

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**KAN BANKALARINDA TALEP TAHMİNİ VE
STOKASTİK STOK YÖNETİMİ**

DOKTORA TEZİ

Seda Hatice GÖKLER

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Semra BORAN

Ocak 2020

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ


**KAN BANKALARINDA TALEP TAHMİNİ VE
STOKASTİK STOK YÖNETİMİ**

DOKTORA TEZİ

Seda Hatice GÖKLER

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ


Bu tez 31/01/ 2020 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.



Doç. Dr.
Gülşen AYDIN KESKİN
Jüri Başkanı




Doç. Dr.
Semra BORAN
Üye



Doç. Dr.
Özer UYGUN
Üye



Dr. Öğr. Üyesi
Tuğba TUNACAN
Üye



Dr. Öğr. Üyesi
Halil İbrahim DEMİR
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Seda Hatice GÖKLER

31.01.2020

TEŞEKKÜR

Bu tez çalışmasında; bilgi, tecrübe ve fikirleri ile her zaman yanımda olan danışman hocam Doç. Dr. Semra BORAN'a, öneri ve tavsiyeleri ile tezimin yön bulmasına önemli katkıları olan Doç. Dr. Gülşen AYDIN KESKİN'e ve Dr. Öğr. Üyesi Halil İbrahim DEMİR'e; uygulama aşamasında verilerin sağlanmasında destek olan Batı Anadolu Bölge Kan Merkezi Başkanı sayın Dr. Erkan ERGEN'e ve Dr. İsmail KÖYLÜ'ye sonsuz teşekkürlerimi sunarım.

Emeklerinin karşılığını ödeyemeyeceğim başta annem Fatma ADIYAMAN ve babam Muhittin ADIYAMAN olmak üzere dualarıyla her zaman yanımda olan tüm aileme; tez çalışması süresince annelerine gösterdikleri anlayış ve sabır için çocuklarım sevgili Asım Ömer ve Amine Reyyan ile eşim Ahmet Emre'ye teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	xi
ÖZET	xiii
SUMMARY	xiv
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
LİTERATÜR ARAŞTIRMASI	9
2.1. Kan Bankası İçin Talep Tahmini	9
2.2. Bozulabilir Ürünler İçin Stok Yönetimi	10
2.3. Kan Bankaları İçin Stok Yönetimi	10
BÖLÜM 3.	
MATERYAL VE YÖNTEMLER	15
3.1. Kan Bankacılığı	15
3.1.1. Kan ve kan bileşenleri	15
3.1.2. Kan gruplama sistemleri	15
3.1.3. Kan bankasının yürüttüğü faaliyetler	16
3.1.3.1. Kan bağışı	17
3.1.3.2. Kanın işlenmesi	18

3.1.3.3. Kan bileşenlerinin stoklanması	19
3.1.3.4. Kan bileşenlerinin taşınması	20
3.1.3.5. Kan bileşenlerinin nakli	20
3.1.3.6. Kan bileşenlerinin imha edilmesi	21
3.1.4. Kan bankasının uyguladığı stok yönetimi	22
3.2. Stok ve Stok Yönetimi	24
3.2.1. Stokastik stok modelleri	25
3.2.1.1. (s,Q) stokastik stok modeli	26
3.2.1.2. (s,S) stokastik stok modeli	27
3.2.1.3. (R,S) stokastik stok modeli	27
3.2.1.4. (R,s,S) stokastik stok modeli	29
3.3. Yapay Zeka Tabanlı Tahmin Yöntemleri	30
3.3.1. Ridge regresyon	31
3.3.2. Gradyan artırma ağacı	32
3.3.3. Derin öğrenme	34
3.3.4. Karar ağaçları	37
3.3.5. Destek vektör makinesi	40
3.3.6. Rassal orman	44
3.3.7. Yapay sinir ağı	46
3.4. Taguchi Deney Tasarımı	49
3.5. İstatistiksel Performans Kriterleri	51

BÖLÜM 4.

ÖNERİLEN MALİYET MODELİ	53
-------------------------------	----

BÖLÜM 5.

UYGULAMA	60
5.1. Verilerin Toplanması	65
5.1.1. Kan bileşeni talep miktarına etki eden değişkenlerin belirlenmesi	65
5.1.2. Uygulamada kullanılacak kan bileşeninin belirlenmesi	70

5.1.3. Uygulamanın yapılacağı transfüzyon merkezlerinin belirlenmesi	71
5.2. Tahmin Yöntemlerinin Kullanılması	71
5.2.1. Mevcut sistemde kan bileşeni talep miktarının belirlenmesi	71
5.2.2. Yapay zeka tabanlı tahmin yöntemleri kullanarak kan bileşeni talep miktarının belirlenmesi	72
5.2.2.1. Ridge regresyon yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	73
5.2.2.2. Gradyan artırma ağacı yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	76
5.2.2.3. Derin öğrenme yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	77
5.2.2.4. Karar ağacı yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	78
5.2.2.5. Destek vektör makinesi yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	80
5.2.2.6. Rassal orman yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	81
5.2.2.7. Yapay sinir ağı yöntemi kullanarak kan bileşeni talep miktarının belirlenmesi	83
5.3. Tahmin yöntemlerinin karşılaştırılması	88
5.4. Stokastik stok modellerinin oluşturulması	93
5.5. Maliyet modelinin oluşturulması	97
 BÖLÜM 6.	
TARTIŞMA VE SONUÇ	102
 KAYNAKLAR	105
ÖZGEÇMİŞ	114

SİMGELER VE KISALTMALAR LİSTESİ

BKM	: Bölge kan merkezi
C	: Çekirdek değeri
CART	: Regresyon ağaçları
Ch	: Birim başına elde tutma maliyeti
CH	: Toplam elde tutma maliyeti
Co	: Sabit sipariş açma maliyeti
CO	: Toplam sabit sipariş açma maliyeti
Cp	: Birim üretim maliyeti
Cs	: Yok satma ceza maliyeti
CS	: Toplam yok satma ceza maliyeti
C_t	: Birim başına diğer TM'lerden veya BKM'lerden karşılama maliyeti
C_T	: Toplam diğer TM'lerden veya BKM'lerden karşılama maliyeti
Cv	: Birim başına TM'lerde işleme ve test etme maliyeti
CV	: Toplam TM'lerde işleme ve test etme maliyeti
Cw	: Birim başına imha maliyeti
d	: Polinom derecesi
Dbc	: TM'nin kan bileşenleri talep miktarı
d_t	: t. periyotta talebe ait olasılık yoğunluk fonksiyonu
DVM	: Destek vektör makineleri
ES	: Talep edilen eritosit süspansiyonu miktarı
e_t	: t zamanındaki rassal hata
FIFO	: İlk giren ilk çıkar yöntemi
I_t	: t dönem sonundaki stok miktarı
I_t^+	: t dönem sonunda bir sonraki döneme aktarılan miktar
I_t^-	: t dönem sonunda yok satılan miktar

i	: Dönemlere ait alt indis
j	: TM'lere ait alt indis
KSS	: Kritik stok seviyesi
L	: Tedarik süresi (gün)
L_i^D	: Tedarik zamanında oluşan talep miktarı
LIFO	: Son giren ilk çıkar yöntemi
M	: Çok büyük pozitif sayı
MA	: Hareketli ortalama
MAE	: Ortalama mutlak hata
MAPE	: Ortalama mutlak yüzde hata
MCKBİÇ	: Maksimum cerrahi kan bileşeni istem çizelgesi
MSE	: Hata kareleri ortalaması
Q	: Sabit sipariş miktarı
R	: Stok miktarının gözden geçirilme zamanı
R^2	: Determinasyon katsayısı
RMSE	: Hata kareleri ortalamasının karekökü
R_t	: Yenileme siparişi miktarı
s	: Yeniden sipariş noktası
S	: En yüksek stok düzeyi
SA	: Elde bulunan stok miktarı
SCC	: MCKBİÇ ile istenen kan bileşenleri miktarı
S/N	: Sinyal-gürültü oranı
TC	: Toplam maliyet
T_{ij}	: BKM'den i . dönemde j . TM'ye gönderilen eritrosit süspansiyon miktarı
TM	: Transfüzyon merkezi
w_i	: i . dönemde imha edilen eritrosit süspansiyon miktarı
x	: Döneme ait normal dağıldığı varsayılan talep miktarı
X_{ij}	: i . dönemde j . hastane tarafından talep edilen eritrosit süspansiyonu sayısı
X_t	: t dönem sonunda elde kalan stok miktarı
y_i	: Gradyan artırma yöntemindeki i . hedef değer

y_i^p	: Gradyan artırma yöntemindeki i. tahmin değeri
y_i^{np}	: Gradyan artırma yöntemindeki yeni i. tahmin değeri
YSA	: Yapay sinir ağı
μ	: Dönem boyunca ortalama talep
σ	: Döneme ait talebin standart sapma
Φ	: Haritalama fonksiyonu
γ	: Çekirdek boyutu
η	: Öğrenme oranı



ŞEKİLLER LİSTESİ

Şekil 3.1. Kan bağışı ve kan kullanım süreci	17
Şekil 3.2. Kan bankası bağış şeması	18
Şekil 3.3. Kan merkezlerinde gerçekleştirilen işlemler ve elde edilen kan bileşenleri	19
Şekil 3.4. (s,Q) stok modeli (Hax, 1984)	26
Şekil 3.5. (s,S) stok modeli (Hax, 1984)	27
Şekil 3.6. (R,S) stok modeli (Hax, 1984)	28
Şekil 3.7. (R,s,S) stok modeli (Hax, 1984)	29
Şekil 3.8. Konvolüsyon katmanında yeni görüntü matrisi oluşturulması	35
Şekil 3.9. Havuzlama katmanında yeni görüntü matrisi oluşturulması	36
Şekil 3.10. Karar ağacı örneği	39
Şekil 3.11. Doğrusal DVM	41
Şekil 3.12. Doğrusal olmayan DVM	41
Şekil 3.13. Doğrusal destek vektör makinesi	41
Şekil 3.14. Rastgele orman örneği	46
Şekil 3.15. YSA yapısı	47
Şekil 4.1. Önerilen maliyet modeli akış şeması	58
Şekil 5.1. Uygulama akış şeması	61
Şekil 5.2. Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesinin talep ettiği ve BKM'nin gönderdiği ES miktarları.....	64
Şekil 5.3. Eskişehir Yunus Emre Devlet Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları	64
Şekil 5.4. Afyonkarahisar Devlet Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları	64
Şekil 5.5. Afyonkarahisar Sağlık Bilimleri Üniversitesi Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları	65

Şekil 5.6. Kütahya Evliya Çelebi Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları	65
Şekil 5.7. Ridge regresyon grafiği	75
Şekil 5.8. VIF grafiği	75
Şekil 5.9. Gradyan artırma ağacı yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları	77
Şekil 5.10. Derin öğrenme yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları	78
Şekil 5.11. Karar ağacı yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları	79
Şekil 5.12. Destek vektör makinası yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları	81
Şekil 5.13. Rassal orman yönteminde oluşturulan ağaç örneği	82
Şekil 5.14. Rassal orman yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları	83
Şekil 5.15. Kan bankası optimum eritrosit süspansiyon miktarı YSA yapısı	84
Şekil 5.16. Parametrelerin S/N oranları ortalaması	86
Şekil 5.17. Optimum kombinasyona ait YSA sonuç ekranı	87
Şekil 5.18. Destek vektör makinası yöntemi ile tahmin edilen ve talep edilen eritrosit süspansiyonu farkı	90
Şekil 5.19. Gradyan artırma ağacı yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları	91
Şekil 5.20. Derin öğrenme yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları	91
Şekil 5.21. Karar ağacı yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları	91
Şekil 5.22. Rassal orman yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları	91
Şekil 5.23. Yapay sinir ağı yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları	92
Şekil 5.24. Ridge regresyon yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları	92

Şekil 5.25. Talep tahmin yöntemleri ile belirlenen eksik ve fazla tahmin miktarları	92
---	----



TABLolar LİSTESİ

Tablo 2.1. Kan bankaları stok yönetimi literatür çalışmaları	13
Tablo 3.1. Kanın katı ve sıvı kısımları	15
Tablo 3.2. AB0 kan gruplama sistemi	16
Tablo 3.3. Kan bileşenlerine ait saklama koşulları, sıvıları ve saklama süreleri.	20
Tablo 3.4. Maksimum cerrahi kan bileşeni istem çizelgesi örneği	22
Tablo 3.5. Mevcut sistemde kritik stok seviyesinin belirlenmesi	23
Tablo 3.6. Stokastik stok türlerine ait gözden geçirme, yeniden sipariş verme noktası ve verilen sipariş miktarları	30
Tablo 4.1. Kullanılan notasyonlar	54
Tablo 5.1. Normallik testi	62
Tablo 5.2. Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesi 2018 yılı eritrosit süspansiyonu verileri	63
Tablo 5.3. Talep edilen kan bileşeni miktarına etki eden değişkenler	66
Tablo 5.4. İleri seçim yöntemi sonuçları	69
Tablo 5.5. İleri seçim yöntemi VIF değerleri	70
Tablo 5.6. 2018 yılına ait Batı Anadolu Bölge Kan Merkezi'nden talep edilen kan bileşeni miktarları	70
Tablo 5.7. Kritik stok seviyesinin belirlenmesi örneği	72
Tablo 5.8. Yapay zeka tabanlı tahmin yöntemlerinde kullanılan veri seti	73
Tablo 5.9. RR sonucunda oluşan VIF değerleri	73
Tablo 5.10. Korelasyon matrisi	74
Tablo 5.11. Gradyan artırma ağacı yönteminde optimum parametrelerin belirlenmesi	76
Tablo 5.12. Gradyan artırma ağacı yönteminde bulunan kriter ağırlıkları	77
Tablo 5.13. Derin öğrenme yönteminde bulunan kriter ağırlıkları	78
Tablo 5.14. Karar ağacı yönteminde optimum parametrelerin belirlenmesi	79

Tablo 5.15. Karar ağacı yönteminde bulunan kriter ağırlıkları	79
Tablo 5.16. Destek vektör makinası yönteminde optimum parametrelerin belirlenmesi	80
Tablo 5.17. Destek vektör makinası yönteminde bulunan kriter ağırlıkları	80
Tablo 5.18. Rassal orman yönteminde optimum parametrelerin belirlenmesi ..	81
Tablo 5.19. Rassal orman yönteminde bulunan kriter ağırlıkları	82
Tablo 5.20. YSA parametreleri ve seviyeleri	85
Tablo 5.21. YSA Taguchi deney tasarımı ve sonuçları	86
Tablo 5.22. ANOVA testi sonucu	87
Tablo 5.23. Yapay zeka tabanlı tahmin yöntemleri ile tahmin edilen eritrosit süspansiyonu miktarları	88
Tablo 5.24. Haftalık gözlem birimi ve miktarlar baz alınarak talep tahmin yöntemlerinin karşılaştırılması	93
Tablo 5.25. On haftalık gözlem biriminde (s,Q) stokastik stok modeli	94
Tablo 5.26. On haftalık gözlem biriminde (s,S) stokastik stok modeli	95
Tablo 5.27. On haftalık gözlem biriminde (R,S) stokastik stok modeli	95
Tablo 5.28. On haftalık gözlem biriminde (R,s,S) stokastik stok modeli	96
Tablo 5.29. Stok modelleri baz alınarak hesaplanan stok durumları	97
Tablo 5.30. Alt maliyet bileşenleri birim değerleri	97
Tablo 5.31. Önerilen model ile hesaplanan eritrosit süspansiyon talepleri beklenen maliyetler	98
Tablo 5.32. Stok modelleri baz alınarak hesaplanan maliyetler	99
Tablo 5.33. Tahmin yöntemleri baz alınarak hesaplanan maliyetler	100

ÖZET

Anahtar kelimeler: Kan bankacılığı, talep tahmin yöntemleri, stokasik stok modeli, toplam maliyet modeli

Hastalıklar, ameliyatlar veya yaralanmalar nedeniyle her gün binlerce insan kan nakline ihtiyaç duymaktadır. Bu nedenle hastanelerden gelen kan talebini karşılayan kan bankalarının doğru miktarda kan bulundurması hayati bir önem taşımaktadır. Kan bankası stoklarında gereğinden az miktarda kanın bulundurulması ihtiyacın karşılanamaması ve can kaybı gibi önemli sorunlar oluştururken, fazla miktarda kanın stoklanması ise kanın bozulmasına ve kan ihtiyacı olan farklı hastanelerin stoksuz kalma durumunu ortaya çıkmaktadır. Bu nedenle optimum miktarda kanın stoklarda bulundurulması gerekmektedir. Ayrıca kan bankası toplam maliyetinin de minimum olması istenmektedir. Bu çalışmada kan bileşenlerine ait talep miktarları optimum düzeyde tahmin edecek ve kan bankasının toplam maliyeti en aza indirecek stokastik bir stok modeli oluşturulması amaçlanmıştır.

Geliştirilen model beş aşamadan oluşmaktadır. Modelin ilk aşamasında, talep edilecek kan bileşeni miktarına etki edeceği düşünülen değişkenlerin belirlenmesi amaçlanmıştır. İkinci aşamada; talep edilecek kan bileşeni miktarı yapay zeka tabanlı tahmin yöntemleri olan; ridge regresyon, gradyan artırma ağacı, derin öğrenme, karar ağaçları, destek vektör makineleri, rassal orman ve yapay sinir ağı yöntemleri kullanılarak tahmin edilmiştir. Üçüncü aşama da ise en iyi tahmin sonucunu veren yöntem, istatistiksel performans kriterleri ile belirlenip; dördüncü aşamada elde edilen talep tahmini sonuçları; (s,Q) , (s,S) , (R,S) ve (R,s,S) stokastik stok modellerinde girdi olarak kullanılmıştır. Stokastik stok modelleri ile verilecek siparişin büyüklüğü, zamanı ve modelin sürekli mi yoksa periyodik olarak mı takip edileceği belirlenmektedir. Son olarak beşinci aşamada ise geliştirilen maliyet modeli ile en düşük maliyeti veren stokastik stok modeli belirlenmiştir.

Geliştirilen modelin uygulanabilirliği; Eskişehir, Afyonkarahisar, Kütahya ve Bilecik'te faaliyet gösteren kamu ve özel hastanelere kan bileşeni tedariki sağlayan Orta Anadolu Bölge Kan Merkezi'nde incelenmiştir. Uygulama sonunda en düşük ortalama eksik ve fazla stok ile minimum toplam maliyete sahip modelin destek vektör makinasını baz alan (s,S) stokastik stok modeli olduğu görülmüştür.

