



T.C.

TOROS ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ULUSLARARASI TİCARET VE LOJİSTİK ANA BİLİM DALI

**ULUSLARARASI TİCARET VE LOJİSTİK TEZLİ YÜKSEK LİSANS
PROGRAMI**

**LİMAN İŞLETMELERİNDE TEU HAREKETLERİNİN GÖZ ÖNÜNE
ALINARAK, YAPAY ZEKA VE İSTATİSTİKSEL YÖNTEMLERLE
TAHMİNLEME**

Öztürk POLAT

YÜKSEK LİSANS TEZİ

TEMMUZ 2020



T.C.

TOROS ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ULUSLARARASI TİCARET VE LOJİSTİK ANA BİLİM DALI

**ULUSLARARASI TİCARET VE LOJİSTİK TEZLİ YÜKSEK LİSANS
PROGRAMI**

**LİMAN İŞLETMELERİNDE TEU HAREKETLERİNİN GÖZ ÖNÜNE
ALINARAK, YAPAY ZEKA VE İSTATİSTİKSEL YÖNTEMLERLE
TAHMİNLEME**

Öztürk POLAT

DANIŞMAN

Dr. Öğr. Üyesi Fikri EGE

YÜKSEK LİSANS TEZİ

TEMMUZ 2020

ETİK BEYAN

Tez Yazım Kurallarına uygun olarak hazırladığım bu çalışmada;

- Sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

12/08/2020

Öztürk POLAT

İmza

LİMAN İŞLETMELERİNDE TEU HAREKETLERİNİN GÖZ ÖNÜNE ALINARAK, YAPAY ZEKA VE İSTATİSTİKSEL YÖNTEMLERLE TAHMİNLEME

(Yüksek Lisans Tezi)

Öztürk POLAT

TOROS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

2020

ÖZET

Bu tezde, liman İşletmelerinde TEU hareketlerinin göz önüne alınarak, yapay zeka ve istatistiksel yöntemlerle tahminleme ve kıyaslama konu olarak belirlendi. Konteyner terminalleri için, yıllık yapılan operasyon miktarı büyük önem arz etmektedir. Bu doğrultuda liman işletmesi, terminallerinde ve ekipmanlarında iyileştirme yapıp, gelecek dönemlerde kendini geliştirebilir ve gelecek planlaması yapabilir. Tez çalışmasında, örnekler bir konteyner limanına ait olan verilerin, MATLAB programı kullanılarak yapay sinir ağıları metodu ile tahminlemesi yapıldı. Öte yandan, istatistiksel tahmin yöntemlerinden, ağırlıklı hareketli ortalama metodu ve üstel düzeltme metodu ile yine aynı veriler üzerinden, tahmin yapıldı ve 3 metodun sonucu kendi aralarında kıyaslandı. Bu çalışmanın sonunda örnek konteyner terminallerinden alınıp, kullanılan verilerin ışığında yapılan tahminlerin sonuçlarının gerçeğe yakınlığı gözlemlendi. Yapılan bu gözlemler liman işletmelerinin yatırımlar ve planlar yapabilmesine yardımcı olur.

Anahtar kelimeler: Konteyner Terminal, TEU, Yapay Sinir Ağları, Ağırlıklı Hareketli Ortalama, Üstel Düzeltme

USING ARTIFICIAL INTELLIGENCE AND STATISTICAL METHODS FOR THE FORECASTING OF TEU MOVEMENTS IN PORT OPERATIONS

(M. Sc. Thesis)

Öztürk POLAT

TOROS UNIVERSITY
GRADUATE EDUCATION INSTITUTE

2020

ABSTRACT

Taking into consideration the TEU movements at the Port operations, the prediction and comparison with statistical method and artificial intelligent were determined as the subject. Annual operation amount for container terminals is at great importance. Accordingly, the port can improve its terminals, improve it self also make future planning. In this thesis study the data belonging to a sample container part, which is based on, was estimated using artificial neural networks method by using matlab program. On the other hand, among the statistical estimation method, the weighted moving average method and the exponential smoothing correction method were estimated again with the same data and the result of the 3 methods were compared among themselves. At the end of this study, the closeness of results of the estimations made with the data obtained from the sample container terminals was observed. It helps port companies make investments and plans.

Keywords: Container Terminal, TEU, Artificial Neural Networks, Weighted Moving Average, Exponential Smoothing

TEŐEKKÜR

Öncelikle tezli yüksek lisans eğitim ve öğretim hayatım süresince kaliteli hizmetlerinden dolayı Toros Üniversitesi'ne, çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren, kıymetli tecrübelerinden faydalandığım değerli Dr. Öğr. Üyesi Fikri EGE ve Dr. Öğr. Üyesi Mehmet Ali AKTAŐ hocalarıma, yüksek lisans eğitimim süresince manevi destekleriyle beni hiçbir zaman yalnız bırakmayan çok değerli aileme ve eşime teşekkürü bir borç bilirim.



ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
ŞEKİLLERİN LİSTESİ	x
KISALTMALAR	xii
GİRİŞ	1
• Araştırma Probleminin Tanımı	1
• Araştırmanın Amacı	2
• Araştırmanın Önemi	2
• Araştırma Yöntemi	2

BİRİNCİ BÖLÜM

LİMAN İŞLETMECİLİĞİ

1. LİMAN İŞLETMECİLİĞİ	3
1.1. Liman	3
1.2. Konteynerler	4
1.2.1. Standart konteynerler (20'DC, 40'DC)	5
1.2.2. Soğutmalı konteynerler (40'RF, 20'RF)	5
1.2.3. Üzeri açılabilen konteynerler (20'HQ, 40'HQ)	5
1.2.4. Dökme Yük konteynerleri	5
1.2.5. Üzeri açık konteynerler (40'OT,20'OT)	5
1.2.6. Tank konteynerler	6
1.3. Konteyner Terminal Ekipmanları	6
1.3.1. Dolu konteyner ekipmanı (Reach Stacker)	7
1.3.2. Boş konteyner ekipmanı (Empty Stacker)	7
1.3.3. RTG vinci (Rubber Tyre Gantry)	8
1.3.4. Gemi vinci (Gantry Crane)	8
1.3.5. Mobil gemi vinci (Mobile Crane)	9
1.4. Konteyner Terminalleri	9
1.5. TEU Nedir?	11

İKİNCİ BÖLÜM
TAHMİN VE TAHMİNLEME

2. TAHMİN VE TAHMİNLEME	12
2.1. Tahmin ve Tahminleme Adımları	12
2.2. Talep Tahmin İlkeleri.....	14
2.3. Tahmin Planlaması ve Hedefler	14
2.3.1. Tahminleme	14
2.3.1.1. Kısa vadeli tahminler	15
2.3.1.2. Orta vadeli tahminler.....	15
2.3.1.3. Uzun vadeli tahminler.....	15
2.4. Tahmin Yöntemleri.....	16
2.4.1. Yargıya dayalı tahmin yöntemleri	16
2.4.2. Kantitatif tahminleme yöntemleri	17
2.5. Tahminleme Temel Adımları.....	20

ÜÇÜNCÜ BÖLÜM
YAPAY ZEKA

3. YAPAY ZEKA	21
3.1. Zeka Nedir?	21
3.2. Öğrenme	21
3.2.1. Makine öğrenimleri.....	22
3.3. Muhakeme	23
3.4. Problem Çözme	24
3.5. Algı	24
3.5.1. Dil algılama	25
3.6. Yapay Zeka Örnekleri.....	25
3.7. Makine Öğrenimi ve Yapay Zeka Arasındaki Fark	26
3.8. Yapay Zeka Tehditleri.....	27
3.9. Yapay Zeka Çalışma Mantığı	27
3.10. Yapay Zeka Metotları.....	29
3.10.1. Uzman sistem	29
3.10.2. Genetik algoritmalar	32

3.11. Arama Alanı	33
3.12. Makine Öğreniminde Genetik Algoritma.....	34
3.13. Yapay Sinir Ağları	36
3.13.1. Yapay zeka nasıl öğrenir?	38
3.14. Başarılar ve Başarısızlıklar	39
3.15. Bulanık Mantık Sistemlerinin Uygulanması	42
3.15.1. Yapay zekada bulanık mantığın dezavantajlar	42

DÖRDÜNCÜ BÖLÜM

AĞIRLIKLI HAREKETLİ ORTALAMA, ÜSTEL DÜZELTME VE YAPAY SİNİR AĞLARI YÖNTEMİ HESAPLAMASI

4. AĞIRLIKLI HAREKETLİ ORTALAMA, ÜSTEL DÜZELTME VE YAPAY SİNİR AĞLARI YÖNTEMİ HESAPLAMASI	44
4.1. Ağırlıklı Hareketli Ortalama Yöntemi Hesaplaması.....	44
4.2. Yapay Sinir Ağları Yöntemi ile Hesaplama.....	51
4.3. Üstel Düzeltme Yöntemi	61

BEŞİNCİ BÖLÜM

SONUÇ VE DEĞERLENDİRME

SONUÇ VE DEĞERLENDİRME	65
KAYNAKÇA.....	75
ÖZGEÇMİŞ	77

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Liman görünümü	4
Şekil1.2. Konteyner ebatları	6
Şekil 1.3. Dolu konteyner ekipmanı	7
Şekil 1.4. Boş konteyner ekipmanı	7
Şekil 1.5. RTG vinci	8
Şekil 1.6. Gemi vinci	8
Şekil 1.7. Mobil vinç	9
Şekil 3.1. Öğrenim modelleri... ..	23
Şekil 3.2. Yapay zeka çalışma mantığı	28
Şekil3.3. Yapay sinir ağları	38
Şekil 4.1. Konteyner iş hacmi TEU1	45
Şekil 4.2. Konteyner iş hacmi TEU2	45
Şekil 4.3. Konteyner iş hacmi TEU3	46
Şekil 4.4. Konteyner iş hacmi TEU4... ..	46
Şekil 4.5. Konteyner iş hacmi TEU5	47
Şekil 4.6. Tahmin işlemleri.....	47
Şekil 4.7. AHO tahmin sonuçları 1	48
Şekil 4.8. AHO tahmin sonuçları 2.....	48
Şekil 4.9. AHO tahmin sonuçları 3.....	49
Şekil 4.10. AHO tahmin sonuçları 4.....	49
Şekil 4.11. AHO tahmin sonuçları 5.....	50
Şekil 4.12. Örnek liman konteyner iş hacmi TEU 1	52
Şekil 4.13. Örnek liman konteyner iş hacmi TEU 2.....	52
Şekil 4.14. Örnek liman konteyner iş hacmi TEU 3.....	53
Şekil 4.15. Örnek liman konteyner iş hacmi TEU 4.....	53
Şekil 4.16. Örnek liman konteyner iş hacmi TEU 5.....	54
Şekil 4.17. Normalizasyon	55
Şekil 4.18. Sinir ağları	56

(devam) Şekillerin Listesi

Şekil 4.19. Training performance	56
Şekil 4.20. Regresyon.....	57
Şekil4.21. Tahmin normalizasyonu	57
Şekil 4.22. YSA sonuç normalizasyonu	58
Şekil 4.23. YSA tahmin sonuçları 1	59
Şekil 4.24. YSA tahmin sonuçları 2	59
Şekil 4.25. YSA tahmin sonuçları 3	60
Şekil 4.26. YSA tahmin sonuçları 4	60
Şekil 4.27. YSA tahmin sonuçları 5	61
Şekil 4.28. Üstel düzeltme yöntemi ile tahminleme.....	62
Şekil 4.29. Üstel düzeltme yöntemi ile tahminleme.....	62
Şekil 4.30. Üstel düzeltme yöntemi ile tahminleme.....	63
Şekil 4.31. Üstel düzeltme yöntemi ile tahminleme.....	63
Şekil 4.32. Üstel düzeltme yöntemi ile tahminleme.....	64
Şekil 5.1. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri	66
Şekil 5.2. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri	66
Şekil 5.3. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri	67
Şekil 5.4. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri	67
Şekil 5.5. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri	68
Şekil 5.6. AHO yöntemi için MAD, MAPE ve MSE parametreleri	68
Şekil 5.7. AHO yöntemi için MAD, MAPE ve MSE parametreleri	69
Şekil 5.8. AHO yöntemi için MAD, MAPE ve MSE parametreleri	69
Şekil 5.9. AHO yöntemi için MAD, MAPE ve MSE parametreleri	70
Şekil 5.10. AHO yöntemi için MAD, MAPE ve MSE parametreleri	70
Şekil 5.11. YSA yöntemi için MAD, MAPE ve MSE parametreleri	71
Şekil 5.12. YSA yöntemi için MAD, MAPE ve MSE parametreleri	71
Şekil 5.13. YSA yöntemi için MAD, MAPE ve MSE parametreleri	72
Şekil 5.14. YSA yöntemi için MAD, MAPE ve MSE parametreleri	72
Şekil 5.15. YSA yöntemi için MAD, MAPE ve MSE parametreleri	73
Şekil 5.16. Tahmin yöntemlerinin MAD, MAPE ve MSE parametreleri	73

KISALTMALAR

Bu çalışmada kullanılmış bazı kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
AI	Artificial Intelligence
CI	Continuous Integration
DSP	Digital Sygnal Processing
ES	Expert System
Ft	Fit
GA	Genetik Algoritma
ID3	Iterative Dichotomiser3
ISO	Uluslararası Standartla örgütü
KBS	Knowledge Based System
MAD	Mean Absolute Deviation
Max	Maksimum
MAPE	Mean Absolute Percentage Error
Min	Minimum
MRI	Manyetik Rezonans Görüntüleme
MSE	Mean Squared Error
PH	Power of Hydrogen
SAS	Statistical Analysis Software
TD	Temporal-Difference
TEU	Twenty- Food Equivalent Unit
YSA	Yapay Sinir Ağları

GİRİŞ

Gelecek yıl terminal iş hacmi ne kadar olabilir? Liman işletmesi yöneticileri bu sorunun cevabını merak ederler. Çünkü gelecek yılın iş hacminin daha önceden tahmin edilmesi, verimli terminal operasyonun sağlanmasını gerçekleştirir. Rekabetin arttığı ve teknolojinin hızlı bir şekilde geliştiği günümüzde arz ve talep sürekli olarak değişmektedir. Ancak sonuç olarak liman işletmesinin yapmış olduğu operasyon hızı ve verimliliğinin en üst safhada olması, liman işletmesinin geleceği için büyük önem arz etmektedir.

Çalışmanın birinci bölümünde gelişmekte olan liman ticaret sektörü tanımı, önemi ve konteyner terminalleri incelenmiştir.

İkinci bölümde istatistiksel tahminleme yöntemlerinden bahsedilmiştir.

Üçüncü bölümde ise yapay zeka ve yöntemleri ele alınmış ve değerlendirilmiştir.

Dördüncü bölümde ağırlıklı hareketli ortalama yöntemi, üstel düzeltme ve yapay sinir ağları yöntemleri kullanılarak hesaplamaları yapılmış ve tahminler elde edilmiştir.

Beşinci bölüm, burada sonuç ve öneriler yer almaktadır.

Araştırma Probleminin Tanımı

Son yıllarda hızlı bir şekilde gelişen liman ticareti, liman işletmelerinin rakipleriyle rekabet etmesi, doğru yatırımlar yapması ve hedefledikleri plana ulaşmaları gibi unsurları esas almaktadır. Liman işletmesinin müşterilerine vermiş olduğu hizmet kalitesi limanın gelişmesinde etkili olan ana faktördür. Bundan dolayı, işletmeler gelecek yılların iş hacmi hesaplamalarını en doğru şekilde yapmalıdır. Doğru şekilde yapılmayan hesaplamalar doğru oranda büyüyemeyen terminalleri, yetersiz ya da fazla ekipmanları, çalışanları ve terminal yoğunluğunu beraberinde getirir. Bunlar liman işletmesinin maddi yönden kaybına neden olabilir.

Araştırmanın Amacı

Limancılık sektöründe geçmiş verilerin, yapay zeka ve istatistiksel yöntemlerle hesaplanması ve gelecek planının doğru olarak yapılmasında hangi yöntemin daha verimli olduğu sorusunun cevaplanması bu çalışmanın amacı olarak belirlenmiştir.

Araştırmanın Önemi

Türkiye, üç yanı denizlerle kaplı bir yarımada ve pek çok işlek limanı olan, ticaret ağı geniş, Orta Doğu'yu Avrupa'ya bağlayan bir lojistik üssüdür. Bu sebeple limanlar için geçmiş yıllarda yapılan konteyner işlem hacmi (TEU) hareketlerinin göz önüne alınarak, yapay zeka ve istatistiksel yöntemlerle gelecek yıllar için hesaplama ve karşılaştırma yapılması, limanların gelecek planlamaları ve büyümeleri için önem arz etmektedir.

Araştırma Yöntemi

Kullanılacak materyal ve yöntemler aşağıdaki gibidir.

1. Örnek bir limandan alınacak olan, 13 yıllık geçmiş TEU sayıları ay bazında yapay zeka kütüphanelerini kullanarak, örnek limanın için ay bazlı 13 yıllık konteyner işlem hacmi (TEU) sayısının tahminlemesinin yapılması.
2. İstatistiksel yöntemlerden ağırlıklı hareketli ortalama ve üstel düzeltme yöntemi kullanılarak yine örnek bir limanın 13 yıllık geçmiş TEU sayıları ay bazında tahminin yapılması.
3. Bu üç yöntemin birbiri ile kıyaslanması ve hangi yöntemin sonucunun daha doğru olduğunun saptanması.

BİRİNCİ BÖLÜM

LİMAN İŞLETMECİLİĞİ

1. LİMAN İŞLETMECİLİĞİ

1.1. Liman

Deniz taşıtlarının durduğu, gemilerin yüklerini, tahliye edip, tekrar yüklediği ve her türlü hizmeti aldığı, gümrüklü ticaret bölgelerine liman denir (Zorlu, 2008).

Limanlar; kara, deniz ve demir yollarının kesiştiği bölgelerde bulunur. Bunun nedeni limana gelecek veya gidecek malların, karayolu ve demiryolu gibi en büyük 2 lojistik taşımacılık yöntemleri ile malların en yakın ve uzak yerlere kolayca, güvenilir ve maliyet olarak uygun bir şekilde taşınmasına olanak sağlamasıdır.

Suya ve karaya ulaşımı, ticari istekleri, rüzgar ve dalgalardan korunmayı sağlayabilmek için liman konumları özel olarak belirlenir. Limanlar doğal yolla oluşmuş veya sonradan yapay yollarla yaratılmış olabilir. Kullanım özelliği olarak limanlar, genel kullanım limanları veya özel kullanım limanları şeklinde ayrılabilirler. Her çeşit yük operasyonunu gerçekleştiren limanlar, genel kullanım limanlarıdır. Yalnızca belirli yük türlerinin operasyonunu yapan limanlar, özel kullanım limanlarıdır (Veldman & Bückmann, 2003).

Gelişen dünya ekonomisinde, ulaşım sektörünün önemli yapılarından biri limanlardır. Büyük çaplı bir hizmet ağını kapsayan denizcilik sektöründe, mal taşımacılığı ve yolcu taşımacılığında en önemli hizmetlerdendir. Bu çalışma alanında yer alan diğer hizmetler; depolama, demirleme rıhtımı ve yanaşma, kargo elleçleme, çekme ve römorkör yardımı, gümrükleme, acil onarım, kılavuzluktur.

Limanlar ekonomik olarak gelişmeye açık veya gelişmiş bölgelere kurulmuştur.



Şekil 1.1. Liman görünümü

Kaynak: <https://www.shutterstock.com/tr/search/container/port> [1]

Firmalar, armatörler, ülkeler için limanların yeterliliği ve büyüklüğü önem arz etmektedir. Liman işletmesinden hizmet alacak gemilerin, hızlı bir şekilde zaman kaybetmeden yanaştırılması, operasyonların hızlı bir şekilde yapılması, limana olan güvenilirliği ve kazancı doğrudan etkiler. Çünkü limanlar bir uluslararası ticareti sağlar. Liman işletmelerinde işlerin artması, endüstriyel hareketliliğin artmasına neden olur. Böylece liman bulunduğu ülke ekonomisine katkı sağlar.

Dünya limanlarının ilerleyen dönemleri dikkate alındığında, varış ve çıkış limanı, aktarma limanı gibi özellikler, taşımacılık sektörünü doğrudan etkilemektedir. Karşılaşılan etkilenme durumu, denizcilik rotalarında birleşmeye, yeni hatların oluşmasına, aktarma limanlarının yaratılmasına olanak sağlamaktadır. Böylece yeni rotalar meydana gelmiştir. Hatlar ve limanlar arasında stratejik iş birliklerinin yapılmasına ve pazarlık stratejisinin güçlenmesine neden olmuştur (Fleming, 2006).

1.2. Konteynerler

Belirlenen tip ve ölçülere uygun, bütün taşıma yolları ile taşınabilen, dayanıklı ve operasyon kolaylığı sağlayabilen (yükleme, boşaltım, iç boşaltım, iç dolum vb.) Uluslararası Standartlar Örgütü (ISO) tarafından kabul edilmiş, özel malzemesi bulunan taşıma kutularıdır (Sürücü, 2016).

Limn operasyonlarında kullanılan birden fazla çeşit konteyner tipi mevcuttur. Konteyner tiplerinden bazıları; soğutmalı (reefer), tank konteyner, standart konteyner, üzeri açık konteyner, dökme yük konteyneri, üzeri açılabilen konteyner

Konteynerler ebat olarak genelde 20' ve 40'lık olarak ayrılır. Ancak 45'lik konteynerler veya ebat olarak daha küçük konteynerlerde vardır.

1.2.1. Standart konteynerler (20'DC, 40'DC)

Genel yükleri taşımak için tasarlanmış kuru yükler için kullanılan konteyner çeşididir. Bu konteynerler 20' ve 40' konteynerler olarak 2'ye ayrılır. En çok kullanılan konteyner çeşitlerinden biri standart konteynerlerdir.

1.2.2. Soğutmalı konteynerler (40'RF, 20'RF)

Operasyon sırasında (yükleme tahliye aktarma vb.) içerisine yüklenen malların belirli bir soğukluk veya sıcaklık derecesi ile muhafaza edilmesini sağlayan konteyner çeşididir. Reefer konteynerler ile genellikle gıda ürünlerinin taşınmaları için kullanılır. Reefer konteynerlerin yüklendiği gemilerde ve istiflendiği terminallerde, bağlı oldukları reefer platformları bulunur. Bu reefer platformlarına, reefer konteynerler priz aracılığı ile bağlanır ve konteynerlerin sıcaklık ve soğukluk derecelerinin muhafazası sağlanır.

1.2.3. Üzeri açılabilen konteynerler (20'HQ, 40'HQ)

Bu konteynerlerin üst kısmı açık olarak imal edilir. Ağır veya uzun malların, konteynerin üst kısmından rahat bir şekilde yüklenmesi ve taşınması için bu konteyner tasarlanmıştır. Bu konteynerlerin üst tavanı açılıp, kapanabilir. Üzeri açık olarak veya üzeri kapatılarak da kullanılabilir. Üzeri kapatıldığında standart bir konteyner şeklini alır.

1.2.4. Dökme Yük konteynerleri

Dökme yük konteynerler tavan kısmında 3 adet yükleme kapağı ve kapı kısmında yer alan 2 adet tahliye kapakları olan konteynerlerdir. Genel olarak ölçüleri 20' olarak üretilmektedir. Kullanım alanı hayvan yemi, tahıl, baharat vb. yüklerin taşınmasıdır.





Tavan bölümlerinde yükleme ve kapı kısımlarında tahliye kapağı bulunan, dökme yüklerin taşınması için kullanılan konteyner çeşididir. Bu konteynerde baharat, tahıl, yem vb. ürünler taşınır.

1.2.5. Üzeri açık konteynerler (40'OT,20'OT)

Bu konteynerler 4 taraf ve zemin olmak üzere, 5 panelden imal edilebilir. Bu konteynerlerin üst kısımları tamamen açıktır. Bunun nedeni ise, boyut olarak yüksek ve uzun malların kolay bir şekilde taşınması için üretilmiş olmasıdır. Konteynere yüklenecek ürünün özelliğine göre, bu konteynerlerin üzeri branda ile örtülebilir.

1.2.6. Tank konteynerler

Silindir şeklinde olan, sıvı veya gaz olarak bilinen malların güvenli bir biçimde taşınması için kullanılan konteyner çeşididir. Silindir düzlem, dikdörtgen yapı içine yerleştirilmiştir. Silindir şeklinde olmasının nedeni, taşınan maddenin sarsılmaması içindir. Bu konteynerlerin doluluk oranı yüzde 85'ten daha aşağı, yüzde 95'ten daha yukarıdır. Bunun nedeni mevzuatta yer alan, tank konteynerlerinde taşınan maddelerin taşıma ve operasyon sırasında tehlike arz etmemesi içindir.

KONTEYNER ÖLÇÜLERİ									
	İÇ ÖLÇÜLERİ			KAPI AÇILIŞ		AĞIRLIK			YÜKLEME HACMI
	UZUNLUK	GENİŞLİK	YÜKSEKLİK	GENİŞLİK	YÜKSEKLİK	MAX. BRÜT	DARA	MAX. YÜKLEME	
 20' DC 10 Standart Palet / 1,2 x 1,0 m 11 Euro Palet / 1,2 x 0,8 m	5.897 mm	2.348 mm	2.390 mm	2.336 mm	2.280 mm	30.480 kg (24.000 kg)	2.240 kg (2.290 kg)	28.240 kg (21.710 kg)	33 metre küp
	19 ft 4.17 in	7 ft 8.44 in	7 ft 9.90 in	7 ft 8.01 in	7 ft 5.45 in	67.200 lb (52.910 lb)	4.940 lb (5.050 lb)	62.260 lb (47.860 lb)	
 40' DC 21 Standart Palet / 1,2 x 1,0 m 25 Euro Palet / 1,2 x 0,8 m	12.031 mm	2.348 mm	2.390 mm	2.336 mm	2.280 mm	32.500 kg (30.480 kg)	3.750 kg (3.770 kg)	28.750 kg (26.710 kg)	68 metre küp
	39 ft 5.66 in	7 ft 8.44 in	7 ft 9.90 in	7 ft 8.01 in	7 ft 5.45 in	71.650 lb (67.200 lb)	8.270 lb (8.310 lb)	63.380 lb (58.890 lb)	
 40' HC	12.031 mm	2.348 mm	2.695 mm	2.336 mm	2.585 mm	32.500 kg (30.480 kg)	3.940 kg (3.990 kg)	28.560 kg (26.490 kg)	76 metre küp
	39 ft 5.66 in	7 ft 8.44 in	8 ft 10.12 in	7 ft 8.01 in	8 ft 5.75 in	71.650 lb (67.200 lb)	8.690 lb (8.880 lb)	62.960 lb (58.400 lb)	
 20' DC OPEN TOP	5.893 mm	2.346 mm	2.384 mm	2.338 mm	2.244 mm	30.480 kg (24.000 kg)	2.320 kg (2.450 kg)	28.160 kg (21.550 kg)	33 metre küp
	19 ft 4.21 in	7 ft 8.36 in	7 ft 9.74 in	7 ft 8.05 in	7 ft 4.35 in	67.200 lb (52.910 lb)	5.120 lb (5.400 lb)	62.080 lb (47.510 lb)	

Şekil 1.2. Konteyner ebatları

Kaynak: <https://www.dnt.com.tr/bilgi/birikimi/28/konteyner-olculeri/> [2]

1.3. Konteyner Terminal Ekipmanları

Konteyner terminallerinde çeşitli saha ekipmanları kullanılır. Saha ekipmanları ile konteynerin alınmasına “elleçleme” denir. Konteyner Terminallerinde elleçleme yapan ekipmanlar şu şekildedir; Dolu konteyner ekipmanı (Reach Stacker), Boş konteyner ekipmanı (Empty Stacker), RTG vinci (Rubber Tyre Gantry), Gemi vinci (Gantry Crane) ve Mobil Gemi vinci (Mobil Crane).

