnai cokelat/kuddarna krem	225000	1
ÄPPLARÖ	Mj+2 krs dg sndran tgn+bngku, l.rg, diwarnai cokelat	225000	2
ÄPPLARÖ	Meja+4 kursi lipat, luar ruang, diwarnai cokelat/kuddarna krem	225000	5

ISBN. : 978-625-5694-08-9

Çizelge 2. Veri setine ait sayısal sütunlara ait istatistikler

İstatistik	price	sold
count	440.000000	440.000000
mean	219500.000000	194.075000
std	16518.782021	654.492679
min	170000.000000	0.000000
25%	225000.000000	0.000000
50%	225000.000000	1.000000
75%	225000.000000	6.500000
max	225000.000000	3460.000000

2.2. Yapay Sini Ağı (YSA) Modelleri

Bu çalışmada, ürün satış miktarlarını tahmin edebilmek amacıyla yapay sinir ağı (YSA) tabanlı çok katmanlı algılayıcı (Multilayer Perceptron – MLP) modellerinden yararlanılmıştır. Yapay sinir ağları, insan beynindeki sinir sisteminden esinlenerek geliştirilmiş, veri ile çıktı arasındaki karmaşık ilişkileri öğrenebilme yeteneğine sahip yapay öğrenme modelleridir (Haykin, 2009). Özellikle çok katmanlı yapılar, doğrusal olmayan desenleri öğrenme konusunda güçlü bir alternatif sunmakta ve klasik regresyon yöntemlerinin sınırlı kaldığı alanlarda daha başarılı sonuçlar verebilmektedir (Zhang vd., 1998).

Çalışma kapsamında farklı katman ve nöron sayılarına sahip altı farklı MLP modeli denenmiştir. Bazı modeller daha sade yapılarla oluşturulmuşken, bazıları daha derin ve Dropout gibi düzenlileştirici teknikleri içeren yapılardır. Dropout, modelin sadece eğitildiği veriye odaklanarak aşırı öğrenmesini (overfitting) önlemeye yardımcı olur ve genelleme yeteneğini artırır (Srivastava vd., 2014).
Kullanılan modeller şu şekildedir:

- MLP-4L (256-128-64-1)
- MLP-3L (256-128-1)
- MLP-3L (128-64-1)
- MLP-3L (64-32-1)
- MLP-3L-DO (256-128-64-1) – Dropout içermektedir.
- MLP-5L-DO (256-128-64-32-16-1) – Daha derin ve düzenlileştirmeli yapıdadır.

Modelleme sürecinde eğitim için ortalama kare hata (MSE) kayıp fonksiyonu ve popüler optimizasyon algoritmalarından biri olan Adam kullanılmıştır. Eğitim tamamlandıktan sonra modellerin tahmin başarımı; RMSE, MAE, MAPE ve R^2 gibi yaygın hata metrikleriyle değerlendirilmiştir. Bu metrikler sayesinde her modelin hem hata düzeyi hem de açıklayıcılık gücü analiz edilmiştir.

Yapay sinir ağlarının yüksek boyutlu, karmaşık ve doğrusal olmayan veri kümelerinde etkili tahminleme yapabildiği birçok çalışmada gösterilmiştir. Derin öğrenmeye dayalı bu modeller, özellikle geleneksel yöntemlerin yetersiz kaldığı durumlarda daha başarılı sonuçlar üretebilmekte; karmaşık üretim süreçlerinde veya belirsiz müşteri davranışlarının analizinde önemli avantajlar sunmaktadır (Emmert-Streib vd., 2020). Mobilya sektörü gibi ürün çeşitliliğinin ve müşteri beklentilerinin yüksek olduğu sektörlerde, yapay sinir ağlarının bu esnek ve uyarlanabilir yapısı; satış tahminleri, üretim planlaması ve stratejik karar alma süreçlerinde değerli katkılar sağlamaktadır (Wang vd., 2018).