DEMAND FORECASTING AND STOCHASTIC INVENTORY MANAGEMENT IN BLOOD BANKS

SUMMARY

Keywords: Blood banking, demand forecasting methods, stochastic stock model, total cost model

Many people need blood transfusions every day due to illnesses, surgeries or injuries. For this reason, it is vital problem that blood banks keep the right amount of blood. While keeping a small amount of blood in the blood bank stocks creates important problems such as not being able to meet the need and lossing the patients life, stocking a large amount of blood results in the deterioration of the blood and effecting the stock of different hospitals that need blood. Therefore, the optimum amount of blood should be kept in stock. In addition, the total cost of the blood bank is desired to be minimum. In this study, it is aimed to create a stochastic stock model that will predict the demand amounts of blood components at an optimum level and minimize the total cost of the blood bank.

The developed model consists of five steps. The first step of the model was determining the variables that are affective in amount of blood component to be requested which was called collecting the data. Firstly, the blood component and transfusion centers were determined. In the second step, the amount of blood component is estimated using artificial intelligence estimation methods, such as ridge regression, gradient boosted tree, deep learning, decision tree, support vector machine, random forest and artificial neural network methods. In the third step, the best predicted demand estimation method was determined by statistical performance criteria. Demand forecast results; (s, Q) , (s, S) , (R, S) and (R, s, S) were used as input in stochastic stock models in the fourth step. Finally, in the fifth step, the stochastic inventory model which has the lowest cost is determined using developed cost model.

Applicability of the developed model; it was examined in the Regional Blood Center, which provides blood components to public and private hospitals operating in Eskişehir, Afyonkarahisar, Kütahya and Bilecik. At the end of the application, it was seen that the model which has optimum excess and obsolete inventory stock quantities and minimum total cost is the (s, S) stochastic inventory model based on the support vector machine.

BÖLÜM 1. GİRİŞ

Günümüzde; sosyal, ekonomik kalkınma ve sağlık hizmetlerinin iyileştirilmesi nedeniyle kan ve kan bileşenleri talebinde bir artış söz konusudur (Shi ve ark. 2017). Bunun yanı sıra tedavi yöntemlerinin gelişmesiyle de hasta veya yaralı insanların iyileşme ihtimali artmaktadır. Dolayısıyla bu iyileşme ve tedavi sürecinde kan bağışı ve bağışlanan kanın stoklanması hayati önem taşımaktadır. Sürecin başarıyla sonuçlanabilmesi için güvenilir, ürün özelliğini kaybetmemiş, zamanında ve yeterli miktarda kan ve kan bileşeninin bölge kan merkezlerinden (BKM'den) temin edilmesi zorunludur. BKM'ler ise kaynağı sadece insan olan ve başka hiç bir kimyasal süreçle elde edilemeyen kan ve kan bileşenlerini etkin bir şekilde değerlendirip sorumluluğundaki tranfüzyon merkezlerinin (TM'nin) ihtiyaçlarını optimum düzeyde sağlamalıdır. Bu nedenle kan bankaları; gönüllü kan bağışçısından temin edilen kan miktarı, talep edilen kan miktarından az olduğu için stok yönetimine ayrıca önem vermek zorundadır.

Kan bankalarının stok yönetiminde stok miktarlarını incelerken toplam maliyet göz ardı etmemelidir. Çünkü kan bankalarına ait toplam maliyet de gün geçtikçe arttığı bilinmektedir (Toner ve ark. 2011).

Bu nedenle TM'lerin kan veya kan bileşeni ihtiyacını optimum düzeyde sağlayacak, ortalama eksik ve fazla stok miktarını en aza indirip talep edilen ve BKM'den gönderilen kan bileşeni miktarları arasındaki farkı en düşük seviyeye çekecek aynı zamanda da elde bulundurma maliyeti, yok satma ceza maliyeti, farklı TM'lerden veya BKM'lerden karşılama maliyeti, yetkili TM'lerde kanı işleme/test etme maliyeti, sipariş açma maliyeti ve imha maliyeti gibi alt maliyet bileşenlerine sahip toplam maliyeti en aza indirecek bir stok modeli kurulmalıdır.

Genel olarak stok yönetimi; işletmeye alınan hammadde veya malzemenin satın alma işlemleriyle başlayıp, son ürün olarak depolara girmesinden ve müşteriye tamamlanmış ürün veya hizmet olarak sunulmasına kadar gerçekleşen tüm stok süreçlerinin yönetilmesidir (Wild, 2002). Ürün veya hizmet üreten işletmeler, talepleri istenilen zamanda karşılamak için üretim kapasitesini ve maliyeti göz önünde bulundurarak yeterli miktarda stok bulundurmak zorundadır. Stok yönetimi iki farklı hedef içerir. Bunlar; talep memnuniyetini en üst seviyeye çıkarmak ve stoktaki süresi dolmuş birim miktarını en aza indirmektir ancak bu hedefler birbiriyle çelişmektedir. Stokta fazla miktarda ürün bulundurulması talep edilen değişiklikleri daha iyi karşılayabilir ancak ürünler için daha fazla depolama süresine neden olur. Böylece raf ömrü nedeniyle kayıplar artar. Dolayısıyla imha edilen ürün miktarı da artış gösterir. Öte yandan stokta az miktarda ürün bulundurulursa; stoksuz kalma ve yok satma meydana gelir. Bu durumda stoğun sonradan karşılanması, müşteri memnuniyetsizliği, müşteri kaybı ve ceza maliyetine katlanma gibi olumsuz durumlar söz konusu olur.

Kan bankası stok yönetimi de optimum miktarda stok bulundururak; hem imha edilen ürün miktarını hem de stoksuz kalınan miktarı azaltarak, her biri farklı saklama sıvısı ve saklama koşuluna sahip kan ve kan bileşenlerinin stoklanmasını, BKM'nin sorumluluk alanı içindeki TM'lere ihtiyaç duyduğu kan ve kan bileşenlerinin sağlamasını, protokolde belirtilen kritik stok seviyesinin takip edilmesini, stoklanan kan miktarını kritik stok seviyesi altına düşürmemek için TM'lerin talebini karşılamasını kapsamaktadır. Kan bankası stok yönetiminde, yok satma miktarı minimumda tutulurken; gelebilecek talepleri karşılayacak kadar da stok bulundurulmalıdır (Najafi ve ark. 2017). Başka bir deyişle kanın ve kan bileşenlerinin stok yönetiminde kıtlık ve israf arasında bir denge sağlanmalıdır. Bu nedenle zaman aşımı kayıpları minimumda tutulmalı ve % 100 kan temini sağlamak için yeterli stok bulundurulmalıdır (Stanger ve ark., 2012). Bunun yanı sıra kan, sıradan bir bozulabilir madde değildir. Kan bağışları ve kan bileşenlerine olan talep düzensizlik gösterdiği için stokastiktir (Beliën ve Forcé, 2012). Dolayısıyla arz ve talebin verimli bir şekilde eşleştirilmesi kolay değildir (Janssen ve ark., 2016).

Günümüzde arz ve talebin verimli bir şekilde eşleştirilmesi için küresel sağlık hizmetlerinde; talepteki belirsizlik, stok yönetimi ve sınırlı insan kaynakları üzerinde odaklanılmıştır (Fortsch ve Khapalova, 2016). Örneğin; talep bilgilerin belirsizliği, yönetimin kaynakları boşuna harcamasına ve yüksek maliyetlere katlanmasına neden olmaktadır. Bu durum, kan bileşenleri gibi kısa raf ömrüne sahip sağlık hizmetlerinde ön planda tutulmasını gerektirmektedir (Privett ve Gonsalvez, 2014 ve Gurgel ve Carmo, 2014). Bunun yanı sıra kan bağışını ve talebini eşitlemek için kan bileşeni stoklarını dengelemek önemli bir sorundur. İhtiyaç duyulduğu anda kan bileşeninin temin edilmesi gerekmektedir. Ayrıca kan, dayanıklı ürünlere göre bağış ve işleme sürecinde en küçük değişimlerden etkilenmektedir. Bu nedenle kan bankası stok yönetimi, dayanıklı diğer ürünlere ait stok yönetimlerine göre daha karmaşık bir yapıya sahiptir.

Kan ve kan bileşenlerinin stoklanması ve talebinin karşılanması pek çok faktörden etkilenmektedir. Bu faktörlerden bazıları; TM'nin BKM'den talep ettiği kan bileşenlerinin kullanılmayan kısmını stoklara iade etmemesi ve bozulabilir bir ürün olması nedeniyle 35 günlük süre sonunda taze kan kategorisinden çıkarılmasıdır. Bunun yanı sıra diğer nedenler;

- a. Kanın acil ve hayati bir ihtiyaç olması,
- b. Talep miktarının belirsiz olması,
- c. Talep zamanının belirsiz olması,
- d. Bağış miktarının belirsiz olması,
- e. Bağış zamanının belirsiz olması,
- f. Hazırlanmasının zaman alıcı olması,
- g. Depolama süresinin kısa olması,
- h. Depolama alanının özel şartlar gerektirmesi,
- i. Depolama maliyetinin yüksek olması,
- j. Alınan kanın işleme süresinin dış etkenlerden etkilendiği için belirsiz olması,

- k. Kan gruplama sistemine bağılı olarak farklı kan gruplarının olması,
- l. Bazı kan bileşeni ihtiyaçlarının özel durumlar nedeniyle eski kandan değil, taze kandan karşılanması gerekliliğidir. Örneğin prematüre bir bebeğe verilecek kan bileşeni en son bağışlanan uygun kan bağışçısının kanından seçilmelidir.

Görüldüğü gibi kan bankası stok yönetiminde; belirsizlik çok fazla olduğu ve stoğu etkileyen parametre değerleri önceden kesin olarak bilinmediği ancak olasılıklar çerçevesinde talep tahmin yapılabildiği için stokastik stok modeli kullanılmalıdır. Bu durumda, kan ve kan bileşenlerine ait stokastik talep söz konusu olduğu için taleple ilgili bilginin, talebin ne zaman ve ne kadar miktarda olacağının, hangi olasılıkla karşılaşılabileceğinin belirlenmesi söz konusudur. Kan bankaları problemlerinde stokastik pek çok unsur göz önünde bulundurulması gerektiğinden, dinamik programlama gibi yöntemleri kullanarak en uygun çözümü bulmak zor ve karmaşık matematiksel işlem gerektirmektedir. Bu nedenle, çoğu araştırmacı sezgisel çözümleri seçmiştir (Abdulwahab ve Wahab, 2014).

Kan bankaları stok yönetiminde gerçekleşen en büyük problemlerden biri; TM'lerin lazım olur diye fazladan kan bileşeni talep etmesi bu nedenle gerçekten kan bileşenine ihtiyaç duyan diğer TM'lerin yok satma ve taleplerini diğer TM'lerden veya BKM'lerden sağlanmasıdır. Bunun yanı sıra diğer problem ise fazladan istenilen kan bileşenlerinin, son kullanım süresinin bitmesiyle ya da uygun olmayan ortamlar ve işlemler nedeniyle imha edilmesidir. Bu durumlarda toplam maliyetlerin de artmasına neden olmaktadır.

Çalışma kapsamında hastanelerden gelen kan taleplerini karşılayan bölge kan merkezi için stokastik bir stok modeli geliştirilmiştir. Kurulacak olan modelin öncelikli amacı; toplam maliyeti en aza indirecek stokastik stok modelinin belirlenmesidir. Bunun yanı sıra; her bir TM'ye maksimum cerrahi kan bileşeni istem çizelgesi ve sadece acil ihtiyaç kadar kan bileşeni gönderilip, stoklarındaki kan bileşeni miktarlarını optimuma çekmek hedeflenmiştir. Böylece TM'deki ihtiyaç başka hastanelere veya bölge kan

merkezlerine sormaya gerek duymadan karşılanabilecektir. Ayrıca, her hastaneye ihtiyacı kadar kan bileşeni gönderilmesi imhaların oranlarının da azalmasını sağlayacaktır.

Geliştirilen modelde öncelikle kan ve kan bileşenleri talebini etkileyen değişkenler belirlenmiştir. Bu değişkenlere bağlı olarak yapay zeka tabanlı tahmin yöntemleri ile talep tahmini yapılmıştır. Modelde yapay zeka tabanlı tahmin yöntemleri olarak ridge regresyon, gradyan artırma ağacı, derin öğrenme, karar ağaçları, destek vektör makineleri, rassal orman ve yapay sinir ağı yöntemleri kullanılmıştır. Çalışma sonunda destek vektör makinasının diğer tahmin yöntemlerine göre mevcut sisteme daha yakın sonuçlar verdiği belirlenmiştir. Karşılaştırma yaparken istatistiksel performans kriterleri olan MSE, RMSE, MAPE, MAE ve R^2 kullanılmıştır. Daha sonra destek vektör makineleri ile belirlenen talep tahminleri (s,Q), (s,S), (R,S), (R,s,S) stokastik stok modellerinde talep girdisi olarak kullanılmıştır. Oluşturulan stokastik stok modelleri ile kan bankasının uyguladığı mevcut stok modeli stok miktarları açısından incelenmiştir. Ayrıca modeller, Tarım ve Kingsman optimizasyonu (2006) baz alınarak geliştirilen toplam maliyet modeli hesaplanarak karşılaştırılmıştır. Geliştirilen modelin Tarım ve Kingsman optimizasyonundan farklı olarak ele aldığı alt maliyet bileşenleri; imha maliyeti, sipariş açma maliyeti, talebi farklı TM'lerden veya BKM'lerden karşılama maliyeti ve BKM tarafından gönderilmediği için TM'lerde gerçekleşen kan işleme ve test etme maliyetidir.

Modelin uygulanabilirliği bir bölge kan merkezi için incelenmiştir. Bunun için öncelikle bölge kan merkezinin uyguladığı stok yönetimi ele alınmıştır. Mevcut stok yönetiminde kan bileşenlerinin talep miktarları; transfüzyon merkezlerinden gelen maksimum cerrahi kan bileşeni istem çizelgesi (MCKBİÇ), kritik stok seviyesi ve transfüzyon merkezlerinde stokta bulunan kan bileşen miktarı göz önünde bulundurularak hesaplanmaktadır. Mevcut stok yönetimi incelendiğinde kliniklerden gelen istekler doğrultusunda kan bileşeni taleplerinin çizelgelendiği görülmektedir. Ancak kritik stok seviyesi hesaplanırken kullanılan hareketli ortalama yöntemi gerekenden fazla veya az talepte bulunulmasına neden olmaktadır. Bu durumda; kritik

stok seviyesinin sistemde oluşan fazla stoğu, eksik stoğu ve imha oranlarını belirleyen en önemli faktör olarak belirlenmiştir. Mevcut stok yönetiminde iki farklı durum söz konusudur.

Bu durumlardan ilkinde; hesaplanan kritik stok seviyesi gerekenden fazla olması ile TM'nin talep ettiği miktar gerçek talebi karşılar ve fazladan kan bileşeni stoklanması gerçekleşir. Bu aşamada;

- a. Kan bileşeninin stokta son kullanım süresinin dolması söz konusu olmaktadır. Dolayısıyla kan bileşeninin imha edilmesi gerekmektedir.
- b. İmha edilen kan bileşeni kan bankasına olan güvenin azalmasına neden olmaktadır.
- c. İmha edilen kan bileşenlerinin depolanması, test edilmesi, işlenmesi ve taşınması gibi maliyetlere katlanılmak zorunda kalınır.
- d. İmha edilen kan bileşenlerinin başka bir TM'de diğer hastaya nakledilmesi imkânsız hale gelir. Çünkü 'A' hastanesine gönderilen bir kan bileşeni 'B' hastanesinde de kullanılma şansını yitirir (Hosseinfard ve Abbasi, 2018).

Diğer durumda ise hareketli ortalama yöntemi ile hesaplanan kritik stok seviyesi gerekenden az olur ve TM'nin talep ettiği miktar gerçek talebi karşılamaz. Böylece;

- a. Acil durumda kan bileşeni yokluğu söz konusu olmaktadır.
- b. Hastanelerdeki kıtlık ve yetersizlik, hastaların yaşamlarıyla ilgili olduğu için ve acil durumlarda sisteme derhal kan bileşenleri verilmesi konusunda baskı uyguladığından istenmeyen bir durumdur. Bunun yanı sıra kıtlıklar, sisteme önemli maliyetler getiren dış kaynaklara veya diğer BKM'lere çağrı yapılmasını gerektirir (Hosseinfard ve Abbasi, 2018).
- c. Kan bileşeni yokluğunda kan bankasına olan güvende azalma söz konusu olmaktadır.
- d. Diğer TM'lerden veya BKM'lerden kan isteme söz konusu olabilir.
- e. TM'nin kan bağıışı kabul edilmesi söz konusu olmaktadır

Bu durumlardan da anlaşıldığı gibi kan talebini belirlerken mümkün düzeyde talebi karşılayacak miktarda belirlenmesi gerekmektedir. Bu nedenle kan ve kan bileşenleri talebini etkileyebilecek değişkenler belirlenmelidir. Değişkenlerin belirlenmesi ile sistemde meydana gelebilecek özel durumlara karşı imhanın ve karşılanamayan kan bileşeni oranının minimum yapılması amaçlanmaktadır.

Kan bankasının uyguladığı mevcut stok modelinin dezavantajlarından biri de; sorun ortaya çıktıktan sonra talep miktarlarında değişiklik yapılmasıdır. Ancak, önerilen stokastik stok modelde değişkenler üzerinde bir değişiklik olması halinde talep miktarındaki değişiklik önceden belirlenebilmektedir. Örneğin; mevcut modelde TM'nin ihtiyaçları nedeni ile ortaya çıkabilecek yeni düzenlemeler BKM ile karşılıklı olarak değerlendirilir. Uygulanacak modelde ise yeni düzenlemeler sorun ortaya çıkmadan yapay zeka tabanlı tahmin yöntemleri ile talep tahmini yapılabilmektedir. Böylece talep edilecek kan bileşeni miktarları daha tutarlı olacaktır.

Uygulama sonucunda; kan bankasının uyguladığı stok modelinde BKM, TM'lere ortalama 54,94 birim eksik ve 0 birim fazla miktarda kan bileşeni göndermiştir. Bu durum destek vektör makinesini baz alan (s,Q) stokastik stok modelinde ise ortalama eksik gönderilen miktar 111,0, fazla gönderilen miktar 120,6; (S,s) stokastik stok modelinde ortalama eksik gönderilen miktar 4,625, fazla gönderilen miktar 2,315; (R,S) stokastik stok modelinde ortalama eksik gönderilen miktar 5,520, fazla gönderilen miktar 16,081 ve (R,s,S) stokastik stok modelinde ortalama eksik gönderilen miktar 6,652, fazla gönderilen miktar 11,923 olarak hesaplanmıştır.

Bunun yanı sıra; geliştirilen maliyet modeline göre en düşük maliyeti veren stokastik stok modeli 104568 \$ ile destek vektör makinesini baz alan (s,S) stokastik stok modeli olmuştur. Ayrıca farklı tahmin yöntemleri ile geliştirilen (s,S) stokastik stok modellerinde en düşük maliyetleri veren ilk 4 yöntem sırasıyla 215091 \$ ile karar ağacı, 223977 \$ ile gradyan artırma ağacı, 227699 \$ ile yapay sinir ağı ve 287682 \$ ile rassal orman olarak belirlenmiştir. Bu sıralama; en iyi ortalama eksik ve fazla stok

miktarını veren stokastik stok modelleri sıralamasıyla farklı olduğu için; model seçiminde maliyetlerin de gözden geçirilmesi gerekliliği ortaya çıkmaktadır.