1.3.1. Dolu konteyner ekipmanı (Reach Stacker)

Şekil 1.3.te görüldüğü gibi, dolu konteynerleri taşımak için kullanılan saha ekipmanıdır. İş yoğunluğu sırasında boş konteynerleri taşımak için de kullanılabilir. Yapısal özelliklerinden dolayı 40' olarak max 4 kat üst üste konteyner istifleyebilir. 20'lik olarak max 5 kat üst süte konteyner istifleyebilir.



Şekil 1.3. Dolu konteyner ekipmanı

Kaynak: <https://www.kalmarglobal.com/equipment-services/reachstackers/Gloria-Reachstacker-DRG450/> [3]

1.3.2 Boş konteyner ekipmanı (Empty Stacker)

Yalnızca boş olan konteynerleri şekil 1.4.te görüldüğü gibi taşımak için kullanılan saha ekipmanıdır. Dolu konteynerleri taşıyamaz. Çünkü dolu konteynerlerin ağırlığını taşıyacak mekanikse özelliklere sahip değildir. Bu yüzden dolu konteyner taşıma yapılamaması durumunda bu ekipman devrilebilir. Yapısal özelliklerinden dolayı 40' olarak max 5 kat üst üste boş konteyner istifleyebilir. 20'lik olarak max 6 kat üst üste boş konteyner istifleyebilir.



Şekil 1.4. Boş konteyner ekipmanı

Kaynak: <https://www.liftandhoist.com/news/terex-port-solutions-largest-rtg-order-in-firms-history/> [4]

1.3.3. RTG vinci (Rubber Tyre Gantry)

Sahada dolu olarak bulunan istifleri şekil 1.5.te görüldüğü gibi üst üste koymaya yarayan saha vincidir. Raylı veya tekerli olarak bulunduğu saha doğrultusunda hareketlerini yapar.




Şekil 1.5. RTG vinci

Kaynak: <https://www.kalmarglobal.com/equipment-services/masted-container-handlers/empty-container-handler-DCG80/> [5]

1.3.4. Gemi vinci (Gantry Crane)

Şekil 1.6.da görüldüğü gibi, belirli mesafe aralıklarında raylar üzerinde hareketlerini gerçekleştiren büyük vinçlerdir. Gemi operasyonlarında tahliye ve yükleme için kullanılırlar.



Şekil 1.6. Gemi vinci

Kaynak: <https://pixabay.com/photos/container-gantry-crane-container-1367604/> [6]

1.3.5. Mobil gemi vinci (Mobile Crane)

Mobil olarak istenilen yere gidebilen ve gemi operasyonları için kullanılan Gantry Crane'e göre şekil 1.7.de görüldüğü gibi daha küçük ve hareketli gemi vinçleridir. Çok fonksiyonlu olmasından dolayı Gantry crane operasyonun riskli ve zor olduğu bölümlerde mobil gemi vinci kullanılır (Koçer, 2009).



Şekil 1.7. Mobil vinç

Kaynak: <https://www.konecranes.com/resources/konecranes-port-solutions-in-moerdijk> [7]

1.4. Konteyner Terminalleri

Nakliye için kullanılan konteynerlerin istiflendiği ve her türlü operasyon hizmeti olarak ticaret yapılmasını sağlayan sahalara konteyner terminalleri denir. Konteyner terminallerinin diğer adı ise, konteyner sahasıdır.

Çoğu zaman mallar, tek bir konteyner ile konteyner terminaline gelir. Müşteriye teslim etmek için, çeşitli ulaşım ağlarına dağıtılır. Konteyner terminalleri, konteynerlerin bakımı ve geçici süre ile istiflenmesi için belirlenmiş bölgelerdir. Konteyner terminali, bazen konteynerde bulunan malın boşaltılması, doldurulması veya depolanması gibi opsiyonları da müşteriye sunar.

Günümüzde gelişmekte olan konteyner trafiği, konteyner taşımada yapılan geniş yatırımlardan dolayı devam etmektedir. Gelişmenin bütün taşıma türlerinde devam edebilmesi için konteynerin kullanılmasının gerekli olduğu görülmektedir.

Konteynerler ile birlikte, daha önceleri taşınması ve istiflenmesi çok zor olan yüklerin, iletilmesi ve istiflenmesine imkan sağlanır.

Böylece zaman içerisinde konteynerler artan talep, daha gelişmiş ve daha büyük limanlar için yeni alt yapılar oluşturulmasına ve yeni konteyner limanları yaratılmasına olanak sağlamıştır.

Lojistik zincirinde bir yapı oluşturmakta olan konteyner terminalleri ve bu yapıda kendi içerisinde birden fazla yapı taşına bölünmektedir. Her bir yapı birbirini tamamlar ve bu yapılarda oluşacak aksaklık ve talep artışı diğer yapıları da etkiler. Yani özenle hazırlanmış kapsamlı bir planlama, uygulamayı en ince ayrıntısına kadar inceleme, aksaklıkları erkenden bulma ve çözmeyi gerektirir. Kapsamlı bir şekilde oluşturulmuş planlamaya uymadan devam etmek, maliyet artması olarak ilerleyen dönemde işletmenin önüne çıkacaktır.

Aynı zamanda birden çok etkinliğin olduğu endüstriyel işletmeler, modern konteyner limanlarıdır. İşletmede, vinçler, kamyonlar, deniz taşıtları, gelişmiş makinalar mevcut durumda olmaktadır. Bu operasyonların ana noktası, konteynerde mevcut olan malın, en erken ve güvenilir bir biçimde yurt dışı veya yurt içi aktarımını sağlamaktır. Uluslararası yük taşımacılığında modern konteyner limanları önemli bir yere sahiptirler.

Limanda bulunan operasyonların önemli bir yapı taşı da gemi operasyonlarıdır. Operasyonun detayı, geminin ilk gelişinden çıkış aşamasına, konteynerin tahliye ve yükleme operasyonu ve operasyon sırasında oluşan bütün durumları ele alır.

1.5. TEU Nedir?

“Twenty-foot Equivalent Unit” İngilizce kelimesinin baş harflerinin oluşturduğu kısaltmaya TEU denir. TEU’nun Türkçe karşılığı, "20 Fit Konteyner Eşdeğer Birimi" ‘dir.

İngiltere’de 1969 yılında, gemi inşası ve deniz taşımaları istatistiklerini alanında çalışan Richard F. Gibney, farklı tiplerdeki gemilerin ve değişik tiplerdeki konteynerlerin boyutlarının istatistiksel olarak hesaplanması için bu hesaplama birimini geliştirmiştir (Talley, 2012).

Taşımacılık sektöründe kullanılan konteyner standartları 20 ft ve 40 ft olarak 2 ana bölüme ayrılır. Genel amaçlı olarak kullanılan konteynerler 20ft: Bu tip konteynerlerin genellikle iç ölçüleri 2391mm yükseklik, 2352mm en ve 5900mm boy olarak üretilmektedir.

İngilizlerin kullanıldığı ölçü birimi “fit”, konteynerlere kısaltma olarak ft ismini vermiştir. Örneğin 20ft, 40ft, 45ft gibi. Bunun dışında konteynerlerin çeşitli bahsedilişleri mevcuttur. Bunlar: 20ft, 20feet ve 20’ şeklindedir. Bu bahsedilişlerin hepsi aynı anlama gelmektedir.

1 adet 20ft’lik konteyner, 1 TEU’ya eşittir. Bu durum konteyner gemilerinde büyüklük ölçüsü olarak kullanılan bir kavramdır. Genel amaçlı olarak kullanılan konteynerler 40ft: Bu tip konteynerlerin genellikle iç ölçüleri 2391 mm yükseklik, 2352 mm en ve 12032 mm boy olarak üretilmektedir. 1 adet 40ft’lik konteyner, 2 TEU’ya eşittir.

TEU kavramı; liman performansı, liman verimi, konteyner terminallerinin konteyner elleçleme kapasitesi ve gemilerin konteyner taşıma kapasitesinin belirlenmesinde kapasite göstergesi olarak kullanılır.

İKİNCİ BÖLÜM

TAHMİN VE TAHMİNLEME

2. TAHMİN VE TAHMİNLEME

2.1. Tahmin ve Tahminleme Adımları

Bazı verilere dayanarak varılan sonuca tahmin denir. Tahmin hayatımızda birçok alanda kullanılır. Gelecek dönemde rüzgar tribünü yapılmasına gerek duyulup duyulmayacağına karar verilmesi, talep tahminini gerektirir. Mağazaya gelen ürünlerin stoklanma gereksinimi tahmini doğurur. Bir çiçekçinin özel günlerde yeterli stok yapabilmesi için, gelebilecek sipariş sayısını tahmin edebilmesi gerekir. Bahçe hasat veriminin gelecek yıl için tahmini; depolama ve giderler yönünden pozitif bir geri dönüş sağlar. Tahminler birkaç ay, birkaç yıl veya birkaç dakika önceden istenebilir. Durumlar veya zaman aralıkları ne olursa olsun, tahmin etkili planlama için önemli bir araçtır.

Bazı durumların tahmini, diğerlerine nazaran daha basittir. Yarın havanın ne zaman kararacağını kesin olarak tahmin edebiliriz. İnsanın kendisinin ne zaman hasta olacağı tahmin edilmesi kesin bir olaydır. Ancak bunlardan farklı olarak, kesinliği olmayan tahminlerde bulunmaktadır. Piyangonun sonucunun tahmin edilmesi ve öleceğimiz tarihin tahmin edilmesi gibi.

Bir durumun veya ölçünün öngörülebilirliği çeşitli faktörlere bağlıdır:

- Duruma katkıda bulunan faktörlerin anlaşılması
- Elde bulunan veri mevcudiyet durumu
- Tahminlerimizin, tahmin edilmeye çalışılan durumu etkileyip etkilemediği

Her 3 faktöründe çoğunlukla sağlandığı bir örnek: elektrik talebi tahminleri. Elektrik talebi tahminleri genellikle doğru olarak hesaplanır. Bu talep genellikle sıcaklıklardan; azınlıkla ekonomik koşullar ve tatiller gibi dönem sapmalarında kaynaklanmaktadır.

Elektrik talebi ve mevsim dönemleri ile ilgili yeterli bilgi geçmişi, temel sürücü ve elektrik talebini değişkenlerini birbirine bağlayan sağlam bir model geliştirilebilirse, tahminler genellikle doğru olabilir (Akman, Yılmaz, & Sönmez, 2018).

Diğer taraftan, koşullardan sadece birini yerine getirdiğimiz durumlardan biri döviz kurudur. Döviz kurunu tahmin ederken bol miktarda veri mevcuttur. Öte yandan, döviz kurlarını etkileyen durumları ve döviz kuru tahminlerinin faiz oranları üzerinde direk etkisi olduğu konusunda geniş bir bilgi ağına sahip değiliz.

Döviz kurunun yükseleceğine dair halka açık tahminler varsa, insanlar hemen ödemek istedikleri fiyatı hemen sağlayacak ve bu durumda tahminler kendi kendini yerine getirecektir. Başka bir düşünüşle, döviz kurları kendi tahminleri haline gelir. Bu “acil piyasa hipotezine” bir örnektir (Tetik & Kanat, 2016).

Sonuç, tahmin döviz kurunun yarın yükselip yükselmeyeceği, atılan madeni paranın yazı ya da tura olarak gelme ihtimalinin tahmin edilebilmesi kadar tahmin edilebilir. Tahmin ne çıkarsa çıksın, edilen tahminin yarısında haklı çıkabilirsiniz. Benzer durumlarda, tahmincilerin kendi sınırlarını aşmamalarının ve taleplerini yeterli miktarda etmeleri gerekir.

Genellikle öngörmede önemli olan adım: bir durumun hangi zamanda doğru tahmin edilebileceğini ve tahmin edilen durumların bozuk para atmanın ne zaman daha doğru olmayacağını bilmektir. Yerinde tahminler, eldeki verilerde bulunan gerçek kalıpları ve ilişkileri bulur. Ancak bir daha tekrarlamayacak geçmiş durumları kopyalayamaz.

Genellikle kişiler, doğru olmayan bir şekilde, değişkenlik gösteren bir ortamda tahmin yapılmasının mümkün olmadığını düşünmektedir. Her ortam değişir ve iyi yapılmış bir tahmin modeli olayların değişme şeklini olabilecek en doğru anda yakalar. Varsayılan olarak kabul edilen durum, geleceğe doğru bu şekilde devam edecektir. Aslında, bir durumun içinde bulunan varsayım, o durumda devam edecektir; satış yapan bir firma satış yapmaya devam edecektir. Tahmin modeli, yalnızca verilerin bulunduğu yerde değil, aynı zaman da verilerin hareket şeklini de yakalamayı amaçlar. Amerika Birleşik Devleti 16. Başkanı Abraham Lincoln’un söylediği gibi: “Eğer ilk önce nerede olduğumuzu ve nereye meylimiz olduğunu bilirsek ne yapmamız gerektiğini ve nasıl yapacağımızı iyi değerlendirebiliriz” (Vidal, 1992).

Öngörme durumları birçok yönden farklılıklar gösterir: doğru sonuçları belirleyen durumlarda, zaman sınırlarında, veri örüntü türlerinde...

Geçmişe dair verilerin olmadığı veya gerçekleşecek durumların geçmişten farklı olduğu koşullarda, tecrübeye dayanan yöntemlere yargıya dayalı tahmin kullanılır. Yeni bir ürünün ilk yılında ki satış tahminini elde etmek isteyebiliriz. Fakat açıkça üzerinde çalışılacak veri bulunmaz. Karşılaşılan durumda yargıya dayalı tahmin yapılır.

2.2. Talep Tahmin İlkeleri

Talep tahmin ilkelerinin bilinmesi talep sonuçlarının en düzgün biçimde kullanılmasına yarar. İlkeler şu şekilde sıralanabilir:

- Tahminlerin sonucunda kusursuzluğa ulaşmak genel olarak mümkün değildir. Sonuçlar, tahminlerden daha farklı değerlere sahip olabilir. Bu durumun nedeni, tahmini yapılacak veriyi etkileyen durumların net bir şekilde bilinmemesi ve tahmin edilemeyen rassal durumlardan kaynaklanır.
- Tahmin sonucunun hatalı olabileceği akıldan çıkarılmamalıdır. Bundan dolayı tahmin değerlerinde alt ve üst sınır oluşturulması gerekmektedir. Adet ve tür durumundan büyük olarak görünen grupların tahminleri hassastır.
- Tahmin sonuçlarının oluşturduğu alan ne kadar az ise, tahmin sonuçları bir o kadar hassaslaşacaktır.
- Tahmin sırasında ilerleyen döneme ait durumların bilinmesi gerekir. Tahmini sonucunun anlamlı, doğru ve bölümler şeklinde olması istenmektedir. Somut bir şekilde olması ve her zaman oluşturulabilir olması önem arz etmektedir (Özdemir & Özdemir, 2006)

2.3. Tahmin Planlaması ve Hedefler

2.3.1. Tahminleme

Üretim, nakliye ve personelin programlanması ile ilgili yargıların bildirilmesine katkı sağladığı ve yarını planlamak için bugün ne yapılması gerektiğiyle ilgili rehber sağlar. Tahminleme planlama ve hedefler iş dünyası için geniş bir istatistiksel fonksiyondur. Buna ek olarak, iş tahminleri çoğunlukla yetersiz yapılır; genellikle planlama ve istenilen hedefle karıştırılır.

Bunlar üç farklı şekildedir.

➤ Tahmin

Eldeki geçmiş verileri ve öngörülerini etkileyebilecek gelecekteki olayların verisi de içinde olması gibi eldeki tüm bilgiler hesaplandığında geleceği olabildiği en iyi şekilde doğru tahmin etmektir.

➤ Hedefler

Ulaşılmak istenen, olmasını istediğimiz şeyler hedeflerdir. Tahminler ve planlar hedefi doğurur; fakat her durumda gerçek olmaz. Genellikle, hedeflere nasıl ve ne şekilde ulaşılacağına dair plan yapılmaz; planların ne kadar gerçekçi olup olmadıklarıyla ilgili kesin bir tahmin olmaz.

➤ Planlama

Amaçlara ve bu amaçlar için yapılan tahminlere, hedeflere bir cevaptır. Planlama, hesaplamalarımızın hedeflerimizle uyumu için en yararlı hareketin belirlenmesidir.

Tahmin, firmanın çoğu alanında güçlü bir yer edindiğinden, yönetimin karar verme aşamasında mutlaka yer edinmesi gereken bir parçadır. Çağdaş kurumların, özgül uygulamaya bağlı olarak kısa, orta ve uzun süreli öngörülerde bulunmaları gerekir (Tuğrul, 2010).

2.3.1.1. Kısa vadeli tahminler

Yapılan işte çalışanın programlanması, işin üretimi ve nakliye aşamasının gerçekleşmesi için kısa vadeli tahminler gereklidir. Kısa vadeli tahminler büyük çoğunlukla programlama sürecinin bir parçası halindedir. Haftalık dönemleri kapsar.

2.3.1.2. Orta vadeli tahminler

Satın alınan hammadde, kiralanmış personel veya satın alınan makine ve ekipman için işlemleri gerçekleştirmede kaynak ihtiyaçlarını belirlemede orta vadeli tahminler kullanılır. Aylık dönemleri kapsar.

2.3.1.3. Uzun vadeli tahminler

İşletme tesisinin genişletilmesi ve yeni makineler alınması gibi işlemleri gerçekleştirmede uzun vadeli tahminler kullanılır. Yıllık dönemleri kapsar.

Kuruluşların belirli olmayan olayları öngörebilmeleri için, çeşitli uygunluklar bulunduran tahmin sistemini geliştirmeleri gereklidir. Bu tarzdaki tahmin sistemleri, bir çeşit tahmin yönteminin uygulanması, tahmin sorunlarının tanımlaması, tüm problemler için en uygun olan yöntemin seçilmesi; zamanla bu tahmin yöntemlerinin değerlendirilmesi ve değerlendirmede uzmanlığın geliştirilmesini sağlamayı gerektirir. Eğer kullanımı başarılı olacaksa, ciddi tahmin yöntemlerinin kullanımına karşı güçlü bir kurumsal dayanağa sahip olmalıdır (Kurgan, 2019).

2.4. Tahmin Yöntemleri

Tahmin yöntemleri 2 gruba ayrılır. Bunlar: Yargıya Dayalı Tahmin yöntemleri ve Kantitatif Tahmin yöntemleridir.

2.4.1. Yargıya dayalı tahmin yöntemleri

Elimizde, geçmişten gelen veriler olmadığında veya gelecek dönemdeki şartların geçmiştekine göre değişiklik gösterdiği durumlarda fikir ve deneyime dayanan metottur.

Bu yöntemler:

Delphi metodu, Pazar araştırması metodu, Satış ekibi tahminleri, Yönetici görüşleri tahmini, Nominal grup yönetimi

- Satış Ekibi Tahminleri: Şirket bünyesindeki satış ekibinin üyelerince belirli aralıklarla yapılan tahminlerden toplanır.
- Yönetici görüşü: Bir ya da birden daha çok yöneticinin veya müşteri fikirlerinin, deneyimlerinin ve teknik bilgilerin sadece bir tahmine varmak için özetlenen tahmin yöntemidir.
- Pazar Araştırması: Bir müşterinin ürüne ya da hizmete ilgisini, verileri düzenleme anketleri ile varsayımlar oluşturarak, deneyerek belirleyen sistematik yaklaşım.
- Delphi Yöntemi: Yaratıcısı belirlenmeden sağlanan bir takım uzman kişinin anlaşmayı sağladığı süreç (Meydan, 2007).

Çoğunlukla gelecek üzerine olan ve yapısal iletişime göre geliştirilen tahminler için kullanılan bir yöntemdir. Uzman kişilerden oluşturulan tahmin grubunun iki veya ikiden daha fazla turda tahmin yaptığı oyun olarak gözükebilir.

- Nominal grup yöntemi: Aynı takımda bulunan kişiler arasında fikir birliği sağlamak üzerine kullanılan puanlama yöntemidir. Sorunların ne olduğu ve bu sorunlar üzerinde hangi sırayla çalışması gerektiği belirlenirken genellikle sesi kimin yüksekse veya en yetkili kişi kim ise onun istediği gerçekleşir.
- Tarihi analog yöntemi: Aynı ürün ve işlerin satış bilgilerinin çözümlemesine dayalı metottur. Daha önce piyasaya sunulan benzer bir ürün ya da hizmetle karşılaştırma sonucu, bir ürün ya da hizmetin gelecekteki talep değeri hakkında bilgi sahibi olunmasını amaçlayan bir yöntemdir. Tarihi Analog yöntemi, özellikle tüketicilere yeni sunulan ürün ve hizmetlerin talep tahminlerini elde etmek amacı ile yapılması halinde yararlı sonuçlar sağlamaktadır (Meydan, 2007).

2.4.2. Kantitatif tahminleme yöntemleri

Bulunan bir veri grubundan tahmine ulaşılmasına yarayan metottur.

Bu yöntemler:

- Naive Yöntemi,
- Ortalama Yöntemleri: Basit ilerleyen ortalamalar, hareketli ortalama yöntemi, ağırlıklı ortalama yöntemi
- Üstel Düzeltme Yöntemleri: Tek üstel düzeltme yöntemi, Holt'un doğrusal yöntemi, Holt-winters yöntemi, Pegel'in sınıflandırması.
- Trend Analiz yöntemleri: Regresyon analizi (Hyndman & Athanasopoulos, 2013).

Naive Yöntemi

Bayes Teoremine dayanan ve sınıflandırma hedefiyle özelleştirilmiş, oldukça daha yalın bir Bayesian yaklaşımdır. Bu algoritma koşullu olasılıklara bağlıdır; amaç edilen sınıftaki belirli bir değerin gerçekleşme oranını inceler ve bu incelemeye dayalı olarak amaç edilen sınıfın değerini tahmini olarak bulmaya çalışır. Bu hesaplama Bayes Formülü yöntemiyle gerçekleştirilir (Makridakis, Wheelwright, & Hyndman, 2008).

Ortalama yöntemleri

- Basit Ortalama: Talep tahminleri bakımından gelecek açısından en yalın bakışlardan bir tanesi de geçmişte bulunanların ortalamalarına doğru yönelim göstereceğini varsaymaktır. Bu varsayım için geleceğe göre en geçerli tahmini, geçmişte olanların hepsini bir toplayıp ortalamasını almasıdır.
- Hareketli Ortalama: Hareketli ortalama metodu yakın geçmişe yöneliktir ve bu yönetime dayanarak dönem talep tahmini gerçekleştirir. Örneğin, geçmiş tarih verilerinden beşi, altısı veya yedisi alınır, en son gerçekleşmiş olan dönem bunlara eklenir. Sonradan alınan bu verilerin ortalaması, daha sonraki dönem talep miktarı olarak kabul edilmektedir.
- Ağırlıklı Hareketli Ortalama: Ağırlıklı hareketli ortalama yöntemi, en yakın veriye verdiği ağırlık en fazladır. Hareketli ortalama yöntemi; belirlenen n kadar bir dönem verisi üzerinden çalışır. Bu çalışmadaki matematiksel işlemler $n=4$ olarak alınır ve yapılır (Frechtling, 2001).

Üstel Düzeltme Yöntemi:

Yakın zaman talepleri, önceki dönem taleplerinden daha fazla ağırlık verilerek, zaman serisi ortalamasını hesaplayan ağırlıklı gerçekleşen ortalama yöntemidir.

- Tek Üstel Düzeltme Yöntemi: Bu yöntemde, içinde bulunduğu döneme göre tahmini değeri, önceki tahmini talebe, o dönem yapılan tahmin hatasının dahil edilmesiyle bulunur. İlk tahminin kabul edilmesiyle ya da diğer yöntemlerden herhangi bir tanesiyle bulunabilir.
- Holt'un doğrusal yöntemi: Doğrusal trendi olan serilerin tahminlemede kullanılan bir yöntemdir.
- Holt-Winters Yöntemi: Doğrusal trendi bulunan ve mevsimlik tesirler içeren serilerde kullanılan bir tahminleme yöntemidir.
- Pegel Sınıflandırması: Üssel Düzeltmeler Yöntemi'nde bulunan diğer bir yöntem, doğrusal olan ve doğrusal olmayan serileri, trend veya mevsimler dalgalanmaları barındırıp barındırmadığı göz önünde tutularak bir sınıflandırmaya dahil etmektir (Makridakis, Wheelwright, & Hyndman, 2008).

Trend analiz yöntemi:

Trend analizi, ayı piyasası (aşağı yönlü piyasa) veya boğa piyasası (yukarı yönlü piyasa) cinsinden bir yönelimi tahmin etmeye çalışmak ve bu tahminleri veriye dönüştürmektir. Teknik analiz açısından ve yapılacak hamlenin başarıya ulaşması yönünden trendlerle beraber hareket etmek son derece faydalıdır. Bu durum trendlerle beraber hareket eden bir yatırımcıya fayda sağlayacaktır.

Trend, piyasanın belli bir süre boyunca genellikle aldığı yöndür. Eğilimler, sırasıyla aşağı yönlü veya yukarı yönlü olabilir. Bir yönün eğilim olarak kabul edilmesi için belirli bir süre gerekli değildir. Yönün uzunluğu, trendin ne kadar belirgin olacağına karar verir.

Trend analiz yöntemleri: Mali tabloların üzerindeki bulguların geniş bir zaman aralığında kritiğinin yapılması, art arda yıllara göre gösterdikleri yönelimlerin belirlenmesi, trend yüzdeleri yönetimi ile gerçekleşir.

İşletmelerin uzun zamanlar ya da seneler bakımından finansal gidişatını ve türlü içeriklerin değişim trendini belirli bir yılı belirleyerek analiz edilmesi eğilim trend analizidir. Çoğu açıdan normal olarak kabul edilmiş olan bir yıl, baz yıl kabul edilir. Kabul edilmiş olan baz yıl üzerinden hesaplamalar gerçekleştirilir. Baz yılın rakam meblağı 100 kabul edilir ve öteki yılların kalemlerinin rakamları bu yıla oranlanır. Yüzdelerin yanında mutlak rakamlarında dikkatle incelenmesi sağlıklı bir şekilde değerlendirme yapılmasını sağlar.

- Regresyon Analizi: Kendi içlerinde sebep sonuç ilişkisi bulunan iki ya da ikiden fazla değişkenin aralarındaki ilişkiyi tanımlamak ve aralarındaki bu ilişkiyi kullanarak o konu ile ilgili tahminler veya tahminler yapabilmek amacı ile gerçekleştirilir. Doğada birçok olayda sebep sonuç ilişkisine rastlamak mümkündür (Makridakis, Wheelwright, & Hyndman, 2008).