ISBN. : 978-625-5694-08-9

2.3. Deneysel Kurulum

Bu çalışmada yürütülen tüm deneysel analizler, çevrimiçi bir veri bilimi platformu olan Kaggle üzerinde, herhangi bir GPU hızlandırması kullanılmaksızın, yalnızca işlemci (CPU) temelli bir ortamda gerçekleştirilmiştir. Kullanılan sanal çalışma ortamı, Linux 6.6.56+ işletim sistemi, 3.11.13 sürümünde Python dili ve TensorFlow 2.18.0 derin öğrenme kütüphanesi ile yapılandırılmıştır. Donanımsal olarak ortam, 2 fiziksel ve toplamda 4 işlemci çekirdeğine sahip bir x86_64 mimarili Intel işlemci, yaklaşık 31.35 GB RAM ve GPU desteği olmayan bir yapı sunmaktadır. Bu donanım ve yazılım ortamı, özellikle kaynak sınırlı koşullarda derin öğrenme modellerinin nasıl bir performans sergilediğini gözlemlemek açısından önemli bir test ortamı sunmaktadır.

Geliştirilen modellerin uygulanmasında Python 3 dili tercih edilmiş, açık kaynaklı popüler kütüphanelerden geniş ölçüde faydalanılmıştır. Verilerin okunması ve işlenmesinde pandas ve numpy, özniteliklerin dönüştürülmesinde ve normalizasyonunda scikit-learn, model kurma ve eğitme işlemlerinde ise TensorFlow ve Keras API'leri kullanılmıştır. Modellerin başarım değerlendirmeleri için RMSE (Kök Ortalama Kare Hatası), MAE (Ortalama Mutlak Hata), MAPE (Ortalama Yüzde Hata) ve R^2 (Determinasyon Katsayısı) gibi regresyon odaklı ölçütler tercih edilmiştir. Ayrıca, modellerin hesaplama süresi de dikkate alınarak tahmin süreleri ayrı ayrı ölçülmüş ve analiz edilmiştir.

Veri kümesi, eğitim (%80) ve test (%20) olmak üzere ikiye ayrılmış; eğitim verisinin %20'si doğrulama (validation) amacıyla kullanılmıştır. Deneyler boyunca farklı mimarilere sahip çok katmanlı yapay sinir ağı (YSA) modelleri denenmiş, bazı modellerde Dropout katmanları eklenerek aşırı öğrenme riskine karşı önlem alınmıştır. Eğitim süreci boyunca her model için 30 epoch boyunca, mini-batch boyutu 8 olacak şekilde eğitim yapılmış ve sonuçlar hem sayısal hem de görsel olarak değerlendirilmiştir.

2.4. Değerlendirme Metrikleri

Model performansını değerlendirmek amacıyla sıklıkla kullanılan dört temel istatistiksel metrik; R^2 (determinasyon katsayısı), MAE (Ortalama Mutlak Hata), RMSE (Kök Ortalama Kare Hatası) ve MAPE (Ortalama Mutlak Yüzde Hata) şeklinde öne çıkmaktadır. Bu metrikler, modelin tahmin gücünü ve hata düzeyini farklı açılardan analiz etmeye olanak tanır. R^2 değeri, bağımlı değişkenin varyansının ne kadarının model tarafından açıklandığını gösterir ve 1'e yaklaştıkça modelin başarısı artar (Chicco vd., 2021). MAE, tahmin edilen değerlerle gerçek değerler arasındaki mutlak farkların ortalamasını vererek modelin genel hata düzeyini yansıtır; bu değerin sıfıra yaklaşması, daha isabetli tahminleri ifade eder (Chai ve Draxler, 2014). RMSE ise büyük hatalara daha fazla ağırlık vererek hata büyüklüğünü ölçer ve modelin daha tutarlı tahminler yapmasını sağlamayı hedefler (Ćalasan vd., 2020). MAPE, tahmin hatalarının yüzdesel ifadesini sunarak özellikle satış tahmini gibi iş dünyası uygulamalarında kolay yorumlanabilirliği sayesinde yaygın olarak kullanılmaktadır (De Myttenaere vd., 2016). Çalışmada kullanılan değerlendirme metrikleri formül ve açıklamaları Çizelge 3'te verilmiştir.