Çalışma kapsamında; Bölüm 2’de literatürde yer alan bozulabilir ürünler ve kan bankaları stok yönetimi çalışmalardan bahsedilmiştir. Bölüm 3’de kan ve kan bileşenleri ile kan bankasının gerçekleştirdiği faaliyetler ile tezde kullanılan stokastik stok modelleri ve yapay zeka tabanlı tahmin yöntemleri anlatılmıştır. Bölüm 4’de ise önerilen stok modeli açıklanmıştır. Bölüm 5’de uygulama ve elde edilen sonuçlarına yer verilerek; son bölüm olan Bölüm 6 ise tartışma ve sonuçlara değinilmiştir.



BÖLÜM 2. LİTERATÜR ARAŞTIRMASI

Çalışma kapsamında kan bankası için yapılan talep tahmini çalışmaları incelenmiştir. Bunun yanı sıra stok yönetimi bazında bozulabilir ürünler ve kan bankaları için oluşturulan stok yönetimi ile ilgili çalışmalar özetlenmiştir.

2.1. Kan Bankası İçin Talep Tahmini

Literatürde talep tahminini baz alan pek çok çalışma mevcuttur. Bu bölümde sadece kanın talep miktarını tahmin eden çalışmalar ele alınmaktadır.

Currie ve ark. (2004) çalışmalarında, nüfus değişimine bağlı olarak kan bileşeni talebini belirleyecek model geliştirmişlerdir. Kurulan model sonunda gelecekte oluşabilecek kan bileşeni talep miktarı tahmin edilmiştir. Lau ve ark. (2013) kan talebinin; yaş, cinsiyet, vücut ağırlığı, transfüzyon yılı ve splenektomi ile potansiyel ilişkilerini belirlemek için matematiksel model oluşturmuşlardır. Fortsch (2014) çalışmasında bütünleşik otoregresif hareketli ortalama (ARIMA) yöntemi kullanılarak kan talebi tahmin etmeyi amaçlamıştır. Tahminde on adet girdi değişkeni kullanılmıştır. Bu değişkenler; toplam kan talebi, O +, O-, A +, A-, B +, B-, AB +, AB- miktarları ve trombositlerdir. Çalışmasında yüksek bozulma oranına sahip trombositler için haftalık, diğer kan ürünleri için hem haftalık hem de aylık talep tahmininde bulunmuştur. Akita ve ark. (2016) ise, yaş ve cinsiyet değişkenlerini baz alan Markov modeli kullanarak kan talebinin tahmin edilmesini amaçlamışlardır. Fortsch ve Khapalova (2016), kan talep tahmini için hareketli ortalama, üstel düzleştirme, ayrıştırma zaman serileri, otoregresif hareketli ortalama ve vektör otoregresif hareketli ortalama gibi talep tahmin yöntemlerini kullanarak; maliyetlerin düşürülmesine, kan kaybının azaltılmasına ve sınırlı kaynakların korunmasına olanak tanıyacak yöntemler sunmuşlardır.

Bunun yanı sıra yapay sinir ağını (YSA) kullanarak kan talebini tahmin eden bazı çalışmalar mevcuttur. Ho ve Chang (2011) ise akut miyeloblastik lösemi hastaları için trombosit transfüzyon gereksinimlerini tahmin etmek için genetik algoritma ile YSA yöntemlerini birleştiren bir model geliştirmişlerdir. Haghani ve ark. (2017) de çalışmalarında talep tahmininde YSA yöntemini; negatif binomial regresyon, poisson regresyon, sıfır yığılmalı poisson regresyon ve sıfır yığılmalı negatif binom regresyon gibi klasik istatistiksel modellerle karşılaştırmışlardır. Firouzi ve ark. (2018) YSA ve bütünleşik otoregresif hareketli ortalama yöntemlerini kullanarak kan trombosit talebini tahmin etmeyi amaçlamışlardır. Tüm bu çalışmalarda da, YSA'nın girdileri insan biyolojisini ilgilendiren yaş, kan grubu ve cinsiyet gibi değişkenlerdir.

Ayrıca literatürde, çalışmamızda baz aldığımız kan bileşeni olan eritrosit süspansiyonu talebini tahmin eden birkaç çalışma mevcuttur. Pereira (2004) eritrosit süspansiyonu talep tahmini için tek değişkenli zaman serisi metodunu kullanmıştır. Drackley ve ark. (2012) ise bağışçı ve hastaların yaşlarına ve cinsiyetlerine bağlı olarak gelecekte oluşabilecek eritrosit süspansiyonu talebini farklı senaryolara göre simülasyon modeli kurarak tahmin etmişlerdir.

2.2. Bozulabilir Ürünler İçin Stok Yönetimi

Kan bileşenleri literatürde, bozulabilir ürün olarak ele alınmış ve bu kategoride değerlendirilmiştir. Bozulabilir ürünler için genel olarak stokastik stok modelleri kullanılmıştır (Kouki ve ark., 2013; Arslan, 2015). Bunun yanı sıra modellerde, dinamik programlama (Perry ve Stadje, 2001; Haijema, 2014) ve simülasyon (Duong ve ark., 2015) gibi bazı çözüm yöntemlerinden yararlanılmıştır.

2.3. Kan Bankaları İçin Stok Yönetimi

Literatürde yer alan kan bankaları için stok modellerinde, geleneksel ana performans kriterleri olarak yok satma ve imha oranlarının incelendiği ve buna uygun modellerin kurulduğu görülmektedir.

Kopach (2004) kan bankalarında yaptığı çalışmada 3 senaryo üzerinde durmuştur. 1.senaryo yeniden sipariş verme seviyesi bulunduğunda, 2.senaryo bir adet yeniden sipariş verme seviyesi bulunduğunda, 3.senaryo ise iki adet yeniden sipariş verme seviyesi bulunduğundaki durumları incelemektedir. Senaryolar sonunda maliyeti en aza indirecek optimum yeniden sipariş verme seviyesi belirlenmeye çalışılmıştır.

Kopach ve ark. (2008) Kanada Kan Merkezleri'nde bir uygulama yapmışlardır. Uygulamada simülasyon kullanarak mevcut model ile karşılaştırma yapılmıştır. Öngörülen modelde maliyetler, talebi karşılayamama ve son kullanma süresinin bitmesi nedeniyle imha edilen ürün sayısı minimize edilmeye çalışılmıştır.

Fontaine ve ark. (2010) maksimum raf ömrünün; eritrosit süspansiyonu kullanılabilirliğini ve kullanım süresinin bitme oranını nasıl değiştireceğini incelemek için altı farklı senaryo geliştirmişlerdir. Eritrosit süspansiyonun stokta beklediği süre azalıkça imha miktarının da azaldığı belirlenmiştir.

Stranger ve ark. (2012) kan bankalarında eritrosit süspansiyonu için stok yönetimi konusuna değinip; son kullanım süresinin geçmesi nedeniyle imha edilen ürün miktarını azaltacak önlemlerde bulunmuşlardır.

Abbasi ve Hosseinifard (2014) ise stok yönetiminde imha ve yok satmanın yanı sıra ortalama stokta bekleme süresinin de önemli bir performans göstergesi olduğu üzerinde durmuşlardır.

Civelek ve ark. (2015) kan bankasında elde tutma, yok satma ve imha maliyetini baz alan toplam maliyeti azaltmak için Markov karar sürecinden yararlanmışlardır.

Puranam ve ark. (2017), sadece A+ kan grubu için dinamik programlama modeli kurmuş ve bu modelin uygulamasını yapmışlardır. Kurulan modelin bozulabilir stok modellerinde kullanılabileceği vurgulanmıştır. Modelin amaç fonksiyonu toplam maliyeti en aza indirmek olarak belirlenmiştir. Toplam maliyet içerisinde yok satma ve imha maliyeti gibi bileşenler yer almaktadır.

Lowalekar ve Ravichandran (2017) kan bileşenlerinde geriye kalan son kullanım süresini ve stoklara ilişkin bilgileri dikkate alan stok politikası geliştirmişlerdir. Bu politikanın bazı durumlar için sürekli ve periyodik gözden geçirmeli stok yöntemlerine göre daha iyi sonuçlar verdiği görülmektedir.

Woodrum ve ark. (2017) kan bankası stok yönetiminde sıklıkla kullanılan geleneksel maksimum cerrahi kan bileşeni istem çizelgesi ile veriye dayalı maksimum cerrahi kan bileşeni istem çizelgesini karşılaştırmışlardır. Karşılaştırma sonunda veriye dayalı maksimum cerrahi kan bileşeni istem çizelgesi ile transfüzyon öncesinde yapılan bazı testlere gerek kalmadığı vurgulanmıştır.

Dunbar ve Yazer (2018) çalışmalarında dünya genelinde en az orana sahip kan grubu olan 0 Rh- için eritrosit süspansiyonu talep miktarını kadın, erkek ve hasta miktarı bazında incelemiştir.

Hosseinfard ve Abbasi (2018) çalışmalarında, tek bir kan bankası yerine birkaç transfüzyon merkezinin tüm transfüzyon merkezine dağıtmak üzere merkezi stok bulundurmasını amaçlamışlardır. Transfüzyon merkezlerine ait stoklarının merkezileştirilmesi ile kan tedarik zincirinin sürdürülebilirliğini ve esnekliğini artırabileceğini savunmuşlardır.

Pi ve ark. (2019) ise; büyük hastanelerin, dalgalanan talepler nedeniyle yoksatma ve imha oranlarını dikkate almadığını vurgulamışlardır.

Literatürde yer alan diğer kan bankaları stok yönetimi çalışmalarında ise genel olarak Markov zincirleri, matematiksel programlama ve simülasyon yöntemleri kullanılmıştır (Tablo 2.1.).

Tablo 2.1. Kan bankaları stok yönetimi literatür çalışmaları

Yıl	Yazar	Kullanılan Yöntem(ler)
2007	Haijema ve ark.	Markov dinamik programlama, Simülasyon
2008	Haijema ve ark.	Markov dinamik programlama
2008	Ma ve Powell	Markov dinamik programlama
2010	Hemmelmayr ve ark.	Değişken komşu arama algoritması, Örneklem
2010	Nguyen ve ark.	Dinamik programlama
2011	de Kort W ve ark.	Simülasyon, Stokastik dinamik programlama
2011	Hess and Grazzini	Simülasyon
2011	Ying	Simülasyon
2011	Zhou ve ark.	Dinamik programlama
2013	Duan ve Liao	Hibrit metasezgisel, Simülasyon
2013	Haijema	Markov modeli, Dinamik programlama, Simülasyon
2014	Abdulwahab ve Wahab	Dinamik programlama
2014	Asllani ve ark.	Simülasyon tabanlı karar destek sistemlei
2014	Baesler ve ark.	Simülasyon
2014	Duan ve Liao	Hibrit metasezgisel, Simülasyon
2015	Gunpinar ve Centeno	Tamsayılı programlama
2016	Liu ve ark.	Markov modeli
2016	Sarhangian ve ark.	Simülasyon
2017	Dillon ve ark.	İki aşamalı stokastik programlama
2017	Lowalekar ve Ravi	Kısıtlar teorisi
2017	Najafi ve ark.	Matematiksel programlama
2017	Wijayanayake ve Dandunna	Matematiksel programlama
2019	Chen ve Wang	Stokastik programlama, Bayes Ağları
2019	Woo ve ark.	Bilgisayar programlama, Kontrol paneli teknolojisi

Literatürdeki kan talep miktarını ele alan modellerin girdilerini; yaş, kan grubu, cinsiyet gibi insan biyolojisini ilgilendiren değişkenler oluşturmaktadır (Drackley ve ark., 2012).

Bu çalışmada ise kan talebi girdilerinin; stokastik dış etkenlerden etkilendiği öngörülmüştür. Bu nedenle girdi değişkeni olarak ameliyat sayısı, il nüfusu, sıcaklık

gibi farklı deęişkenler kullanılmıştır. Bunun yanı sıra çalışmada, literatürdeki dięer çalışmalardan farklı olarak yapay zeka tabanlı yöntemler kullanılarak kan bileşeni talep miktarları tahmin edilmiştir. Literatürde; kan bankalarına ait talep tahmin yöntemlerinde niceliksel tahmin yöntemleri ve YSA kullanıldığı görölmektedir. Ancak destek vektör makinesi, karar ağacı gibi yapay zeka tabanlı tahmin yöntemlerinin kullanıldığı bir çalışmaya rastlanılmamıştır. Çalışmada, tahmin edilen talepler stokastik stok modellerinde kullanılmıştır. Ayrıca, matematiksel toplam maliyet modeli geliştirilip en az maliyete sahip stokastik stok modelinin tercih edilmesi sağlanmıştır.



BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Kan Bankacılığı

3.1.1. Kan ve kan bileşenleri

Kan; damar ağı adı verilen atardamar, toplardamar ve kılcal damarın içinde dolaşan plazma ve hücresel kısımdan oluşan kırmızı renkli hayati bir sıvıdır. Yetişkin sağlıklı bir insanda kilosuna bağlı olmak kaydıyla ortalama 4-7 litre kan bulunmaktadır. Kanın %55'i sıvı, %45'i katı kısımdan oluşmaktadır (Tablo 3.1.).

Tablo 3.1. Kanın katı ve sıvı kısımları

Sıvı Kısım (Plazma)	Katı Kısım (Hücresel)
Su	Eritrosit
Şeker, protein	Lökosit
Kimyasal madde	Trombosit

3.1.2. Kan gruplama sistemleri

Literatürde kanı ayıran farklı gruplama sistemleri bulunmasına rağmen AB0 ve RhD gruplama sistemleri en yaygın kullanılanlardır. AB0 gruplama sistemlerinde kan; bileşeni olduğu eritrositin üzerinde yer alan antijen yapısına göre dörde ayrılmaktadır. Kan grubu adı verilen bu gruplar A,B, 0 ve AB olarak adlandırılmaktadır. Hasta veya yaralılara verilecek kan grupları kendi kan yapısına bağlı olarak değişmektedir. Tablo 3.2.'de kan grupları ile kan alıp verecekleri hasta-donör ilişkileri özetlenmiştir.

Tablo 3.2. AB0 kan gruplama sistemi

Eritrosit üzerindeki antijen yapısı	Kan grubu	Kimlere kan verir?	Kimlerden kan alır?
A	A	A, AB	A, 0
B	B	B, AB	B, 0
0	0	A,B, AB, 0	0
AB	AB	AB	AB, A, B, 0

RhD gruplama sisteminde ise D antijeninin varlığında kana pozitif (+), yokluğunda ise negatif (-) işaretleri verilmektedir. Böylece, tıp uzmanları tarafından sekiz ana kan tipi oluşturulmuştur. Bu kan grupları AB +, AB-, A +, A-, B +, B-, 0 + ve 0- 'dir.


3.1.3. Kan bankasının yürüttüğü faaliyetler

Ülkemizde, güvenli kan ihtiyacının karşılanması sorumluluğu ‘Sağlıkta Dönüşüm Programı’ kapsamında Türk Kızılay’ına verilmiştir. Kızılay bünyesinde bulundurduğu; kan bağış merkezleri, laboratuvarları, BKM’leri ve TM’leri ile kanının toplanması, test edilmesi, işlenip kan bileşeni haline getirilmesi ve tranfüzyon merkezlerine transfer edilmesini sağlamaktadır. Ülke genelinde 18 bölge kan merkezi, 67 kan bağış merkezi ve 300’den fazla mobil kan bağış aracı ile hizmet verir (www.kizilay.org.tr) Erişim tarihi: 19.03.2018.

Ülkemizde kan bankacılığı ve kan bileşenlerinin stoklanması hizmeti üç birimde verilmektedir. Bunlar;

- Bölge Kan Merkezleri
- Transfüzyon Merkezleri (Hastaneler)
- Kan Bağış Merkezleri’dir.

Şekil 3.1.’de kan bağışından kan bileşenlerinin nakline kadar gerçekleşen işlemler özetlenmiş ve kan bağışından hasta veya yaralılar için nakline kadar gerçekleştirdiği faaliyetler 6 ana başlıkta incelenmiştir.



Şekil 3.1. Kan bağıışı ve kan kullanım süreci


3.1.3.1. Kan bağıışı

Kan bağıışı; donör adı verilen gönüllü bağıışçılar tarafından hasta veya yaralı insanlarda kullanılmak üzere kan veya kan bileşenlerinin bir kısmının bağıışlanmasıdır. Kan bağıışı iki şekilde olabilir:

- Tam kan bağıışı
- Aferez işlemi

Tam kan bağıışında donörden $450 \pm \%10$ mL'lik kan bağıışı alınırken, aferez işleminde donör aferez cihazına bağlanarak kandan istenilen kan bileşeni alınıp geri kalan kan bileşenleri donöre tekrar geri verilmektedir.

Şekil 3.2.'de kan bankasına ait kan bağıış şeması yer almaktadır.



Şekil 3.2. Kan bankası bağış şeması


3.1.3.2. Kanın işlenmesi

Kan merkezleri A ve B tipi olmak üzere iki çeşittir. A tipi kan merkezlerinde daha geniş ölçüde kan alımı ve dağıtımı gerçekleştirilir. B tipi kan merkezlerinde ise daha dar kapsamlı işlemler gerçekleştirilir.

Kan bağış merkezlerinde donörün kan bağışı ile başlayan işlemler BKM'de devam etmektedir. BKM'de kanın işlenmesi ve stoklanması yapılmaktadır. BKM'ye gelen kan bağışları öncelikle karantinaya alınarak kan bağış torbasıyla aynı etiket numarasına sahip içerisinde kan örneği bulunan hortum laboratuara gönderilir.

Laboratuarda kanın nakle uygun olup olmadığının belirlenmesi için test ve kontroller gerçekleştirilir. Testlerden nakil için uygun sonucunu alan kan bağışları karantinadan çıkarılır ve hastalara nakil edilmek üzere işlenme aşamasına geçer.

İşlenme aşamasında kan; test ve işlemlerden sonra, transfüzyon kullanımı için hastanelere verilen eritrosit süspansiyonuna, taze donmuş plazmaya ve trombositlere ayrılır. Ayrılan her bir kan bileşeni için ayrı ayrı işlemler uygulanır (Şekil 3.3.). Son olarak kan bileşenleri stoklanma alanlarına gönderilir.