Analiz yönteminde matematiksel bir model kullanılır çünkü iki ya da ikiden daha fazla parametre arasındaki ilişkiyi açıklamak gereklidir. Bu model regresyon modeli olarak adlandırılır.

2.5. Tahminleme Temel Adımları

Öngörme, çoğunlukla temel adımlar içerir.

Adım 1: Sorun Tanımlama: Sorun tanımlama, tahminin en zor bölümüdür. Sorunu dikkatli bir şekilde geri çevirmek, yapılan tahminlerin ne şekilde kullanılacağı, yapılan tahminlerin kimi gerektirdiğini ve öngörme görevinin tahmini gerektiren firmada ne şekilde etkilediğini anlamayı gerektirir. Tahmincinin elde bulunması gereken bilgileri bulundurma, veri tabanı koruma ve gelecek durumlarla ilgili planlamalar yapılması için tahminlerin kullanılması durumlarında bulunacak kişilerle iletişim içinde olması gereklidir.

Adım 2: Bilgi toplama: Her durumda ve zamanda iki türlü bilgi bulunması gereklidir. İstatiksel veriler ve verileri toplayıp, tahminleri kullanan kişilerin uzmanlıkları. Genellikle, istatiksel modelin en iyi şekilde oluşturulması için yeteri kadar tarihsel bilgi toplamak zordur. Bu gibi durumlarda, genellikle yargı tahmin yöntemleri kullanılır. Ara sıra, tahmin edilen sistemin yapısal farklılığından dolayı eski veriler çok fazla yararlı olmaz. Ancak, tercihen en yeni veriler bu gibi durumlarda kullanılabilir. Buna ek olarak, iyi bir şekilde hazırlanmış istatiksel sistemin evrime bağlı olarak değişiklikler içereceği unutulmaması gereken bir ayrıntıdır; kullanımı kolaylık sağlayan iyi veriler dikkate alınmalı ve atılmamalıdır.

Adım 3: Ön (keşif) analizi: Veriler her zaman grafik olarak çizilmeyle başlanmalıdır. Sabit kalıplar içeriyor mu? Açık bir meyil var mı? Mevsimselliğe dikkat edilmeli mi? İş tekrarlamalarının varlığına bir kanıt bulunuyor mu? Verilerde aykırılık var mı ve uzmanlar tarafından açıklanmalı mı? Elde bulunan değişkenlerdeki ilişkilerin güçlülük durumu nedir?

Adım 4: Modellerin seçimi ve uyumu: Kullanılabilecek en uygun biçim, geçmişe dair eldeki bilgilerin kullanılabilirliğine, tahmin ile açıklayıcı değişkenlerin arasında bulunan bağlantıların durumuna ve tahminlerin ne şekilde kullanılacağıyla bağlantılıdır. Yaygın olan, iki veya üç modelin karşılaştırılmasıdır.

Adım 5: Bir tahmin modelini kullanma ve değerlendirme: Model seçilir ve değişkenleri tahmin edildikten sonra seçilen model tahmin için kullanılabilir. Modelin göstereceği başarı sadece tahmin süresi hakkında veriler toplandıktan sonra doğru olarak değerlendirilir (Hyndman & Athanasopoulos, 2013).

ÜÇÜNCÜ BÖLÜM

YAPAY ZEKA

3. YAPAY ZEKA

3.1. Zeka Nedir?

İnsan davranışları oldukça basit ve akıllıcadır. Fakat hayvanlar tarafından gerçekleştirilen karmaşık hareketler tamamen akıllıca değildir. Aralarındaki fark nedir? Büyük altın arayıcısı yaban arısı *Sphex ichneumon eus*'un davranışını ele alalım. Dişi yaban arısı yuvasına yiyecek getirdiği zaman davetsiz misafirleri kontrol etmek için yuvaya girer ve yuva güvenliyse yiyecekleri taşır. Yaban arısının bu davranışını inceleyen kişi, arının yuvayı her girişinde kontrol edip yiyecekleri öyle taşıdığını görür. Bu davranış art arda defalarca tekrarlanabilir. Zeka, zihnin yeni oluşan her duruma uyum sağlayan ve öğrenmeden yararlanan yetenek birleşimidir (Mehrotra, 2019).

Yapay Zeka, genel olarak bilgisayar kontrolü altındaki bir robotun zeka gerektiren pek çok faaliyeti yerine getirme kabiliyetidir. Yapay zekanın kısıtlı ya da sadeleştirilmiş alanlarda birtakım başarıları vardır. Bununla beraber, yapay zekanın başlangıcından (1956) itibaren geçen 30 yıllık zamanda yavaş bir yol kat etmiştir.

Psikolojideki ana fikir, insan zekasını tek bir kabiliyet ya da kavramsal işleyiş olarak değil; bir takım ayrı bileşen olarak bilinmesidir. Yapay zekada yapılan araştırmalar başlıca olarak aşağıdaki bileşenlerde toplanmıştır;

Öğrenme, akıl yürütme, problem çözme, algılama ve dil anlama.

3.2. Öğrenme

Öğrenme birkaç şekilde olabilir. Bunlardan en basit olan, deneme yanılma yoluyla öğrenme şeklidir. Örneğin, bir satranç oyunundaki problemlerin çözümü ile ilgili basit bir program kullanılabilir. Kişi, eşe ulaşana kadar hamleleri rastgele yapar. Program başarılı olan hamleyi hemen hatırlar ve bir sonraki bu problem için bilgisayar hemen çözüm ortaya koyar.

Ögelerin tek tek olarak basit şekilde ezberlenmesi ezberci öğrenmedir. Ezberci öğrenme, sorunlara çözüm üretme, kelime dağarcığı genişletme vb.

Öğrenmenin bir bilgisayar uygulamasına uyarlanması basittir. Genellemenin uygulama sorunu kolay değildir. Öğrenme genelleme içerir, öğrencilerin daha önce karşılaşmadıkları durumlarda çok daha güzel başarı elde etmelerine yardımcı olur. Gelişmiş olan çağdaş yöntemler, programların bulunan karmaşık kurallarını verilerden genelleştirmesine yardımcı olur.

3.2.1. Makine öğrenimleri

Günümüzde yapay zekaları araştırmak için laboratuvarlar bulunmaktadır. Bu laboratuvarların dışında kullanılan uygulamaların çoğu bir kısmı tecrübeler ve bilgilere dayalı bir işlevin performansını geliştiren çok büyük ölçülü algoritmik sistemlerin grubunu ifade eden makine öğrenme algoritmasına dayanır. Makine öğrenimi algoritmaları istatistikeldir. Yani yaşanan dünyaya göre konumlandırılmadan önce, lazım olan çıktı kalitesini sağlamak için çoğunlukla çok büyük bir eğitim bilgi kümelerinden, kalıpları çıkarmaya dayanır.

Makine öğrenimi yöntemleri, performans arttırmak için işlemler gerçekleştirir. Çoğu sürekli entegrasyon (CI) projesi yapay zeka ile birlikte denetimli öğrenmeyi de kullanır. Algoritma burada tahminlerde bulunmayı insanlar tarafından etiketlenmiş çoğu veri örneğini inceleyerek öğrenir. Örneğin; makine öğrenimi, hayvanların veya galaksilerin görüntülerine atanan etiket ya da elektronik ortama aktarılan verileri kopyalar. Kopyalanan veriler, etiketlenmemiş birbirine benzeyen görüntülerin hangi şekilde sınıflandırılması gerektiğine göre makineler için birer eğitim veri kümesidir.

Denetimsiz öğrenme, bir diğer yaygın olan öğrenme paradigmasıdır. Büyük ve karmaşık veri kümelerinin etiketi olmayanları için kullanılır. Gözetimsiz öğrenme, verilerin ortak özelliklerinin anlaşılmasını kolaylaştırmak için belirlemede yardımcıdır. Örneğin; politikada yaşanan müdahaleler veya kamu fonları için vatandaşlar fikir sunmaya davet edilir ve ortaya çıkan bilgilerin kümesinin yetkililer tarafından işlenmesi zor olabilir. Çünkü bunların hepsi değişik şekillerde yazılmış binlerce fikir barındırır.

Makine öğrenimi, büyük veri kümelerini bir araya getiren ya da bu veri kümelerini yorumlayan CI tasarıları için çok uygundur. Veriler insanlar tarafından, genellikle görüntüler ve videolardan ortaya çıkan içeriklerdir. Çevrimiçi platformlar, akıllı cihaz uygulamaları ya da sosyal medya aracılığıyla görüntüler bir araya gelir.



Şekil 3.1. Öğrenim modelleri

Kaynak: <https://www.drozdogan.com/yapay-zeka-ile-sagligi-tamamen-degistirmek/> [8]

Yapay zekanın bir alt kümesi makine öğrenimidir. Makine öğrenimi, veri kümelerinden kalıp çıkarmakla ilgilenir. Bu olayın arkasında bulunan kuram, bilgisayarın belirli olan görevleri yerine getirmede bunları programlanmadan öğrenebilmeleridir. Makine öğrenmesi tekrarlanandır. Yani modeller yeni olan bilgilerle veya verilerle karşı karşıya kaldıkça, herhangi bir bağıllık olmadan uyum sağlama ve güvenilir sonuçlar ortaya çıkarmak için öğrenme yeteneğine sahiptirler.

3.3. Muhakeme

Muhakeme nedeni, içinde bulunulan durum ile ilgili sonuçlar çıkarmaktır. Çıkarımlar genelden özele ya da özelden genele doğru sınıflandırılır. Birinci: “Rabia ya evde ya da alışverişte; Rabia evde değil, bu yüzden Rabia alışverişte.” Ve ikinci: “Buna benzer daha önceki kazaların nedeni alet arızasıydı; buna neden olan büyük olasılık ile cihaz arızasıydı.” Bu ikisi arasındaki fark: genelden özele dava, sonucun gerçekliğini garanti eder; diğerindeyse kazanın araç arızasından kaynaklandığı sonucuna destek sağlar.

Ancak bununla birlikte, daha ileri düzeyde araştırmalar öncül olanın gerçekliğine karşın sonucun esasen yanlış olduğunu ortaya çıkarabiliyorlar.

Bilgisayarlar özellikle de çıkarımlar çizmek için programlamada önemli başarılar elde edilmiştir. Bununla birlikte, bir programın sadece çıkarımlar yapabilmesi nedeniyle mantıklı olduğu söylenemez. Akıl yürütme, eldeki görev veya durumla ilgili çıkarımların çizilmesini içerir. Yapay zeka ile yüzleşmenin en zor sorunlarından biri, bilgisayarlara konuyu ilgisiz olandan ayırt etme yeteneği vermektir.

3.4. Problem Çözme

Sorunların genel bir şekli bulunur ve bu tarz veriler kullanıldığında x bulunur. Yapay zeka (AI) çok fazla çeşitli sorun barındırır. Örneğin; masa oyunlarındaki hangi hamlelerin kazandığını belirlemek, fotoğraftan kişileri tanımlamak ve bir robotun verilen herhangi bir görevi yerine getirmesine yardımcı olan birtakım hareketlerin planlamasının yapılması.

Problem çözme şekilleri ikiye ayrılır: genel amaçlı ve özel amaçlı. Özel amaçlı metot, belirli olan bir soruna özel hazırlanır ve genel olarak sorunun içinde bulunduğu durum ile ilgili çok özel niteliklerden faydalanır. Genel amaçlı yöntem ise çok çeşitli sorunlara uygulanabilir. AI'da kullanılan genel anlamı bir yöntem, bulunan mevcut durum ve hedef durumun arasında olan farklılıkların yavaş yavaş azaltılmasını barındıran araç sonu analizidir. Program, mevcut gidişat amaç durumundaki hedefe dönüştürülene kadar hareketleri bir araç listesi içinden bulur. Örneğin; karmaşık olmayan bir robot üzerinden başlatma, bırakma, ileriye hareket etme, geri hareket etme, dönüş, hareket etme ve hareket kapasitesinden oluşabilir.

3.5. Algı

Algılama gerçekleşirken çevre, gerçek ya da çeşitli yapay duyu organları tarafından taranır. Algılamayı kapsayan süreçler görünen sahneyi nesne, ayırt edici özellik ve ilişki bakımından çözümler. Analiz tek veya aynı olan nesnenin bakıldığı açı, bakılan kısmın gölge yansıtıp yansıtmasına ya da herhangi başka bir şeye bağlı olup olmamasına dayanarak değişik durumlarda birden fazla görünüm ortaya koyabildiğinden dolayı karmaşıktır.

Bulduğumuz zamanda, kendini kontrol edebilen araba benzeri bir aygıtın önü açık bir yolda ölçülü hızla kullanılmasını sağlamak için yapay algı yeterince gelişmiştir. Ve mobil olan bir robot ofisteki boş şişeleri bulup temizler ve dolaşır. Hareketli bir TV gözü ve sabit olan bir eli bulunan robot FREDDY (1966-1973 döneminde yapılmıştır), algıyı ve eylemi bir bütün durumuna getiren en eski sistemdir. FREDDY çeşitli objeleri tanıyabiliyor ve oyuncak bir araba gibi basit yapıları herhangi bileşenlerden bir araya getirmesi istenebiliyor.

3.5.1. Dil algılama

Bir dil, konvansiyonla anlamı olan işaretler sistemidir. Trafik işaretleri, örneğin, bir mini dil oluşturur, örneğin tehlike işareti öndeki tehlike anlamına gelen bir konudur. Dilden farklı olan bu anlam-anlam konvansiyonu, 'Bu bulutlar yağmur demektir' ve 'Basınçtaki düşüş, vananın arızalı olduğu anlamına gelir' gibi ifadelerde örnek verilen doğal anlamdan çok farklıdır. Dil, işaretler sistemi demektir. Örneğin: trafik işaretleri mini bir dil oluşturur, tehlike işareti ilerideki tehlike anlamına gelir.

İngilizce gibi tam kapsamlı insan dillerini ayırt etmede önemli bir özelliktir. Yaratıcı bir dil, içerisinde sınırı olmayacak kadar çok farklı cümlenin yöntemini sağlayacak kadar zengindir.

İngilizce ağır kısıtlı bir bağlam olarak görünür. Örneğin: Parry ve Shrdlu programlarını cevaplayabilen bilgisayar programlarını yazmak biraz daha kolaydır. En uygun biçimde yaratılmış program dili kural olarak: bilgisayarın dilsel olarak davranışında dilin, insan anadili olan bir konuşmacıdan ayırt edilemediği noktaya kadar kullanılabilir.

O halde anadili, insan olan bir konuşmacıdan dili ayırt edilemez bir biçimde kullanan bilgisayarın anlaması mecburi değilse; hangi anlayışta yer alır?

Bu sorunun evrensel biçimde kabul edilen herhangi bir cevabı bulunmamaktadır. Ortaya atılan bir kurama göre, kişinin anlayıp anlamadığı sadece o kişinin davranışına değil bununla birlikte tarihi ile de bağlantı içindedir. Kişi dili öğrendikten sonra anlayabildiğini söyleyebilir ve eğitilmiş olması dil toplumundaki yerini almasını sağlar.

3.6. Yapay Zeka Örnekleri

Yapay zeka alanı, insan zekasını ve davranışını taklit eden özgür çalışan sistemler oluşturmaya başlar. Yapay zeka örnekleri;

Konuşma Tanıma ve Doğal Dil İşleme: insanın bir dili konuşma, dinleme, okuma ve yazma yeteneğini benzeten eden yapay zeka belleğidir.

Bilgisayarla Görme ve Görüntü İşleme: görünenlere dayanarak, görüntüleri izleme ve bilgileri işleme yeteneğini taklitler.

Robotik, yapay zekanın fiziksel olarak iletişim kurmasına ve çevresiyle hareket etmesine müsaade eder.

Makine Öğrenimi, bir bilgisayarın devam eden kişilerin birbirini etkilemesi olayına etki ve yönlendirme olmaksızın öğrenmesine yardım edebilmek için örüntü tanıma ve sınıflandırmadan yardım almak, yapay zekanın insan öğrenme sürecine çözümüdür.

İnsan beyni, öğrenmesi gerekenler için nöron ağları kullanır. Sinir ağları nöronları, bilgisayarlar ve makinelerde benzer bilişsel kabiliyetler yaratmak amacıyla kullanır.

3.7. Makine Öğrenimi ve Yapay Zeka Arasındaki Fark

Terimler kimi zamanlar birbirinin yerine kullanılabilir. Yapay zekanın bir alt kümesi aslında makine öğrenimidir. Makine öğrenimi, bilgisayarın belirli bir görevi yerine getirmesine yardımcı olması için dağıtılan AI kodu çeşididir. Bu teknolojiye sahip olan bir makineye veri girişi sağlandığında, veri gruplarını ayırt etmeyi ve gruplarını sınıflandırmayı öğrenir. Makinenin gittikçe uzmanlaşması ve doğruluğunun zamanla artması daha fazla veri toplamasıyla sağlanır (Mehrotra, 2019).

İnsanlar da makine öğrenimi gerçekleştirir. Satranç oyununu belki öğrenirsiniz. Oyunun her parçasının isimlerini öğrenerek ve tahtada ilerlediği yolu görerek başlarsınız. Asıl bilgileri öğrendikten sonra, başka kişilerle oyun oynamaya başlarsınız ve gün geçtikçe kazanma olanağınızı artırmak için yöntemler geliştirirsiniz. Satranç ustası olabilmek için yıllarca pratik yapmış ve strateji üretmiş olmak gerekir.

Makine öğrenimi ile satranç oynamak için kapsamlı bir makinenin olması, öğrenme süresini çok daha az bir zamana sığdırabilir. Oyunun parçalarını tarif etmek, başarılı olabilmesi için matematiksel olarak yöntemler geliştirmek ve ustalık kazanmak için kendisine karşı sınırsız kez oyunlar oynamak pratikleşmeyi sağlar. Makinelerin öğrenimi insanlara göre çok daha hızlı gerçekleşir, çünkü aşırı bilgi yüklemesi yapılabilir ve uyku gibi ihtiyaçlara gerek duymazlar. İnsan beynine göre çok fazla veri sınıflandırmasını işleyebilirler ve daha hızlı şekilde öğrenirler.

3.8. Yapay Zeka Tehditleri

Yapay zekanın potansiyel bir tehdit olduđu tartışılan bir konudur. İnsanlar Sophia'nın 2016 South by Southwest Festivalindeki "insanları yok edeceğim" cümlesini kurmasından sonra, eğer AI teknolojisi kötü düşünceli kişilere düşerse olacaklardan korkuyorlar ve "yapay zeka bir tehdit mi?" diye soruyorlar.

Birincisi, yapay zekanın yanlış kullanım sorunu bulunuyor. Yapay zeka teknolojileri terörizm için ve siber saldırılara yönelik kullanılabilir mi? Yapay zeka, bilgisayar korsanlarına siber suç için daha etkili bir yazılım ve yöntemler tasarlamada kolaylık sağlıyor. Yapay zeka destekli sürücüsüz otomobiller ve dronlar uzaktan kontrol edilebildiklerinden dolayı silah konumunda bir tehdit olarak kullanılabilirler.

Zenginleştirilmiş durumda olan yapay zekadan birkaç yıl kadar uzaktayken, yapay zeka kaynağı belirli bir görevi yerine getirmek için kodlandığında, neler olduğu ile ilgili çok fazla sorular bulunur ve mantıksal verimliliğin sonsuzluğuyla, makine insanların birer engel olduğu kanısına varıyor. Makine her zaman ne yapması gerekiyorsa onu yapması için programlanmıştır, yapmasını istemediğiniz hiçbir şeyi yapmaz.

Makine İstihbarat Araştırma Enstitüsü: son derece akıllı olan bir makinenin, yaratıcılarının bu mekanizmaları ortaya çıkarırken düşündüğünün sonucuna göre değil, tasarlandığı mekanizmalara uygun bir biçimde kararlar vereceğini iddia etmektedir (Bensinger, 2016).

3.9. Yapay Zeka Çalışma Mantığı

Belki de çoğumuzun neredeyse hiç anlayamadığı bir teknolojiyle -bilim adamları da dahi bu olayı açıklamak için zor zamanlar geçirdiler- karmaşık bir şekilde dönüştürülmesi şaşırtıcıdır.

İnsanların zeka ve analitik düşünme yetisinin çok yönlülüğü bu noktada hala AI'nın erişemeyeceğinin çok daha ötesindedir.

Yapay zeka, beynin çalışma şeklini taklit etme ve anlama girişimimizin bir sonucudur; bunun beyine benzer fonksiyonlarının başka türlü otonomlara uygulanmasıdır. Örneğin: dronlar, robotlar ve ajanlar...


İnsanlar bilgileri saklamak için biyolojik hücreler yerine devreleri, yarı iletkenler ve manyetik ortamlardan yararlanan bilgisayarlar gibi düşünmese de yine de bazı ilginç paralellikler bulunmaktadır.

Tek bir nöron, tek başına size çok sınırlı nicelikte bilgi sağlar, ancak retina ve koklea dediğimiz farklılıklara sahip yeterli nöronları beraber çalıştırır ve DSP'ler aracılığıyla özgün olarak modüle edilen elektrik sinyallerine yalnızca belirli tür uyaranlara cevap olarak verilen bir model elde edilir.

Yapay zekadaki SAS'ın açıkladığı şekilde yapay zeka: büyük ölçüdeki veriyi, yazılımın verilerin özelliklerinden ve kalıplarından öğrenmesine yarayan bir dizi akıllı algoritmalarla bütünleştirerek çalışır.

Bir beyin çalışma sistemini benzetmeye uğraşırken AI, SAS primerinin belirttiği kadar bir dizi farklı alt alandan yararlanır.

Makine öğrenimi, belirli bir sonuç çıkarmak veya belirli bir şeyi aramaya göre programlanmadan verilerdeki gizli bilgileri bulmak karşı analitik model oluşturmayı otomatik hale getirir.



Şekil 3.2. Yapay zeka çalışma mantığı

Kaynak: <https://www.thetambellinigroup.com/artificial-intelligence-transforming-the-nature-of-work-learning-and-learning-to-work/> [9]

Sinir ağları, beyin birbirine bağlı halde bulunan nöron dizisini taklit eder ve verilerden anlam çıkarmak, bağlantıları bulmak için çeşitli birimler arasındaki bilgi aktarımını sağlar.

Derin öğrenme, konuşma ve görüntü tanıma benzeri uygulamalara göre verilerdeki karmaşık kalıpların bulunması için ciddi büyüklükteki sinir ağlarını ve çok daha fazla bilgi işlem gücünü kullanır.

İstatiksel analiz yazılımlarında (SAS) konuşma, yorumlama ve cevaplama yeteneğini kullanma; doğal ve insan benzeri bir etkileşim oluşturmakla alakalıdır.

Bilgisayar vizyonu, resim ve videoların içeriğini anlamak, makinelerin etrafındaki şeyleri anlamasını ve doğru zamanlı görüntüleri kullanmasını sağlamak için derin öğrenme ve desen tanıma kullanır. İnsan dilini analiz edip, anlamayı ve ona cevap vermeyi içermeye Doğal Dil İşleme denir.

3.10. Yapay Zeka Metotları

3.10.1. Uzman sistem

Uzman sistem, insan uzman kadar karar verme yeteneği sağlamak ve karmaşık sorunları çözmek için kurulmuş olan bir bilgisayar programıdır. Bunu yaparken, kullanıcı sorgularına uygun bir şekilde kıyaslama yapar ve çıkarım kurallarını kullanarak veri tabanından bilgi çıkarır.

Yapay zekanın parçalarından biri uzman sistemdir ve yapay zekanın ilk başarılı yaklaşımı olan ilk ES 1970 yılında geliştirilmiştir. Bir uzman, karmaşık durumdaki bir konuyu veri tabanında gizlenmiş olan bilgiyi çıkararak çözer. Sistem, buluşsal yöntemleri ve gerçekleri sanki bir insan uzmanmış gibi kullanarak kompleks problemler için karar vermede yardımcı olur. Herhangi bir karmaşık sorun, uzman bilgisi içererek çözebileceği için buna uzman sistem denir. Bu sistemler: tıp, bilim vb. gibi belirli bir alana uygun planlanmıştır.

Uzman bir sistemin verimi, uzmanın veri tabanında saklanan bilgisini baz alır. Sistemin gösterdiği başarının fazla olması, KB'de depolanan bilgi çokluğuna dayanır. ES'nin en bilindik örneklerinden bir tanesi: Google arama motoruna yazdığımızda yazım hatalarının önerisidir

Yapay Zeka (AI), bir bilgisayar becerisi inceleme dalından türetilen bilgisayar programlarıdır. Yapay zekanın bilimsel hedefi, akıllı davranışlar gösteren bilgisayar programları yaratarak zekayı anlamaktır. Bir bilgisayar tarafından yargılama kavramları ya da simgesel çıkarım ve yöntemleri; bu sonuç ve tahminleri yapmak için kullanılan verinin makine içinde ne şekilde simgeleneceği ile alakalıdır.

Kuşkusuz AI dil öğrenme, sorunları çözmeye ve anlama gibi işlemlere hitap ediyor. Yalnız yapay zeka alanında, bugüne kadarki ilerlemelerin neredeyse çoğu bir problemi hesaplamak yerine, problem çözmeye alanında problemleri akla getiren sistemler oluşturmak düşüncesiyle kavramlar ve yöntemler geliştirilerek gerçekleştirilmiştir. AI programlarına, belirli olan görevler üzerine bilgi birikimi getirilerek görev alanlarındaki sorunları çözmeye uzman düzeyinde olgunluk kazanan veri tabanlı ya da uzman sistemler denir. Çoğu defa, uzman sistemler terimi, uzman olmayanlardan veya ders kitaplarından toplanan bilginin tersine; veri tabanı, insan uzmanlar tarafından kullanılan bilgileri barındıran uygulamalara ayrılmıştır.

Çoğu zaman, bilgi tabanlı sistemler (KBS) ve uzman sistemler (ES) olmak üzere bu iki terim aynı anlamı olarak kullanılır. Beraber irdelenen sistemler, AI uygulama tipini en yaygın biçimde ifade ederler.

Görev alanı, insanların entelektüel uğraşlarının uzman bir sisteme alınmasına denir.

Hedefe yönelik problem çözmeye faaliyetleri görevi ifade eder. Görevin gerçekleştirildiği alan etki alanını ifade eder. Belirleme, planlama, zamanlama, konfigürasyon ve tasarımlar tipik görevlerdir. Bilgi mühendisliği uzman bir sistem tasarlamak olarak bilinir ve bunu uygulayanlara bilgi mühendisleri denir.

Bilgi mühendisi, bilgisayarın problemini çözmek amacıyla gerekli olan tüm donanımlara sahip olduğundan emin olmalıdır ve gerekli verinin bilgisayarın belleğinde sembol desenleri olarak temsil edileceği bir ya da birden daha fazla form tercih etmelidir.

Bu nedenle veri temsilini belirlemelidir. Ayrıca yargılama yollarından bir tanesini belirleyerek bilgisayarın veriyi en verimli şekilde kullanabilmesini amaçlamalıdır.

3.10.1.1. Uzman sistemlerin yapı taşları

Her uzman sistem iki ana kısımdan oluşur: veri tabanı ve akıl yürütme.

Uzman sistemlerin veri tabanı hem sezgisel hem de olgusal veri barındırır. Olgusal veri, yaygın olarak paylaşılan, genellikle gazete, dergi ya da kitapta bulunan ve belirli bir kısımdaki bilgileri kişilerce genel olarak üzerinde anlaşılabilir görev alanı verisidir.