ISBN. : 978-625-5694-08-9

Çizelge 3. Değerlendirme metrikleri formül ve açıklamaları

Metrik	Formül	Açıklama
R^2 (Determination Coefficient)	$R^2 = 1 - \Sigma(yi - \hat{y}i)^2 / \Sigma(yi - \bar{y})^2$	Modelin açıklayıcılık oranını gösterir. 1'e ne kadar yakınsa model o kadar iyidir.
MAE (Mean Absolute Error)	$MAE = (1/n)\ \Sigma\ \|yi - \hat{y}i\|$	Hataların mutlak değerlerinin ortalamasıdır. Yönü dikkate alınmaz.
RMSE (Root Mean Squared Error)	$RMSE = \sqrt{[(1/n)\ \Sigma\ (yi - \hat{y}i)^2]}$	Büyük hataları daha çok cezalandıran bir metriktir.
MAPE (Mean Absolute Percentage Error)	$MAPE = (100/n)\ \Sigma\ \|(yi - \hat{y}i) / yi\|$	Yüzde cinsinden hata oranını gösterir. Küçük gerçek değerlerde şişebilir.

3. BULGULAR VE DEĞERLENDİRME

Yapay Sinir Ağı (YSA) modellerine ait performans ölçütleri Çizelge 4'te verilmektedir. Modellerin yapılarının ağ derinliği, katman genişliği ve Dropout (DO) kullanımı gibi mimari farklılıklarının regresyon başarımı üzerindeki etkilerini kapsamlı bir şekilde ortaya koymaktadır.

Çizelge 4. Yapay Sinir Ağı (YSA) modellerine ait performans ölçütleri

YSA (Yapay Sinir Ağları Modelleri)	Süre	RMSE	MAE	MAPE	R2
MLP-4L(256-128-64-1)	0.6552 sn.	1.6484	0.6809	14.1805	1.0000
MLP-3L(256-128-1)	0.3530 sn.	99.8935	17.5018	40.6452	0.9533
MLP-3L(128-64-1)	0.3504 sn.	157.9925	29.0598	38.9285	0.8833
MLP-3L(64-32-1)	0.3522 sn.	185.7815	33.9478	15.9950	0.8386
MLP-3L-DO(256-128-64-1)	0.3671 sn.	6.1273	2.3991	36.2228	0.9998
MLP-5L-DO(256-128-64-32-16-1)	0.4140 sn.	51.9180	12.6310	55.5202	0.9874

MLP-4L (256-128-64-1) modeli, en yüksek başarıyı elde etmiş olup RMSE (1.6484), MAE (0.6809), MAPE (14.1805) gibi hata oranları oldukça düşük ve R^2 değeri tam anlamıyla 1.0000 olarak ölçülmüştür. Bu durum, modelin neredeyse mükemmel bir şekilde öğrenme gerçekleştirdiğini göstermektedir. Buna karşın, MLP-3L (256-128-1), benzer bir mimari olmasına rağmen daha az katman içerdiği için performans açısından ciddi bir düşüş göstermiştir. Özellikle RMSE değeri 99.8935'e yükselmiş ve MAPE değeri %40.6452 gibi oldukça yüksek bir hata oranına ulaşmıştır.

Daha dar mimarilere sahip olan MLP-3L (128-64-1) ve MLP-3L (64-32-1) modelleri de performans açısından yetersiz kalmış, R^2 değerleri sırasıyla 0.8833 ve 0.8386 olarak gözlenmiştir. Bu durum, katman ve nöron sayısındaki azalmaların modelin öğrenme kapasitesini ciddi oranda sınırladığını göstermektedir.

Dropout uygulanan MLP-3L-DO (256-128-64-1) modeli ise dikkat çekici bir şekilde düşük hata oranlarıyla (RMSE: 6.1273, MAE: 2.3991) ve yüksek bir R^2 değeri (0.9998) ile güçlü bir

ISBN. : 978-625-5694-08-9

performans sergilemiştir. Bu sonuç, düzenlileştirici bir teknik olan Dropout'un aşırı öğrenmeyi engelleyerek modelin genellenebilirliğini önemli ölçüde artırdığını ortaya koymaktadır.