Şekil 3.3. Kan merkezlerinde gerçekleştirilen işlemler ve elde edilen kan bileşenleri

3.1.3.3. Kan bileşenlerinin stoklanması

Paketlenmiş taze gıda ve farmasötik ürünler gibi bozunabilir maddeler; sabit bir kullanım tarihine veya satış tarihine göre belirlenmiş bir raf ömrüne sahiptir (Hajjema, 2014). Kan bileşenleri de bileşenlerine ve içerisine konulan koruyucu kimyasallara göre farklı saklama sürelerine sahiptir. Kan bileşenlerinin raf ömrü büyük oranda

depolandıkları koşulların uygunluğuna bağlıdır. Uygunsuz saklama koşulları bakteri bulaşmasına veya kan bileşenlerinin etkinliklerinin kaybına neden olur. Tablo 3.3., kan bileşenlerinin farklı saklama koşullarını, saklama kimyasallarını ve raf ömrünü göstermektedir. Tabloda trombositlerin raf ömrü 5 ve eritrosit süspansiyonunun raf ömrü 42 gün olmasına rağmen gerekli testlerin tamamlanması ile kullanılabilir raf ömürleri sırasıyla 3 ve 35 güne düşmektedir. Bu süreden sonra kan bileşenleri transfüzyon için kullanılamazlar.

Tablo 3.3. Kan bileşenlerine ait saklama koşulları, sıvıları ve saklama süreleri

Kan bileşeni	Saklama koşulları	Saklama sıvısı	Saklama süresi
Eritrosit süspansiyonu	Buzdolabında 2–7 °C	Sitrat, Adenin	21-35 gün
Taze donmuş plazma	Buzdolabında (–18) – (–86) °C)	Sitrat	Çok uzun
Tam kan	Budolabında (2–7 °C)	Sitrat, Adenin	21-35 gün (42 gün)
Trombosit süspansiyonu	Trombosit karıştırıcısındaki tepsilerde (22–24 °C)	Sitrat	6-8 saat (sürekli hareketli)

Bu aşamada stoklar; serbest ve rezerve stok olmak üzere ikiye ayrılmaktadır. Rezerve stok belirli bir hasta veya yaralı için ayrılmış kan bileşeni stoğu iken; serbest stok herhangi bir uygun hasta için kullanılabilen kan bileşenleridir. Serbest stokta bulunan kan bileşenleri bölgede bulunan kan transfüzyon merkezlerine talep miktarları doğrultusunda dağıtılmaktadır.

3.1.3.4. Kan bileşenlerinin taşınması

TM olarak adlandırılan hastaneler kan tedarikini BKM'den sağlamaktadır. Kan bileşenleri, BKM'de bulunan kan bileşeni stoğu ve TM'den gelen talep miktarları göz önünde bulundurularak BKM'den TM'ye transfer edilmektedir. Kan bileşenleri TM'lerine özel kutularda, taşıma sıcaklığını izlemek amacıyla sıcaklık göstergeleri kullanılarak taşınmaktadır.

3.1.3.5. Kan bileşenlerinin nakli

Kan transfüzyonları nakilleri ameliyatlarda, doğumlarda, organ nakillerinde, kanser ve anemi gibi hastalıklar için tedavi gören hastalarda gereklidir (Wijayanayake ve

Dandunna, 2017). BKM'den TM'ye gelen kan bileşenleri hasta veya yaralıları AB0 ve RhD grupta sistemleri dikkate alınarak nakilleri yapılmaktadır.

Bazı durumlarda, donör ve hastanın kanları grupta sistemlerine göre uyumlu olmasına rağmen düzensiz antikorlar nedeniyle uyumsuzluk göstermektedir. Bu nedenle, kan transfüzyonlarından önce numuneleri çapraz eşleme (cross-match) ile karşılaştırılarak hasta kanı ve donör kan bileşeninin uyumluluk testlerini yapılmaktadır (Lang, 2010). Çapraz eşleme sonrası uygun görülmeyen nakiller yerine farklı çapraz eşlemeler uygulanmaktadır.

TM'lerde nakil sonrasında ileride oluşabilecek sorunlar için hastalara verilen kan bileşenleri ve donörlere ait bilgiler birlikte kayıt altına alınmaktadır.

3.1.3.6. Kan bileşenlerinin imha edilmesi

Kan bankalarında stok yönetiminin genel amacı yok satma ve imha arasındaki dengeyi kurmaktır. Böylece kullanım süresi nedeniyle imha edilen kan bileşeni miktarı minimumda tutulurken %100 kan temini sağlamak için yeterli stok bulundurulabilir.

Stokta bulunan kan bileşenlerinin son kullanım süresi tamamlanmadan veya yapısı bozulmadan hastalara nakil edilmesi gerekmektedir. Aksi takdirde kan bileşenleri imha edilmektedir. İmha nedenlerinden bazıları şunlardır:

- a. Kullanım süresinin dolması
- b. Cihaz ayırma hatası
- c. Torba kırılması, hatası
- d. Personel inceleme hatası
- e. Rezerveyken son kullanma süresi bitmesi
- f. Çeşitli enfeksiyon şüpheleri (HIV, sfiliz vb.)
- g. Düşük volüm (Kan torbasında 450 ±%10 ml'den daha az miktarda kan bulunması)
- h. Isınma

- i. Uygun olmayan kan bağıışı (ilaç kullanımı, pıhtılı kan)
- j. Kanın kalite standartlarını karşılayamaması (Yağlı plazma)

3.1.4. Kan bankasının uyguladığı stok yönetimi

Kan bankasının uyguladığı stok yönetiminde BKM'ler, TM'lerden belirli aralıklarla gelen kan bileşeni taleplerini elindeki kan stoğu miktarına bağlı olarak karşılamakla yükümlüdür.

TM'ler kan bileşeni talebinde bulunurken üç karar değişkenine ihtiyaç duymaktadır. Bunlar; maksimum cerrahi kan bileşeni istem çizelgesi (MCKBİÇ), kritik stok seviyesi ve TM'nin stoklarında bulunan kan bileşeni miktarlarıdır. MCKBİÇ, TM'nin klinikler bazında ihtiyaç duyduğu kan bileşeni miktarını gösteren bir çizelgedir. MCKBİÇ'deki miktarlar; kliniklerin istediği ve cerrahi işlemlerde kullanılacak çizelge miktarı olduğu için tamamının TM'ye gönderilmesi gerekmektedir. Tablo 3.4.'de bu çizelgenin bir örneği görülmektedir.

Tablo 3.4. Maksimum cerrahi kan bileşeni istem çizelgesi örneği

	Girişim	İşlem
Genel Cerrahi	Kolesistektomi	Kan grubu/Antikor tarama
	Eksploratif laparotomi	Kan grubu/Antikor tarama
	Karaciğer biyopsisi	Kan grubu/Antikor tarama
	Kolon rezeksiyonu	Çapraz karşılaştırma 2 ünite ES
Kalp ve Göğüs Cerrahisi	Anjioplasti	Kan grubu/Antikor tarama
	Açık kalp cerrahisi	Çapraz karşılaştırma 4 (+4) ünite ES
	Açık plevral/Akciğer biyopsisi	Kan grubu/Antikor tarama
Beyin Cerrahisi	Kraniyotomi	Kan grubu/Antikor tarama
	Menenjiyom	Kan grubu/Antikor tarama
	Kafa travması, Ekstradural hematoma	Çapraz karşılaştırma 4 ünite ES

Kan bileşeni talebi oluşturulurken kullanılan ikinci karar değişkeni ise kritik stok seviyesidir. TM'ler kan talebinde bulunurken MCKBİÇ yanı sıra kritik stok seviyesi

kadar fazladan kan bileşeni istemektedir. Kritik stok seviyesi TM tarafından hareketli ortalama ile belirlenip ilgili BKM'ye bildirilir. Kritik stok seviyesi hesaplanırken geçmiş 26 haftalık döneme ait transfüzyon sayıları çıkarılır ve bu sayıların haftalık olarak gruplara göre dağılım çizelgesi hazırlanır. Her grup için, en yüksek kullanım olduğu haftadaki sayı o grubun genel toplamından çıkartılır; kalan sayı 25'e bölünür. Böylelikle o kan grubu için haftalık kritik stok seviyesi hesaplanmış olur (Denklem 3.1).

$$KSS_i = \frac{\sum_{i=1}^{26} ES_i - \max ES_i}{25} \quad (3.1)$$

Denklemde yer alan KSS_i kan grubu için haftalık kritik stok seviyesini; ES ise talep edilen eritosit süspansiyonu miktarını göstermektedir. Tablo 3.5.'de küçük bir hastane için kritik stok seviye hesabının nasıl yapıldığı örnek olarak verilmiştir.

Tablo 3.5. Mevcut sistemde kritik stok seviyesinin belirlenmesi

Haftalar	0+	A+	B+	AB+	0-	A-	B-	AB-
1	4	2	-	2	1	1	-	-
2	-	6	6	-	-	2	-	3
3	10	-	-	2	-	-	-	1
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
26	5	2	3		5	4	2	-
Toplam transfüzyon	102	96	29	4	43	23	16	6
En yüksek hafta	20	13	6	2	9	8	2	3
Alt toplam	82	83	23	2	34	20	14	3
Kritik stok seviyesi	4	4	1	0	2	1	1	0

Kritik stok seviyesinin sürdürülebilirliği konusunda ilgili BKM ile TM'nin işbirliği yapması esastır. Bu işbirliğinin temelini, kan bileşeni israfını önleyecek ancak TM'nin ihtiyaçlarını karşılayacak önlemlerin alınması oluşturur.

Mevcut stok yönetiminde talep miktarını belirleyen son karar değişkeni ise TM'nin elinde bulunan stok miktarıdır. Talep miktarı, MCKBİÇ ve kritik stok seviyesinden TM'nin elindeki stok miktarının düşürülmesiyle oluşturulur. Özet olarak; TM'nin kan bileşenleri talep miktarı (D_{bc}), MCKBİÇ ile istenen kan bileşenleri miktarı SCC, kritik stok seviyesi KSS_i ve elde bulunan stok miktarı SA olmak üzere Denklem 3.2 ile hesaplanmaktadır.

$$D_{bc} = SCC + KSS_i - SA \quad (3.2)$$

3.2. Stok Ve Stok Yönetimi

Stok, işletmenin ihtiyaçlarını karşılamak üzere bulundurduğu bitmiş ürün, çeşitli düzeylerde tamamlanmamış parçalar, yarı mamuller veya hammaddeleri ifade etmek için kullanılan bir kavramdır (Küçük, 2009).

Stok yönetimi ise üretim veya hizmet üreten işletmenin maliyet etkinliğini ve üretim kapasitesini göz önünde bulundurarak müşteri ve üretim bölümlerinin, araç-gereç, ürün ve malzeme taleplerini karşılamak için gerekli miktarda stok bulundurmasıdır. Burada önemle dikkat edilmesi gereken konuların başında, fazla stoktan oluşan giderler ve stok yetersizliğinden dolayı oluşacak işletme zararlarıdır (Ayanoglu, 2006).

Stok yönetiminin en önemli bileşeni stok kontrolüdür. Stok kontrolünün sonucunda;

- Hangi maddeler stoklanmalıdır?
- Stok miktarları ne kadar olmalıdır?
- Stok için verilecek siparişler ne kadar olmalıdır?
- Stok için verilecek siparişler ne zaman yapılmalıdır? gibi sorulara cevap alınmaktadır.

Stok kontrolünün amacı stok maliyetini minimum yapacak stok miktarı ve sipariş zamanını belirlemektir. Bunun yanı sıra imha oranlarının da azaltılması diğer bir amaç olarak gösterilebilmektedir.

Stok modelleri sistemi etkileyen parametrelerin kesin olarak bilinip bilinmemesine göre deterministik ve stokastik olmak üzere iki grupta incelenebilmektedir. Sistemi etkileyen parametrelerin kesin olarak tahmin edilebildiği, tam ve belirlilik altında karar vermenin söz konusu olduğu durumlarda deterministik stok modelleri kullanılmaktadır. Gerçek hayatta çoğu zaman talebi, talebin oluşacağı zamanları, üretim miktarını ve sistemi etkileyen tüm parametreleri önceden kesin olarak belirlemek az rastlanılan bir durumdur.

Sistemdeki stoğu etkileyen parametrelerin önceden kesin olarak bilinmediği ancak olasılıklar çerçevesinde tahmin yapılabildiği durumda ise, stokastik stok modelleri kullanılmaktadır. Bu durumda, taleple ilgili bilginin; ne zaman ve ne kadar taleple, hangi olasılıkla karşılaşılabileceği belirlenmelidir. Gerçek hayatta stokastik stok modellerinin kullanılması stok yönetimi açısından daha etkili karar verilmesini sağlamaktadır.


3.2.1. Stokastik stok modelleri

Talebin stokastik olduğu varsayıldığında stok yönetimi stoğun gözden geçirilme sıklığına göre ikiye ayrılmıştır. Bu modeller sürekli gözden geçirme ve periyodik gözden geçirmedir. Taleplerin belirli aralıklarla sipariş edildiği periyodik gözden geçirme politikaları, operasyonel rahatlıkları nedeniyle oldukça popülerdir buna rağmen sürekli gözden geçirme politikalarının da, toplam maliyeti kontrol etmede periyodik gözden geçirme politikalarına kıyasla daha üstün olduğu gösterilmiştir (Lowalekar ve Ravichandran, 2017).

Literatürde sıklıkla yer alan sürekli gözden geçirmenin kullanıldığı (s,Q) ve (s,S) stokastik stok modelleri, periyodik gözden geçirmenin kullanıldığı (R,S) ve (R,s,S) stokastik stok modelleri mevcuttur. 's' yeniden sipariş noktası, 'Q' sabit sipariş miktarı, 'R' stok miktarının gözden geçirilme zamanı, 'S' en yüksek stok düzeyi olmak üzere stokastik stok modelleri aşağıda özetlenmiştir.

3.2.1.1. (s,Q) stokastik stok modeli

“Sipariş noktası-Sipariş miktarı” olarak adlandırılan (s,Q) stokastik stok modelinde stok, s düzeyine veya bu seviyenin altına indiğinde Q birim sipariş verilmektedir (Şekil 3.4.) (Hax ve ark., 1984).



Şekil 3.4. (s,Q) stok modeli (Hax, 1984)

(s, Q) stokastik stok modelinde; yeniden sipariş noktası (Denklem 3.3) ve sipariş büyüklüğü (Denklem 3.4) stoğun davranışını kontrol eden değişkenlerdir.

$$s = L_i^D + z \sigma_D \sqrt{l} \quad (3.3)$$

$$Q = \sqrt{\frac{2 C_o D_i}{C_h}} \quad (3.4)$$

Denklemlerde yer alan L_i^D tedarik zamanında oluşan talep (birim), z çevrime ait hizmet düzeyine standart normal dağılım tablosunda karşılık gelen değeri, σ_D talebin standart sapmasını (birim), l tedarik süresini (gün), C_o sipariş partisi başına sipariş maliyetini (para birimi /sipariş), D_i i. döneme ait talebi (birim), C_h ise birim başına dönemsel elde bulundurma maliyetini göstermektedir.


Bu modelde sürekli gözden geçirme söz konusu olduğundan $R = 0$ olarak alınmaktadır. Talebin değişken olduğu durumda sipariş verilen süreler de değişken olur. Bunun yanı sıra tedarikçinin durumuna ve diğer dış etmenlere bağlı olarak tedarik süresi de değişebilir. Modelin avantajı sipariş miktarının sabit bir değer almasıdır. Böylece

sürekli sipariş miktarı hesaplanmak zorunda kalınmaz. Modelin dezavantajı ise stok miktarının sürekli olarak gözden geçirilip kayıt altına alınmasıdır.

3.2.1.2. (s,S) stokastik stok modeli

(s,S) stok modelinde de stok miktarı s düzeyine veya bu seviyenin altına indiğinde stok seviyesi S düzeyine çıkana kadar Q_i miktarda sipariş verilmektedir (Şekil 3.5.) (Hax ve ark., 1984). (s,S) stokastik stok modelinde kullanılan s ve Q değerleri (s,Q) stokastik stok modelinde kullanılan Denklem 3.3 ve Denklem 3.4 ile hesaplanmaktadır. Ancak (s,S) stokastik stok modelinde Q değeri her dönem için ayrı ayrı hesaplanmalıdır. Modelde yer alan maksimum stok seviyesi (S) parametresi ise Denklem 3.5 ile ifade edilmektedir.

$$S = s + Q \quad (3.5)$$



Şekil 3.5. (s,S) stok modeli (Hax, 1984)

(s,S) stok modelinin dezavantajı stoğun sürekli kontrol edilmesi ve her sipariş verilğinde verilecek sipariş miktarının hesaplanması zorunluluğudur. Avantajı ise belirlenen stok seviyesi kadar stok tutulacağı için mevcut stok alanı yeterli olacaktır. Bunun yanı sıra stok tutma maliyeti de daha az olacaktır.


3.2.1.3. (R,S) stokastik stok modeli

Stok miktarının periyodik olarak gözden geçirildiği (R,S) stokastik stok modelinde her gözlem noktasında stok miktarı S düzeyine ulaşacak miktarda sipariş verilmektedir (Şekil 3.6.) (Hax ve ark., 1984).

3.2.1.4. (R,s,S) stokastik stok modeli

Modelde; stok miktarının kontrol edildiği her R birim zamanda, stok miktarı s düzeyine veya bu seviyenin altına indiyse stok miktarı S birim olana kadar Q_i miktar sipariş verilmektedir. Başka bir deyişle bu model, (R, S) stokastik stok modelinin genelleştirilmiş bir versiyonudur.

(s,S) stokastik stok modelinin $R=0$ olması veya (R,S) stokastik stok modelinin $s=S-1$ olması durumunda (R,s,S) stokastik stok modeli ifade edilmiş olur (Silver ve ark., 2001). Bu model; (s,S) ve (R,S) modellerinin bir araya getirilmesinden oluşmuş bir kombinasyondur. Şekil 3.7.'de (R,s,S) stok modeli görülmektedir (Hax, 1984).



Şekil 3.7. (R,s,S) stok modeli (Hax, 1984)

(R,s,S) stokastik stok modeli belirsiz talepler ve teslim süreleri olan stok sistemlerinde yaygın olarak kullanılmaktadır. (R,s,S) stokastik stok modelinde kullanılan gözden geçirme periyodu Denklem 3.9 ile, sipariş noktası Denklem 3.10 ile ve maksimum stok seviyesi Denklem 3.11 ile ifade edilmektedir.

$$R = D_{L+T} z \sigma_D \sqrt{l + T} \quad (3.9)$$

$$s = L_i^D + z \sigma_D \sqrt{l} \quad (3.10)$$

$$S = s + Q \quad (3.11)$$

Tablo 3.6.'da stokastik stok türlerine ait gözden geçirme, yeniden sipariş verme noktası ve verilen sipariş miktarları özetlenmiştir.