Sezgisel veri yargılayıcı, deneyimsel ve titizdir. Sezgisel veri gerçek bilgiye göre çok düşük bir ihtimal ile tartışılır ve genellikle bireyseldir.

Sezgisel veri uygulama, karşılaştırma ve akıl yürütme bilgisidir

Bilgiyi biçimlendiren ve düzenleyen bilgi gösterimidir. Kullanılan temsil, üretim kuralı ya da basit kuraldır.

Kural, bir IF kısmı ve bir THEN kısmından oluşur (koşul ve işlem olarak da adlandırılır). IF kısmı, mantıksal dizi koşulunu listeler. IF kısmında üretim kuralı tarafından temsil edilen veri karşılanır. Bu durum akıl yürütme çizgisiyle ilgilidir. Yani THEN kısmı sorun çözme eylemini gerçekleştirir.

Kural tabanlı uzman sistemler bilgilerini kural biçimde gösterir. Genellikle kullanım sıklığı çok olan temsil, birim olarak adlandırılır ve daha pasif veri görüşüne dayanır (liste, çerçeve, şema).

Birim, temsil edilecek bir varlık üzerindeki sembolik verinin bir bütünüdür. Genellikle bir birim, varlığın özelliklerinin listesini ve buna benzer özelliklere göre ilişkili değerleri barındırır. Görev alanları, çeşitli ilişkilerde bulunan varlıklardan oluşur. İlişkileri belirtmek için özellikler kullanılır. Özelliklerin değerleri, ilişkilere bağlanan birimlerin adlarıdır.

Bir birim başka bir birimin özel olan bilgisini temsil eder. Ya da bazı birimler başka bir birimin parçaları olabilir. Problem çözme modeli, sorunu çözmek amacıyla gerçekleşen adımları düzenler ve kontrol eder.

Bir akıl yürütme çizgisi oluşturmak için IF-THEN kurallarının zincirlenmesini güçlü bir paradigmayı kapsar. Bazı dizi koşullarının başlamasıyla zincirleme oluşur. Bu sonuca doğru ilerlerse yöntemin adı ileri zincirleme olur. Ulaşılabilecek hedefin sonucu belli ise ve bu sonuca giden yol bilinmiyorsa, geriye doğru yargılama çağrılır ve yöntem geriye doğru zincirleme olur. Bu problem çözme yöntemleri, bir yargılama çizgisi oluşturmak amacıyla veri tabanındaki verileri yok sayıyorsa ve kullanan çıkarsama prosedürlerine verilen uygulama modüllerine yerleştirilmiştir.

Uzmanın kullandığı veri tabanı zaman içerisinde öğrendiği tecrübelerdir. Tecrübeye kadar fazla ise veri deposu o kadar büyük olur. Veri tabanındaki bilgileri, bilgi aracılığı ile tasarım, tanı, analizde avantaj oluşturacak şekilde yorumlamasına yardımcı olur. Uzman sistem bilgi tabanı ve bir çıkarsama motorundan oluşur. Uzman sistemin diğer birkaç özellikleri: belirsizlikle akıl yürütme ve akıl yürütme çizgisinin açıklaması.

Bilgi belirsizdir ve eksiktir. Güven faktörü veya ağırlık ile ilişkilendirilmiş kurallar belirsiz bilgi ile başa çıkmak için kullanılır. Belirsizlik ile akıl yürütme: belli olmayan bir bilgiyi akıl yürütme aşamasında belli olmayan veriler ile beraber kullanma yöntemi kümesidir. Bulanık mantık alt sınıf yöntemi belirsizlikte mantık yürütmek için önemli bir yöntemdir. Bunları kullanan sistemlere, bulanık sistemler denir.

Sezgisel bilgi kullanan uzman sistem güvenilirdir (insanlardaki gibi). Şüpheli cevabı olan sorunun, mantığını bilmek isteriz. Cevaba inanma yönelimimiz gerçeğin mantıklı olmasına bağlıdır. Bu nedenle uzman sistemlerde sorulan soru şu şekildedir: A neden cevap? Çıkarsama motoru yönünden kullanılan akıl yürütme çizgisinin izlenimi açıklamaları elde eder.

Bilgi, uzman sistemdeki en önemli bileşen konumundadır. Görev alanları ile ilgili içerilen yüksek kaliteli, özel veriler uzman sistemin gücünü gösterir. Bilgide güç bulunur.

Yapay zeka araştırmacıları, veri temsili ve yargılama yöntemlerinin, bulunan içeriğini araştırmayı ve eklemeyi sürdürecektir.

Verinin önemi ve bulunan bilgiyi edinme metodu uzman sistemlerde yavaş ve sıkıcı olduğundan dolayı; uzman sistemlerin geleceği, veri altyapısının kodlanmasına ve veri elde etme darboğazının kırılması ve temsil edilmesi ile ilişkilidir.

Uzman sisteminin asıl maksadı, insan uzmanlar ile ilgili bilgiyi toplamak ve uzman kişilerin yetenek ve bilgilerini çoğaltmaktır. Sistem sonradan, uzmanlık alanının katılımını gerektirmeden, o alandaki komplike sorunları ortadan kaldırmak amacıyla veri ve becerileri değerlendirir.

3.10.2. Genetik algoritmalar

Evrimsel algoritmaların büyük bir çoğunluğuna ait olan adapte edilebilir sezgisel arama algoritmalarına Genetik Algoritma (GA) denir. Genetik algoritmalar, genetiğin düşüncelerine ve doğal seçilime dayanmaktadır. Çözüm alanının başarı sağlayan bölgesini elde etmek amacıyla, geçmiş verilerle elde edilen herhangi bir aramanın doğru şekilde kullanılmasıdır. Arama problemlerine ve problem çözme sorunlarına bakarak, yüksek nitelikli çözümler meydana getirmek amacıyla kullanılırlar.

Genetik algoritmalar, doğal seçim gidişatını benzer şekilde çevrelerindeki değişimlere ayak uydurabilen cinslerin ayakta kalıp üremesini ve gelecek kuşaklara aktarılmasını sağlar. Problemi çözmek düşüncesiyle ilerleyen kuşaklar arasında “en uygun olanın hayatta kalmasını” amaçlar. Nesiller, birey popülasyonlarından meydana gelir ve bireyler bir noktayı, olası çözümü temsil eder. Bireyler: bit dizisi, tamsayı, karakter, kayan nokta olarak temsil edilir. Popülasyonun kromozom davranışına ve aynı zamanda genetik yapıya sahip benzeşime dayanan algoritmalar, genetik algoritmalarlardır.

Bu benzetmede kastedilen GA'ların temeli şöyledir:

Nüfus içinde eş uğruna rekabet vardır

Başarılı bireylerin çiftleşmeleri diğer bireylerden daha çok yavru oluşturabilmektir.

Kuşaklar boyunca yayılan genler uygun olan bireyden alınan genlerdir. Bazı ebeveynler daha iyi yavrular ortaya çıkarır.

Çevre için daha uygun olan nesiller, birbirini takip edenlerdir.

3.11. Arama Alanı

Arama alanında bireylerin nüfusu vardır. Bireyler, oluşan soruna göre arama alanında ki bir çözüm yolunu simgeler. Bireyler, bileşenlerin sonu olan uzunluk vektörü şeklinde oluşturulur. Genler bu değişken bileşenlere benzerler. Böylelikle, birkaç genden bir kromozom oluşur.

Fitness Puanı, her bireyin “rekabet etme” kabiliyetini gösterir. Hangi birey optimum şarta sahip ya da yakın ise o aranır.

Genetik algoritma, n bireylerin çözelti ve kromozom nüfusunu fitness skorları ile beraber korur. Üreme ihtimali diğerlerine nazaran daha fazla olan bireyler iyi fitness skorlarına sahip olanlardır. Ebeveynlerin kromozomlarını birleştirerek çiftleşen ve uygun yavrular üretenlerden, daha iyi fitness skorları olan bireyler seçilir. Ölen bireler olur ve ölenlerin yerini yeni gelen bireyler alır. Sonunda eski nüfusun çiftleşme imkanları bittiğinde yeni nesil yaratır çünkü nüfus büyüklüğü sabittir. İlerleyen nesiller boyunca kalıplar en az şekilde kalırken daha iyi çözümlerin bulunacağı sanılmaktadır.

Nesiller, önceki nesillerin bireylerinden daha iyi gene sahiptirler. Böylelikle, yeni olan her neslin kendinden önceki nesillere nazaran daha iyi kısmi çözümleri bulunur. Oluşan yeni yavrular, önceki nüfus toplulukları aracılığıyla oluşturulan yavrulardan bir fark göstermediği zaman, nüfus yakınsamaktadır. Algoritma, probleme göre bir dizi çözüm yoluna dönüştürülür.

3.12. Makine Öğreniminde Genetik Algoritma

Veriler veya örnekler makine öğreniminde problemlere çözüm olarak kullanılır. Bunun için iki yol bulunur. Ya aramada etkili çözüm bulmak amacıyla aday olan çözümler sınıfı ya da çözüm verilerden oluşturulur. En yakın komşu sınıflandırma ve karar ağacı induksiyonu olan ID3, bir çözüm oluşturur.

Eğim alçalma algoritması nöral boşlukta arama yapmak amacı ile kullanılır. Ağ ağırlıkları arama kullanımına örnek olarak giriş-çıkış eşlemesini etkileyenleri bulmak gösterilebilir.

Makine öğrenim programlarında fazlaca kullanılan genetik algoritmalar, stokastik aramadır. Bununla beraber, ID3 benzeri algoritmalar hızlıdır ve hesaplama bakımından kolaydır. Çözümlerin yapısı ile ilgili örneğin, önyargı ID3'te bağımsız niteliklere yöneliktir; birbirine en yakın olan yöntemlerinde, çıkışlar girdi benzerliğine aktarılır.

Bununla beraber, arama kullanılarak büyük bir alanda sorunların üstesinden gelebilmek için karmaşık potansiyel çözümlerin örneklerine karşı test edilebilir.

Maliyet artan hesaplamadadır. Buna ek, algoritma içinde endüktif sapma bulunur ve sonunda açık kontroller sağlandığı halde kontrol edilmesi zor olur.

Genetik algoritmalar çoğu açıdan, makine öğrenme yönteminin kontrolsüz ve aptal kısmıdır.

Çoğu, en az veriye ve yaklaşımlara dayanarak çözüm bulur. Bulunan çözümler çeşitli alanlarda etkili durumdadır.

Genetik algoritma (GA) bir problemin çözümünde rastlantısal işlemler yardımı ile çözüme yaklaşma metodudur. GA doğada bulunan en iyi olan seçilir ve yaşamını sürdürür mantığı çerçevesinde işlemektedir. Bu seçim işlemleri GA' nın bazı temel işlemleri ile gerçekleştirilir.

Bunlar;

- Amaç fonksiyonunun belirlenmesi
- Kodlama
- Başlangıç popülasyonunun oluşturulması
- Seçme
- Çaprazlama
- Mutasyon

İşlemleridir. Bu işlemler sonucunda bir döngü tamamlanmış olmaktadır. İstenilen sonu elde edilinceye kadar döngü devam ettirilir (Doğan, 2007).

Üç nedenden dolayı genetik algoritmalar makine öğrenmesinde önemlidir.

İlki: ayrık uzaylar üzerinde bulunan gradyan tabanlı metotların kullanılmadığı yerlerde hareket ederler. Bilgisayarlar, sinir ağı mimarilerini, hücresel otomatları, kural kümelerini aramak amacı ile kullanılabilir. Bu açıdan değişkeni bulunan noktalara kullanılabilirler.

İkincisi, temel olarak güçlendirici öğrenme algoritmalarıdır. Öğrenmenin performansı, sistemin tek bir sayı ile uygunluğuyla tanımlanır. Nöralin farklı kısımlarına aynı olmayan sinyaller gönderen ağ, geri yayılma benzeri hata katkısına dayalıdır. Böylelikle, bilginin performans ölçümü olduğu durumlarda geniş olarak kullanılırlar. Rakipleri: Q-öğrenme, TD öğrenme...

En son olarak, genetik algoritmalar bir nüfus barındırır ve kimi zaman kişinin arzuladığı tek şey varlık değil bir gruptur. Bunun en iyi örneği çok etmenli sistemlerde öğrenmedir. Genetik algoritmalar yapay zekada: arama ve öğrenmenin yanı sıra; akıl yürütmede de kullanılır. Satranç oyun programını, ayrımı açıklığa kavuşturmak amacıyla düşünebiliriz. Satranç oynamayabilme eğilimi, makine öğrenimi elde etmek için kullanılabilir. Ancak, program iyi bir hareket bulabilmek uğruna oyunu oynarken, aramayı kullanır.

3.13. Yapay Sinir Ağları

Sinir ağı, beyni benzetme teşebbüsüdür. Sinir ağı kuramı, biyolojik nöronların birkaç temel özelliğinin çıkarılabilir ve benzetilebilir şekilde uygulanabileceği, böylelikle daha basit beyin yaratıldığı düşüncesi çevresinde döner. Bilinmesi gereken ilk şey, yapay sinir ağının modüllerinin beynin hesaplama kapasitesini baştan yaratma girişiminde bulunduğuudur. Bununla beraber, mutlaka bilinmesi lazım olan ikinci şey, kimse gerçek bir beyin kadar karmaşık olan yapıyı benzetebildiğini söyleyemez. İnsan beyninin tahminen on ve yüz milyar nörona sahip olduğu düşünülürken, karakteristik bir yapay sinir ağının (YSA) 1000'den daha çok yapay nöron bulundurması mümkün değildir.

Problemin ağa gösterimi çok önemli bir etkidir. YSA sadece sayısal bilgilerle çalışır ve problemin sayısal değerlere çevrilmesi gerekmektedir. Bu da kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulmamış olması problemin çözümünü engelleyebilir (Tütüncü, 2009).

İlk önce, gerçek sinir ağlarının işlevlerinin ne şekilde yapıldığına bakalım. Bağlantı gücü, nöral ağ araştırmalarının bir ihtimal en önemli kavramıdır. Sinir bilimi, beyindeki gerçek bilgi sahipleridir ve bizlere bir nöronun ona bağlı olan nöronları ne kadar güçlü şekilde etkilediğine dair güvenilir deliller sunar. Bir görevin öğrenilip tekrarlanması, yeni ya da sabit bir uyarıcıyla karşı karşıya kalmasıyla birlikte; beynin iletişim gücünün değişmesine ve bazı temas halindeki irtibatların güçlü duruma getirilip yenilerinin meydana getirilmesine, diğer bağlantıların zayıflatılmasına veya bazı durumlarda ortadan kalkmasına sebep olabilir.

Sinirsel bağlantının ikinci ana ögesi, kısıtlama ve uyarma ayırımıdır. İnsan beyninde, nöronlar kısıtlayıcı ya da uyarıcıdır. Yani etkinleştirme, birbirine bağlı nöronları ateşleme tahminlerini arttırdığı veya hızı azalttığı anlamındadır. Üretilen engel olma veya uyarma miktarı bağlantı kuvvetine bağlıdır. Daha güçlü olan bir bağlantı fazla uyarma ya da engelleme anlamındadır, daha zayıf konumdaki bağlantı ise az anlamı taşır.

Nöronun cevabında üçüncü önemli bileşen, transfer fonksiyonudur. Transfer işlevi, bir nöronun başlatılma hızının aldığı girdiye bakarak ne şekilde değiştiğini teknik ayrıntıya girmeden açıklar. Örneğin, hassas olan bir nöron az bir girdi ile başlatılabilir. Nöronun bir başlangıç noktası olabilir ve nadiren başlangıç noktasının altında veya üstünde başlayabilir.

Bir nöronun, başlama biçimi çan eğrisi stili olabilir ve başlatılma hızını maksimuma çıkarıp, daha sonra çok fazla uyarıldığında azaltılır ya da dengelenir.

Nöron, girdilerini toplar, ortalar ya da tamamen karmaşıktır. Aktarım işlevi, bu davranışların matematiksel şekilde simgelenip gösterimine denir. Transfer fonksiyonunu yalın toplama makineleri şeklinde düşünülebilir ve sinir ağına göre iyi bir anlayış geliştirmek için dikkate alınmalıdır

Üç kavrama da sahip: Transfer Fonksiyonu, Bağlantı Gücü ve Uyarma / Engel Olma. Artık yapay sinir ağlarının inşa edilmesine bunlarla bakabiliriz. Teorik olarak, genellikle 'düğüm' olarak adlandırılan yapay nöron, biyolojik olanın önemli öğelerini tutar. Düğümler birbirine bağlanır ve bağlantının kuvvetine maksimum engelleme için -1, maksimum uyarma için +1 değeri girilir. İkisi arasında bulunan değerler kabul edilebilir. Yüksek olan büyüklükler bağlantının daha kuvvetli olduğunu gösterir. İster bir gerçek mikroçipte ister bilgisayar benzetiminde yapay nöronlardaki transfer işlemi tipik olarak düğümlerin tasarımına yerleştirilmiştir.

Organizasyonlar, biyolojik ve yapay sinir ağları arasındaki en önemli farktır. Çok fazla yapay sinir ağı çeşidi bulunurken, birçoğu aynı temel yapıya uygun olarak düzenlenmiştir. Üç bileşeni vardır: girdi düğümü, bir ya da birden fazla 'gizli' düğüm katmanı ve çıktı düğümü.

Giriş düğümleri, duyu organlarına benzer ve bilgileri alır. Verilerin ilk alındığı yerdir. Bilgi, dizi stok değeri biçiminde ya da sayısallaştırılmış bir resim veya sayısal olarak ifade edilebilen başka bir formdadır. Her bir düğüme bir sayı verilir ve bilgileri aktivasyon değerleri olarak sağlar. Yüksek olan sayılar daha büyük aktivasyonları temsil eder.

Yapay nöronlar, biyolojik nöronların yaptığı gibi sıklıkla başlatılarak aktivasyon seviyelerini iletmek yerine, bu aktivasyon değerini bağlı düğümlere geçirerek etkinleştirmeyi gösterir.

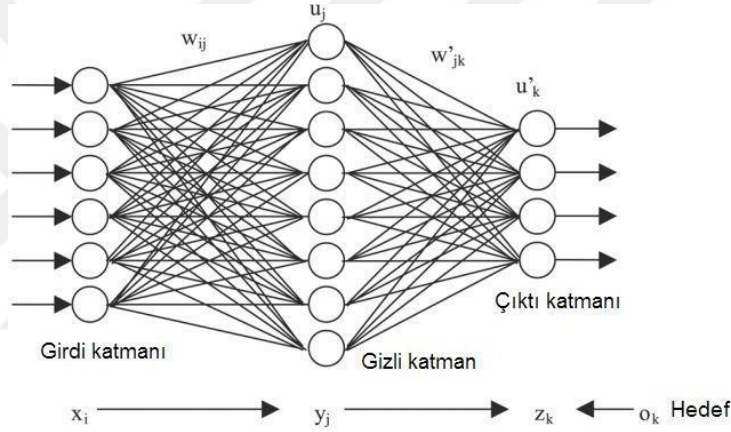
Alınan ilk etkinleşmeden sonra, veriler ağdan geçirilir. Engelleme / uyarma koşulları, aktarım fonksiyonları, bağlantı güçleri etkinleştirme değerinin ne kadarlık kısmının bir sonraki düğüme aktarılmış olduğunu belirler. Her düğüm, aldığı etkinleştirme değerlerini toplayarak kendisinin etkinleştirme değerine ulaşır ve bunu ağdaki düğümlere aktarır. Böylelikle etkinleştirme, giriş düğümlerinden gizli katmanlara kadar aktif olana kadar akar. Eğer ağ uygun biçimde oluşturulmuşsa, girdi çıktığı anlamlı bir şekilde yansıtılmalıdır.

Örneğin, cinsiyet tanıma ağı, giriş düğümlerinde kadın ya da erkek resmiyle gösterilebilir ve resim bir kadını simgeliyorsa çıkış düğümünü 1,0 veya bir erkek ise 0,0 olarak ayarlamalıdır. Böylelikle, ağıdaki bilgiyi dışarıya aktarır.

3.13.1. Yapay zeka nasıl öğrenir?

Bağlantı kuvvetlerinin, nöral ağ yapılarındaki veri depolarıdır. Sinir ağlarında, öğrenmenin önceliği bağlantı kuvvetlerini ayarlama sürecidir. Geri Yayılma, bugüne kadar tanımlanan tipteki sinir ağlarından en popüler olan öğrenme şeklidir. Başlamanın sağlanması için ağ başlatılır ve tüm bağlantı gücü gelişigüzel ayarlanarak ağ boş sayfa olarak durur.

Ağa sonradan bazı veriler sunulur, mesela daha önce ismi geçen "cinsiyet tanımlama" tasarlanıyor ve giriş düğümleri fotoğrafın dijitalleştirilmiş olan versiyonunu kullanıyor.



Şekil 3.3. Yapay sinir ağları

Kaynak: <https://bilimfili.com/dunyayi-degistirmekte-olan-yapay-sinir-aglari-nedir> [10]

Bağlantı kuvvetleri herhangi değerlerden başka bir şeye ayarlanmamış olsa bile aktivasyon bağlantı aracılığıyla akar ve çıkış düğümü, aktivasyon seviyesi olarak kaydedilir. Yanıtlar ilk başta rastgele şekilde olacaktır, çünkü ağ henüz eğitilmemiştir. Bu noktada geri yayılma aktif konuma gelir. Ağın verdiği cevap ve doğru olan cevap kullanılan resme bakarak karşılaştırılır. Daha sonra, çıkış düğümünden geriye doğru gidildiğinde bir dahaki sefere bağlantı gücü, resmin vereceği cevabın istenilen cevaba en uygun olacağı biçimde oluşturulur.

Tüm bu süreç: giriş, işleme, çıktının doğru yanıt ile kıyaslanması ve ilişki kuvvetlerinin ayarlanması; 'yineleme' ya da 'geri yayılma döngüsü' olarak tarif edilir. Ağa sonra başka resim sunulur ve cevap doğru yanıtla karşılaştırılır, gerekirse ilişki kuvvetleri ayarlanır. Yapılan bu iş çoğu zaman binlerce yineleme gerektirir. Bunun sonucunda, ağ kadın ve erkekleri tarif etmede oldukça yetkin konuma gelir. Ek olarak, ağın erkekleri kadınlardan ayırt etmeyi öğrenememesi ve her resmin yanıtını ezberleme riski bulunur. Bunu test etmek amacıyla, kullanılan veriler (ya da resimler) iki gruba ayrılmalıdır: transfer ve eğitim seti. Öğrenme tamamlandıktan sonra transfer seti kullanılır ve geri yayılma döngüleri esnasında ise eğitim seti kullanılır. Şayet ki ağ, eğitim setindeki gibi yeni transfer bildirenleri üzerinde de performans sağlıyorsa, öğrenmenin tamamlandığını anlayabiliriz.

Birçok geri yayılım modelleri delta öğrenme kuralını gerektirir. Bu sayede çıktı tabakasındaki hata miktarını ağırlıklar vasıtasıyla giriş tabakasına doğru geriye yayarak yeni çıktıların oluşması için ağırlıkların güncellenmesi sağlanır. Bu işlem daha önceden belirlenen kabul edilebilir hata değerine indirgenene kadar devam eder. YSA mimarisinde gizli katman yok ise her bir iterasyonda hata değerinin düşmesi ve genel minimum hata değerine ulaşması kesin bir işlemdir. Çünkü hata yüzeyi parabolik bir dağılım gösterir. Ancak, YSA mimarisinde gizli katman ya da katmanlar varsa hata yüzeyi parabolik olmayacağı için ağırlıkların ayarlanması sırasında yerel minimumlara takılabilir (Doğan E. , 2008).

3.14. Başarılar ve Başarısızlıklar

Esasen, sinir ağları birçok alanda artan bir başarıya ulaşmaktadır ve önemli boyutta başarılı AI için zorluklar çıkaran alanlarda bulunma eğilimindedir. Sinir ağları, tasarımlarından dolayı desen işlemcilerdir. Karmaşık verilerde bile önemli hususları ve eğilimleri tanımlayabilirler. İlave olarak, simgesel AI sistemlerine göre bulanık veya statik dolu resimler aşılmaz bir zorluktur. Yine de bu gibi kusursuz olmayan verilerle çalışabilirler. Ayırt edici tasvirler, petrol çıkarımı, yeni madencilik ve sinir ağlarının el yazısını okuması amacıyla potansiyel alanları bulmasına, borsa tahminleri yapmasına imkan sağlar.

Sinir ađları bizim bulunduđumuz durumları iyi grr ve mcadele ettiđimiz olaylarla mcadele eder. Symbolic AI, mantık teoremleri reten, ustalık noktasında satran oynayan ve karmařık matematiksel iřlevleri hesaplayan makineler retmede iyi bir dzeydedir. Ancak Symbolic AI, grltl ya da kusuru bulunan verilerle uđrařmak, grsel bir sahneyi iřlemek ve deđiřime ayak uydurmak gibi durumlarda sıkıntılar yařamakta. Sinir ađlarında ise tam tersi durumdadır gleri grmeyle alakalı: hataya dayanıklı, karmařık, paralel iřlemede yatar. Zayıflıkları ise resmi akıl yrtme ve kural takibindedir.

Eleřtirmenler, sinir ađının kırılmaz ve farklı kuralları bulunan mantık trevlerini ğrenememesinin sebebini sinir ađlarının, zihnin alıřma řeklinin bir aıklaması bulunmadıđının kanıtlanmış olmasına bađlar. Nral ađa savunuculuk edenler, sorunun nemli blmnn soyut kural takip becerisinin bulunduđu yapay sinir ađlarının, uyguladıđından daha ok dđme ihtiya duyduđuna karřılıdır. Daha byk ađların retilmesi amacıyla eřitli giriřimlerde bulunulmasına rađmen, dđmler eklendike hesaplama yk artar ve nemli ađlar zor hale gelir. Farklı bir eleřtirmen grubu, sinir ađlarının sıradan olduđunu ne sryor; insan beyni iřlevinin dođru modelleri olarak kabul edilemeyeceđini dřnyorlar.

Yapay sinir ađları nron gibi zellikler ierir. Bunlar: inhibisyon / uyarma, bađlantı gleri vs. Yapay sinir ađları, beynin iřleyiři iin mhim sayılabilecek birok unsuru dikkate almaz. rneđin sinir sistemi eřitli nrotransmitter kullanır ve yapay sinir ađları bu gibi farklılıklara dikkat etmez. Aynı olmayan nronlar farklı enerji kaynakları, iletim hızları ve uzamsal konumlar bulundurur. Fetal geliřim anında ok fazla organizasyon bulunur ve beyinler karıřık, randomize bađlantı kuvveti olarak bařlamaz. Bunlardan biri ya da tamamı beynin mekanizması bakımından ođunlukla gerekli olarak grlebilir ve yapay sinir ađı modellerine eklenmeden modellerin basitleřtirilmesi mmkndr.

Geri yayılma řekli ađlara ynelik biimde ortaya ıkan temel itirazlardandır. Sinir ađlarının biliř modeli olarak bařarılı sayılabilmesi iin biyolojik ya da psikolojik olarak uygun bir ğrenme simlasyonu retmelilerdir. Esasen, 'Denetimsiz Nral Ađ' olarak bilinen yeni bir sinir ađı eřidi ile arařtırma uygulanmaktadır.