Diğer taraftan, derinleştirilmiş ve Dropout kullanılan MLP-5L-DO (256-128-64-32-16-1) modeli, nispeten daha uzun bir eğitim süresine (0.4140 sn) sahip olmasına rağmen, beklenenin aksine hata değerleri oldukça yüksektir (RMSE: 51.9180, MAE: 12.6310, MAPE: %55.5202). Bu durum, ağın karmaşıklığının aşırı hale gelerek öğrenme sürecini olumsuz etkilediğini ve muhtemelen modelin yeterince iyi optimize edilemediğini ya da fazla öğrenme zorluğu yaşadığını düşündürmektedir.

Sonuç olarak, bu tablo YSA modellerinde katman sayısının, nöron yapısının ve düzenlileştirici tekniklerin model başarımı üzerinde doğrudan etkili olduğunu göstermektedir. Optimal katman sayısı ve uygun Dropout uygulaması ile model hem yüksek doğruluk hem de genelleme başarısı elde edebilmektedir. Ancak aşırı karmaşık mimariler, eğitim süresi ve hata oranlarında dengesizliklere yol açarak performans kaybına neden olabilmektedir. Regresyon modelleri ile elde edilen tahminlerin gerçek yoğunluk değerleriyle karşılaştırılması Görsel 1'de verilmiştir.