Tablo 3.6. Stokastik stok türlerine ait gözden geçirme, yeniden sipariş verme noktası ve verilen sipariş miktarları

Gözden geçirme	Stokastik stok modelleri	Yeniden sipariş verme noktası		Sipariş miktarı
Sürekli	s,Q	Stok miktarı s ve altında iken		Q
	s,S	Stok miktarı s ve altında iken		$Q_i = S - s$
Periyodik	R,S	Her R birim zamanda		$Q_i = S - \text{stok miktarı}$
	R,s,S	Her R birim zamanda	Stok miktarı s ve altında ise	$Q_i = S - \text{stok miktarı}$
			Stok miktarı s'den fazla ise	Sipariş verilmez

3.3. Yapay Zeka Tabanlı Tahmin Yöntemleri

Gerçek hayattaki büyük, karmaşık ve birbiri ile çelişen verilerin elle işlenmesi ve analiz edilmesi mümkün değildir. Bu nedenle makine öğrenmesini ve derin öğrenmeyi kapsayan yapay zekada bilgisayarlar, geçmiş verileri öğrenerek kendisine verilmeyen veya gelecekte oluşabilecek bilgileri tahmin edilmek üzere kullanılmaktadır.

Yapay zekanın alt dalı olan makine öğrenmesi, veriden yapı çıkaran ve bu yapıyı doğrulayan algoritmaları konu alır. Bu algoritmalar anlaşılması zor ve karmaşık olmamalarına rağmen, tamamen açık ve kolay algoritmalar da değildir (Witten ve ark., 2011).

Makine öğrenmesinde kullanılacak modeli kurmak için eğitim ve test aşaması olmak üzere iki aşama gereklidir. Eğitim aşamasında belirli miktarda eğitim verisi kullanılarak bir model oluşturulur. Bu aşamada kullanılan veri eğitim verisi olarak adlandırılır. Test aşamasında ise eğitim aşamasında oluşturulan modele test aşaması için ayrılan veya gelecekte toplanacak olan çıktı verileri sorulup tahmin etmesi beklenir. (Marsland, 2014).

Makine öğrenmesi eğitici öğrenme, eğiticişiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana başlık altında incelenmektedir. Eğitici öğrenmede veriler ve veriler sonucunda oluşan sonuçlar sisteme tek tek gösterilip sonuç bulması beklenmektedir. Literatürde en yaygın kullanılan eğitici öğrenme yöntemler Naive Bayes, destek vektör makineleri, karar ağaçları ve rassal ormanlar'dır. Eğiticişiz öğrenmede ise veriler sisteme hep birlikte verilir. Sistem bu verilerin arasındaki ilişkileri kullanarak kendini

eğitir. Eğiticişiz öğrenmede en yaygın kullanılan yöntem sınıflandırmadır. Pekiştirmeli öğrenmede ise karşılaştığı durumlara bağılı olarak öğrenen ve sonuçta doğru tahminleri maksimize etmeyi amaçlayan makine öğrenmesi yöntemidir.

Çalışma kapsamında; eğitici öğrenme yöntemleri olan gradyan artırma ağacı, destek vektör makineleri, karar ağaçları, rassal orman, yapay sinir ağı, ridge regresyon ve eğiticişiz öğrenme yöntemi olan derin öğrenme yöntemleri incelenmiştir.

3.3.1. Ridge regresyon

Hoerl ve Kennard (1970) tarafından geliştirilen ridge regresyon, çoklu doğrusal bağlantı durumunda en küçük kareler yönteminin yetersiz kalması nedeniyle geliştirilen etkili bir tahmin yöntemidir.

En küçük kareler yönteminde, regresyon katsayıları Denklem 3.12 kullanılarak tahmin edilir.

$$\hat{B} = (X'X)^{-1}X'Y \quad (3.12)$$

Değişkenler standartlaştırıldığında ise (Denklem 3.13)

$$X'X = R \quad (3.13)$$

şeklinde ifade edilir. Denklemlerde yer alan X bağımsız değişken matrisini, Y bağımsız değişkeni ve R bağımsız değişkenlerin korelasyon matrisini göstermektedir. Yöntemde bağımsız değişkenler arasında bağımlı ilişkiler varsa iki veya daha fazla değişken aynı özellikleri gösteriyor olabilir bu nedenle belirleme katsayısındaki (R^2) artış yanıltıcıdır. Bu durumda varyans artış faktörü (VIF) Denklem 3.14 kullanılarak modeli gerçekten etkileyen değişkenler belirlenmektedir.

$$VIF = \frac{1}{1 - R^2} \quad (3.14)$$

VIF değerinin 10'dan yüksek olması değişkenler arasında ciddi çoklu doğrusal bağlantı sorunu olduğunu göstermektedir (Pao, 2008; Hair ve ark., 2009; Vu ve ark., 2015). Bu durumun üstesinden gelmek için kullanılan yöntemlerden biri de ridge regresyondur.

Ridge regresyonda ise Denklem 3.13'de yer alan korelasyon matrisine k parametresi eklenerek tahmin yapılır (Denklem 3.15).

$$\tilde{B} = (X'X + kI)^{-1} X' y \quad 0 < k < 1, k \in R^+ \quad (3.15)$$

Denklemde yer alan $\tilde{B}$ ridge tahmincisini, X bağımsız değişken matrisini, k yanalılık katsayısını, I birim matrisini ve y bağımlı değişkeni ifade etmektedir. Literatürde optimum k değerinin seçimi için ridge regresyon grafiği (Ridge Trace) önerilmiştir (Hoerl ve Kennard, 1970).

Tahmin denklemindeki yanalılık miktarı Denklem 3.16 ile kovaryans matrisi ise Denklem 3.17 ile ifade edilmektedir.

$$E(\tilde{B} - B) = [(X'X + kI)^{-1} X'X - I] B \quad (3.16)$$

$$V(\tilde{B}) = (X'X + kI)^{-1} X'X(X'X + kI)^{-1} \quad (3.17)$$

Ridge regresyon adımları aşağıdaki gibi özetlenebilir:

- a1. Bağımlı ve bağımsız değişkenleri belirleme
- a2. Ridge tahmincisinde yanalılık değerini (k) belirleme
- a3. Ridge tahmincisi hesaplama (Denklem 3.15)
- a4. Tahmin denklemi oluşturma
- a5. a4'de oluşturulan tahmin denklemi kullanılarak tahmin etme

3.3.2. Gradyan artırma ağacı

Friedman (1999) tarafından geliştirilen gradyan artırma (iyileştirme) ağacı parametrik olmayan bir eğitici makine öğrenmesi algoritmasıdır (Ayar, 2015). Gradyan artırma

yöntemi; sıralı olmayan, kategorik bir hedefe sahip olan sınıflandırma problemleri ve sürekli ya da sıralı bir hedefe sahip olan regresyon problemleri için kullanılabilir. Gradyan artırma yöntemindeki öğrenme prosedüründe öncelikle basit bir regresyon modeli kurulur. Daha sonra bağımsız değişkenlerden daha doğru bir tahmin sağlamak için art arda yeni modeller oluşturulur ve güçlü bir model oluşturmak için zayıf öğrenmiş modellerden yararlanılır. Bu algoritmanın arkasındaki temel fikir, kayıp fonksiyonunun negatif gradyanı ile maksimum korelasyon gösterecek yeni temel öğrencileri inşa etmektir (Zhou ve ark., 2017). Başka bir deyişle sonraki tahminleri önceki tahminlerden daha az hata oranı ile oluşturmak amaçlanmaktadır. Hata oranının belirlenmesi için MSE istatistiksel performans kriterinin kullanıldığını varsayarsak (Boehmke ve Greenwell) kayıp fonksiyonu Denklem 3.18 ile hesaplanır.

$$L(y_i - y_i^p) = MSE = \sum (y_i - y_i^p)^2 \quad (3.18)$$

Denklemde yer alan $L(y_i - y_i^p)$ kayıp fonksiyonu, y_i i. hedef değerini ve y_i^p i. tahmin değerini göstermektedir.

Tahminlerin gerçekleşen değere yakın değer alması için Denklem 3.19 Denklem 3.20'ye dönüştürülüp kayıp fonksiyon minimum yapılmaktadır. Denklemlerde yer alan y_i^{np} i. yeni tahmin değerini, η öğrenme oranını, $\sum (y_i - y_i^p)$ hata oranları toplamını göstermektedir.

$$y_i^p = y_i^p + \eta \delta \frac{\sum (y_i - y_i^p)^2}{\delta y_i^p} \quad (3.19)$$

$$y_i^{np} = y_i^p - \eta 2 \sum (y_i - y_i^p) \quad (3.20)$$

Denklem 3.29 kullanılarak algoritma, önceden belirlenen maksimum yineme sayısına ulaşılan kadar yinelenmeye devam etmektedir ve bu süreçte modele eklenen karar ağaçları değiştirilmemektedir (Touzani ve ark., 2018).

Gradyan artırma yönteminin avantajı yinelemeli ve çoklu karar ağaçları yöntemlerinin performanslarının karşılaştırılmasıdır. Gradyan artırma tekniğinin en büyük dezavantajı ise “aşırı uyum” yani ezberleme riskinin çok olmasıdır (Golas ve ark., 2018). Bu da sistemin verilen örnekleri ezberlemesine; dolayısıyla eğitim başarı oranının yüksek olmasına rağmen test başarı oranının düşük çıkmasına neden olur.

Gradyan artırma yönteminin performansı; algoritma tarafından gerçekleştirilen maksimum iterasyon sayısına (Nrounds), öğrenme oranını kontrol eden parametreye (η), ağacın yaprak düğümünde başka bir bölüm gerçekleştirmek için gereken minimum azalmaya (γ), örnek büyüklüğü belli bir eşiğin altına düştüğünde bir düğümün bölünmesini önleyen parametreye (MCW), her bir ağacın ağırlık tahmini üzerindeki değere (MDS) ve eğitim ve test örnekleri arasındaki oranını gösteren parametre (SR) seçimine bağlıdır (Nieto ve ark., 2018).

Gradyan artırma ağaç yönteminin adımları aşağıdaki gibidir:

- a1. Rassal başlangıç parametre değerlerini (Nrounds, η , γ , MCW, MDS, SR) belirleme
- a2. Gradyan artırma ağacını eğitme ve doğrulama
- a3. Kayıp fonksiyonunu hesaplama
- a4. Sonlandırma kriterlerine uyup uymadığını sorulama
 - a4.1. Uyuyor ise adımları sonlandırma
 - a4.2. Uymuyor ise Nrounds, η , γ , MCW, MDS, SR değerlerini değiştirme ve a2 adımına geri dönme

3.3.3. Derin öğrenme

Derin öğrenme, girdiler veya gözlenen özellikler ile sonuç arasındaki ilişkileri eşleştirmek için çok katmanlı (derin) bir mimarinin kullanıldığı yapay zeka dalıdır. Bu derin mimari, derin öğrenmeyi çok sayıda değişkeni işlemek için özellik ile uygun hale getirir ve özellik geliştirmenin ayrı bir adım olması yerine, derin öğrenmenin genel öğrenme algoritmasının bir parçası olarak özellikler üretmesini sağlar.

Derin öğrenme metotları basit fakat doğrusal olmayan modüller bir araya getirerek elde edilen çoklu öğrenme metodlarıdır. Derin öğrenme, yapay zeka metodlarının

sorunlarının çözümünde büyük ilerlemeler kaydetmektedir. Yüksek boyutlu verilerdeki karmaşık yapıların keşfedilmesinde çok iyi olduğu için birçok bilim, işletme ve idare alanında kullanılmıştır (LeCun ve ark., 2015). Derin öğrenmenin özellikle görüntü ve konuşmayı tanıma gibi doğal dil işleme alanlarında etkili olduğu kanıtlanmıştır (Wiley, 2016).

Derin öğrenme yapısal olarak, tümü (veya çoğu) öğrenmeye tabi olan ve çoğu doğrusal olmayan giriş-çıkış eşlemelerini hesaplayan çok katmanlı basit modül yığındır. (LeCun ve ark., 2015). Derin öğrenme yapısında yer alan katmanlar ve bu katmalarda yapılan işlemler şu şekildedir:

- a. Konvolüsyon katmanında filtre kullanılarak görüntü matrisinden daha küçük boyutlu yeni bir görüntü matrisi elde edilir. Örneğin; 5 x 5'lik oluşturulan 3 adet görüntü matrisi, kullanılan 3 x 3'lük filtre matrisi ile 1 x 1'lik görüntü matrisine dönüştürülmüştür (Şekil 3.8.).

Görüntü matrisi

2	3	5	2	6
7	2	4	4	9
8	3	2	1	7
2	9	5	2	5
9	1	5	7	4

3	4	2	3	8
8	3	5	1	5
2	4	3	2	4
3	8	6	5	3
5	3	6	3	8

5	3	2	2	6
8	2	5	3	7
9	3	2	5	3
7	3	3	4	6
8	4	6	5	7

Kullanılan filtre

1	0	-1
0	1	1
1	-1	0

Yeni görüntü matrisi

	28	

Şekil 3.8. Konvolüsyon katmanında yeni görüntü matrisi oluşturulması

Filtre sonucu oluşan yeni görüntü matrisi; eski görüntü matrisinde seçilen 3 x 3'lük matrisin ve filtre matrisinin ayrı ayrı çarpılıp toplanması ile oluşturulmuştur (Denklem 3.21- Denklem 3.24).

$$X = 1x3 + 0x5 + \dots + (-1)x2 + 0x1 \quad (3.21)$$

$$Y = 1x4 + 0x2 + \dots + (-1)x3 + 0x2 \quad (3.22)$$

$$Z = 1x3 + 0x2 + \dots + (-1)x2 + 0x5 \quad (3.23)$$

$$X + Y + Z = 10 + 8 + 10 = 28 \quad (3.24)$$

- b. Havuzlama katmanında $N \times N$ boyutundaki görüntü matrisi daha küçük $n \times n$ boyutundaki matrislere ayrılır. $n \times n$ boyutundaki en büyük değerler alınarak yeni görüntü matrisi oluşturulur. Örneğin; Şekil 3.9.'da 4×4 'lük boyuta sahip görüntü matrisi, havuzlama işleminde 2×2 'lik boyutlara ayrılıp bu matris içinde en büyük değerler seçilerek havuzlama sonucu oluşan yeni görüntü matrisi elde edilmiştir.

Görüntü matrisi

8	5	6	2
4	2	4	3
8	7	6	7
5	5	2	3

Havuzlama işlemi

8		6	
8			7

Havuzlama sonucu oluşan yeni görüntü matrisi

8	6
8	7

Şekil 3.9. Havuzlama katmanında yeni görüntü matrisi oluşturulması

- c. Tam bağlantılı katmanda her nöron kendinden sonra gelen nöronla bağlanır. Bu sebeple tam bağlantılı katman olarak adlandırılır.
- d. Düzleştirilmiş doğrusal birim katmanı (RELU) aktivasyon işleminin gerçekleştiği katmandır. Literatürde hiperbolik tanjant, sinüs, step, eşik gibi aktivasyon fonksiyoları bulunsu da derin öğrenmede sıklıkla kullanılan aktivasyon fonksiyonu Denklem 3.25'de yer alan maksimum aktivasyon fonksiyonudur (Yang ve ark. 2015).

$$f(x) = \max(0, x) \quad (3.25)$$

- e. Dropout katmanı, yapısında bulunan bazı düğümleri kaldırarak aşırı öğrenme adı verilen ezberlemenin önüne geçen katmandır.

- f. Normalizasyon katmanı ağı performansını arttırmak için girdi ve çıktı verilerine ait değerlerin belirli bir aralıkta temsil edilmesini sağlamaktadır. Literatürde sıklıkla kullanılan ‘Min-max normalizasyon’ denklemi Denklem 3.26’da verilmiştir.

$$X^i = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.26)$$

- g. Entropi katmanı ise her bir veri için 0 ile 1 arasında değerler üretilir. Bu aşamada 1’e yakın olan değerler incelenen verinin sınıfını ifade etmektedir.

Derin öğrenmenin, makine öğrenmelerinden avantajlı olduğu bazı konular vardır. Bunlar; birçok katmanda kullanılan hesapları tek bir seferde yapabilmesi, makine öğreniminde tanımlamanız gereken parametreleri bile kendisinin keşfetmesi ve daha iyi parametreler ile değerlendirmelerde bulunabilmesidir <http://industryolog.com/deeplearning/> (Erişim tarihi: 17 Eylül 2019). Derin öğrenmenin dezavantajı ise aşırı uyum sorunu riskinin olmasıdır (Golas ve ark., 2018).

Derin öğrenme çalışma adımları şu şekilde özetlenebilir:

- a1. Derin öğrenme ile çözümünün uygunluğunu tespit etme
- a2. Veri setini; eğitim ve test verisi olarak ayırma ve normalizasyon katmanında analiz için normalize etme
- a3. Uygun derin öğrenme mimarisini (filtreleme, havuzlama, düzleştirilmiş doğrusal birim katmanları gibi) belirleme
- a4. Eğitim veri setini kullanarak sistemi eğitme
- a5. Entropi katmanı kullanılarak verinin sınıfını belirleme
- a6. Test veri setinin performansını test etme

3.3.4. Karar ağaçları

Karar ağacı çok sayıda kriter içeren bir veri kümesini bir dizi karar kuralları uygulayarak benzer kriterlere sahip verileri aynı sınıfa veya tahmine ulaştırmayı

amaçlayan bir yöntemdir. Basit, hızlı ve yapısal olarak bir ağaca benzeyen özelliğinden dolayı kolay anlaşılabilir sonuçlar verdiği için en popüler makine öğrenme yöntemlerinden biri olarak kabul edilmektedir (Borgelt ve ark., 2006). Ancak karar ağaçlarının bazı dezavantajları vardır. Bunlardan ilki; verinin yapısına bağlı olarak karmaşık karar ağaçlarının oluşturulmasıdır. Bu durumda dallanmanın takibi ve sonuçların yorumlanması zorlaşmaktadır. Bununla birlikte karar ağaçlarında aşırı uyum söz konusudur. Ayrıca karar ağacı çok fazla özelliğe dağılmış olan bilginin sadece sınırlı bir bölümünü ele alır. Bu da optimum tahmin doğruluğunun altına düşülmesine yol açar (Borgelt ve ark., 2006). Karar ağacının diğer dezavantajı ise kayıp veriye izin vermemesidir.

Literatürde karar ağaçları için 2 farklı şekilde algoritma geliştirilmiştir. Bu algoritmalarındaki en önemli adım; kök düğümlerden itibaren bütün düğümlerin hangi kritere göre ve nasıl bölüneceğine karar vermektir (Breiman ve ark, 1984). Bu nedenle entropi, Gini katsayısı ve bilgi kazancını baz alan katkı değerleri hesaplanmaktadır.

a. Entropiye dayalı algoritmalar

Entropi; olayların ortaya çıkmasıyla ilgilenen ve 0 ile 1 arasında değer alan belirsizlik ölçüsüdür. Entropi değerinin 0'a yaklaşması belirsizliğin azalmasına, 1'e yaklaşması belirsizliğin artmasına neden olmaktadır (Denklem 3.27). Entropi değeri; kategorik verilerde kullanılan ID3 algoritması ve nümerik özelliğe sahip verilerde kullanılan C4.5 algoritması için uygundur. Karar ağaçlarının kök düğümüne en az entropi değerine sahip kriter ile başlanılmaktadır.

$$H = - \sum p(x) \log p(x) \quad (3.27)$$

Denklemde yer alan H entropiyi, p(x) belirli bir sınıfa ait grubun yüzdesini göstermektedir.

b. Regresyon ağaçları (CART)

CART algoritmasında oluşturulan dallardaki değişkenlerin katkı değerlerinin belirlenmesi için de Gini katsayısı kullanılmaktadır (Denklem 3.28).

$$Gini\ katsayısı = \frac{f(C_i, T)}{|T|} \quad (3.28)$$

Denklemden, T eğitim setini, C_i i. sınıfı göstermektedir.