Dřnldđ kadar bulanık deđildir ve 20 yıldan daha uzun zamandan beri gz nnde olmadan sessizce alıřan bir yapay zeka yazılımı řekli olduđundan yapay zekanın bir alt kmesi olarak kabul edilir Bulanık mantık, operatrn elveriřli deneyimine dayanır.

Özellikle deneyimli operatör verisini yakalamak amacıyla kullanılan kural tabanlı yöntemdir. Bulanık mantık, karar verme süreci gerçekleştirdiğinden dolayı AI yazılım araçlarının üyesi olarak dahil edilebilir.

Bulanık mantık, 70'lerden sonra pratik bir uygulama olarak gösterilmiştir. Japonlar 70'lerden beri geleneksel şekilde bulanık mantık uygulamalarının üreticisi oldular. Bulanık mantık hisse senedi alım satım çalışmalarında, kameralarda ve çamaşır makinelerinde ortaya çıktı. Amerika Birleşik Devletleri son on yılda bulanık mantık kullanmaya başladı. "Bulanık mantık" teriminin olumsuz çağrışımından dolayı bize kullanımını anlatmakta başarılı olmazlar.

Bulanık mantık, hisse senedi alım satım vb. uygulamalarda gösterildiği gibi mühendislik dışı uygulamalarda da kullanılabilir. El yazısı tanıma sistemlerinde ve tıbbi tanı uygulamalarında da kullanılmıştır. Bulanık bir mantık sistemi, giriş ve çıkışları bulunan sistemlere uygulanabilir.

Mühendislikte ve diğer bilim dallarında sistemler, kesinliği olan matematiksel modelleri kullanmak suretiyle modellenirler. Klasik kontrol teorisi, oluşturulan bu modeller yardımıyla iyi çözümler üretebilir. Fakat sistemin matematiksel modelinin çok karmaşık olduğu veya kesin bilinmediği durumlarda, klasik mantık ya hiç çözüm üretememekte yada istenen performansı sağlayamamaktadır (Özel, 2006).

Bulanık mantık sistemleri, çoklu giriş-çıkışa sahip olan ve doğrusal olmayan sistemlere uygundur. Aşırı olmayacak sayıda giriş ve çıkış yerleştirilebilir. Bulanık mantık, sistem sıradan yollarla kolay olmayan şekilde modellenemediğinde de iyi performans sergiler.

Bazı mühendisler, anlayış eksikliğinden dolayı bulanık mantığı kullanmak istemiyorlar. Bulanık mantığın, uzun zamandır matematiksel derslerde bulunmayanlar için korkutucu olmasına rağmen, anlaşılması zor değildir

İkili mantık 1 ya da 0'dır. Bulanık mantık ise 0 ile 1 arasındaki değerlerin sürekli olmasıdır.

Aynı zamanda %0 ve %100 olarak da düşünebiliriz. Örnek olarak: GENÇ değişkendir. 5 yaşın % 100 ü GENÇ, 18'in %50'si GENÇ ve 30'un %0 ı GENÇ durumundadır.

İkili dünyada 18'in altındakilerin hepsi %100 GENÇ ve 18'in üstündekilerin tamamı %0 GENÇ olur.

Bulanık mantık sisteminin tasarımı, tüm girişlere üyelik fonksiyonu ve çıkışlara ait üyelik verilmesiyle başlar. Üyelik fonksiyonlarına net bir çıktı değeri vermek amacıyla bazı kural uygulanır.

Bulanık mantıkta TEMPERATURE” girdi ve “FAN SPEED” çıktıdır. Girişlere üyelik işlevleri topluluğu oluşturulur. Üyelik işlevi, bulanık değişken kümelerinin grafiksel şekilde gösterilmesidir. Örneğin, üç bulanık set kullanılsın, SOĞUK, SICAK ve SICAK. Daha sonra soğuk-normal-sıcak grafikte gösterildiği gibi üç sıcaklık setinin her biri için bir üyelik fonksiyonu oluşturulur.

3.15. Bulanık Mantık Sistemlerinin Uygulanması

Uzay ve uzay araçlarının yükseklik kontrolüne bağlı olarak havacılık alanında kullanılır.

Otomotivde hız kontrolü, trafik kontrolü amacıyla kullanılmıştır.

Büyük şirketlerin işlerinde kişisel değerlendirme ve karar verme destek sistemlerinde kullanılır.

Kimya endüstrisinde kurutma, pH ve kimyasal damıtma işlemini kontrolde uygulanır. Yapay zekadaki farklı uygulamalarda ve doğal dil işlemede kullanılır.

Uzman sistemlerde olduğu şekilde modern kontrol sistemlerinde de yaygın biçimde kullanılır.

Bir kişinin daha hızlı şekilde nasıl karar vereceğini taklit ettiğinden dolayı sinir ağlarıyla birlikte kullanılır. Verilerin kümelenmesini ve kısmi gerçekler oluşturarak bulanık kümeleri anlamlı verilere dönüştürülerek gerçekleşir.

3.15.1. Yapay zekada bulanık mantığın dezavantajlar

Bulanık Mantık sistemlerinde dezavantajlar şöyledir:

Genellikle sistem yanlış veri ve girdilerle çalışır. Bu şekilde çalışan sistemlerin doğruluğu tehlikeye atılmış olunur.

Bir sorunu bulanık mantık kullanarak çözmek için, bulunan sistematik yaklaşım tek değildir. Sonuç olarak, sorun için birden fazla çözüm doğar ve karışıklığa neden olur.

Bu sistemler makine öğrenmesini ya da sinir ağlarını tanıyamaz

En büyük dezavantajı, bütünüyle insan bilgisine ve insan uzmanlığına bağımlıdırlar.

Sonuçlarda oluşan yanlışlıklardan dolayı, yaygın olarak kabul edilmezler.

Bulanık mantık kontrol sistemi kurallarının belirli zamanlarda güncellenmesi gerekir.

Sistemleri doğrulamak için fazla test gereklidir.



DÖRDÜNCÜ BÖLÜM

AĞIRLIKLIL HAREKETLİ ORTALAMA, ÜSTEL DÜZELTME VE YAPAY SİNİR AĞLARI YÖNTEMİ HESAPLAMASI

4. AĞIRLIKLIL HAREKETLİ ORTALAMA, ÜSTEL DÜZELTME VE YAPAY SİNİR AĞLARI YÖNTEMİ HESAPLAMASI

4.1. Ağırlıklı Hareketli Ortalama Yöntemi Hesaplaması

İstatistiksel tahmin yöntemlerinden; Ağırlıklı hareketli ortalama yöntemini kullanmayı tercih ettik. Bu yöntemin en belirgin özelliği, en yakın veriye en büyük ağırlığı vermesidir.

Talep yapılarında hareketli ortalama yönteminin basit kaldığı durumlarda ağırlıklı hareketli ortalama yöntemine başvurulur. Ve böylece hareketli ortalama da yaşanılacak sorunların önüne geçilir. Seçilecek değerler (n) ve ağırlıklı katsayılar (w) olarak rastgele seçilir.

Ağırlıklı hareketli ortalama formülü:

$$AHO_{(n)} = w_1 y_t + w_2 y_{t-1} + \dots + w_n y_{t-n+1} \quad (4.1)$$

n → seçilecek değer sayısı

t → satır sayısı

w → ağırlık kat sayısı

Verilen ağırlıklı hareketli ortalama formülünde, dörderli ağırlıklı ortalama kullanılacaktır. Örnek bir limandan ele alınan aylık elleçlenen toplam konteyner iş hacmi TEU sayıları, (Şekil 4.1.- 4.5.) mevcuttur. Veriler 2007 yılından 2019 yılına kadar Konteyner İşlem Hacmi (TEU) sütununda yer almaktadır. Tahmin hesabı yapılabilmesi için, hesaplamalara 2007 yılının Ocak, Şubat, Mart ve Nisan aylarının verilerini kullanarak, 2007 Mayıs ayının TEU sayılarını tahminleme ile başlanacaktır. Daha sonra diğer ayları da hesaplanacaktır. En son 2019 yılının ayları da hesaplanıp, tahminler ile konteyner iş hacmi TEU sayılarının arasında ne kadarlık bir fark çıkacağı gözlenip, tahmin sonucu elde edilecektir.

Ay	Konteyner İşlem Hacmi (TEU)
Ocak 07	107.000
Şubat 07	109.000
Mart 07	108.000
Nisan 07	107.000
Mayıs 07	110.000
Haziran 07	111.000
Temmuz 07	110.000
Ağustos 07	113.000
Eylül 07	108.000
Ekim 07	106.000
Kasım 07	105.000
Aralık 07	106.000
Ocak 08	110.000
Şubat 08	112.000
Mart 08	111.000
Nisan 08	115.000
Mayıs 08	114.000
Haziran 08	117.000
Temmuz 08	119.000
Ağustos 08	120.000
Eylül 08	117.000
Ekim 08	113.000
Kasım 08	111.000
Aralık 08	111.000
Ocak 09	108.000
Şubat 09	112.000
Mart 09	110.000
Nisan 09	114.000
Mayıs 09	112.000
Haziran 09	115.000
Temmuz 09	116.000
Ağustos 09	117.000
Eylül 09	113.000
Ekim 09	111.000
Kasım 09	112.000
Aralık 09	110.000

Şekil 4.1. Konteyner iş hacmi TEU1

Ay	Konteyner İşlem Hacmi (TEU)
Ocak 10	120.000
Şubat 10	122.000
Mart 10	123.000
Nisan 10	121.000
Mayıs 10	124.000
Haziran 10	126.000
Temmuz 10	128.000
Ağustos 10	130.000
Eylül 10	129.000
Ekim 10	135.000
Kasım 10	136.000
Aralık 10	136.000
Ocak 11	130.000
Şubat 11	134.000
Mart 11	136.000
Nisan 11	135.000
Mayıs 11	138.000
Haziran 11	140.000
Temmuz 11	142.000
Ağustos 11	146.000
Eylül 11	139.000
Ekim 11	134.000
Kasım 11	134.000
Aralık 11	132.000
Ocak 12	141.000
Şubat 12	144.000
Mart 12	146.000
Nisan 12	148.000
Mayıs 12	146.000
Haziran 12	151.000
Temmuz 12	153.000
Ağustos 12	156.000
Eylül 12	150.000
Ekim 12	150.000
Kasım 12	140.000
Aralık 12	135.000

Şekil 4.4. Konteyner iş hacmi TEU4

Ay	Konteyner İşlem Hacmi (TEU)
Ocak 13	153.000
Şubat 13	155.000
Mart 13	154.000
Nisan 13	156.000
Mayıs 13	155.000
Haziran 13	158.000
Temmuz 13	159.000
Ağustos 13	162.000
Eylül 13	160.000
Ekim 13	153.000
Kasım 13	152.000
Aralık 13	163.000
Ocak 14	159.000
Şubat 14	162.000
Mart 14	164.000
Nisan 14	163.000
Mayıs 14	168.000
Haziran 14	171.000
Temmuz 14	173.000
Ağustos 14	175.000
Eylül 14	168.000
Ekim 14	166.000
Kasım 14	165.000
Aralık 14	166.000
Ocak 15	158.000
Şubat 15	169.000
Mart 15	163.000
Nisan 15	162.000
Mayıs 15	166.000
Haziran 15	168.000
Temmuz 15	169.000
Ağustos 15	168.000
Eylül 15	162.000
Ekim 15	159.000
Kasım 15	161.000
Aralık 15	165.000

Şekil 4.3. Konteyner iş hacmi TEU3

Ay	Konteyner İşlem Hacmi (TEU)
Ocak 16	157.000
Şubat 16	159.000
Mart 16	160.000
Nisan 16	162.000
Mayıs 16	163.000
Haziran 16	165.000
Temmuz 16	168.000
Ağustos 16	170.000
Eylül 16	161.000
Ekim 16	162.000
Kasım 16	160.000
Aralık 16	163.000
Ocak 17	168.000
Şubat 17	170.000
Mart 17	174.000
Nisan 17	173.000
Mayıs 17	175.000
Haziran 17	179.000
Temmuz 17	180.000
Ağustos 17	183.000
Eylül 17	175.000
Ekim 17	171.000
Kasım 17	170.000
Aralık 17	172.000

Şekil 4.4. Konteyner iş hacmi TEU4

Ay	Konteyner İşlem Hacmi (TEU)
Ocak 18	177.000
Şubat 18	179.000
Mart 18	178.000
Nisan 18	183.000
Mayıs 18	187.000
Haziran 18	189.000
Temmuz 18	193.000
Ağustos 18	188.000
Eylül 18	187.000
Ekim 18	188.000
Kasım 18	186.000
Aralık 18	185.000
Ocak 19	198.000
Şubat 19	199.000
Mart 19	197.000
Nisan 19	201.000
Mayıs 19	209.000
Haziran 19	203.000
Temmuz 19	218.000
Ağustos 19	218.000
Eylül 19	192.000
Ekim 19	189.000
Kasım 19	188.000
Aralık 19	188.000

Şekil 4.5. Konteyner iş hacmi TEU5

Yıl (t)	Konteyner İş Hacmi TEU (Y_t)	Tahmin ()
Ocak	107.000	
Şubat	109.000	
Mart	108.000	
Nisan	107.000	
Mayıs	110.000	$AHO_{(4)} = F_5 = w_1 y_4 + w_2 y_3 + w_3 y_2 + w_4 y_1$
Haziran	111.000	$AHO_{(4)} = F_6 = w_1 y_5 + w_2 y_4 + w_3 y_3 + w_4 y_2$
Temmuz	110.000	$AHO_{(4)} = F_7 = w_1 y_6 + w_2 y_5 + w_3 y_4 + w_4 y_3$
Ağustos	113.000	$AHO_{(4)} = F_8 = w_1 y_7 + w_2 y_6 + w_3 y_5 + w_4 y_4$
Eylül	108.000	$AHO_{(4)} = F_9 = w_1 y_8 + w_2 y_7 + w_3 y_6 + w_4 y_5$
Ekim	106.000	$AHO_{(4)} = F_{10} = w_1 y_9 + w_2 y_8 + w_3 y_7 + w_4 y_6$
Kasım	105.000	$AHO_{(4)} = F_{11} = w_1 y_{20} + w_2 y_9 + w_3 y_8 + w_4 y_7$
Aralık	106.000	$AHO_{(4)} = F_{12} = w_1 y_{11} + w_2 y_{10} + w_3 y_9 + w_4 y_8$

Şekil 4.6. Tahmin işlemleri

2007 Mayıs ayı için tahmin hesaplaması yapılırken, 2007 yılının Ocak, Şubat, Mart ve Nisan aylarının elleçlenen toplam konteyner TEU sayılarını baz aldık. Mart ayının en yakın olan veri Nisan ayı olduğu için, Nisan ayına en büyük katsayıyı verdik. Veriye en uzak değer Ocak olduğundan, Ocak ayına en küçük katsayıyı verdik. 4 erli ağırlıklı hareketli ortalama kullanılacağından dolayı, Nisan ayına 0,4, Mart ayına 0,3, Şubat ayına 0,2 ve Ocak ayına 0,1 katsayılarını verdik. 2007 ve 2019 yılları arasında yer alan bütün aylar için aynı hesaplanma yöntemi takip ettik.

Ay	Konteyner İşlem Hacmi (TEU)	AHO Tahmin Sonuçları
Ocak 07	107.000	
Şubat 07	109.000	
Mart 07	108.000	
Nisan 07	107.000	
Mayıs 07	110.000	107.700
Haziran 07	111.000	108.600
Temmuz 07	110.000	109.600
Ağustos 07	113.000	110.000
Eylül 07	108.000	111.400
Ekim 07	106.000	110.200
Kasım 07	105.000	108.400
Aralık 07	106.000	106.700
Ocak 08	110.000	105.900
Şubat 08	112.000	107.400
Mart 08	111.000	109.500
Nisan 08	115.000	110.600
Mayıs 08	114.000	112.700
Haziran 08	117.000	113.500
Temmuz 08	119.000	115.100
Ağustos 08	120.000	117.000
Eylül 08	117.000	118.500
Ekim 08	113.000	118.300
Kasım 08	111.000	116.200
Aralık 08	111.000	113.700
Ocak 09	108.000	112.000
Şubat 09	112.000	110.000
Mart 09	110.000	110.500
Nisan 09	114.000	110.300
Mayıs 09	112.000	111.800
Haziran 09	115.000	112.200
Temmuz 09	116.000	113.400
Ağustos 09	117.000	114.700
Eylül 09	113.000	115.800
Ekim 09	111.000	115.000
Kasım 09	112.000	113.300
Aralık 09	110.000	112.400

Şekil 4.7. AHO tahmin sonuçları 1

Ocak 10	120.000	111.100
Şubat 10	122.000	114.500
Mart 10	123.000	118.000
Nisan 10	121.000	120.800
Mayıs 10	124.000	121.700
Haziran 10	126.000	122.700
Temmuz 10	128.000	124.100
Ağustos 10	130.000	125.900
Eylül 10	129.000	128.000
Ekim 10	135.000	128.800
Kasım 10	136.000	131.500
Aralık 10	136.000	133.700
Ocak 11	130.000	135.100
Şubat 11	134.000	133.500
Mart 11	136.000	133.400
Nisan 11	135.000	134.200
Mayıs 11	138.000	134.600
Haziran 11	140.000	136.300
Temmuz 11	142.000	138.000
Ağustos 11	146.000	139.900
Eylül 11	139.000	142.800
Ekim 11	134.000	141.800
Kasım 11	134.000	138.700
Aralık 11	132.000	136.200
Ocak 12	141.000	133.700
Şubat 12	144.000	136.200
Mart 12	146.000	139.700
Nisan 12	148.000	143.000
Mayıs 12	146.000	145.900
Haziran 12	151.000	146.400
Temmuz 12	153.000	148.400
Ağustos 12	156.000	150.500
Eylül 12	150.000	153.100
Ekim 12	150.000	152.500
Kasım 12	140.000	151.500
Aralık 12	135.000	146.600

Şekil 4.8. AHO tahmin sonuçları 2

Ocak 13	153.000	141.000
Şubat 13	155.000	144.700
Mart 13	154.000	148.900
Nisan 13	156.000	152.200
Mayıs 13	155.000	154.900
Haziran 13	158.000	155.100
Temmuz 13	159.000	156.300
Ağustos 13	162.000	157.600
Eylül 13	160.000	159.600
Ekim 13	153.000	160.200
Kasım 13	152.000	157.500
Aralık 13	163.000	154.900
Ocak 14	159.000	157.400
Şubat 14	162.000	158.200
Mart 14	164.000	160.300
Nisan 14	163.000	162.300
Mayıs 14	168.000	162.700
Haziran 14	171.000	165.100
Temmuz 14	173.000	167.800
Ağustos 14	175.000	170.400
Eylül 14	168.000	172.900
Ekim 14	166.000	171.400
Kasım 14	165.000	169.100
Aralık 14	166.000	166.900
Ocak 15	158.000	165.900
Şubat 15	169.000	162.600
Mart 15	163.000	164.700
Nisan 15	162.000	164.100
Mayıs 15	166.000	163.300
Haziran 15	168.000	164.500
Temmuz 15	169.000	165.700
Ağustos 15	168.000	167.400
Eylül 15	162.000	168.100
Ekim 15	159.000	165.800
Kasım 15	161.000	162.700
Aralık 15	165.000	161.300

Şekil 4.9. AHO tahmin sonuçları 3

Ocak 16	157.000	162.300
Şubat 16	159.000	160.400
Mart 16	160.000	159.800
Nisan 16	162.000	159.600
Mayıs 16	163.000	160.300
Haziran 16	165.000	161.700
Temmuz 16	168.000	163.300
Ağustos 16	170.000	165.500
Eylül 16	161.000	167.700
Ekim 16	162.000	165.500
Kasım 16	160.000	163.900
Aralık 16	163.000	161.800
Ocak 17	168.000	161.700
Şubat 17	170.000	164.300
Mart 17	174.000	167.000
Nisan 17	173.000	170.500
Mayıs 17	175.000	172.200
Haziran 17	179.000	173.700
Temmuz 17	180.000	176.100
Ağustos 17	183.000	178.000
Eylül 17	175.000	180.500
Ekim 17	171.000	178.800
Kasım 17	170.000	175.500
Aralık 17	172.000	172.600

Şekil 4.8. AHO tahmin sonuçları 2

Ocak 18	177.000	171.500
Şubat 18	179.000	173.500
Mart 18	178.000	176.100
Nisan 18	183.000	177.500
Mayıs 18	187.000	180.100
Haziran 18	189.000	183.200
Temmuz 18	193.000	186.100
Ağustos 18	188.000	189.600
Eylül 18	187.000	189.600
Ekim 18	188.000	188.700
Kasım 18	186.000	188.200
Aralık 18	185.000	187.000
Ocak 19	198.000	186.100
Şubat 19	199.000	190.700
Mart 19	197.000	194.600
Nisan 19	201.000	196.600
Mayıs 19	209.000	199.100
Haziran 19	203.000	203.200
Temmuz 19	218.000	203.800
Ağustos 19	218.000	210.000
Eylül 19	192.000	214.100
Ekim 19	189.000	206.100
Kasım 19	188.000	198.600
Aralık 19	188.000	192.100

Şekil 4.11. AHO tahmin sonuçları 5

Ağırlıklı hareketli ortalama yönteminde, tahmin sırasında yapılan işlemlerde en büyük katsayının en yakın veriye verilmesinin nedeni; gelecek ay elleçlenen konteyner TEU sayısının, son aydan daha fazla olacağına kabul edilmesidir. Ağırlıklı hareketli ortalama formülünde tahmin yapılacak ay için bir önceki 4 ayın verileri ile ağırlık katsayıları çarpılarak tahminler hesaplanır. Örnek bir limandan alınan 2007 ve 2019 yılları arasında yer alan bütün aylar için hesaplama yapıldı.

Formülde yer alan ağırlıklı katsayı (w) ve hesaplama için devreye giren yıllarda bulunan verilerin çarpma işlemleri tamamlanmıştır. Çıkan değerlerin toplanması sonucunda ağırlıklı hareketli ortalama yöntemi ile hesaplanan ay bazlı tahmin sonuçları elde edildi.

Hesaplama sonucunda elde edilen değerler tahmin sütununun altında gösterilmiştir. Tahmin sütununda 2007 ve 2019 yılları arasında yer alan ayların tahmin konteyner iş hacmi TEU verileri yer almaktadır. Dörderli ağırlıklı ortalama kullandığımız için 2007 yılında bulunan Ocak, Şubat, Mart ve Nisan ayları verileri için tahmin hesaplaması yapılmadı. Ocak, Şubat, Mart ve Nisan ayları verileri, Mayıs ayını hesaplamak için kullanılmıştır.

4.2. Yapay Sinir Ağları Yöntemi ile Hesaplama

Yapay zeka yöntemlerinden, yapay sinir ağları tahmin yöntemini kullanarak ay bazında, konteyner iş hacmi TEU hesaplayacağız. Örnek durumlar için bilgiler toplayan yapay sinir ağları yöntemi, gruplama yaparak, öğretilen bilgiler ile diğer örnekleri kıyaslamaya yarayan bir yöntemdir. Yapay sinir ağları yöntemini tercih etmemizdeki en önemli özelliklerden biri, giriş ve çıkış bilgilerini öğrenme sırasında sisteme verilerek belli kurallar koyulabilmesidir. Algoritma ve bilgilerinde kesin tanısı yoktur. Aksine doğruluk için deneyimlerden yararlanır. Ağa yayılan bellek vardır. Bu sebeple hata toleransı mevcuttur. Daha önce istatistiksel tahmin yöntemlerinden, ağırlıklı hareketli ortalama yöntemi ile hesaplama yaparken kullanılan, konteyner iş hacmi TEU bilgilerini bu yöntemde de kullanacağız. Fakat bu yöntem birden fazla girdi gerektirdiği için, girdi olarak rakip liman sayısı, acente sayısı ve terminal sayısı gibi örnek bir limandan alınan bilgileri de kullanılacaktır. Çünkü YSA'da tek bir girdi ile çıktı olmadan bir hesaplama yapılamamaktadır. Daha doğrusu yapılan hesaplama ve grafiklerde veri azlığından kaynaklanan hatalar ve hesaplama sonuçlarında NAN değerleri ile karşılaşabilmektedir.

Yapay sinir ağları yöntemi ile tahminleme yapmak için MATLAB programı kullanılacaktır. MATLAB programı; birden fazla değerler dizisine sahip, sayısal olarak ele alınan hesaplamaları yapabilen bir programdır. MATLAB, matris laboratuvarıdır. İlk olarak bu program matris programları için tasarlanmıştır. Daha sonra ise veri hesaplamaları, derin öğrenme ve makine öğrenmesi işlemlerinde kullanılmaya başlanmıştır.

Örnek bir limandan elde edilen veriler (Şekil 4.12.- 4.16.) mevcuttur.