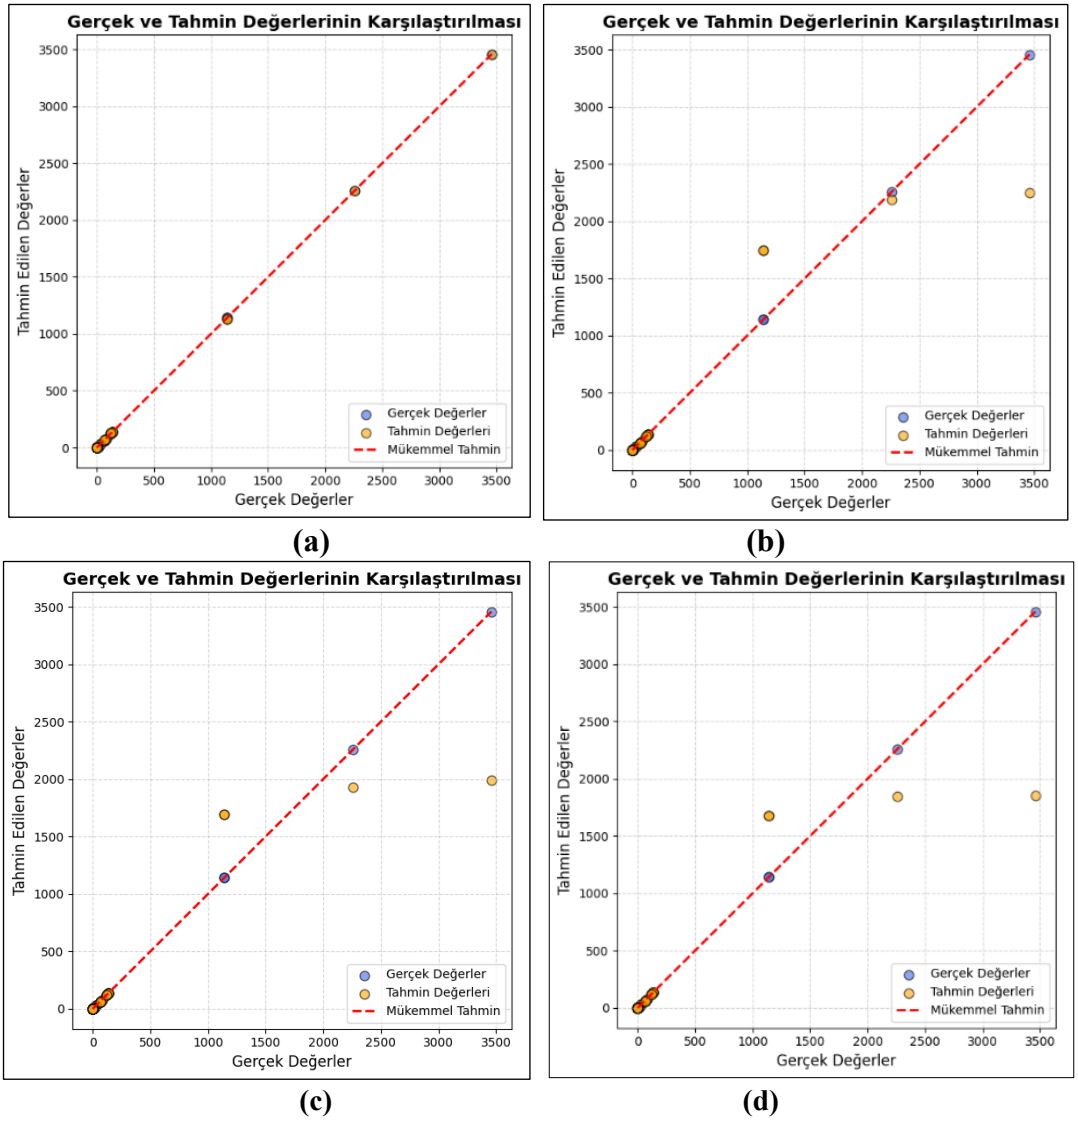

ISBN. : 978-625-5694-08-9

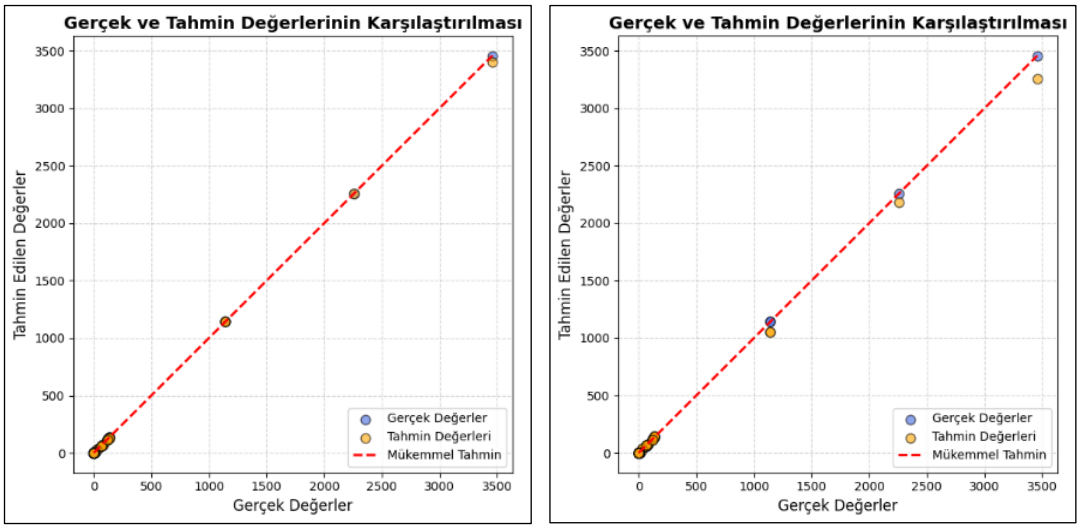

(e) **(f)**

Görsel 1. Regresyon modelleri ile elde edilen tahminlerin gerçek yoğunluk değerleriyle karşılaştırılması: (a) MLP-4L(256-128-64-1), (b) MLP-3L(256-128-1), (c) MLP-3L(128-64-1), (d) MLP-3L(64-32-1), (e) MLP-3L-DO(256-128-64-1), (f) MLP-5L-DO(256-128-64-32-16-1)

Grafiklerde, altı farklı modelin gerçek ve tahmin edilen değerleri karşılaştırılmıştır. Her bir grafikte, yatay eksende gerçek değerler, dikey eksende ise ilgili modelin tahmin ettiği değerler yer almaktadır. Kırmızı kesikli çizgi, ideal durumu yani tahminlerin tam olarak gerçek değerlere eşit olduğu durumu temsil etmektedir.