Literatürde sıklıkla karşılaşılan CART algoritmaları; her düğümde ağacın ikiye ayrıldığı Twoing algoritması ve Gini algoritmasıdır (Han ve ark., 2012).

Bunun yanı sıra ID3, C4.5 ve CART algortimalarında kullanılan ve değişken etkinliğini ölçen bir diğer gösterge de bilgi kazancıdır. Karar ağacında veri kümesinde bilgi kazancının maksimum olduğu değişken ile dallanmaya başlanılır (Denklem 3.29).

$$Bilgi\ kazancı(S, D) = H(S) - \sum_{V \in D} \frac{|V|}{|S|} H(V) \quad (3.29)$$

Denklemden yer alan S orijinal veri kümesini, D kümenin bölünmüş bir parçasını ve V de S'nin bir alt kümesini göstermektedir.

Şekil 3.10.'da karar ağacı örneği görülmektedir.



Şekil 3.10. Karar ağacı örneği

Karar ağacı algoritması aşağıdaki gibi özetlenebilir.

- a1. İncelenen düğümdeki her bir A niteliği için öğrenme kümesi oluşturma
- a2. Öğrenme kümesindeki örnekleri en iyi ayıran niteliği entropi, bilgi kazancı gibi göstergeler kullanarak belirleme
- a3. Seçilen nitelik ile ağacın bir düğümünü ve bu düğümden çocuk düğümleri veya ağacın yapraklarını oluşturma
- a4. Çocuk düğümlere ait alt veri kümesinin örneklerini belirleme
- a5. a3'de oluşturulan her alt veri kümesi için örneklerin hepsi aynı sınıfa ait olup olmadığının veya örnekleri bölecek nitelik kalıp kalmadığının veya kalan niteliklerin değerini taşıyan örnek olup olmadığının araştırılması
 - a5.1. Yoksa adımları sonlandırma
 - a5.2. Varsa a2 adımına geri dönme

3.3.5. Destek vektör makinesi


Vapnik ve Chervonekis tarafından 1960'lı yılların sonunda geliştirilen destek vektör makineleri (DVM), yapısal risk minimizasyona göre çalışan en popüler, en sağlam ve en yaygın olarak kullanılan eğitici bir yapay zeka yöntemidir (Smola ve Schölkopf, 2004; Basak ve ark., 2007). Yapısal risk minimizasyonu, geleneksel makina öğrenme yöntemlerinde kullanılan deneysel risk minimizasyonunun aksine çok sayıda eğitim verisi zorunluluğu, yerel minimuma takılma, düşük yakınsama oranı ve aşırı uyum sorunlarının üstesinden gelmektedir (Vapnik ve ark., 1996).

DVM yönteminin temel amacı bilinmeyen veya test için ayrılmış veriler ile karşılaşıldığında sınıflama veya tahmin hatasını en küçük yapacak düzlemi veya hiperdüzlemi seçmektir.


DVM, regresyon ve sınıflandırma problemlerinde yaygın olarak kullanılmaktadır. DVM, çeşitli uygulamalarda diğer birçok yapay zeka tabanlı yöntemlere göre daha iyi performans göstermiştir (Cristianini ve Shawe-Taylor, 2000). DVM çalışma prensibi olarak yapısal risk minimizasyonu sağlayarak genelleme hatasını iyileştirmeye çalışır (Smola ve Schölkopf, 2004). DVM'nin en önemli avantajı, sınıflandırma problemini

kareli optimizasyon problemine dönüştürüp çözmesidir. Böylece problemin çözümüne ilişkin öğrenme aşamasında işlem sayısı azalmakta ve diğer teknik/algoritmalarla göre daha hızlı çözüme ulaşılmaktadır (Osowski ve ark., 2004). Bunun yanı sıra karmaşık ve doğrusal olmayan tahminleri gerçekleştirmede oldukça güçlüdür.

DVM veri setinin doğrusal ayrılma (Şekil 3.11.) veya ayrılmamasına (Şekil 3.12.) göre iki durumda incelenmektedir. Doğrusal DVM, girdi alanı ile sayısal çıktı alanı arasındaki eşlemeyi tanımlamak için n boyutlu düzlem kullanır. Buna karşılık, doğrusal olmayan DVM'ler genellikle daha yüksek boyutlu hiperdüzleme sahiptir.




Şekil 3.11. Doğrusal DVM



Şekil 3.12. Doğrusal olmayan DVM

Doğrusal DVM'de veri setini ayıran karar doğrusu yeni eklenecek veriyi de inceleyebilmesi için her sınıfın sınır çizgilerine en uzak noktada olması gerekmektedir (Şekil 3.13.).



Şekil 3.13. Doğrusal destek vektör makinesi

Bu nedenle Şekil 3.15.'de $Z_2 > Z_1$ olduğu için destek vektör makinesi eğrisi olarak Z_2 'nin ortasında yer alan eğri seçilmiştir. Destek vektör makinesi eğrisi Denklem 3.30'la ifade edilmektedir (Theodoridis ve Koutroumbas, 2003).

$$g(\vec{X}) = \vec{w}^T \vec{X} + w_0 \quad (3.30)$$

Denklemde yer alan $\vec{w}^T$ ağırlık vektörünü, w_0 eşik değerini göstermektedir.

Örnek olarak düzlemin iki ayrı sınıfı tahmin ettiği düşünülürse Denklem 3.31 ve Denklem 3.32 kullanılarak toplam uzaklık hesaplanır.

$$g(\vec{X}) \geq +1 \quad \forall \vec{X} \in \text{sınıf 1} \quad (3.31)$$

$$g(\vec{X}) \leq -1 \quad \forall \vec{X} \in \text{sınıf 2} \quad (3.32)$$

Şekil 3.15.'de görüldüğü gibi Z_2 'nin destek vektör makinesi eğrisine olan uzaklığı eşit ve Denklem 3.33 kadardır.

$$Z = \frac{|g(\vec{X})|}{\|\vec{w}\|} = \frac{1}{\|\vec{w}\|} \quad (3.33)$$

Toplam uzaklık ise Denklem 3.31- Denklem 3.33 kullanılarak elde edilir (Denklem 3.34).

$$\frac{1}{\|\vec{w}\|} + \frac{1}{\|\vec{w}\|} = \frac{2}{\|\vec{w}\|} \quad (3.34)$$

Denklem 3.35'in minimize edilmesi aynı zamanda iki sınıf arasındaki ayrılabilirliği maksimize etmektedir. Böylece destek vektör makinesinin tahmin doğruluğu artmış olur. Doğrusal DVM'de en iyi ayırıcı denklemi bulmak için Denklem 3.36 kullanılmaktadır ve denklem 2. dereceden eşitsizlik kısıtlı doğrusal olmayan optimizasyon problemidir. Bu nedenle Lagrange çarpanları ile çözülmektedir (Denklem 3.37). Denklemde yer alan α_i pozitif Lagrange çarpımını ifade etmektedir.

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (3.35)$$

$$y_i(w^t x_i + b) \geq 1, \quad \forall_i \quad (3.36)$$

$$L_p = \frac{1}{2} w^t w - \sum_{i=1}^n \alpha_i y_i (w^t x_i + b) + \sum_{i=1}^n \alpha_i \quad (3.37)$$

Sınıfları ayıracak karar fonksiyonu ise Denklem 3.38 kullanılarak elde edilmiştir.

$$f(x) = \sum \alpha_i y_i x_i x + b \quad (3.38)$$

Doğrusal olmayan DVM’de ise doğrusal hiperdüzlemi çizmek imkânsız hale gelir. Başka bir deyişle karmaşık verinin düz bir düzlemle ayrılması mümkün olmaz. Bu nedenle doğrusal olmayan sınıflar arasındaki en iyi sınırı bulabilmek için veri, orijinal giriş uzayından daha yüksek boyutlu bir uzaya haritalama fonksiyonu (Φ) kullanılarak taşınır (Cortes ve Vapnik, 1995) (Denklem 3.39).

$$x \in R^n \rightarrow (x) \Phi \in R^f \quad (3.39)$$

Doğrusal olmayan DVM; yüksek boyutlu uzayda doğrusal DVM gibi çalışarak verileri ayıran optimum hiperdüzlemi arar. Bu durumda Denklem 3.38’de yer alan karar fonksiyonunda sadece x yerine $\Phi(x)$ kullanılır (Denklem 3.40).

$$f(x) = \left(\sum \alpha_i y_i \Phi(x_i)^T \Phi(x_j) + b \right) \quad (3.40)$$

Ancak denklemde yer alan $\Phi(x)$ haritalama fonksiyonunu elde etmek genellikle zordur. Bu nedenle haritalama işlemini yapabilmek için çekirdek fonksiyonlarından yararlanılır. Literatürde sıklıkla kullanılan çekirdek fonksiyonları Denklem 3.41- Denklem 3.44’de gösterilmiştir. Formüllerde yer alan C çekirdek değeri, d polinom derecesini ve γ çekirdek boyutunu göstermektedir.

$$\text{Doğrusal fonksiyon} \quad C(x_i, x_j) = x_i^T x_j \quad (3.41)$$

$$\text{Polinomiyal fonksiyon} \quad C(x_i, x_j) = (x_i x_j)^d \quad (3.42)$$

$$\text{Sigmoid fonksiyon} \quad C(x_i, x_j) = \tanh k x_i x_j - \delta \quad (3.43)$$

$$\text{Radyal tabanlı fonksiyon} \quad C(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma \geq 0 \quad (3.44)$$

Destek vektör makinasının adımları aşağıdaki gibi özetlenebilir.

- a1. Eğitim seti ve çapraz doğrulama setini rassal olarak alt örneklem gruplarına ayırma
- a2. C ve σ parametre değerlerini ayarlama
- a3. Destek vektör makinasını eğitme
- a4. Çapraz doğrulama seti modelini değerlendirme
- a5. Model performans tahmincisinin en yüksek değeri alıp almadığını kontrol etme
 - a5.1. En yüksek değeri aldıysa model ve parametre değerlerini saklama
 - a5.2. En yüksek değeri almadıysa parametre değerlerine ait tüm kombinasyonların bitip bitmediğini kontrol etme
 - a5.2.1. Bitti ise Bulunan parametre değerlerine ince ayar yapma
 - a5.2.2. Bitmedi ise a2'e gitme

3.3.6. Rassal orman

Rassal orman temeli birden çok karar ağacının birleştirilmesine dayanan ve Leo Breiman tarafından geliştirilen bir makine öğrenmesi yöntemidir (Breiman, 2001). Rassal ormanlar ayrı ayrı eğitilmiş karar ağaçları topluluğudur (Ramanathan ve ark., 2017) .

Rassal orman hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Bunun yanı sıra yeterli ağaca sahip olması durumunda aşırı uyum sorununun üstesinden gelmektedir. Ayrıca eksik değerlerde de çalışabiliyor olması en büyük avantajlarından biridir.

Rassal orman oluşturulurken iki önemli parametre belirlenmelidir (Pal, 2005). Bunlardan ilki her bir düğümde kullanılan nitelik (değişken) sayısını belirten M değeridir. Başlangıçta M değeri araştırmacılar tarafından rassal olarak belirlenebilir

de Denklem 3.45'in kullanılması öngörülmüştür (Breiman, 2001). M değeri rassal orman için oluşturulan tüm ağaçlarda sabit değer almalıdır. Denklemde yer alan N değeri ise toplam nitelik sayısını ifade etmektedir.

$$M \leq \sqrt{N} \quad (3.45)$$

Önemli olan ikinci değişken ise oluşturulacak ağaç sayısıdır. Literatürde en uygun ağaç sayısının deneme yanılma yöntemiyle bulunduğu görülmektedir. Optimum parametreler; hata oranlarının en az olduğu kombinasyon olarak belirlenmektedir.

Rassal orman yönteminde de karar ağacında olduğu gibi bölünme işlemlerinde homojen dağılıma sahip düğümler tercih edilmektedir. Homojenliğin sağlanabilmesi için rassal ormanda gini indeksini kullanmaktadır. Verilen bir eğitim veri setinde rassal bir örnek için hesaplanan Gini indeksi Denklem 3.46 ile ifade edilir.

$$\sum_j \sum_{i \neq j} \left(\frac{f(C_i, T)}{|T|} \right) \left(\frac{f(C_j, T)}{|T|} \right) \quad (3.46)$$

Denklemde yer alan $\frac{f(C_i, T)}{|T|}$ ifadesi T eğitim setindeki seçilen örneğin C_i sınıfına ait olma olasılığını ifade etmektedir. Gini indeksi azaldıkça dalın homojenliği artacağı için; bir alt düğümün Gini indeksi bir üst düğümün Gini indeksinden daha az olduğunda o dal başarılı kabul edilir. Gini indeksi sıfıra ulaştıkça ağaç dallanma işlemi sonlanır (Watts ve ark., 2011).

Rassal orman yönteminde yer alan ağaçlarda oluşan tahminlerin ortalaması alınarak ortalama bir tahmin üretilir. Tahminlerde kullanılan eşitlik; amaç fonksiyonu öklidyen ise Denklem 3.47 ile, öklidyen değilse Denklem 3.48 ile hesaplanmaktadır. Denklemlerde yer alan P_{ort} ortalama tahmin değerini, P_i i. ağaca ait tahmin değerini, α öklidyen olmayan ortalama tahmin değerini ve t_i i. ağacın eğim açısını ifade etmektedir.


$$P_{ort} = \frac{\sum_{i=1}^N P_i}{N} \quad (3.47)$$

$$\alpha = \text{atan} 2 \left(\frac{1}{N} \sum_{i=1}^N \sin t_i, \frac{1}{N} \sum_{i=1}^N \cos t_i \right) \quad (3.48)$$

Rassal orman yönteminin adımları şu şekilde özetlenebilir.

- a1. Toplam N tane niteliğin içerisinde M tane nitelik seçme
- a2. N nitelik arasından en iyi ayırma noktasını kullanarak düğümü hesaplama
- a3. a1'de oluşturulan düğümü çocuk düğümlere ayırma
- a4. T düğüm sayısına ulaşılan kadar a1. ve a3. adımlarını tekrarlama
- a5. n tane ağaç oluşturmak için n kere a1. ve a4. adımlarını tekrarlama

Şekil 3.14.'de karar ağacında verilen örneğin rassal orman yöntemine dönüştürülmüş hali gösterilmektedir.




Şekil 3.14. Rassal orman örneği

3.3.7. Yapay sinir ağı

Yapay sinir ağı (YSA) yöntemi son zamanlarda yaygın olarak kullanılan makine öğrenme yöntemlerinden biridir (Ho ve Chang, 2011). Yapay sinirler ya da ağ olarak adlandırılan yoğun ölçüde birbirine bağlanmış uyarlanabilir basit uygulama

elemanlarından oluşmuş yapılar, paralel bilgi işleme sistemleri olarak da tanımlamak mümkündür (Basheer ve Hajmeer, 2000).

YSA çalışma prensibi olarak eğitim aşamasında öncelikle olayların örneklerine bakar, genelleştirme yapar ve bilgi toplar. Test aşamasında ise daha önce hiç görmediği veya gelecekte oluşabilecek çıktı tahmini yapmaktadır. YSA'nın yapısı Şekil 3.15.'de gösterilmiştir.



Şekil 3.15. YSA yapısı

Temel görevi kendisine girdi olarak gösterilen veri setine karşılık gelen çıkış kümesini tahmin etmek olan YSA biyolojik sinir ağlarından ilham alan bir bilgi işlem sistemidir. YSA'nın avantajlarından bazıları; hatalara karşı toleranslı olması, çevresel değişime adapte olabilmesi, eksik bilgi ile çalışabilmesi ve belirsizlik altında karar verebilmesidir. Bu nedenle doğrusal olmayan, karmaşık ve belirsiz ilişkilerin belirlenmesi gereken stokastik durumlarda kullanılabilmektedir.

Yapay sinir ağının dezavantajı ise ağın bilgisinin bağlantı ağırlıklarında ve eşik değerlerinde depolandığı için yaptığı hesaplamaların yorumlanamaz olmasıdır (Borgelt ve ark., 2006).

YSA'nın 5 temel ögesi bulunmaktadır:

- a. Girdiler yapay sinir ağına dış dünyadan gelen bilgileri ifade etmektedir. Bir yapay sinir hücresine dış dünyadan olduğu kadar başka hücrelerden ve kendi kendisinden de bilgilerin gelmesi mümkündür (Öztemel, 2016). Girdi değerleri işlem hızını ve tahmin doğruluğunu arttırmak için normalize edilerek ağa gönderilmektedir. Literatürde sıklıkla kullanılan normalizasyon 'Min-Max Normalizasyon'udur (Denklem 3.49).

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.49)$$

- b. Ağırlıklar ($w_1, w_2, \dots, w_i$) her girdi değeri için ayrı ayrı belirlenir. Ağırlıklar; yapay hücreye gelen bilginin önemini ve hücre üzerinde etkisini gösterir. Ağırlıkların büyük veya küçük olması girdinin önemli veya önemsiz olduğunu göstermez. Buna rağmen ağırlıkların artı veya eksi olması etkisinin pozitif veya negatif yönde olduğunun göstergesidir (Öztemel, 2016).
- c. Toplama fonksiyonu ağırlıklandırılmış girdi değerlerini eşik değeri ile toplayarak hesaplanmaktadır. Toplama fonksiyonu sonucu net girdi olarak adlandırılır. Literatürde en çok kullanılan toplama fonksiyonu ağırlıklı toplama fonksiyonudur (Denklem 3.50). Bu fonksiyonların dışında çarpım, maksimum, minimum, çoğunluk ve birikimli toplama fonksiyonu bulunmaktadır.

$$\text{Net Girdi} = \sum_{i=1}^N X_i * v_{ij} \quad (3.50)$$

Denklemde yer alan X_i , i. giriş verilerini; v_{ij} , giriş ile gizli katman arasındaki ağırlığı temsil eder. Bir problemde kullanılacak en uygun toplama fonksiyonunu genellikle deneme yanılma yolu ile belirlenir (Öztemel, 2016).

- d. Aktivasyon fonksiyonu ile hücreye gelen net girdi işlenerek hücrenin bu girdiye karşılık üreteceği çıktı belirlenir. Literatürde yaygın olarak kullanılan

aktivasyon fonksiyonları Lineer (Denklem 3.51), Sigmoid, Hiperbolik, Step, Sinus, Eşik değeri ve Gaussian'dır. Denklemde yer alan x proses elemanına gelen net girdiyi ifade etmektedir.

$$F(x) = x \quad (3.51)$$

e. Çıktılar aktivasyon işlevi sonucunda belirlenip çevreye veya diğer sinir hücresine gönderilen değerleri ifade etmektedir.