Ay	Konteyner İşlem Hacmi (TEU)	Rakip Liman Sayısı	Acente Sayısı	Terminal Sayısı
Ocak 07	107.000	8	28	1
Şubat 07	109.000	8	28	1
Mart 07	108.000	8	28	1
Nisan 07	107.000	8	28	1
Mayıs 07	110.000	8	28	1
Haziran 07	111.000	8	28	1
Temmuz 07	110.000	8	28	1
Ağustos 07	113.000	8	28	1
Eylül 07	108.000	8	28	1
Ekim 07	106.000	8	28	1
Kasım 07	105.000	8	28	1
Aralık 07	106.000	8	28	1
Ocak 08	110.000	8	33	1
Şubat 08	112.000	8	33	1
Mart 08	111.000	8	33	1
Nisan 08	115.000	8	33	1
Mayıs 08	114.000	8	33	1
Haziran 08	117.000	8	33	1
Temmuz 08	119.000	8	33	1
Ağustos 08	120.000	8	33	1
Eylül 08	117.000	8	33	1
Ekim 08	113.000	8	33	1
Kasım 08	111.000	8	33	1
Aralık 08	111.000	8	33	1
Ocak 09	108.000	9	31	1
Şubat 09	112.000	9	31	1
Mart 09	110.000	9	31	1
Nisan 09	114.000	9	31	1
Mayıs 09	112.000	9	31	1
Haziran 09	115.000	9	31	1
Temmuz 09	116.000	9	31	1
Ağustos 09	117.000	9	31	1
Eylül 09	113.000	9	31	1
Ekim 09	111.000	9	31	1
Kasım 09	112.000	9	31	1
Aralık 09	110.000	9	31	1

Şekil 4.12. Örnek liman konteyner iş hacmi TEU1

Ocak 10	120.000	10	35	2
Şubat 10	122.000	10	35	2
Mart 10	123.000	10	35	2
Nisan 10	121.000	10	35	2
Mayıs 10	124.000	10	35	2
Haziran 10	126.000	10	35	2
Temmuz 10	128.000	10	35	2
Ağustos 10	130.000	10	35	2
Eylül 10	129.000	10	35	2
Ekim 10	135.000	10	35	2
Kasım 10	136.000	10	35	2
Aralık 10	136.000	10	35	2
Ocak 11	130.000	10	35	2
Şubat 11	134.000	10	35	2
Mart 11	136.000	10	35	2
Nisan 11	135.000	10	35	2
Mayıs 11	138.000	10	35	2
Haziran 11	140.000	10	35	2
Temmuz 11	142.000	10	35	2
Ağustos 11	146.000	10	35	2
Eylül 11	139.000	10	35	2
Ekim 11	134.000	10	35	2
Kasım 11	134.000	10	35	2
Aralık 11	132.000	10	35	2
Ocak 12	141.000	10	39	2
Şubat 12	144.000	10	39	2
Mart 12	146.000	10	39	2
Nisan 12	148.000	10	39	2
Mayıs 12	146.000	10	39	2
Haziran 12	151.000	10	39	2
Temmuz 12	153.000	10	39	2
Ağustos 12	156.000	10	39	2
Eylül 12	150.000	10	39	2
Ekim 12	150.000	10	39	2
Kasım 12	140.000	10	39	2
Aralık 12	135.000	10	39	2

Şekil 4.13. Örnek liman konteyner iş hacmi

Ocak 13	153.000	11	42	4
Şubat 13	155.000	11	42	4
Mart 13	154.000	11	42	4
Nisan 13	156.000	11	42	4
Mayıs 13	155.000	11	42	4
Haziran 13	158.000	11	42	4
Temmuz 13	159.000	11	42	4
Ağustos 13	162.000	11	42	4
Eylül 13	160.000	11	42	4
Ekim 13	153.000	11	42	4
Kasım 13	152.000	11	42	4
Aralık 13	163.000	11	42	4
Ocak 14	159.000	12	45	4
Şubat 14	162.000	12	45	4
Mart 14	164.000	12	45	4
Nisan 14	163.000	12	45	4
Mayıs 14	168.000	12	45	4
Haziran 14	171.000	12	45	4
Temmuz 14	173.000	12	45	4
Ağustos 14	175.000	12	45	4
Eylül 14	168.000	12	45	4
Ekim 14	166.000	12	45	4
Kasım 14	165.000	12	45	4
Aralık 14	166.000	12	45	4
Ocak 15	158.000	12	45	4
Şubat 15	169.000	12	45	4
Mart 15	163.000	12	45	4
Nisan 15	162.000	12	45	4
Mayıs 15	166.000	12	45	4
Haziran 15	168.000	12	45	4
Temmuz 15	169.000	12	45	4
Ağustos 15	168.000	12	45	4
Eylül 15	162.000	12	45	4
Ekim 15	159.000	12	45	4
Kasım 15	161.000	12	45	4
Aralık 15	165.000	12	45	4

Şekil 4.14. Örnek liman konteyner iş hacmi TEU3

Ocak 16	157.000	14	47	5
Şubat 16	159.000	14	47	5
Mart 16	160.000	14	47	5
Nisan 16	162.000	14	47	5
Mayıs 16	163.000	14	47	5
Haziran 16	165.000	14	47	5
Temmuz 16	168.000	14	47	5
Ağustos 16	170.000	14	47	5
Eylül 16	161.000	14	47	5
Ekim 16	162.000	14	47	5
Kasım 16	160.000	14	47	5
Aralık 16	163.000	14	47	5
Ocak 17	168.000	14	48	6
Şubat 17	170.000	14	48	6
Mart 17	174.000	14	48	6
Nisan 17	173.000	14	48	6
Mayıs 17	175.000	14	48	6
Haziran 17	179.000	14	48	6
Temmuz 17	180.000	14	48	6
Ağustos 17	183.000	14	48	6
Eylül 17	175.000	14	48	6
Ekim 17	171.000	14	48	6
Kasım 17	170.000	14	48	6
Aralık 17	172.000	14	48	6
Ocak 18	177.000	15	55	6
Şubat 18	179.000	15	55	6
Mart 18	178.000	15	55	6
Nisan 18	183.000	15	55	6
Mayıs 18	187.000	15	55	6
Haziran 18	189.000	15	55	6
Temmuz 18	193.000	15	55	6
Ağustos 18	188.000	15	55	6
Eylül 18	187.000	15	55	6
Ekim 18	188.000	15	55	6
Kasım 18	186.000	15	55	6
Aralık 18	185.000	15	55	6

Şekil 4.13. Örnek liman konteyner iş hacmi

Ocak 19	198.000	15	57	7
Şubat 19	199.000	15	57	7
Mart 19	197.000	15	57	7
Nisan 19	201.000	15	57	7
Mayıs 19	209.000	15	57	7
Haziran 19	203.000	15	57	7
Temmuz 19	218.000	15	57	7
Ağustos 19	218.000	15	57	7
Eylül 19	192.000	15	57	7
Ekim 19	189.000	15	57	7
Kasım 19	188.000	15	57	7
Aralık 19	188.000	15	57	7

Şekil 4.16. Örnek liman konteyner iş hacmi TEU5

MATLAB programının verilerimizi algılayabilmesi için, verilerimizin normalizasyon işlemleri yapılması gerekmektedir. Veriler arası karşılaştırmalar yapılabilmesini sağlayan verilerin oluşturulmasına normalizasyon denir. Normalizasyon yöntemlerinden, Min-Max Normalizasyon yöntemini kullanıldı. Min max normalizasyon yöntemi; doğrusal olarak verileri normalize etmeye yarayan bir yöntemdir. Maksimum değeri verinin en büyük halidir. Minimum değeri ise verinin en küçük halidir. Birbirinden farklı verileri, kıyaslamaya yarayan bir yöntemdir. En çok bilgisayar programlamada kullanılır. Normalizasyonun doğruluğunun anlaşılması için, veriler içinde en az bir adet 0 ve 1 olması gerekir. Diğer veriler 0 ve 1 değerlerinin arasında yer alır. Normalizasyon formülü:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4.2)$$

- X → Girdi verisi
- X_{min} → Verileri içerisinde mevcut olan en küçük değer
- X_{max} → Verileri içerisinde mevcut olan en büyük değer
- X' → Normalize değeri


Konteyner iş hacmi TEU, rakip liman sayısı, acente sayısı ve terminal sayısı gibi örnek bir limanlardan elde edilen veriler normalize edildi (Şekil 4.17.). Her bir veri grubunda yer alan minimum ve maksimum değerleri bulup, min-max normalizasyon formülünde yerlerine koyup sonuçları bulundu.

Konteyner İşlem Hacmi (TEU) Normalizasyon	Rakip Liman Sayısı Normalizasyon	Acente Sayısı Normalizasyon	Terminal Sayısı Normalizasyon
0,017699115	0	0	0
0,03539823	0	0	0
0,026548673	0	0	0
0,017699115	0	0	0
0,044247788	0	0	0
0,053097345	0	0	0
0,044247788	0	0	0
0,07079646	0	0	0
0,026548673	0	0	0
0,008849558	0	0	0
0	0	0	0
0,008849558	0	0	0
0,044247788	0	0,172413793	0
0,061946903	0	0,172413793	0
0,053097345	0	0,172413793	0
0,088495575	0	0,172413793	0
0,079646018	0	0,172413793	0
0,10619469	0	0,172413793	0
0,123893805	0	0,172413793	0
0,132743363	0	0,172413793	0
0,10619469	0	0,172413793	0
0,07079646	0	0,172413793	0
0,053097345	0	0,172413793	0
0,053097345	0	0,172413793	0
0,026548673	0,142857143	0,103448276	0
0,061946903	0,142857143	0,103448276	0
0,044247788	0,142857143	0,103448276	0
0,079646018	0,142857143	0,103448276	0
0,061946903	0,142857143	0,103448276	0
0,088495575	0,142857143	0,103448276	0
0,097345133	0,142857143	0,103448276	0
0,10619469	0,142857143	0,103448276	0
0,07079646	0,142857143	0,103448276	0
0,053097345	0,142857143	0,103448276	0
0,061946903	0,142857143	0,103448276	0
0,044247788	0,142857143	0,103448276	0
0,132743363	0,285714286	0,24137931	0,166666667
0,150442478	0,285714286	0,24137931	0,166666667
0,159292035	0,285714286	0,24137931	0,166666667

Şekil 4.17. Normalizasyon

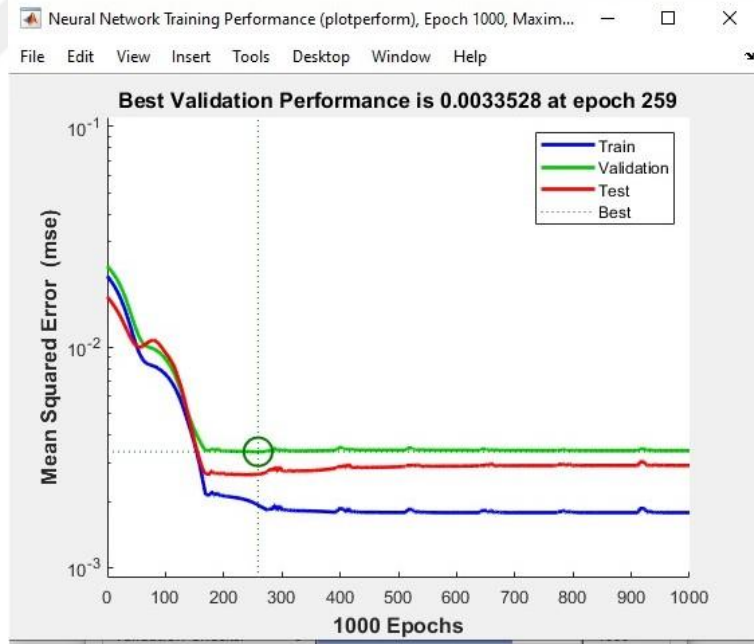
Devrik dönüşüm formülü ile veriler düzenledi. Veriler MATLAB programına aktarılmaya hazır bir hale geldi.

Sistemde input (girdi) ve target (hedef) veri grupları tanımladı. Rakip liman sayısı, acente sayısı ve terminal sayısı gibi verileri input olarak alındı. Konteyner iş hacmi TEU bilgisini hedef olarak sisteme verildi. Amacımız YSA eğitmektir. Başka bir bilgi sistemde oluşturulmamıştır. Elde yer alan mevcut bilgiler sisteme öğretildi. YSA eğitmek için, girdi normalizasyon ve hedef normalizasyon verileri baz alındı. YSA da ileri besleme geri yayılım yöntemi kullanıldı. Yapay sinir ağları ileri besleme ve geri yayılım olarak 2 ana bölüme ayrılır. İleri besleme bölümünde YSA için giriş verileri verilir. Daha sonra elde edilen sonuç verileri hata fonksiyonuna verilir. Böylece hatalar geriye doğru yayılarak güncellenir. Bu aşamalar için kodlama ve hesaplama gerekmektedir. Ancak bu durumların önüne geçmek için MATLAB özelliklerini kullanıldı.

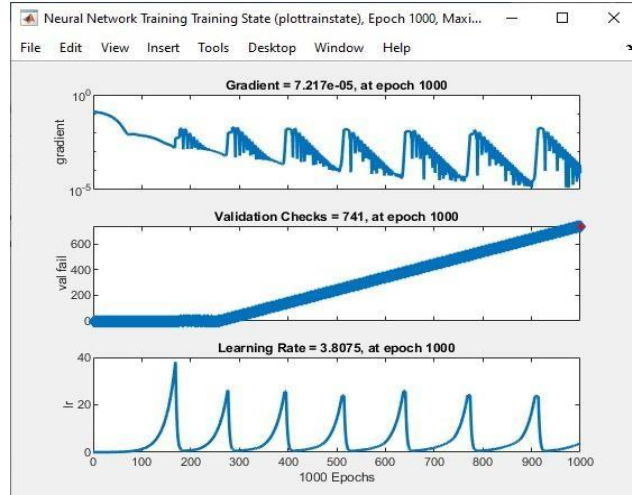


Şekil 4.18. Sinir ağıları

YSA hesaplaması öğretiminin sonucunda bulunan performans, antrenman ve refresyon grafikleri Şekil 4.19.- 4.21.de görüldüğü gibi mevcuttur. Öğrenim sırasında iterasyon sayısını 1000 olarak alındı. İtreasyon sayısının 1000 olması YSA'nın her tekrarında daha hızlı ve verimli öğrenmesi sağlamaktadır.

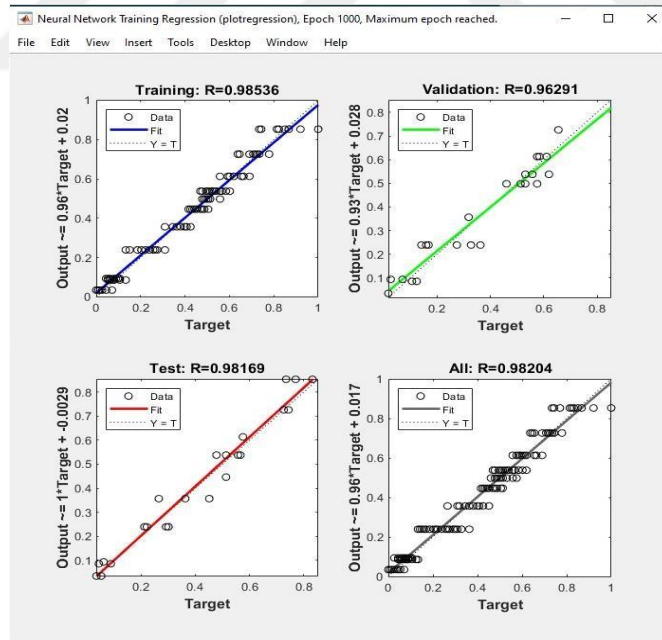


Şekil 4.19. Training performance



Şekil 4.20. Regresyon

YSA'nın çıktı verileri ve hedef verilerinin birbirlerine en yakın olması eğitim, doğrulama ve test setlerini içeren regresyon grafiğini sunmaktadır. Hesap sonuçlarının doğruluğa en yakın derecede çıkması, 45 derecelik doğru alanında yığın oluşması ile doğru orantılıdır. Grafikte (Şekil 4.21.) yer alan R değerinin (%98 üzeri) yüksek olması, YSA'nın sonuç verimini göstermektedir. Bulunan R değeri %98 'nin üzerindedir. Tahmin çalışmasının sonucu verimlidir.



Şekil 4.21. Tahmin normalizasyonu

Yapay sinir ağlarının öğrenimi sonucunda tahmin yapılan 2007-2019 verileri sistem tarafından normalizasyon değerleri Şekil 4.22.de olduğu gibi verilmiştir. Verilen değerler normalizasyon formülünde yerlerine konularak tahmin sonucu konteyner iş hacmi TEU verilerine ulaşılmıştır.

Yapay sinir ağıları metodunu kullanarak MATLAB programı aracılığı ile 2007-2019 yılları arasında yer alan ay bazlı konteyner iş hacmi TEU verileri tahmin yöntemiyle bulunmuştur. Veriler Şekil 4.23.- 4.27.de görüldüğü gibi mevcuttur.

Konteyner İşlem Hacmi (TEU) Normalizasyon	Rakip Liman Sayısı Normalizasyon	Acente Sayısı Normalizasyon	Terminal Sayısı Normalizasyon	YSA Tahmin Normalizasyon
0,017699115	0	0	0	0,04591092
0,03539823	0	0	0	0,04591092
0,026548673	0	0	0	0,04591092
0,017699115	0	0	0	0,04591092
0,044247788	0	0	0	0,04591092
0,053097345	0	0	0	0,04591092
0,044247788	0	0	0	0,04591092
0,07079646	0	0	0	0,04591092
0,026548673	0	0	0	0,04591092
0,008849558	0	0	0	0,04591092
0	0	0	0	0,04591092
0,008849558	0	0	0	0,04591092
0,044247788	0	0,172413793	0	0,071278661
0,061946903	0	0,172413793	0	0,071278661
0,053097345	0	0,172413793	0	0,071278661
0,088495575	0	0,172413793	0	0,071278661
0,079646018	0	0,172413793	0	0,071278661
0,10619469	0	0,172413793	0	0,071278661
0,123893805	0	0,172413793	0	0,071278661
0,132743363	0	0,172413793	0	0,071278661
0,10619469	0	0,172413793	0	0,071278661
0,07079646	0	0,172413793	0	0,071278661
0,053097345	0	0,172413793	0	0,071278661
0,053097345	0	0,172413793	0	0,071278661
0,026548673	0,142857143	0,103448276	0	0,071459341
0,061946903	0,142857143	0,103448276	0	0,071459341
0,044247788	0,142857143	0,103448276	0	0,071459341
0,079646018	0,142857143	0,103448276	0	0,071459341
0,061946903	0,142857143	0,103448276	0	0,071459341
0,088495575	0,142857143	0,103448276	0	0,071459341
0,097345133	0,142857143	0,103448276	0	0,071459341
0,10619469	0,142857143	0,103448276	0	0,071459341
0,07079646	0,142857143	0,103448276	0	0,071459341
0,053097345	0,142857143	0,103448276	0	0,071459341
0,061946903	0,142857143	0,103448276	0	0,071459341

Şekil 4.22. YSA sonuç normalizasyonu

Ay	Konteyner İşlem Hacmi (TEU)	YSA Tahmin Sonuçları
Ocak 07	107.000	110.188
Şubat 07	109.000	110.188
Mart 07	108.000	110.188
Nisan 07	107.000	110.188
Mayıs 07	110.000	110.188
Haziran 07	111.000	110.188
Temmuz 07	110.000	110.188
Ağustos 07	113.000	110.188
Eylül 07	108.000	110.188
Ekim 07	106.000	110.188
Kasım 07	105.000	110.188
Aralık 07	106.000	110.188
Ocak 08	110.000	113.054
Şubat 08	112.000	113.054
Mart 08	111.000	113.054
Nisan 08	115.000	113.054
Mayıs 08	114.000	113.054
Haziran 08	117.000	113.054
Temmuz 08	119.000	113.054
Ağustos 08	120.000	113.054
Eylül 08	117.000	113.054
Ekim 08	113.000	113.054
Kasım 08	111.000	113.054
Aralık 08	111.000	113.054
Ocak 09	108.000	113.075
Şubat 09	112.000	113.075
Mart 09	110.000	113.075
Nisan 09	114.000	113.075
Mayıs 09	112.000	113.075
Haziran 09	115.000	113.075
Temmuz 09	116.000	113.075
Ağustos 09	117.000	113.075
Eylül 09	113.000	113.075
Ekim 09	111.000	113.075
Kasım 09	112.000	113.075
Aralık 09	110.000	113.075

Şekil 4.23. YSA tahmin sonuçları 1

Ocak 10	120.000	131.522
Şubat 10	122.000	131.522
Mart 10	123.000	131.522
Nisan 10	121.000	131.522
Mayıs 10	124.000	131.522
Haziran 10	126.000	131.522
Temmuz 10	128.000	131.522
Ağustos 10	130.000	131.522
Eylül 10	129.000	131.522
Ekim 10	135.000	131.522
Kasım 10	136.000	131.522
Aralık 10	136.000	131.522
Ocak 11	130.000	131.522
Şubat 11	134.000	131.522
Mart 11	136.000	131.522
Nisan 11	135.000	131.522
Mayıs 11	138.000	131.522
Haziran 11	140.000	131.522
Temmuz 11	142.000	131.522
Ağustos 11	146.000	131.522
Eylül 11	139.000	131.522
Ekim 11	134.000	131.522
Kasım 11	134.000	131.522
Aralık 11	132.000	131.522
Ocak 12	141.000	145.476
Şubat 12	144.000	145.476
Mart 12	146.000	145.476
Nisan 12	148.000	145.476
Mayıs 12	146.000	145.476
Haziran 12	151.000	145.476
Temmuz 12	153.000	145.476
Ağustos 12	156.000	145.476
Eylül 12	150.000	145.476
Ekim 12	150.000	145.476
Kasım 12	140.000	145.476
Aralık 12	135.000	145.476

Şekil 4.26. YSA tahmin sonuçları 4

Ocak 13	153.000	157.821
Şubat 13	155.000	157.821
Mart 13	154.000	157.821
Nisan 13	156.000	157.821
Mayıs 13	155.000	157.821
Haziran 13	158.000	157.821
Temmuz 13	159.000	157.821
Ağustos 13	162.000	157.821
Eylül 13	160.000	157.821
Ekim 13	153.000	157.821
Kasım 13	152.000	157.821
Aralık 13	163.000	157.821
Ocak 14	159.000	163.644
Şubat 14	162.000	163.644
Mart 14	164.000	163.644
Nisan 14	163.000	163.644
Mayıs 14	168.000	163.644
Haziran 14	171.000	163.644
Temmuz 14	173.000	163.644
Ağustos 14	175.000	163.644
Eylül 14	168.000	163.644
Ekim 14	166.000	163.644
Kasım 14	165.000	163.644
Aralık 14	166.000	163.644
Ocak 15	158.000	163.644
Şubat 15	169.000	163.644
Mart 15	163.000	163.644
Nisan 15	162.000	163.644
Mayıs 15	166.000	163.644
Haziran 15	168.000	163.644
Temmuz 15	169.000	163.644
Ağustos 15	168.000	163.644
Eylül 15	162.000	163.644
Ekim 15	159.000	163.644
Kasım 15	161.000	163.644
Aralık 15	165.000	163.644

Şekil 4.25. YSA tahmin sonuçları 3

Ocak 16	157.000	161.260
Şubat 16	159.000	161.260
Mart 16	160.000	161.260
Nisan 16	162.000	161.260
Mayıs 16	163.000	161.260
Haziran 16	165.000	161.260
Temmuz 16	168.000	161.260
Ağustos 16	170.000	161.260
Eylül 16	161.000	161.260
Ekim 16	162.000	161.260
Kasım 16	160.000	161.260
Aralık 16	163.000	161.260
Ocak 17	168.000	174.046
Şubat 17	170.000	174.046
Mart 17	174.000	174.046
Nisan 17	173.000	174.046
Mayıs 17	175.000	174.046
Haziran 17	179.000	174.046
Temmuz 17	180.000	174.046
Ağustos 17	183.000	174.046
Eylül 17	175.000	174.046
Ekim 17	171.000	174.046
Kasım 17	170.000	174.046
Aralık 17	172.000	174.046
Ocak 18	177.000	184.319
Şubat 18	179.000	184.319
Mart 18	178.000	184.319
Nisan 18	183.000	184.319
Mayıs 18	187.000	184.319
Haziran 18	189.000	184.319
Temmuz 18	193.000	184.319
Ağustos 18	188.000	184.319
Eylül 18	187.000	184.319
Ekim 18	188.000	184.319
Kasım 18	186.000	184.319
Aralık 18	185.000	184.319

Şekil 4.26. YSA tahmin sonuçları 4

Ocak 19	198.000	200.066
Şubat 19	199.000	200.066
Mart 19	197.000	200.066
Nisan 19	201.000	200.066
Mayıs 19	209.000	200.066
Haziran 19	203.000	200.066
Temmuz 19	218.000	200.066
Ağustos 19	218.000	200.066
Eylül 19	192.000	200.066
Ekim 19	189.000	200.066
Kasım 19	188.000	200.066
Aralık 19	188.000	200.066

Şekil 4.27. YSA tahmin sonuçları 5

4.3. Üstel Düzeltme Yöntemi

İstatistiksel tahmin yöntemlerinden; Üstel düzeltme yöntemi ile tahminle yapma tercih edildi. Yakın zaman talepleri, önceki dönem taleplerinden daha fazla ağırlık verilerek, zaman serisi ortalamasını hesaplayan ağırlıklı gerçekleşen ortalama yöntemidir. Bu yöntemde üstel düzeltme sabiti kullanılır. Bu sabit değerin yüksek olması güncel verilere daha fazla ağırlık verilmesine neden olur. Üstel düzeltme yönteminde sabit değer genellikle 0 ve 1 arasındaki değerlerdir.

Üstel düzeltme yöntemi formülü:

$$\hat{Y}_{t+1} = aY_t + (1 - a)\hat{Y}_t \quad (4.3)$$

a → Üstel düzeltme sabiti

Y → Gerçekleşen

\hat{Y} → Bir önceki dönem tahmini

Yapay Sinir ağları ve AHO yöntemlerinde baz alınan Aylık Konteyner İşlem hacmi (TEU) verilerini baz alarak hesaplama yapıldı. Üstel düzeltme sabiti (a) 0,1 olarak ele alındı.

2017 yılının ocak ayından itibaren hesaplamaya başlandı. Çünkü daha eski veriye sahip olunmadığı için şubat ayı baz alındı. Şubat ayının tahmini TEU verisi ocak ayında yapılan olarak ele alındı. Ve böylece mart ayı için hesaplama yapmaya devam edildi. Formülde verilerin yerine koyuldu.

Böylece mart ayı için şubat ayında yapılan TEU verisi ile üstel düzeltme sabiti çarpılmış oldu. Daha sonra 1 değerinden üstel düzeltme sabiti çıkarılarak, bir önceki dönem tahmin verisi ile çarpıldı ve iki değer toplanarak mart ayı için hesaplanan tahmin değeri bulunmuş oldu. Bu hesaplamalar tek tek diğer yılların, ay TEU verileri içinde uygulandı. Ve üstel düzeltme yöntem tahmini sütununda gösterildi.