Noktaların bu çizgiye ne kadar yakın konumlandığı, modelin tahmin başarısını göstermektedir. Tüm modellerde noktalar genel olarak bu çizgiye oldukça yakın yer almakta, bu da modellerin yüksek doğrulukla tahmin yaptığını göstermektedir. Bazı grafiklerde birkaç uç değerde hafif sapmalar görülse de, genel dağılım tahminlerin tutarlı ve güvenilir olduğunu işaret etmektedir. Bu durum, modellerin öğrenme sürecinde veri yapısını iyi kavradığını ve başarılı bir şekilde genelleme yaptığını göstermektedir.

4. GENEL DEĞERLENDİRME VE SONUÇLAR

Bu çalışmada, yapay sinir ağı (YSA) tabanlı modeller kullanılarak satış tahmini gerçekleştirilmiştir. Fiyat, ürün adı ve açıklama gibi çeşitli özniteliklerin kullanıldığı analizde, farklı mimarilere sahip çok katmanlı algılayıcı (MLP) modellerin tahmin performansları karşılaştırılmıştır. Elde edilen sonuçlar, özellikle karmaşık ve doğrusal olmayan veri yapılarında derin sinir ağlarının yüksek başarı sağladığını ortaya koymuştur. MLP-4L (256-128-64-1) mimarili model, hem hata metrikleri hem de determinasyon katsayısı açısından en başarılı sonuçları vermiştir. Bu modelin RMSE, MAE ve MAPE değerlerinin oldukça düşük olması ve R^2 değerinin 1.0000 çıkması, tahminlerinin yüksek doğrulukla yapıldığını göstermektedir.

Öte yandan, Dropout gibi düzenlileştirici tekniklerin kullanıldığı MLP-3L-DO modeli de oldukça yüksek performans sergilemiş ve bu durum Dropout uygulamasının aşırı öğrenmeyi önlemede etkili olduğunu doğrulamıştır. Ancak, daha sade mimarilere sahip olan ve dar katmanlarla oluşturulan MLP-3L (64-32-1) gibi modellerin öğrenme kapasitesinin düşük olduğu ve başarımlarının belirgin biçimde azaldığı görülmüştür. Benzer şekilde, daha derin ve karmaşık yapıya sahip MLP-5L-DO modelinin beklenenden düşük performans sergilemesi, aşırı karmaşıklığın öğrenme sürecine zarar verebileceğini göstermiştir.

ISBN. : 978-625-5694-08-9

Model tasarımı sürecinde, ne çok basit ne de aşırı karmaşık yapılar tercih edilmeli; katman ve nöron sayısı açısından dengeli bir yapı kurulmalıdır. Bu bağlamda, MLP-4L modeli en uygun yapı olarak öne çıkmaktadır. Ayrıca, overfitting'in önlenmesi ve modelin genellenebilirliğinin artırılması açısından Dropout gibi düzenlileştirici tekniklerin uygun oranlarda kullanılması önemli bir katkı sağlamaktadır. Bunun yanı sıra, ürün açıklamaları gibi metinsel verilerin daha etkin biçimde vektörleştirilmesi ve daha gelişmiş nitelik mühendisliği yaklaşımlarının uygulanması modelin başarımını artırabilir.

Son olarak, bu çalışmada kullanılan veri seti belirli bir zaman dilimini temsil ettiği için, gerçek zamanlı ve sürekli güncellenebilen veri kaynaklarının entegre edilmesi sistemin ticari değerini ve uygulanabilirliğini artıracaktır. Genel olarak değerlendirildiğinde, bu yaklaşım IKEA gibi büyük perakende zincirlerinin satış tahmin süreçlerinde YSA modellerinin etkili bir şekilde kullanılabileceğini göstermektedir. Aynı zamanda, benzer ürün çeşitliliğine ve müşteri profiline sahip diğer firmalar için de güçlü ve uygulanabilir bir karar destek yöntemi sunmaktadır.