YSA'na ait süreç adımları şu şekilde özetlenebilir:

- a1. Girdi değişkenlerini belirleme ve normalize etme
- a2. Çıktı değişkenlerini belirleme ve normalize etme
- a3. Veri setini üçe ayırma (Eğitim, doğrulama, test verisi)
- a4. Öğrenme algoritmasını belirleme
- a5. Yapay sinir ağını eğitme
- a6. Ağırlıkları ve yanlılık değerini rassal olarak belirleme
- a7. Katman sayısını belirleme
- a8. Diğer ANN parametrelerini belirleme
- a9. Ağı doğrulama
- a10. Hedefe ulaşıp ulaşılmadığının kontrol etme
 - a10.1. Ulaşıldıysa ağı test etme
 - a10.2. Ulaşılmadıysa a7'ye geri dönme

3.4. Taguchi Deney Tasarımı

Deney tasarımı; analiz edilecek problemin karar değişkenlerine ait seviye değerlerinin önceden belirlenmiş bir tasarım matrisine göre sistematik olarak değiştirilerek deneylerin yapılıp, sonuçların kaydedilmesidir. Yaygın bir deney tasarımı yöntemi olan Taguchi yöntemi, geleneksel deney tasarımından farklı olarak daha az deneyle kısa sürede ve az maliyetle uygun sonuçlara ulaşmaktadır.

Deney tasarımında sisteme ait performans sinyal-gürültü (S/N) oranı adı verilen performans göstergesi ile ölçülmektedir. Sistemin hedeflenen amacına bağlı olarak üç

farklı sinyal-gürültü oranı mevcuttur. S/N oranları sırasıyla en büyük en iyi, en küçük en iyi ve nominal en iyi olarak tanımlanmaktadır (Denklem 3.52-3.54).

$$SN = -10 \log \left(\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right) \quad (3.52)$$

$$SN = -10 \log \left(\frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (3.53)$$

$$SN = -10 \log \left(\frac{1}{n} \sum_{i=1}^n \frac{\bar{y}^2}{S^2} \right) \quad (3.54)$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (3.55)$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 \quad (3.56)$$

Denklemlerde yer alan y_i performans karakteristiğinin i . değerini, n deney tekrar sayısını, $\bar{y}$ gözlem değerlerinin ortalamasını (Denklem 3.55) ve S^2 gözlem değerlerinin ortalamasını (Denklem 3.56) göstermektedir.

Sistem parametrelerinin performans üzerinde etkili olup olmadığını belirlemek için ANOVA yöntemi kullanılır. Son olarak, en büyük ortalama S/N oranı değerine sahip parametrelerin seviyeleri optimum sonuç olarak belirlenir.

Taguchi yöntemi adımları aşağıdaki gibidir:

- a1. Kalite karakteristiğini belirleme
- a2. Faktörler ve seviyelerini belirleme
- a3. Ortogonal dizi seçme
- a4. Deneyleri yapma
- a5. S/N oranlarını hesaplama
- a6. ANOVA testi kullanarak etkili faktörlerin belirleme
- a7. Optimum faktör seviyelerinin kombinasyonunun belirleme

3.5. İstatistiksel Performans Kriterleri

Gerçek hayattaki büyük, karmaşık ve birbiri ile çelişen değişkenlere sahip verilerden geleceğe yönelik tahminler yapmak oldukça zordur. Tahmin problemlerinde tahmin hatalarının minimum seviyede tutulması gerekmektedir. Tahmin hatası, tahmin edilen değer ile gerçekleşen değer arasındaki farktır. Tahmin doğruluğunun saptanabilmesi için bir takım istatistiksel performans kriterleri kullanılmaktadır. Çalışmada mevcut ve önerilen stok modellerinin karşılaştırılması için hata kareleri ortalaması (MSE), hata kareleri ortalamasının karekökü (RMSE), ortalama mutlak yüzde hata (MAPE), ortalama mutlak hata (MAE) ve determinasyon katsayısı (R^2) istatistiksel performans kriterleri kullanılmıştır.

- a. MSE tahmin hatalarının belirlenmesinde en yaygın olarak kullanılan ölçüttür. Denklem 3.57 yardımıyla hesaplanmaktadır (Nahmias, 2013).

$$MSE = 1/N \sum_{i=1}^N (T_i - P_i)^2 \quad (3.57)$$

- b. RMSE tahmin hatalarının büyüklüğünü tanımladığı için diğer doğruluk ölçütlerine göre birçok uygulayıcı tarafından tercih edilmektedir (Hyndman ve Koehler, 2006). Denklem 3.58 yardımıyla hesaplanmaktadır.

$$RMSE = \sqrt{1/N \sum_{i=1}^N (T_i - P_i)^2} \quad (3.58)$$

- c. MAPE mutlak yüzde hataların ortalaması olarak tanımlanmaktadır (Denklem 3.59).

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \left[\frac{|T_i - P_i|}{T_i} \right] \times 100 \quad (3.59)$$

- d. MAE ortalama mutlak hata olarak tanımlanıp Denklem 3.60 yardımıyla hesaplanmaktadır.

$$MAE = \frac{1}{N} \sum_{i=1}^N |T_i - P_i| \quad (3.60)$$

- e. R^2 (veya r^2) bir modele ait uyum iyiliği hakkında bilgi veren ve 0 ile 1 arasında değer alan determinasyon katsayısıdır (Denklem 3.61). R^2 değerinin 1 olması regresyon tahminlerinin verilere mükemmel bir şekilde uyduğunu gösterirken; 0'a yaklaşması tahminlerin verilerle uyumsuz olduğunu göstermektedir.

$$R^2 = \left[\frac{\sum_{i=1}^N ((T_i - \bar{T})(P_i - \bar{P}))}{\sqrt{\sum_{i=1}^N (T_i - \bar{T})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \right]^2 \quad (3.61)$$

Denklemlerde yer alan T_i , i. gerçek değeri; $\bar{T}$, gerçek değerlerin ortalamasını, P_i i. tahmin edilen değeri ve $\bar{P}$ i. tahmin edilen değerlerin ortalamasını göstermektedir.

BÖLÜM 4. ÖNERİLEN MODEL

Önerilen modeldeki amaç, kan bileşenlerinin temini ve stoklanması sırasında oluşacak toplam maliyetin en aza indirilmesidir. Bu nedenle toplam maliyeti en aza indirecek bir toplam maliyet modeli geliştirilmiştir. Modelde; elde bulundurma maliyeti, yok satma ceza maliyeti, farklı TM'lerden veya BKM'lerden karşılama maliyeti, yetkili TM'lerde kanı işleme/test etme maliyeti, sipariş açma maliyeti ve imha maliyeti gibi alt maliyet bileşenleri mevcuttur. Maliyeti en aza indirmek için modele en uygun olan stokastik stok modelinin belirlenmesi gerekmektedir. Stokastik stok modeli sayesinde; verilecek siparişin büyüklüğü, zamanı ve modelin sürekli mi yoksa periyodik olarak mı takip edileceği belirlenmektedir. Stokastik stok modelinin performansını; tahmin edilen değer, gerçekleşen değerlere yakın sonuçlar vermesi etkilemektedir. Bu nedenle öncelikle, en iyi tahmin sonuçlarını veren talep tahmin yöntemi belirlenmiş ve buradan elde edilen sonuçlar stokastik stok modellerinde girdi olarak kullanılmıştır.

Önerilen model beş aşamadan oluşmaktadır. Bu aşamalar; verilerin toplanması, tahmin yöntemlerinin kullanılması, tahmin yöntemlerinin karşılaştırılması, stokastik stok modellerinin oluşturulması ve toplam maliyet modelinin geliştirilmesidir. Birinci aşamada yer alan verilerin toplanması iki alt başlıkta incelenmektedir. Bunlar; kan bileşeni talebine etki eden değişkenlerin ve uygulamada kullanılacak kan bileşeninin belirlenmesidir. İkinci aşamada tahmin yöntemleri kullanılarak talep belirlenmeye çalışılmıştır. Bu aşamada; öncelikle kan bankasının uyguladığı stok yönetimi incelenmiş bununla birlikte kan bileşeni talebi yapay zeka tabanlı yöntemleri kullanılarak tahmin edilmiştir. Uygulamada; literatürde sıklıkla kullanılan gradyan artırma ağacı (Ahmad ve ark., 2018), derin öğrenme (Singaravel ve ark., 2018; Bedi ve Toshniwal, 2019; Law ve ark., 2019), karar ağacı (Moon, 2013; Shao ve ark., 2014; Brentan ve ark., 2017a), destek vektör makineleri (Wu ve ark., 2012; Brentan, 2017b; Mouatadid ve Adamowski, 2017; Al-Musaylh ve ark., 2018), rassal orman (Brentan

ve ark., 2018; Johannesen ve ark, 2019), yapay sinir ağı (Ivanin ve Direktor, 2018; Anand ve Suganthi, 2018; Hamzaçebi ve ark., 2019) ve ridge regresyon (Marziali ve ark., 2019) yapay zeka tabanlı tahmin yöntemleri kullanılmıştır.

Çalışmada yapay zeka tabanlı yöntemler kullanılmasının nedeni; kan bileşeni olan eritrosit süspansiyonu talep verilerinde girdi ve çıktı değişkenleri arasındaki ilişkinin matematiksel bir eşitlik ile ifade edilmesi yerine doğrusal olmayan, karmaşık ve belirsiz ilişkilerin belirlenmesi için kullanılmasıdır. Üçüncü aşamada, istatistiksel performans kriterleri kullanılarak gerçekleşen kan talebi miktarları ile en yakın sonucu veren tahmin yöntemi belirlenmiştir. Dördüncü aşamada ise en iyi sonucu veren tahmin yöntemi kullanılarak (s,Q) , (s,S) , (R,S) ve (R,s,S) stokastik stok modelleri oluşturulmuştur. Son olarak beşinci aşamada ise; stokastik stok modelleri arasından en az toplam maliyete sahip stok modeli belirlenmiştir.

Çalışmada geliştirilen toplam maliyet modeli; Tarım ve Kingsman'ın maliyet modeli baz alınarak oluşturulmuştur. Maliyet modelinde; stoksuz kalma olasılığına karşı belirlenen hizmet düzeyi kısıtı (2004) ve ceza maliyeti kısıtı (2006) kullanılmıştır. Tarım ve Kingsman maliyet modelinin seçilme nedeni ise sipariş zamanının ve miktarlarının birlikte tespit edilmesi ve bu iki değişkenin birbirine bağımlılığının ihmal edilmemesidir. Maliyet modelinde kullanılan notasyonlar Tablo 4.1.'deki gibidir.

Tablo 4.1. Kullanılan notasyonlar

Notasyon	Açıklaması
TC	Toplam maliyet
C_h	Birim başına elde tutma maliyeti
C_s	Yok satma ceza maliyeti
C_t	Birim başına diğer TM'lerden veya BKM'lerden karşılama maliyeti
C_v	Birim başına TM'lerde işleme ve test etme maliyeti
C_o	Sabit sipariş açma maliyeti
C_p	Birim üretim maliyeti
C_w	Birim başına imha maliyeti

Tablo 4.1. (Devamı)

Notasyon	Açıklaması
C_H	Toplam elde tutma maliyeti
C_S	Toplam yok satma ceza maliyeti
C_T	Toplam diğer TM'lerden veya BKM'lerden karşılama maliyeti
C_V	Toplam TM'lerde işleme ve test etme maliyeti
C_O	Toplam sabit sipariş açma maliyeti
C_H	Toplam elde tutma maliyeti
S	Maximum stok seviyesi
μ	Dönem boyunca ortalama talep
X	Döneme ait normal dağıldığı varsayılan talep miktarı
σ	Döneme ait talebin standart sapma
X_{ij}	i. dönemde j. hastane tarafından talep edilen eritrosit süspansiyonu sayısı
T_{ij}	BKM'den i. dönemde j. TM'ye gönderilen eritrosit süspansiyon miktarı
W_i	i. dönemde imha edilen eritrosit süspansiyon miktarı
R_t	Yenileme siparişi miktarı
w_{ij}	$\begin{cases} 1, & t \text{ dönem içinde imha yapılırsa} \\ 0, & t \text{ dönem içinde imha yapılmazsa} \end{cases}$
y_{ij}	$\begin{cases} 1, & i. \text{ dönem içinde j. TM karşılama yaptıysa} \\ 0, & i. \text{ dönem içinde j. TM karşılama yapmadıysa} \end{cases}$
z_{ij}	$\begin{cases} 1, & t \text{ dönem içinde sipariş verilirse} \\ 0, & t \text{ dönem içinde sipariş verilmezse} \end{cases}$
d_t	t. periyotta talebe ait olasılık yoğunluk fonksiyonu
I_t	t dönem sonundaki stok miktarı
I_t^+	t dönem sonunda bir sonraki döneme aktarılan miktar
I_t^-	t dönem sonunda yok satılan miktar
X_t	t dönem sonunda elde kalan stok miktarı
M	Çok büyük pozitif sayı
i	Dönemlere ait indis $i=1, \dots, N$
j	TM'lere ait indis $j=1, \dots, M$

Maliyet modelinde amaç fonksiyonu beklenen toplam maliyeti en aza indirmeyi amaçlamaktadır (Denklem 4.1).

$$E \{TC\} = \int_{d_1} \dots \int_{d_N} \sum_{t=1}^N (C_o t_{ij} + C_p R_t + C_h I_t^+ + C_s I_t^-) g_1(d_1) \dots g_N(d_N) d(d_N) \dots d(d_1) \quad (4.1)$$

Modelde kullanılan kısıtlar ise (Denklem 4.2- Denklem 4.6) olarak belirlenmiştir.

$$X_t - Sz_{ij} \leq 0 \quad t = 1, \dots, N \quad (4.2)$$

$$I_t = \sum_{i=1}^t (X_i - d_i) \quad t = 1, \dots, N \quad (4.3)$$

$$I_t^+ = \max(0, I_t) \quad t = 1, \dots, N \quad (4.4)$$

$$I_t^- = -\min(0, I_t) \quad t = 1, \dots, N \quad (4.5)$$

$$X_t, I_t^+, I_t^- \geq 0 \quad I_t \in R, \quad \delta_t \in \{0,1\} \quad t = 1, \dots, N \quad (4.6)$$


Denklem 4.2 t dönemindeki yenileme miktarının maksimum stok seviyesine eşit veya az olmasını sağlamaktadır. Denklem 4.3 ise t dönemi sonundaki stok miktarının; eldeki stok miktarından talep miktarının çıkarılmasıyla elde edilmesini ifade etmektedir. Bunun yanı sıra Denklem 4.4’de yer alan I_t^+ bir dönem sonrasına aktarılan stok miktarı, Denklem 4.5’de yer alan I_t^- t dönem sonunda stoksuz kalma miktarını göstermektedir. Denklem 4.4’de t dönemindeki elde bulunan stok miktarı dönem içerisindeki talep miktarından büyük ise I_t^+ , denklem ile hesaplanan değeri; küçük ise 0 değerini alır. Benzer şekilde Denklem 4.5’de t dönemindeki elde bulunan stok miktarı dönem içerisindeki talep miktarından büyük ise I_t^- , 0 değerini; küçük ise denklem ile hesaplanan değeri alır. Bu nedenle Denklem 4.5’de stoksuz kalma miktarının negatif olmaması için denklemin başına '-' işareti yer almaktadır.

Çalışma, Tarım ve Kingsman’ın optimizasyonu ile alt maliyet bileşenleri açısından benzerlik göstermektedir ancak çalışmaya eklenen bazı alt maliyet bileşenleri vardır. Bu alt bileşenler;

- a. İmha maliyeti,
- b. Sipariş açma maliyeti,
- c. Talebi farklı TM’lerden veya BKM’lerden karşılama maliyeti,
- d. BKM tarafından gönderilmediği için TM’lerde gerçekleşen kan işleme ve test etme maliyetidir.

TM’ler; son kullanım süresinin bitmesi, uygunsuz ortamlarda kan bileşenlerinin bozulması gibi nedenlerle kan bileşenlerini imha etmek zorunda kalmaktadır. Bu durumda, kan bileşeni için imha edilene kadar katlanılan; bağış süreci maliyeti, test

edilme maliyeti, işleme maliyeti, depolama maliyeti ve dağıtım maliyeti gibi maliyetler de boşuna kullanılmış kaynak olmaktadır. Bunun yanı sıra BKM’de herhangi bir kan bileşeni için yok satma durumu varsa yok satma ceza maliyeti uygulanır ve kan bileşeni tedarikinin sağlanması için iki durum söz konusu olur. İlk durumda eğer yok satma gerçekleşen TM kan bağıışı kabul etmede yetkili ise kan bağıışı kabul eder. Bu durumda test etme ve işleme maliyeti oluşur. Diğer durumda ise TM kan bağıışı kabul etmede yetkili değilse diğer TM’lerden veya BKM’lerden kan bileşeni istenir. Bu durumda toplam maliyete karşılama maliyeti de eklenmektedir. BKM’de yok satma karşılanmazsa hasta veya yaralının kaybı söz konusudur. Dolayısıyla BKM bu maliyetlere katlanmak zorundadır. Şekil 4.1.’de tahmin edilen kan bileşeni miktarının gerekenden fazla veya az olması durumları göz önünde bulundurularak önerilen maliyet modeli akış şeması görülmektedir.



Şekil 4.1. Önerilen maliyet modeli akış şeması

Bu maliyetlerin dışında toplam maliyete stokta bulundurma ve sipariş açma maliyetleri de eklenmiştir.

Dolayısıyla kan bankasına ait toplam maliyet; elde bulundurma stok maliyeti, yok satma ceza maliyeti, farklı TM'lerden veya BKM'lerden karşılama maliyeti, yetkili

TM'lerde kan işleme/test etme maliyeti, sipariş açma maliyeti ve imha maliyeti bileşenlerinden oluşturulmuştur.