Ay	Konteyner İşlem Hacmi (TEU)	Üstel Düzeltme Yöntem Tahmini
Ocak 07	107.000	
Şubat 07	109.000	107.000
Mart 07	108.000	107.200
Nisan 07	107.000	107.280
Mayıs 07	110.000	107.252
Haziran 07	111.000	107.527
Temmuz 07	110.000	107.874
Ağustos 07	113.000	108.087
Eylül 07	108.000	108.578
Ekim 07	106.000	108.520
Kasım 07	105.000	108.268
Aralık 07	106.000	107.941
Ocak 08	110.000	107.747
Şubat 08	112.000	107.973
Mart 08	111.000	108.375
Nisan 08	115.000	108.638
Mayıs 08	114.000	109.274
Haziran 08	117.000	109.747
Temmuz 08	119.000	110.472
Ağustos 08	120.000	111.325
Eylül 08	117.000	112.192
Ekim 08	113.000	112.673
Kasım 08	111.000	112.706
Aralık 08	111.000	112.535
Ocak 09	108.000	112.382
Şubat 09	112.000	111.943
Mart 09	110.000	111.949
Nisan 09	114.000	111.754
Mayıs 09	112.000	111.979
Haziran 09	115.000	111.981
Temmuz 09	116.000	112.283
Ağustos 09	117.000	112.655
Eylül 09	113.000	113.089
Ekim 09	111.000	113.080
Kasım 09	112.000	112.872

Şekil 4.28. Üstel düzeltme yöntemi ile tahminleme

Aralık 09	110.000	112.785
Ocak 10	120.000	112.506
Şubat 10	122.000	113.256
Mart 10	123.000	114.130
Nisan 10	121.000	115.017
Mayıs 10	124.000	115.615
Haziran 10	126.000	116.454
Temmuz 10	128.000	117.409
Ağustos 10	130.000	118.468
Eylül 10	129.000	119.621
Ekim 10	135.000	120.559
Kasım 10	136.000	122.003
Aralık 10	136.000	123.403
Ocak 11	130.000	124.662
Şubat 11	134.000	125.196
Mart 11	136.000	126.077
Nisan 11	135.000	127.069
Mayıs 11	138.000	127.862
Haziran 11	140.000	128.876
Temmuz 11	142.000	129.988
Ağustos 11	146.000	131.189
Eylül 11	139.000	132.670
Ekim 11	134.000	133.303
Kasım 11	134.000	133.373
Aralık 11	132.000	133.436
Ocak 12	141.000	133.292
Şubat 12	144.000	134.063
Mart 12	146.000	135.057
Nisan 12	148.000	136.151
Mayıs 12	146.000	137.336
Haziran 12	151.000	138.202
Temmuz 12	153.000	139.482
Ağustos 12	156.000	140.834
Eylül 12	150.000	142.350
Ekim 12	150.000	143.115
Kasım 12	140.000	143.804

Şekil 4.29. Üstel düzeltme yöntemi ile tahminleme

Aralık 12	135.000	143.424
Ocak 13	153.000	142.581
Şubat 13	155.000	143.623
Mart 13	154.000	144.761
Nisan 13	156.000	145.685
Mayıs 13	155.000	146.716
Haziran 13	158.000	147.545
Temmuz 13	159.000	148.590
Ağustos 13	162.000	149.631
Eylül 13	160.000	150.868
Ekim 13	153.000	151.781
Kasım 13	152.000	151.903
Aralık 13	163.000	151.913
Ocak 14	159.000	153.021
Şubat 14	162.000	153.619
Mart 14	164.000	154.457
Nisan 14	163.000	155.412
Mayıs 14	168.000	156.171
Haziran 14	171.000	157.353
Temmuz 14	173.000	158.718
Ağustos 14	175.000	160.146
Eylül 14	168.000	161.632
Ekim 14	166.000	162.268
Kasım 14	165.000	162.642
Aralık 14	166.000	162.877
Ocak 15	158.000	163.190
Şubat 15	169.000	162.671
Mart 15	163.000	163.304
Nisan 15	162.000	163.273
Mayıs 15	166.000	163.146
Haziran 15	168.000	163.431
Temmuz 15	169.000	163.888
Ağustos 15	168.000	164.399
Eylül 15	162.000	164.759
Ekim 15	159.000	164.484
Kasım 15	161.000	163.935

Şekil 4.30. Üstel düzeltme yöntemi ile tahminleme

Aralık 15	165.000	163.642
Ocak 16	157.000	163.777
Şubat 16	159.000	163.100
Mart 16	160.000	162.690
Nisan 16	162.000	162.421
Mayıs 16	163.000	162.379
Haziran 16	165.000	162.441
Temmuz 16	168.000	162.697
Ağustos 16	170.000	163.227
Eylül 16	161.000	163.904
Ekim 16	162.000	163.614
Kasım 16	160.000	163.453
Aralık 16	163.000	163.107
Ocak 17	168.000	163.097
Şubat 17	170.000	163.587
Mart 17	174.000	164.228
Nisan 17	173.000	165.205
Mayıs 17	175.000	165.985
Haziran 17	179.000	166.886
Temmuz 17	180.000	168.098
Ağustos 17	183.000	169.288
Eylül 17	175.000	170.659
Ekim 17	171.000	171.093
Kasım 17	170.000	171.084
Aralık 17	172.000	170.976
Ocak 18	177.000	171.078
Şubat 18	179.000	171.670
Mart 18	178.000	172.403
Nisan 18	183.000	172.963
Mayıs 18	187.000	173.967
Haziran 18	189.000	175.270
Temmuz 18	193.000	176.643
Ağustos 18	188.000	178.279
Eylül 18	187.000	179.251
Ekim 18	188.000	180.026
Kasım 18	186.000	180.823

Şekil 4.29. Üstel düzeltme yöntemi ile tahminleme

Aralık 18	185.000	181.341
Ocak 19	198.000	181.707
Şubat 19	199.000	183.336
Mart 19	197.000	184.902
Nisan 19	201.000	186.112
Mayıs 19	209.000	187.601
Haziran 19	203.000	189.741
Temmuz 19	218.000	191.067
Ağustos 19	218.000	193.760
Eylül 19	192.000	196.184
Ekim 19	189.000	195.766
Kasım 19	188.000	195.089
Aralık 19	188.000	194.380

Şekil 4.32. Üstel düzeltme yöntemi ile tahminleme



BEŞİNCİ BÖLÜM

SONUÇ VE DEĞERLENDİRME

SONUÇ VE DEĞERLENDİRME

Liman işletmeleri buldukları ülke içerisinde ve dünya ticaret ağında yer alabilmek ve gelişmiş bir liman olabilmek için diğer işletmelerden bir adım daha öne çıkmak zorundalar. Bundan dolayı terminal kapasitelerinin hacmini, bir sonraki yılın konteyner iş hacmine göre düzenlemeleri ve geliştirmeleri gerekmektedir. Hızlı gelişen teknoloji, liman işletmelerinin hedeflerini gerçekleştirmede tahmin yöntemi kullanma arayışını zorunlu hale getirmiştir.

Çalışmamızda gözlendiği üzere ağırlıklı hareketli ortalama yöntemi, üstel düzeltme yöntemi ve yapay sinir ağları yöntemi ile konteyner işlem hacmi (TEU) tahminlemesi yapılmıştır.

Şekil 4.1.- 4.5.te olduğu gibi, 2007-2019 yılları arasında yer alan aylık veriler görülmektedir. Belirtilen konteyner iş hacmi TEU sütunu örnek olarak ele alınan liman işletmesinin verilerini içermektedir. AHO tahmin sonuçları (Şekil 4.7.- 4.11.) sütununda yer alan sonuçlar, ağırlıklı hareket ortalama yöntemi ile oluşan tahminlerdir.

Şekil 4.23.- 4.27.de gösterilen YSA tahmin sonuç verileri, yapay sinir ağları hesaplamasının tahmin sonucudur. Şekil 4.28.- 4.32.de olduğu gibi üstel düzeltme yöntem tahmini, üstel düzeltme yöntemi ile hesaplanmış tahmin sonucudur.

YSA, AHO ve Üstel Düzeltme Yöntemiyle bulunan tahmin hesaplarının birbiriyle karşılaştırma yapılabilmesi ve doğruluk ölçülerinin bulunması için 3 adet yöntem kullanılır. Kullanılan yöntemler MAD, MAPE ve MSE'dir. MSE; ortalama hata kare, MAD; ortalama mutlak sapma, MAPE; ortalama mutlak yüzde hatadır. Yöntemlerin hesaplamalarının sonucunda çıkan değerler ne kadar küçük olur ise, gerçek talebe o kadar yaklaşımış olunur. Üç yöntem için MAD, MAPE ve MSE parametreleri tek tek hesaplandı.

$$\text{MAD} = \frac{\sum_{i=1}^k |y_i - F_i|}{k} \quad (5.1) \quad \text{MSE} = \frac{\sum_{i=1}^k (y_i - F_i)^2}{k} \quad (5.2) \quad \text{MAPE} = 100 \times \frac{\sum_{i=1}^k |y_i - F_i| / y_i}{k} \quad (5.3)$$

Üstel Düzeltme yöntemi için MAD, MAPE ve MSE değerleri:

Ay	Konteyner İşlem Hacmi (TEU)	Üstel Düzeltme Yöntem Tahmini ¹	Tahmin - Gerçekleşen ¹	Tahmin - Gerçekleşen ²	Tahmin - Gerçekleşen ³ /Gerçekleşen x 100 %
Ocak 07	107.000				
Şubat 07	109.000	107.000	2.000	4.000.000	1,835
Mart 07	108.000	107.200	800	640.000	0,741
Nisan 07	107.000	107.280	280	78.400	0,262
Mayıs 07	110.000	107.252	2.748	7.551.504	2,498
Haziran 07	111.000	107.527	3.473	12.063.118	3,129
Temmuz 07	110.000	107.874	2.126	4.519.366	1,933
Ağustos 07	113.000	108.087	4.913	24.140.438	4,348
Eylül 07	108.000	108.578	578	334.127	0,535
Ekim 07	106.000	108.520	2.520	6.351.577	2,378
Kasım 07	105.000	108.268	3.268	10.681.197	3,113
Aralık 07	106.000	107.941	1.941	3.768.992	1,831
Ocak 08	110.000	107.747	2.253	5.074.882	2,048
Şubat 08	112.000	107.973	4.027	16.220.553	3,596
Mart 08	111.000	108.375	2.625	6.889.194	2,365
Nisan 08	115.000	108.638	6.362	40.478.284	5,532
Mayıs 08	114.000	109.274	4.726	22.335.351	4,146
Haziran 08	117.000	109.747	7.253	52.612.192	6,200
Temmuz 08	119.000	110.472	8.528	72.728.210	7,166
Ağustos 08	120.000	111.325	8.675	75.260.401	7,229
Eylül 08	117.000	112.192	4.808	23.114.438	4,109
Ekim 08	113.000	112.673	327	106.911	0,289
Kasım 08	111.000	112.706	1.706	2.909.496	1,537
Aralık 08	111.000	112.535	1.535	2.356.691	1,383
Ocak 09	108.000	112.382	4.382	19.198.740	4,057
Şubat 09	112.000	111.943	57	3.195	0,050
Mart 09	110.000	111.949	1.949	3.799.091	1,772
Nisan 09	114.000	111.754	2.246	5.043.558	1,970
Mayıs 09	112.000	111.979	21	450	0,019
Haziran 09	115.000	111.981	3.019	9.114.888	2,625
Temmuz 09	116.000	112.283	3.717	13.817.417	3,204
Ağustos 09	117.000	112.655	4.345	18.883.029	3,714
Eylül 09	113.000	113.089	89	7.936	0,079
Ekim 09	111.000	113.080	2.080	4.327.136	1,874
Kasım 09	112.000	112.872	872	760.662	0,779

Şekil 5.1. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 09	110.000	112.785	2.785	7.755.909	2,532
Ocak 10	120.000	112.506	7.494	56.153.308	6,245
Şubat 10	122.000	113.256	8.744	76.460.964	7,167
Mart 10	123.000	114.130	8.870	78.672.933	7,211
Nisan 10	121.000	115.017	5.983	35.793.881	4,944
Mayıs 10	124.000	115.615	8.385	70.300.157	6,762
Haziran 10	126.000	116.454	9.546	91.127.395	7,576
Temmuz 10	128.000	117.409	10.591	112.179.031	8,275
Ağustos 10	130.000	118.468	11.532	132.994.272	8,871
Eylül 10	129.000	119.621	9.379	87.967.195	7,271
Ekim 10	135.000	120.559	14.441	208.547.523	10,697
Kasım 10	136.000	122.003	13.997	195.917.607	10,292
Aralık 10	136.000	123.403	12.597	158.693.262	9,263
Ocak 11	130.000	124.662	5.338	28.490.147	4,106
Şubat 11	134.000	125.196	8.804	77.507.856	6,570
Mart 11	136.000	126.077	9.923	98.475.240	7,297
Nisan 11	135.000	127.069	7.931	62.902.700	5,875
Mayıs 11	138.000	127.862	10.138	102.779.247	7,346
Haziran 11	140.000	128.876	11.124	123.748.026	7,946
Temmuz 11	142.000	129.988	12.012	144.283.054	8,459
Ağustos 11	146.000	131.189	14.811	219.354.148	10,144
Eylül 11	139.000	132.670	6.330	40.063.183	4,554
Ekim 11	134.000	133.303	697	485.243	0,520
Kasım 11	134.000	133.373	627	393.046	0,468
Aralık 11	132.000	133.436	1.436	2.061.405	1,088
Ocak 12	141.000	133.292	7.708	59.410.438	5,467
Şubat 12	144.000	134.063	9.937	98.744.665	6,901
Mart 12	146.000	135.057	10.943	119.756.505	7,495
Nisan 12	148.000	136.151	11.849	140.398.762	8,006
Mayıs 12	146.000	137.336	8.664	75.066.603	5,934
Haziran 12	151.000	138.202	12.798	163.780.835	8,475
Temmuz 12	153.000	139.482	13.518	182.734.156	8,835
Ağustos 12	156.000	140.834	15.166	230.011.433	9,722
Eylül 12	150.000	142.350	7.650	58.515.080	5,100
Ekim 12	150.000	143.115	6.885	47.397.215	4,590
Kasım 12	140.000	143.804	3.804	14.469.601	2,717

Şekil 5.2. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 12	135.000	143.424	8.424	70.955.412	6,240
Ocak 13	153.000	142.581	10.419	108.552.369	6,810
Şubat 13	155.000	143.623	11.377	129.435.268	7,340
Mart 13	154.000	144.761	9.239	85.364.035	6,000
Nisan 13	156.000	145.685	10.315	106.406.226	6,612
Mayıs 13	155.000	146.716	8.284	68.621.432	5,344
Haziran 13	158.000	147.545	10.455	109.315.909	6,617
Temmuz 13	159.000	148.590	10.410	108.365.651	6,547
Ağustos 13	162.000	149.631	12.369	152.989.542	7,635
Eylül 13	160.000	150.868	9.132	83.393.510	5,708
Ekim 13	153.000	151.781	1.219	1.485.484	0,797
Kasım 13	152.000	151.903	97	9.394	0,064
Aralık 13	163.000	151.913	11.087	122.926.701	6,802
Ocak 14	159.000	153.021	5.979	35.742.561	3,760
Şubat 14	162.000	153.619	8.381	70.235.420	5,173
Mart 14	164.000	154.457	9.543	91.061.057	5,819
Nisan 14	163.000	155.412	7.588	57.582.791	4,655
Mayıs 14	168.000	156.171	11.829	139.937.054	7,041
Haziran 14	171.000	157.353	13.647	186.228.310	7,980
Temmuz 14	173.000	158.718	14.282	203.972.508	8,255
Ağustos 14	175.000	160.146	14.854	220.632.552	8,488
Eylül 14	168.000	161.632	6.368	40.555.684	3,791
Ekim 14	166.000	162.268	3.732	13.924.100	2,248
Kasım 14	165.000	162.642	2.358	5.561.819	1,429
Aralık 14	166.000	162.877	3.123	9.750.105	1,881
Ocak 15	158.000	163.190	5.190	26.933.357	3,285
Şubat 15	169.000	162.671	6.329	40.059.252	3,745
Mart 15	163.000	163.304	304	92.225	0,186
Nisan 15	162.000	163.273	1.273	1.621.337	0,786
Mayıs 15	166.000	163.146	2.854	8.145.398	1,719
Haziran 15	168.000	163.431	4.569	20.872.224	2,719
Temmuz 15	169.000	163.888	5.112	26.130.005	3,025
Ağustos 15	168.000	164.399	3.601	12.964.151	2,143
Eylül 15	162.000	164.759	2.759	7.614.736	1,703
Ekim 15	159.000	164.484	5.484	30.069.135	3,449
Kasım 15	161.000	163.935	2.935	8.615.280	1,823

Şekil 5.3. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri

Ocak 16	157.000	163.777	6.777	45.934.447	4,317
Şubat 16	159.000	163.100	4.100	16.807.918	2,578
Mart 16	160.000	162.690	2.690	7.234.870	1,681
Nisan 16	162.000	162.421	421	177.068	0,260
Mayıs 16	163.000	162.379	621	385.995	0,381
Haziran 16	165.000	162.441	2.559	6.549.283	1,551
Temmuz 16	168.000	162.697	5.303	28.124.365	3,157
Ağustos 16	170.000	163.227	6.773	45.872.403	3,984
Eylül 16	161.000	163.904	2.904	8.435.393	1,804
Ekim 16	162.000	163.614	1.614	2.604.794	0,996
Kasım 16	160.000	163.453	3.453	11.920.057	2,158
Aralık 16	163.000	163.107	107	11.511	0,066
Ocak 17	168.000	163.097	4.903	24.043.721	2,919
Şubat 17	170.000	163.587	6.413	41.127.797	3,772
Mart 17	174.000	164.228	9.772	95.487.804	5,616
Nisan 17	173.000	165.205	7.795	60.755.907	4,506
Mayıs 17	175.000	165.985	9.015	81.272.871	5,152
Haziran 17	179.000	166.886	12.114	146.740.083	6,767
Temmuz 17	180.000	168.098	11.902	141.664.005	6,612
Ağustos 17	183.000	169.288	13.712	188.020.096	7,493
Eylül 17	175.000	170.659	4.341	18.842.873	2,480
Ekim 17	171.000	171.093	93	8.695	0,055
Kasım 17	170.000	171.084	1.084	1.174.886	0,638
Aralık 17	172.000	170.976	1.024	1.049.540	0,596
Ocak 18	177.000	171.078	5.922	35.070.364	3,346
Şubat 18	179.000	171.670	7.330	53.726.280	4,095
Mart 18	178.000	172.403	5.597	31.324.609	3,144
Nisan 18	183.000	172.963	10.037	100.744.486	5,485
Mayıs 18	187.000	173.967	13.033	169.870.551	6,970
Haziran 18	189.000	175.270	13.730	188.515.530	7,265
Temmuz 18	193.000	176.643	16.357	267.554.269	8,475
Ağustos 18	188.000	178.279	9.721	94.505.182	5,171
Eylül 18	187.000	179.251	7.749	60.050.718	4,144
Ekim 18	188.000	180.026	7.974	63.589.713	4,242
Kasım 18	186.000	180.823	5.177	26.800.131	2,783
Aralık 18	185.000	181.341	3.659	13.389.714	1,978

Şekil 5.2. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 18	185.000	181.341	3.659	13.389.714	1,978
Ocak 19	198.000	181.707	16.293	265.470.851	8,229
Şubat 19	199.000	183.336	15.664	245.359.286	7,871
Mart 19	197.000	184.902	12.098	146.350.807	6,141
Nisan 19	201.000	186.112	14.888	221.646.541	7,407
Mayıs 19	209.000	187.601	21.399	457.917.995	10,239
Haziran 19	203.000	189.741	13.259	175.804.175	6,532
Temmuz 19	218.000	191.067	26.933	725.397.533	12,355
Ağustos 19	218.000	193.760	24.240	587.572.001	11,119
Eylül 19	192.000	196.184	4.184	17.506.726	2,179
Ekim 19	189.000	195.766	6.766	45.774.609	3,580
Kasım 19	188.000	195.089	7.089	50.255.682	3,771
Aralık 19	188.000	194.380	6.380	40.707.102	3,394
			1.073.934	11.339.681.759	690,960
		MAD	6.929		
		MSE	73.159.237		
		MAPE	4,46		

Şekil 5.5. Üstel düzeltme yöntemi için MAD, MAPE ve MSE parametreleri

Üstel düzeltme yönteminde; MAD parametresi 6929, MSE parametresi 73.159.237 ve MAPE parametresi 4,46 bulunmuştur.

AHO yöntemi için MAD, MAPE ve MSE değerleri:

Ay	Konteyner İşlem Hacmi (TEU)	AHO Tahmin Sonuçları	Tahmin - Gerçekleşen	Tahmin - Gerçekleşen ²	Tahmin - Gerçekleşen / Gerçekleşen x 100 %
Ocak 07	107.000				
Şubat 07	109.000				
Mart 07	108.000				
Nisan 07	107.000				
Mayıs 07	110.000	107.700	2.300	5.290.000	2,09
Haziran 07	111.000	108.600	2.400	5.760.000	2,16
Temmuz 07	110.000	109.600	400	160.000	0,36
Ağustos 07	113.000	110.000	3.000	9.000.000	2,65
Eylül 07	108.000	111.400	3.400	11.560.000	3,15
Ekim 07	106.000	110.200	4.200	17.640.000	3,96
Kasım 07	105.000	108.400	3.400	11.560.000	3,24
Aralık 07	106.000	106.700	700	490.000	0,66
Ocak 08	110.000	105.900	4.100	16.810.000	3,73
Şubat 08	112.000	107.400	4.600	21.160.000	4,11
Mart 08	111.000	109.500	1.500	2.250.000	1,35
Nisan 08	115.000	110.600	4.400	19.360.000	3,83
Mayıs 08	114.000	112.700	1.300	1.690.000	1,14
Haziran 08	117.000	113.500	3.500	12.250.000	2,99
Temmuz 08	119.000	115.100	3.900	15.210.000	3,28
Ağustos 08	120.000	117.000	3.000	9.000.000	2,50
Eylül 08	117.000	118.500	1.500	2.250.000	1,28
Ekim 08	113.000	118.300	5.300	28.090.000	4,69
Kasım 08	111.000	116.200	5.200	27.040.000	4,68
Aralık 08	111.000	113.700	2.700	7.290.000	2,43
Ocak 09	108.000	112.000	4.000	16.000.000	3,70
Şubat 09	112.000	110.000	2.000	4.000.000	1,79
Mart 09	110.000	110.500	500	250.000	0,45
Nisan 09	114.000	110.300	3.700	13.690.000	3,25
Mayıs 09	112.000	111.800	200	40.000	0,18
Haziran 09	115.000	112.200	2.800	7.840.000	2,43
Temmuz 09	116.000	113.400	2.600	6.760.000	2,24
Ağustos 09	117.000	114.700	2.300	5.290.000	1,97
Eylül 09	113.000	115.800	2.800	7.840.000	2,48
Ekim 09	111.000	115.000	4.000	16.000.000	3,60
Kasım 09	112.000	113.300	1.300	1.690.000	1,16

Şekil 5.6. AHO yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 09	110.000	112.400	2.400	5.760.000	2,18
Ocak 10	120.000	111.100	8.900	79.210.000	7,42
Şubat 10	122.000	114.500	7.500	56.250.000	6,15
Mart 10	123.000	118.000	5.000	25.000.000	4,07
Nisan 10	121.000	120.800	200	40.000	0,17
Mayıs 10	124.000	121.700	2.300	5.290.000	1,85
Haziran 10	126.000	122.700	3.300	10.890.000	2,62
Temmuz 10	128.000	124.100	3.900	15.210.000	3,05
Ağustos 10	130.000	125.900	4.100	16.810.000	3,15
Eylül 10	129.000	128.000	1.000	1.000.000	0,78
Ekim 10	135.000	128.800	6.200	38.440.000	4,59
Kasım 10	136.000	131.500	4.500	20.250.000	3,31
Aralık 10	136.000	133.700	2.300	5.290.000	1,69
Ocak 11	130.000	135.100	5.100	26.010.000	3,92
Şubat 11	134.000	133.500	500	250.000	0,37
Mart 11	136.000	133.400	2.600	6.760.000	1,91
Nisan 11	135.000	134.200	800	640.000	0,59
Mayıs 11	138.000	134.600	3.400	11.560.000	2,46
Haziran 11	140.000	136.300	3.700	13.690.000	2,64
Temmuz 11	142.000	138.000	4.000	16.000.000	2,82
Ağustos 11	146.000	139.900	6.100	37.210.000	4,18
Eylül 11	139.000	142.800	3.800	14.440.000	2,73
Ekim 11	134.000	141.800	7.800	60.840.000	5,82
Kasım 11	134.000	138.700	4.700	22.090.000	3,51
Aralık 11	132.000	136.200	4.200	17.640.000	3,18
Ocak 12	141.000	133.700	7.300	53.290.000	5,18
Şubat 12	144.000	136.200	7.800	60.840.000	5,42
Mart 12	146.000	139.700	6.300	39.690.000	4,32
Nisan 12	148.000	143.000	5.000	25.000.000	3,38
Mayıs 12	146.000	145.900	100	10.000	0,07
Haziran 12	151.000	146.400	4.600	21.160.000	3,05
Temmuz 12	153.000	148.400	4.600	21.160.000	3,01
Ağustos 12	156.000	150.500	5.500	30.250.000	3,53
Eylül 12	150.000	153.100	3.100	9.610.000	2,07
Ekim 12	150.000	152.500	2.500	6.250.000	1,67
Kasım 12	140.000	151.500	11.500	132.250.000	8,21

Şekil 5.7. AHO yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 12	135.000	146.600	11.600	134.560.000	8,59
Ocak 13	153.000	141.000	12.000	144.000.000	7,84
Şubat 13	155.000	144.700	10.300	106.090.000	6,65
Mart 13	154.000	148.900	5.100	26.010.000	3,31
Nisan 13	156.000	152.200	3.800	14.440.000	2,44
Mayıs 13	155.000	154.900	100	10.000	0,06
Haziran 13	158.000	155.100	2.900	8.410.000	1,84
Temmuz 13	159.000	156.300	2.700	7.290.000	1,70
Ağustos 13	162.000	157.600	4.400	19.360.000	2,72
Eylül 13	160.000	159.600	400	160.000	0,25
Ekim 13	153.000	160.200	7.200	51.840.000	4,71
Kasım 13	152.000	157.500	5.500	30.250.000	3,62
Aralık 13	163.000	154.900	8.100	65.610.000	4,97
Ocak 14	159.000	157.400	1.600	2.560.000	1,01
Şubat 14	162.000	158.200	3.800	14.440.000	2,35
Mart 14	164.000	160.300	3.700	13.690.000	2,26
Nisan 14	163.000	162.300	700	490.000	0,43
Mayıs 14	168.000	162.700	5.300	28.090.000	3,15
Haziran 14	171.000	165.100	5.900	34.810.000	3,45
Temmuz 14	173.000	167.800	5.200	27.040.000	3,01
Ağustos 14	175.000	170.400	4.600	21.160.000	2,63
Eylül 14	168.000	172.900	4.900	24.010.000	2,92
Ekim 14	166.000	171.400	5.400	29.160.000	3,25
Kasım 14	165.000	169.100	4.100	16.810.000	2,48
Aralık 14	166.000	166.900	900	810.000	0,54
Ocak 15	158.000	165.900	7.900	62.410.000	5,00
Şubat 15	169.000	162.600	6.400	40.960.000	3,79
Mart 15	163.000	164.700	1.700	2.890.000	1,04
Nisan 15	162.000	164.100	2.100	4.410.000	1,30
Mayıs 15	166.000	163.300	2.700	7.290.000	1,63
Haziran 15	168.000	164.500	3.500	12.250.000	2,08
Temmuz 15	169.000	165.700	3.300	10.890.000	1,95
Ağustos 15	168.000	167.400	600	360.000	0,36
Eylül 15	162.000	168.100	6.100	37.210.000	3,77
Ekim 15	159.000	165.800	6.800	46.240.000	4,28
Kasım 15	161.000	162.700	1.700	2.890.000	1,06

Şekil 5.8. AHO yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 15	165.000	161.300	3.700	13.690.000	2,24
Ocak 16	157.000	162.300	5.300	28.090.000	3,38
Şubat 16	159.000	160.400	1.400	1.960.000	0,88
Mart 16	160.000	159.800	200	40.000	0,13
Nisan 16	162.000	159.600	2.400	5.760.000	1,48
Mayıs 16	163.000	160.300	2.700	7.290.000	1,66
Haziran 16	165.000	161.700	3.300	10.890.000	2,00
Temmuz 16	168.000	163.300	4.700	22.090.000	2,80
Ağustos 16	170.000	165.500	4.500	20.250.000	2,65
Eylül 16	161.000	167.700	6.700	44.890.000	4,16
Ekim 16	162.000	165.500	3.500	12.250.000	2,16
Kasım 16	160.000	163.900	3.900	15.210.000	2,44
Aralık 16	163.000	161.800	1.200	1.440.000	0,74
Ocak 17	168.000	161.700	6.300	39.690.000	3,75
Şubat 17	170.000	164.300	5.700	32.490.000	3,35
Mart 17	174.000	167.000	7.000	49.000.000	4,02
Nisan 17	173.000	170.500	2.500	6.250.000	1,45
Mayıs 17	175.000	172.200	2.800	7.840.000	1,60
Haziran 17	179.000	173.700	5.300	28.090.000	2,96
Temmuz 17	180.000	176.100	3.900	15.210.000	2,17
Ağustos 17	183.000	178.000	5.000	25.000.000	2,73
Eylül 17	175.000	180.500	5.500	30.250.000	3,14
Ekim 17	171.000	178.800	7.800	60.840.000	4,56
Kasım 17	170.000	175.500	5.500	30.250.000	3,24
Aralık 17	172.000	172.600	600	360.000	0,35
Ocak 18	177.000	171.500	5.500	30.250.000	3,11
Şubat 18	179.000	173.500	5.500	30.250.000	3,07
Mart 18	178.000	176.100	1.900	3.610.000	1,07
Nisan 18	183.000	177.500	5.500	30.250.000	3,01
Mayıs 18	187.000	180.100	6.900	47.610.000	3,69
Haziran 18	189.000	183.200	5.800	33.640.000	3,07
Temmuz 18	193.000	186.100	6.900	47.610.000	3,58
Ağustos 18	188.000	189.600	1.600	2.560.000	0,85
Eylül 18	187.000	189.600	2.600	6.760.000	1,39
Ekim 18	188.000	188.700	700	490.000	0,37
Kasım 18	186.000	188.200	2.200	4.840.000	1,18

Şekil 5.9. AHO yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 18	185.000	187.000	2.000	4.000.000	1,08
Ocak 19	198.000	186.100	11.900	141.610.000	6,01
Şubat 19	199.000	190.700	8.300	68.890.000	4,17
Mart 19	197.000	194.600	2.400	5.760.000	1,22
Nisan 19	201.000	196.600	4.400	19.360.000	2,19
Mayıs 19	209.000	199.100	9.900	98.010.000	4,74
Haziran 19	203.000	203.200	200	40.000	0,10
Temmuz 19	218.000	203.800	14.200	201.640.000	6,51
Ağustos 19	218.000	210.000	8.000	64.000.000	3,67
Eylül 19	192.000	214.100	22.100	488.410.000	11,51
Ekim 19	189.000	206.100	17.100	292.410.000	9,05
Kasım 19	188.000	198.600	10.600	112.360.000	5,64
Aralık 19	188.000	192.100	4.100	16.810.000	2,18
			668.300	4.518.530.000	437,46
		MAD	4.397		
		MSE	29.727.171		
		MAPE	3		

Şekil 5.10. AHO yöntemi için MAD, MAPE ve MSE parametreleri

AHO yönteminde; MAD parametresi 4397, MSE parametresi 29.727.171 ve MAPE parametresi 3 olarak bulunmuştur.