KAYNAKLAR

[1] Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer, A., Sihn, W. ve Monostori, L., *Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer*, Procedia CIRP, 72, 1051-1056, 2018.

[2] Bender, J. ve Ovtcharova, J., *Prototyping machine-learning-supported lead time prediction using AutoML*, Procedia Computer Science, 180, 649-655, 2021.

[3] Wuest, T., Weimer, D., Irgens, C. ve Thoben, K. D., *Machine learning in manufacturing: advantages, challenges, and applications*, Production & Manufacturing Research, 4(1), 23-45, 2016.

[4] Lee, J., Bagheri, B. ve Kao, H. A., *A cyber-physical systems architecture for industry 4.0-based manufacturing systems*, Manufacturing Letters, 3, 18-23, 2015.

[5] Schuh, G., Anderl, R., Gausemeier, J., ten Hompel, M. ve Wahlster, W., *Industrie 4.0 maturity index. Managing the digital transformation of companies*, 61, 2017.

[6] Mayr, A., Kißkalt, D., Meiners, M., Lutz, B., Schäfer, F., Seidel, R. vd., *Machine learning in production–potentials, challenges and exemplary applications*, Procedia CIRP, 86, 49-54, 2019.

[7] Masoumi, A. ve Bond, B. H., *Machine learning-based prediction of processing time in furniture manufacturing to estimate lead time and pricing*, European Journal of Wood and Wood Products, 83(1), 35, 2025.

[8] Mirhoseini Taba Zavareh, S. M., Ghofrani, M. ve Masoumi, A., *The study of Effective Factors On Selecting Finish Type and Color Spectrum and Finishing Method In The*

ISBN. : 978-625-5694-08-9

Industry Of Home Furniture (Case Study: Tehran Province), Iranian Journal of Wood and Paper Industries, 13(2), 147-160, 2022.

[9] Friedman, J. H., *Greedy function approximation: a gradient boosting machine*, Annals of Statistics, 1189-1232, 2001.

[10] Chen, T. ve Guestrin, C., *Xgboost: A scalable tree boosting system*, Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785-794, 2016.

[11] Emmert-Streib, F., Yang, Z., Feng, H., Tripathi, S. ve Dehmer, M., *An introductory review of deep learning for prediction models with big data*, Frontiers in Artificial Intelligence, 3, 4, 2020.

[12] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O. vd., *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, Journal of Big Data, 8(1), 53, 2021.

[13] Nuhrija, M., *IKEA Indonesia Chair Product Dataset*, Kaggle. https://www.kaggle.com/datasets/mnuhrija/ikea-indonesia-chair-product (Erişim tarihi: 02.08.2025)

[14] Haykin, S., *Neural Networks and Learning Machines* (3rd ed.), Pearson Education, 2009.

[15] Zhang, G., Patuwo, B. E. ve Hu, M. Y., *Forecasting with artificial neural networks: The state of the art*, International Journal of Forecasting, 14(1), 35-62, 1998.

[16] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., *Dropout: a simple way to prevent neural networks from overfitting*, The Journal of Machine Learning Research, 15(1), 1929-1958, 2014.

[17] Wang, J., Ma, Y., Zhang, L., Gao, R. X. ve Wu, D., *Deep learning for smart manufacturing: Methods and applications*, Journal of Manufacturing Systems, 48, 144–156, 2018.

[18] Chicco, D., Warrens, M. J. ve Jurman, G., *The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation*, PeerJ Computer Science, 7, e623, 2021.

[19] Chai, T. ve Draxler, R. R., *Root mean square error (RMSE) or mean absolute error (MAE)?–Arguments against avoiding RMSE in the literature*, Geoscientific Model Development, 7(3), 1247-1250, 2014.

[20] De Myttenaere, A., Golden, B., Le Grand, B. ve Rossi, F., *Mean absolute percentage error for regression models*, Neurocomputing, 192, 38-48, 2016.

[21] Ćalasan, M., Aleem, S. H. A. ve Zobaa, A. F., *On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical*

ISBN. : 978-625-5694-08-9

solution based on Lambert W function, Energy Conversion and Management, 210, 112716, 2020.