YSA yöntemi için MAD, MAPE ve MSE değerleri:

Ay	Konteyner İşlem Hacmi (TEU)	YSA Tahmin Sonuçları	Tahmin - Gerçekleşen	Tahmin - Gerçekleşen ²	Tahmin - Gerçekleşen / Gerçekleşen x 100 %
Ocak 07	107.000	110.188	3.188	10.162.923	2,98
Şubat 07	109.000	110.188	1.188	1.411.187	1,09
Mart 07	108.000	110.188	2.188	4.787.055	2,03
Nisan 07	107.000	110.188	3.188	10.162.923	2,98
Mayıs 07	110.000	110.188	188	35.319	0,17
Haziran 07	111.000	110.188	812	659.451	0,73
Temmuz 07	110.000	110.188	188	35.319	0,17
Ağustos 07	113.000	110.188	2.812	7.907.716	2,49
Eylül 07	108.000	110.188	2.188	4.787.055	2,03
Ekim 07	106.000	110.188	4.188	17.538.791	3,95
Kasım 07	105.000	110.188	5.188	26.914.658	4,94
Aralık 07	106.000	110.188	4.188	17.538.791	3,95
Ocak 08	110.000	113.054	3.054	9.329.901	2,78
Şubat 08	112.000	113.054	1.054	1.111.946	0,94
Mart 08	111.000	113.054	2.054	4.220.924	1,85
Nisan 08	115.000	113.054	1.946	3.785.014	1,69
Mayıs 08	114.000	113.054	946	893.992	0,83
Haziran 08	117.000	113.054	3.946	15.567.059	3,37
Temmuz 08	119.000	113.054	5.946	35.349.104	5,00
Ağustos 08	120.000	113.054	6.946	48.240.127	5,79
Eylül 08	117.000	113.054	3.946	15.567.059	3,37
Ekim 08	113.000	113.054	54	2.969	0,05
Kasım 08	111.000	113.054	2.054	4.220.924	1,85
Aralık 08	111.000	113.054	2.054	4.220.924	1,85
Ocak 09	108.000	113.075	5.075	25.754.666	4,70
Şubat 09	112.000	113.075	1.075	1.155.422	0,96
Mart 09	110.000	113.075	3.075	9.455.044	2,80
Nisan 09	114.000	113.075	925	855.800	0,81
Mayıs 09	112.000	113.075	1.075	1.155.422	0,96
Haziran 09	115.000	113.075	1.925	3.705.989	1,67
Temmuz 09	116.000	113.075	2.925	8.556.178	2,52
Ağustos 09	117.000	113.075	3.925	15.406.367	3,35
Eylül 09	113.000	113.075	75	5.611	0,07
Ekim 09	111.000	113.075	2.075	4.305.233	1,87
Kasım 09	112.000	113.075	1.075	1.155.422	0,96

Şekil 5.11. YSA yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 09	110.000	113.075	3.075	9.455.044	2,80
Ocak 10	120.000	131.522	11.522	132.762.428	9,60
Şubat 10	122.000	131.522	9.522	90.673.396	7,81
Mart 10	123.000	131.522	8.522	72.628.880	6,93
Nisan 10	121.000	131.522	10.522	110.717.912	8,70
Mayıs 10	124.000	131.522	7.522	56.584.364	6,07
Haziran 10	126.000	131.522	5.522	30.495.333	4,38
Temmuz 10	128.000	131.522	3.522	12.406.301	2,75
Ağustos 10	130.000	131.522	1.522	2.317.269	1,17
Eylül 10	129.000	131.522	2.522	6.361.785	1,96
Ekim 10	135.000	131.522	3.478	12.094.690	2,58
Kasım 10	136.000	131.522	4.478	20.050.174	3,29
Aralık 10	136.000	131.522	4.478	20.050.174	3,29
Ocak 11	130.000	131.522	1.522	2.317.269	1,17
Şubat 11	134.000	131.522	2.478	6.139.206	1,85
Mart 11	136.000	131.522	4.478	20.050.174	3,29
Nisan 11	135.000	131.522	3.478	12.094.690	2,58
Mayıs 11	138.000	131.522	6.478	41.961.142	4,69
Haziran 11	140.000	131.522	8.478	71.872.110	6,06
Temmuz 11	142.000	131.522	10.478	109.783.079	7,38
Ağustos 11	146.000	131.522	14.478	209.605.015	9,92
Eylül 11	139.000	131.522	7.478	55.916.626	5,38
Ekim 11	134.000	131.522	2.478	6.139.206	1,85
Kasım 11	134.000	131.522	2.478	6.139.206	1,85
Aralık 11	132.000	131.522	478	228.237	0,36
Ocak 12	141.000	145.476	4.476	20.033.707	3,17
Şubat 12	144.000	145.476	1.476	2.178.289	1,02
Mart 12	146.000	145.476	524	274.678	0,36
Nisan 12	148.000	145.476	2.524	6.371.066	1,71
Mayıs 12	146.000	145.476	524	274.678	0,36
Haziran 12	151.000	145.476	5.524	30.515.648	3,66
Temmuz 12	153.000	145.476	7.524	56.612.037	4,92
Ağustos 12	156.000	145.476	10.524	110.756.619	6,75
Eylül 12	150.000	145.476	4.524	20.467.454	3,02
Ekim 12	150.000	145.476	4.524	20.467.454	3,02
Kasım 12	140.000	145.476	5.476	29.985.513	3,91

Şekil 5.14. YSA yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 12	135.000	145.476	10.476	109.744.542	7,76
Ocak 13	153.000	157.821	4.821	23.246.838	3,15
Şubat 13	155.000	157.821	2.821	7.960.848	1,82
Mart 13	154.000	157.821	3.821	14.603.843	2,48
Nisan 13	156.000	157.821	1.821	3.317.853	1,17
Mayıs 13	155.000	157.821	2.821	7.960.848	1,82
Haziran 13	158.000	157.821	179	31.863	0,11
Temmuz 13	159.000	157.821	1.179	1.388.868	0,74
Ağustos 13	162.000	157.821	4.179	17.459.883	2,58
Eylül 13	160.000	157.821	2.179	4.745.873	1,36
Ekim 13	153.000	157.821	4.821	23.246.838	3,15
Kasım 13	152.000	157.821	5.821	33.889.833	3,83
Aralık 13	163.000	157.821	5.179	26.816.889	3,18
Ocak 14	159.000	163.644	4.644	21.564.096	2,92
Şubat 14	162.000	163.644	1.644	2.701.801	1,01
Mart 14	164.000	163.644	356	126.938	0,22
Nisan 14	163.000	163.644	644	414.370	0,39
Mayıs 14	168.000	163.644	4.356	18.977.212	2,59
Haziran 14	171.000	163.644	7.356	54.114.918	4,30
Temmuz 14	173.000	163.644	9.356	87.540.055	5,41
Ağustos 14	175.000	163.644	11.356	128.965.192	6,49
Eylül 14	168.000	163.644	4.356	18.977.212	2,59
Ekim 14	166.000	163.644	2.356	5.552.075	1,42
Kasım 14	165.000	163.644	1.356	1.839.507	0,82
Aralık 14	166.000	163.644	2.356	5.552.075	1,42
Ocak 15	158.000	163.644	5.644	31.851.527	3,57
Şubat 15	169.000	163.644	5.356	28.689.781	3,17
Mart 15	163.000	163.644	644	414.370	0,39
Nisan 15	162.000	163.644	1.644	2.701.801	1,01
Mayıs 15	166.000	163.644	2.356	5.552.075	1,42
Haziran 15	168.000	163.644	4.356	18.977.212	2,59
Temmuz 15	169.000	163.644	5.356	28.689.781	3,17
Ağustos 15	168.000	163.644	4.356	18.977.212	2,59
Eylül 15	162.000	163.644	1.644	2.701.801	1,01
Ekim 15	159.000	163.644	4.644	21.564.096	2,92
Kasım 15	161.000	163.644	2.644	6.989.233	1,64

Şekil 5.13. YSA yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 15	165.000	163.644	1.356	1.839.507	0,82
Ocak 16	157.000	161.260	4.260	18.149.055	2,71
Şubat 16	159.000	161.260	2.260	5.108.372	1,42
Mart 16	160.000	161.260	1.260	1.588.030	0,79
Nisan 16	162.000	161.260	740	547.347	0,46
Mayıs 16	163.000	161.260	1.740	3.027.006	1,07
Haziran 16	165.000	161.260	3.740	13.986.323	2,27
Temmuz 16	168.000	161.260	6.740	45.425.298	4,01
Ağustos 16	170.000	161.260	8.740	76.384.615	5,14
Eylül 16	161.000	161.260	260	67.689	0,16
Ekim 16	162.000	161.260	740	547.347	0,46
Kasım 16	160.000	161.260	1.260	1.588.030	0,79
Aralık 16	163.000	161.260	1.740	3.027.006	1,07
Ocak 17	168.000	174.046	6.046	36.548.907	3,60
Şubat 17	170.000	174.046	4.046	16.366.630	2,38
Mart 17	174.000	174.046	46	2.077	0,03
Nisan 17	173.000	174.046	1.046	1.093.215	0,60
Mayıs 17	175.000	174.046	954	910.938	0,55
Haziran 17	179.000	174.046	4.954	24.546.385	2,77
Temmuz 17	180.000	174.046	5.954	35.455.246	3,31
Ağustos 17	183.000	174.046	8.954	80.181.831	4,89
Eylül 17	175.000	174.046	954	910.938	0,55
Ekim 17	171.000	174.046	3.046	9.275.492	1,78
Kasım 17	170.000	174.046	4.046	16.366.630	2,38
Aralık 17	172.000	174.046	2.046	4.184.353	1,19
Ocak 18	177.000	184.319	7.319	53.572.968	4,14
Şubat 18	179.000	184.319	5.319	28.295.545	2,97
Mart 18	178.000	184.319	6.319	39.934.257	3,55
Nisan 18	183.000	184.319	1.319	1.740.700	0,72
Mayıs 18	187.000	184.319	2.681	7.185.854	1,43
Haziran 18	189.000	184.319	4.681	21.908.431	2,48
Temmuz 18	193.000	184.319	8.681	75.353.585	4,50
Ağustos 18	188.000	184.319	3.681	13.547.142	1,96
Eylül 18	187.000	184.319	2.681	7.185.854	1,43
Ekim 18	188.000	184.319	3.681	13.547.142	1,96
Kasım 18	186.000	184.319	1.681	2.824.565	0,90

Şekil 5.14. YSA yöntemi için MAD, MAPE ve MSE parametreleri

Aralık 18	185.000	184.319	681	463.277	0,37
Ocak 19	198.000	200.066	2.066	4.269.812	1,04
Şubat 19	199.000	200.066	1.066	1.137.107	0,54
Mart 19	197.000	200.066	3.066	9.402.516	1,56
Nisan 19	201.000	200.066	934	871.698	0,46
Mayıs 19	209.000	200.066	8.934	79.810.062	4,27
Haziran 19	203.000	200.066	2.934	8.606.289	1,45
Temmuz 19	218.000	200.066	17.934	321.615.721	8,23
Ağustos 19	218.000	200.066	17.934	321.615.721	8,23
Eylül 19	192.000	200.066	8.066	65.066.039	4,20
Ekim 19	189.000	200.066	11.066	122.464.152	5,86
Kasım 19	188.000	200.066	12.066	145.596.857	6,42
Aralık 19	188.000	200.066	12.066	145.596.857	6,42
			638.017	4.409.332.720	423,62
	MAD	4.090			
	MSE	28.264.953			
	MAPE	2,72			

Şekil 5.15. YSA yöntemi için MAD, MAPE ve MSE parametreleri

YSA yönteminde; MAD parametresi 4090, MSE parametresi 28.264.953 ve MAPE parametresi 2,72 olarak Şekil 5.16.da görüldüğü gibi bulunmuştur.

Hesaplanan parametreler sonucunda ortaya çıkan değerlerden, YSA yöntemin MAPE, MSE ve MAD sonucu, diğer tahmin yöntemlerine göre daha küçüktür. Değerler ne kadar küçük olur ise, gerçek talebe o kadar yaklaşımış olunur. Bu sebeple çalışmamızda gözlemlediğimiz sonuç, YSA tahmin yönteminin, AHO ve Üstel düzeltme tahmin yöntemlerine göre daha gerçek tahminler gerçekleştirdiği olmuştur.

	YSA	AHO	Üstel Düzeltme
MAD	4090	4297	6929
MSE	28.264.953	29.727.171	73.159.237
MAPE	2,72	3	4,46

Şekil 5.16. Tahmin yöntemlerinin MAD, MAPE ve MSE parametreleri

Bu çalışmadan elde edilen sonuçların zayıf ve güçlü yönleri gösterilebilir. Aynı zamanda ilerleyen çalışmalar için fırsatlar ve tehditler üzerinde bir değerlendirme yapılabilir. Çalışmanın swot analizinde:

Güçlü Yanlar (Strengths)

- Liman işletmesi yöneticilerinin gelecek yıl, terminal iş hacmini bilmek istemeleri.
- Liman işletmelerinin yeniliklere olan destekleri ve büyük yatırımları.

Zayıf Yönler (Weaknesses)

- İstatistiksel tahmin yöntemlerinde tek girdi ve tek çıktı elde edilirken, YSA tahminlemede tek girdi ile herhangi bir sonuç elde edilememesi ve birden fazla girdi verisinin bulunması zorunluluğu.

Fırsat (Opportunities)

- Limacılık sektörünün hızlı gelişmesi ve liman ticaret ağındaki büyümeler
- Limanlar arasındaki rekabetin gün geçtikçe artması

Tehtit (Threats)

- Rakip liman sayısının fazlalığı
- Güçlü limanların varlığı
- Yapay zeka teknolojisinin hızlı ilerlemesi

Çalışmada tahmin uygulamasının işletme performansı ve yeşil lojistik üzerinde etkileri:

- Kullanılacak ekipman ve personel sayısının planlanması.
- Yeteri kadar terminal kullanılması ve planlanması.
- Planlar doğrultusunda konteyner taşıyan ve limana gelecek gemilerin atıklarının daha planlı depolanması.
- Liman girişinde araç kuyruklarının azalması.

KAYNAKÇA

- Akman, T., Yılmaz, C., & Sönmez, Y. (2018). *Elektrik Yüğü Tahmin Yöntemlerinin Analizi*. Gazi Mühendislik Bilimler Dergisi.
- Bensinger, R. (2016). *Alignment for Advanced Machine Learning Systems*. Machine Intelligence Research Institute.
- Doğın E. (2007). *Regression analysis and artificial intelligence approach with traffic accident prediction models for Turkey and some chosen big cities*, Yüksek Lisans, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale.
- Doğın E. (2008). *Estimation of total sediment load in rivers using artificial intelligence methods*, Doktora, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Fleming, D. K. (2006). *World container port rankings*. Maritime Policy & Management.
- Frechtling, D. C. (2001). *Forecasting Tourism Demand: Methods and Strategies*. Butterworth Heinemann.
- Hyndman, R. J., & Athanasopoulos, G. (2013). *Forecasting Principles and Practice*. Texts.
- Koçer, H. (2009). *Bir hidrolik mobil vincin tasarım, analiz ve optimizasyonu*, Yüksek Lisans, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Kurgan, N. (2019). *Üretim Yönetimi ve Organizasyon*.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (2008). *Forecasting Methods and Applications*. Wiley India Pvt. Limited.
- Mehrotra, D. (2019). *Basic of Artificial Intelligence & Machine Learning*. Notion Press.
- Meydan, Y. A. (2007). *Talep tahmin yöntemleri ve orta ölçekli bir işletmede uygulanması* Yüksek Lisans, İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Özdemir, A., & Özdemir, A. (2006). *Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması*. Ege Akademik Bakış Dergisi, 6.
- Özel Y. (2006). *Determination of electrical energy production with different coals and their performances by using artificial intelligence technique*, Doktora, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Sürücü, M. C. (2016). *Konteyner tip veri merkezi detaylı tasarımı, güç hesaplamaları ve cihaz seçimleri yapılması*, Yüksek Lisans, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Talley, W. K. (2012). *Companion to Maritime Economics*. UKA: Wiley-Blackwell.
- Tetik, N., & Kanat, E. (2016). *Döviz Kuru Riskinin Ölçülmesinde Garch Yönteminin Uygulanması*. Sosyal ve Beşeri Bilgiler Araştırmaları Dergisi, 17(37).
- Tuğrul, Ö. (2010). *Günlük Veri Tahminleme Yöntemleri*. Yüksek Lisans, Boğaziçi Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

- Tütüncü K. (2009). *Modelling of diesel engine performance and fuel optimisation by artificial intelligence techniques*, Doktora, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Veldman, S. J., & Bückmann, E. H. (2003). *A Model on Container Port Competition: An Application for the West European Container Hub-Ports*. Maritime Economics & Logistics.
- Vidal, G. (1992). *Abraham Lincoln Selected Speeches and Writings*. Paperback Classics.
- Zorlu Ö. (2008). *Türkiye limanlarının işletme verimliliğinin irdelenmesi ve transit liman ihtiyacı*, Yüksel Lisans, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.



İNTERNET KAYNAKLARI

[1] İnternet: <https://www.shutterstock.com/tr/search/container+port> adresinden 03 Mart 2020'de alınmıştır.

[2] İnternet: <https://www.dnt.com.tr/bilgi-birikimi/28/konteyner-olculeri/> adresinden 07 Mart 2020'de alınmıştır.

[3] İnternet: <https://www.kalmarglobal.com/equipmentservices/reachstackers/Gloria-Reachstacker-DRG450/> adresinden 08 Mart 2020'de alınmıştır.

[4] İnternet: <https://www.liftandhoist.com/news/terex-port-solutions-largest-rtg-order-in-firms-history/> adresinden 11 Mart 2020'de alınmıştır.

[5] İnternet: <https://www.kalmarglobal.com/equipment-services/masted-container-handlers/empty-container-handler-DCG80/> adresinden 14 Mart 2020'de alınmıştır.

[6] İnternet: <https://pixabay.com/photos/container-gantry-crane-container-1367604/> adresinden 17 Mart 2020'de alınmıştır.

[7] İnternet: <https://www.konecranes.com/resources/konecranes-port-solutions-in-moerdijk> adresinden 20 Mart 2020'de alınmıştır.

[8] İnternet: <https://www.drozdogan.com/yapay-zeka-ile-sagligi-tamamen-degistirmek/> adresinden 23 Mart 2020'de alınmıştır.

[9] İnternet: <https://www.thetambellinigroup.com/artificial-intelligence-transforming-the-nature-of-work-learning-and-learning-to-work/> adresinden 25 Mart 2020'de alınmıştır.

[10] İnternet: <https://bilimfili.com/dunyayi-degistirmekte-olan-yapay-sinir-aglari-nedir> adresinden 29 Mart 2020'de alınmıştır.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : Öztürk POLAT
Uyruğu : TC
Doğum Tarihi (gün/ay/yıl) : 06.09.1992
Doğum Yeri : MERSİN
Medeni hali : Evli
Adresi :
Telefon :
E-Posta : polatozturk6@gmail.com

Eğitim Derecesi	Eğitim Birimi	Mezuniyet yılı
Yüksek lisans (Devam ediyor)	Toros Üni. Sos. Bil. Ens. UTL Tezli YL.	2020
Lisans	Toros Üniversitesi Müh Fak. Bilgisayar Mühendisliği	2016
Lise	Çağ Fen Lisesi	2010

Yabancı Dil

İngilizce

Yayımlar

-

İlgi Alanları



T.C.
TOROS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İNTİHAL PROGRAMI RAPORU

ULUSLARARASI TİCARET VE LOJİSTİK ANA BİLİM DALI BAŞKANLIĞINA

Tarih: 09/06/2020

Tez Başlığı:

Limán İşletmelerinde TEU Hareketlerinin Göz Önüne Alınarak, Yapay Zeka Ve İstatiksel Yöntemlerle Tahminleme

Yukarıda başlığı gösterilen tez çalışmamın;

a) Giriş,

b) Ana bölümler ve

c) Sonuç kısımlarından oluşan toplam 89 sayfalık kısmına ilişkin, 09/06/2020 tarihinde enstitü tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %5 'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç
- 3- Benzer kelime sayısı 10 adet

yapıldığında en fazla %10,

- 1- Kaynakça hariç
- 2- Alıntılar dahil
- 3- Benzer kelime sayısı 10 adet

yapıldığında en fazla %30'u geçmemelidir.

Tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Yukarıda belirtilen başlıkta danışmanım ile birlikte tamamlamış olduğum tezimin fikir/araştırma sorusu, yöntem, bulgular ve tartışma kısımları özgün olup kısmen veya tamamen diğer çalışmalardan alınan kısımlar olduğu durumlarda kaynak belirtilmesine dikkat edilmiştir. Tezimin, tez yazım kurallarına uygun olarak ve intihal olmaksızın hazırladığımı taahhüt eder; intihal olması durumunda tez çalışmamın başarısız sayılacağını ve mezuniyetimin iptalini kabul ederim.

Gereğini saygılarımla arz ederim.

Öğrencinin Adı Soyadı : Öztürk POLAT

İmzası : Tarih: 09/06/2020

Yukarıda kişisel ve tez bilgileri verilen öğrencimin belirtilen başlıkta birlikte tamamlamış olduğumuz tez çalışması Turnitin intihal yazılım programında kontrol edilmiş ve etik bir ihlale rastlanmamıştır. İntihal yazılım programının rapor çıktısı ektedir. Ayrıca tezin fikir/araştırma sorusu, yöntem, bulgular ve tartışma kısımları özgün olup kısmen veya tamamen diğer çalışmalardan alınan kısımlar olduğu durumlarda kaynak belirtilmesine dikkat edilmiştir.

Gereğini saygılarımla arz ederim.

Danışmanın Unvanı-Adı-Soyadı : Dr. Öğr. Üyesi Fikri EGE

İmzası : Tarih: 09/06/2020

Ek: İntihal yazılım programının rapor çıktısı (4 sayfa)

LİMAN İŞLETMELERİNDE TEU HAREKETLERİNİN GÖZ ÖNÜNE ALINARAK, YAPAY ZEKA VE İSTATİSTİKSEL YÖNTEMLERLE TAHMİNLEME

Yazar Öztürk Polat

Gönderim Tarihi: 09-Haz-2020 11:45PM (UTC+0300)

Gönderim Numarası: 1340901937

Dosya adı: zt_rk_Polat-Tez-_ntihal_i_in.docx (6.48M)

Kelime sayısı: 13753

Karakter sayısı: 95106

LİMAN İŞLETMELERİNDE TEU HAREKETLERİNİN GÖZ ÖNÜNE ALINARAK, YAPAY ZEKA VE İSTATİSTİKSEL YÖNTEMLERLE TAHMİNLEME

ORIJINALLIK RAPORU

%**5**

BENZERLİK ENDEKSİ

%**2**

İNTERNET
KAYNAKLARI

%**0**

YAYINLAR

%**4**

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	dspace.baskent.edu.tr İnternet Kaynağı	<%1
2	Submitted to Bahcesehir University Öğrenci Ödevi	<%1
3	Submitted to Anadolu University Öğrenci Ödevi	<%1
4	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	<%1
5	Submitted to Trakya University Öğrenci Ödevi	<%1
6	Submitted to Eskisehir Osmangazi University Öğrenci Ödevi	<%1
7	Submitted to TechKnowledge Turkey Öğrenci Ödevi	<%1
8	Submitted to Afyon Kocatepe University	

Öğrenci Ödevi

9

acikerisim.selcuk.edu.tr:8080

İnternet Kaynağı

10

www.stlojistik.com.tr

İnternet Kaynağı

11

acikerisim.deu.edu.tr

İnternet Kaynağı

12

Submitted to (school name not available)

Öğrenci Ödevi

13

KAZAN, Halim and TAVSAMAZ, Arzu.
"HAVACILIKTA ÜREYEN RUTİN OLMAYAN
(NONROUTINE) İŞLERİN ADAM X SAAT
TAHMİNİ: GERÇEK ZAMANLI BAKIM
KARTLARINDA UYGULAMA", İstanbul
Üniversitesi İşletme Fakültesi, 2014.

Yayın

14

Submitted to Ege Üniversitesi

Öğrenci Ödevi

15

Submitted to Istanbul Bilgi University

Öğrenci Ödevi

16

www.hayatkocu.org

İnternet Kaynağı

17

Submitted to Alamo Community College District

Öğrenci Ödevi

18	www.salesforce.com İnternet Kaynağı	<%1
19	Submitted to College of Banking and Financial Studies Öğrenci Ödevi	<%1
20	paperzz.com İnternet Kaynağı	<%1
21	Submitted to Middle East Technical University Öğrenci Ödevi	<%1
22	Submitted to Balıkesir Üniversitesi Öğrenci Ödevi	<%1
23	Submitted to Altınbas University Öğrenci Ödevi	<%1
24	Submitted to RMIT University Öğrenci Ödevi	<%1
25	Submitted to Baskent University Öğrenci Ödevi	<%1
26	Submitted to Ordu Üniversitesi Öğrenci Ödevi	<%1
27	Submitted to Akdeniz University Öğrenci Ödevi	<%1

Alıntılarını çıkart

Kapat

Eşleşmeleri çıkar

< 10 words

Bibliyografyayı Çıkart

üzerinde