Modelde yer alan Denklem 4.7 elde bulundurma ve ceza maliyetini, Denklem 4.8 BKM'den karşılanamayan diğer TM'lerden veya BKM'lerden karşılanan talebin karşılama maliyetini, Denklem 4.9 TM'lerde işleme ve test etme maliyetini, Denklem 4.10 sabit sipariş açma maliyetini, Denklem 4.11 imha maliyetini göstermektedir.

$$C_H = (S_{ij} - \mu) - (C_h + C_s)(S_{ij} - \mu) \int_{S-\mu}^{+\infty} \phi(x; \sigma) dx + (C_h + C_s) \frac{\sigma}{\sqrt{2\pi}} \exp \frac{-(S-\mu)^2}{2\sigma^2} \quad (4.7)$$

$$C_T = y_{ij} (C_t) (X_{ij} - T_{ij}) \quad (4.8)$$

$$C_V = (1 - y_{ij}) (C_v) (X_{ij} - T_{ij}) \quad (4.9)$$

$$C_O = z_{ij} (C_o) \quad (4.10)$$

$$C_W = w_{ij} (C_w) \quad (4.11)$$

Toplam maliyet ise Denklem 4.12 yardımıyla hesaplanmaktadır. Bu maliyet hesabında MATLAB R2014A'dan yararlanılmıştır.


$$TC = \sum_{j=1}^M \sum_{i=1}^N C_h (S_{ij} - \mu) - (C_h + C_s)(S_{ij} - \mu) \int_{S-\mu}^{+\infty} \phi(x; \sigma) dx + (C_h + C_s) \frac{\sigma}{\sqrt{2\pi}} \exp \frac{-(S-\mu)^2}{2\sigma^2} + y_{ij} (C_t) (X_{ij} - T_{ij}) + (1 - y_{ij}) (C_v) (X_{ij} - T_{ij}) + z_{ij} (C_o) + w_{ij} (C_w) \quad (4.12)$$

BÖLÜM 5. UYGULAMA

Geliştirilen model; Eskişehir, Afyonkarahisar, Kütahya ve Bilecik illerinde faaliyet gösteren kamu ve özel hastanelere kan tedariki sağlayan Batı Anadolu Bölge Kan Merkezi'nde uygulanmıştır. Batı Anadolu BKM'de iki tip TM mevcuttur. İlki BKM'den talep ettiği kan bileşeni miktarından az kan gönderilmesi halinde kan bağışı kabul eden TM'ler, diğeri ise kan bağışı kabul edemeyen TM'lerdir. BKM'de Kızılay'ın verdiği yetki çerçevesinde, kendi bünyesinde yer alan TM'de kan bağışı kabul eden tek hastane Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesi'dir. Batı Anadolu Bölge Kan Merkezi'nde başka hiçbir TM'nin böyle bir yetkisi yoktur.

Modelde, elde edilen verilere göre aşağıdaki varsayımlarda bulunulmaktadır:

- a. Çalışmada kullanılan eritrosit süspansiyonu raf ömrü 35 gün olarak kabul edilmektedir.
- b. Herbir TM için teslim süresinin ortalama 1 gün olduğu varsayılmaktadır.
- c. Talebin verildiği ve alındığı zaman arasındaki yok satma olasılığı 0,2 olarak varsayılmaktadır.
- d. Stokta tutulan her birim için stokta bulundurma maliyeti söz konusudur.
- e. BKM; kan bağışı alma konusunda yetkili TM'nin talep ettiği kan bileşeni ihtiyacını karşılayamazsa, TM kendi bünyesinde kan bağışı kabul edip, kanı işleme ve test etme yetkisine sahiptir. Bu da kan işleme ve test etme maliyetine yol açmaktadır.
- f. BKM; kan bağışı alma konusunda yetkili olmayan TM'nin talep ettiği kan bileşeni ihtiyacını karşılayamazsa, başka TM'lerden veya BKM'lerden karşılama maliyetine katlanmak üzere kan tedariki sağlayabilir.
- g. BKM'nin karşılayamadığı her birim sipariş için yok satma ceza maliyeti uygulanır.



Şekil 5.1. Uygulama akış şeması

- h. Son kullanım süresi dolmuş veya uygun olmayan saklama koşullarında saklanmadığı/ işlem yapılmadığı için imha edilen her birime imha maliyeti uygulanır.
- i. Kan bileşenleri, ilk giren ilk çıkar (FIFO) sırasına göre verilir. Ancak kanser hastaları, prematüre bebekler gibi vücut dirençleri düşük hastalar için en son kabul edilen uygun kan bileşeni gönderilmektedir.

Ayrıca kan bankası talep değerleri incelendiğinde; örnek büyüklüğü 30'dan büyük olduğu için Kolmogorov-Smirnov testi kullanılarak normal dağılıma uygunluk testi yapılmıştır. Test sonucunda %95 güven aralığında anlamlılık düzeyi 0,05 değerinden büyük olduğu için verilerin normale yakın dağıldığını söylenebilmektedir (Tablo 5.1.)

Tablo 5.1. Normallik testi

Talep edilen eritrosit süspansiyonu miktarı	İstatistik	Kolmogorov-Smirnov	
		Örnek sayısı	Anlamlılık Düzeyi
	,170	520	,058

Önerilen model baz alınarak çizilen uygulama akış şeması Şekil 5.1.'de yer almaktadır.


Kan bankalarının amacı, yeterli miktarda güvenli kan sağlamaktır. Kan bağışının yetersiz olması hasta veya yaralının sağlığını riske sokabilir. Bu nedenle kan bankaları her hangi bir sıkıntının önlenmesi için fazla miktarda kan talebinde bulunmaktadır. Dolayısıyla BKM'ler bazı dönemlerde TM'lerin talep ettiği miktarları karşılayamamaktadır. Tablo 5.2.'de Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesinin 2018 yılının haftalarına ait talep ettiği ve Batı Anadolu Bölge Kan Merkezi'nin karşıladığı miktarlara ait değerler yer almaktadır.

Tablo 5.2. Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesi 2018 yılı eritrosit süspansiyonu verileri


Hafta	Talep Edilen ES	Gönderilen ES	Hafta	Talep Edilen ES	Gönderilen ES
1.	392	224	27.	740	139
2.	412	359	28.	701	99
3.	262	248	29.	855	236
4.	371	347	30.	714	200
5.	314	296	31.	732	226
6.	291	271	32.	723	228
7.	392	359	33.	701	192
8.	278	274	34.	688	203
9.	416	365	35.	67	49
10.	328	286	36.	505	105
11.	261	259	37.	732	232
12.	313	311	38.	766	240
13.	166	165	39.	666	240
14.	314	313	40.	338	223
15.	365	365	41.	416	252
16.	411	399	42.	409	335
17.	206	206	43.	268	228
18.	152	152	44.	346	309
19.	416	416	45.	244	225
20.	262	261	46.	196	192
21.	326	324	47.	206	206
22.	456	445	48.	251	251
23.	493	351	49.	267	267
24.	605	257	50.	334	329
25.	643	156	51.	360	339
26.	385	98	52.	174	159

ES: Eritrosit süspansiyonu


Şekil 5.2.-Şekil 5.6.'da ise sırasıyla Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesinin, Eskişehir Yunus Emre Devlet Hastanesi'nin, Afyonkarahisar Devlet Hastanesi'nin, Afyonkarahisar Sağlık Bilimleri Üniversitesi Hastanesi'nin ve Kütahya Evliya Çelebi Hastanesi'nin 2018 yılına ait talep ettiği ve BKM tarafından gönderilen eritrosit süspansiyonu miktarları verilmiştir.




Şekil 5.2. Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesinin talep ettiği ve BKM'nin gönderdiği ES miktarları




Şekil 5.3. Eskişehir Yunus Emre Devlet Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları



Şekil 5.4. Afyonkarahisar Devlet Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları



Şekil 5.5. Afyonkarahisar Sağlık Bilimleri Üniversitesi Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları



Şekil 5.6. Kütahya Evliya Çelebi Hastanesi'nin talep ettiği ve BKM'nin gönderdiği ES miktarları

Şekillerden de anlaşılacağı gibi özellikle bazı dönemlerde talep edilen ve gönderilen eritrosit süspansiyonu miktarları arasında oldukça büyük bir fark vardır. Bu da TM'lerin stoklarında kan bileşeni mevcut değilse diğer TM'lerden veya BKM'lerden bileşen talebinde bulunulmasına dolayısıyla yok satma ceza maliyetine, kanı işleme/test etme maliyetine ve karşılama maliyetine neden olmaktadır.

5.1. Verilerin Toplanması

5.1.1. Kan bileşeni talep miktarına etki eden değişkenlerin belirlenmesi

Talep edilecek kan bileşeni miktarının gerçekleşecek duruma en yakın şekilde belirlenebilmesi için öncelikle kan ve kan bileşenleri talebini etkileyebilecek bağımsız değişkenler belirlenmelidir. Kan ve kan bileşenleri talebine etki edebileceği düşünülen

değişkenler Tablo 5.3.'de özetlenmektedir. Bu değişkenler, bölge kan merkezinde çalışan uzman doktorlar ile beyin fırtınası yöntemine bağlı olarak belirlenmiştir. Yapılan kısıtlı aramalar sonunda literatürde, çalışmada belirlenen bağımsız değişkenler kullanılarak talep tahmini yapıldığı görülmemiştir.

Tablo 5.3. Talep edilen kan bileşeni miktarına etki eden değişkenler

Notasyon	Talep edilen kan bileşeni miktarına etki eden değişkenler
C ₁	Bir dönem önce BKM'den karşılanamayan, acil ihtiyaç nedeni ile TM'nin gerçekleştirdiği kan bağıışı sayısı (adet/hafta)
C ₂	Önceki haftaya ait kan bileşeni talep miktarları (adet/hafta)
C ₃	Hastane yatak kapasitesi (adet)
C ₄	Hastanede kan bileşeni kullanımını arttıran yeni tedavi uygulamalarının devreye girmesi (adet)
C ₅	Toplam muayene sayısı (adet/ hafta)
C ₆	Acil muayene sayısı (adet/ hafta)
C ₇	Yatan hasta sayısı (adet/ hafta)
C ₈	Yatak doluluk oranı
C ₉	Hastane tipi (rolü) (AI, AII, B, C, D)
C ₁₀	Ameliyat sayıları (adet/ hafta)
C ₁₁	Hastanenin bulunduğu il/ilçe nüfusu (kişi/yıl)
C ₁₂	Resmi tatiller (adet/ hafta)
C ₁₃	Organ nakli sayısı (adet/ hafta)
C ₁₄	Göçmen sayısı (kişi/yıl)
C ₁₅	Ortalama sıcaklık değerleri (°C)

Modelde kullanılan C₁ ve C₂ değişken verileri Batı Anadolu Bölge Kan Merkezi'nden; C₃, C₄, C₅, C₆, C₇, C₈, C₉ ve C₁₃ değişken verileri Kamu Hastaneler Birliği'nden; C₁₁ değişken verisi Türkiye İstatistik Kurumu'ndan; C₁₂ değişken verisi 2017-2018 yıllık takviminden; C₁₄ değişken verisi T.C. İçişleri Bakanlığı Göç İdaresi Genel Müdürlüğü'nden ve C₁₅ değişken verisi T.C. Orman ve Su İşleri Bakanlığı Meteoroloji Genel Müdürlüğü'nden temin edilmiştir.

Kan ve kan bileşenleri talep miktarlarının; hastanelerde yapılan toplam muayene sayısı, acil muayene sayısı, yatan hasta sayısı ve ameliyat sayısı ile doğru oranda değiştiği düşünülmektedir. Değişkenlere ait sayı ve oranlar arttıkça talep edilecek kan miktarı da doğru orantılı bir şekilde değişmektedir. Bunun yanı sıra yatak doluluk oranının (Denklem 5.1) kan ve kan bileşenleri talep miktarlarını etkilediği

varsayılmaktadır. Yatak doluluk oranı; belirli bir zaman dilimi içerisinde hasta yataklarının ne oranda kullanıldığını göstermektedir (Yıldız, 2017).

$$\text{Yatak doluluk oranı} = \frac{\text{Yatılan Gün Sayısı} \times 100}{1 \text{ yıl (365 gün)} \times \text{Hasta Yatak Sayısı}} \quad (5.1)$$

Yine hastanenin tipi de kan talebine etki edebilecek değişken olarak alınacaktır. Hastane tipi; hastanenin eğitim araştırma hastanesi olup olmadığı, bulunduğu il ve ilçe nüfusu, klinik sayısı, yatak sayısı, tıbbi teknolojinin varlığı, uzman tabip ve diğer sağlığa dayalı insan gücü sayısı göz önünde bulundurularak sınıflandırılmasıdır. AI tipi hastaneler; bakanlıkça ilgili mevzuatına göre en az beş branşta eğitim yetkisi verilmiş ve buna göre eğitim kadroları tamamlanmış, üçüncü basamak tedavi ve rehabilitasyon hizmetlerinin verildiği, eğitim araştırma faaliyetlerinin yürütüldüğü ve aynı zamanda uzman ve yan dal uzman tabiplerinin yetiştirildiği genel dal yataklı tedavi kurumlarıdır. AII tipi hastaneler; bölge sağlık merkezi statüsündeki illerde veya bu merkezlerle bağlı illerde faaliyet gösteren, eğitim-araştırma statüsü bulunmayan hastanelerdir. B tipi hastaneler; AI ve AII tipi hastaneler dışında kalan, il merkezlerindeki genel hastaneler ile güçlendirilmiş ilçelerde faaliyet gösteren, 24 saat esasına dayalı olarak dahili branş acil havuz nöbeti ve cerrahi branş acil havuz nöbeti tutulabilen, bünyesinde en az II. Seviye acil servis ve II. Basamak yoğun bakım ünitesi bulunan sağlık kuruluşlarıdır. C tipi hastaneler; güçlendirilmiş ilçelerde veya sağlık hizmet sunumu bakımından sağlık bölge planlaması kapsamında güçlendirilmiş ilçe merkezleri ile irtibatlandırılmış ilçelerde faaliyet gösteren, bünyesinde dört ana branşta uzman tabip hizmet veren, ilave olarak diğer branşlardan en az ikisinden uzman tabip bulunduran, bünyesinde en az I. basamak yoğun bakım ünitesi ve I. seviye acil servis bulunan hastanelerdir. D tipi hastaneler ise; 4 ana branşta; her branş için en az 1 uzman tabip planlanması yapılmış olan ve aile hekimi dahil olmak üzere birden fazla uzman tabip bulunduran, mevcut uzmanlık dallarında uzman düzeyinde poliklinik muayene hizmetleri verilebilen, yatırılan hastaların uzman düzeyinde takip ve tedavisini sağlayabilen, acil sağlık hizmetlerinin 1. seviye acil servis yapılması içerisinde sunulabilen, bünyesinde, ameliyathane, ameliyat sonrası bakım odası, diş polikliniği, doğumhane, monitörlü gözlem odası bulunan, diyaliz birimini ihtiyaca göre yapılandırılabilen sağlık kuruluşlarıdır (Şencan ve ark., 2009).

Hastanenin bulunduğu il veya ilçe nüfusunun ve göçmen sayısının da muayene sayısı, acil muayene sayısı gibi durumları etkileyeceğinden talep miktarında da etkili olduğu varsayılmaktadır.

Bu değişkenlerin aksine kan talep miktarlarında ramazan ve kurban bayramı tatilleri ile resmi tatillerin olduğu günlerde hastane personelinin acil olmayan durumlar dışında ameliyat ve muayene yapmaması nedeniyle kan talebinde azalış gözlenmektedir. Sonuç olarak, kan ve kan bileşenleri talebinde bazı özel günler bazında değişimler söz konusudur. Ayrıca kan ve kan bileşenleri talebinin haftanın günlerine göre de değişiklik gösterdiği düşünülmektedir. Hastane politikalarından kaynaklanan bu dalgalanma hafta içi talebin çok, hafta sonu ise az olmasına neden olmaktadır.

Talep edilecek kan bileşeni miktarının; önceki haftalara ait kan bileşeni talep miktarlarından da etkilenebileceği düşünülerek değişken olarak seçilmiştir.

Bunun yanı sıra BKM'den karşılanamayan ve acil ihtiyaç nedeni ile TM'nin gerçekleştirdiği kan bağışı sayısı da talep edilen kan bileşeni miktarına etki eden değişken olarak ele alınmıştır.

Ayrıca yeni tedavi yöntemlerinin denenmesinin ve organ nakli sayısının, talep edilen kan bileşeni miktarını arttıran iki önemli karar değişkeni olduğu düşünülmektedir.

Kan ve kan bileşenlerinin talep miktarları ve zamanları rassallık gösterdiği gibi bağış miktarları da bazı değişkenlerden etkilenmektedir. Bunların başında; mevsimler, aylar ve hava durumu gelmektedir. Hava sıcaklığının çok düşük veya çok yüksek olması kan bağış miktarlarının azalmasına neden olmaktadır. Yine ramazan ve kurban bayramı ile resmi tatillerin olduğu günlerde bağış miktarlarında da değişimler söz konusudur. Dolayısıyla veriler durağan olmayan bir yapı göstermektedir. Bu yapıdan dolayı her kan bileşeni için hem haftalık hem de aylık talep tahmini geliştirilmelidir. Bunun yanı sıra insanları kan bağışı için motive etmeyi amaçlayan reklamlar ve etkinlikler de kan bağış miktarında etkilidir (Lang, 2010).

Model üzerinde etkili olduğu düşünülen değişkenlerin gerçekten modele etki edip etmediğini ve bağımsız değişkenlerin birbirleri arasında doğrusal bağlantı sorunu olup olmadığını belirlemek için ileri seçim yöntemi kullanılmıştır. Ancak literatürde bu sorunun çözümü için çoklu doğrusal bağlantısı olan değişkenler modelden çıkarılmak yerine kullanılan bazı yöntemler de vardır. Bunlardan biri bağımsız değişkenlerin birbirinden bağımsız bileşenlere dönüştürülmesidir (Sevinç, 2013 Diğer yöntemler ise Ridge regresyon yönteminin kullanılması veya tahminin yapay sinir ağı gibi yapay zeka tabanlı yöntemlerle gerçekleştirilmesidir (Pao, 2008). Bu nedenle önerilen modelde yapay zeka tabanlı tahmin yöntemleri de uygulanmıştır.

%5 anlam düzeyinde ileri seçim (Tablo 5.4.) için C₂, C₃, C₅, C₇, C₈, C₉, C₁₀, C₁₁, C₁₂, C₁₄ ve C₁₅ değişkenleri modele etki ederken; C₁, C₄, C₆ ve C₁₃ değişkenleri modelde etkisi olmayan değişkenler olarak belirlenmiştir.

Tablo 5.4. İleri seçim yöntemi sonuçları

	DF	Adj SS	Adj MS	F-Değeri	P-Değeri
C1	1	4037,000	4037,00	2,5400	0,112
C2	1	11418,00	11418,0	7,1800	0,008
C3	1	54884,00	54884,0	34,530	0,000
C5	1	107196,0	107196	67,440	0,000
C6	1	3334,000	3334,00	2,1000	0,148
C7	1	38477,00	38477,0	24,210	0,000
C8	1	59343,00	59343,0	37,330	0,000
C9	1	234390,0	234390,	147,46	0,000
C10	1	22214,00	22214,0	13,980	0,000
C11	1	21839,00	21839,0	13,740	0,000
C12	1	16112,00	16112,0	10,140	0,002
C14	1	40480,00	40480,0	25,470	0,000
C15	1	5407,000	5407,00	3,4000	0,066
Hata	506	804295	1590		
Toplam	519	11823865			

İleri seçim yöntemi için R² ve düzeltilmiş R² değerleri %93 olarak bulunmuştur ancak veri kümesindeki çoklu doğrusal bağlantı sorununu gösteren Tablo 5.5. incelendiğinde varyans artış faktör (VIF) değerlerinin 10'dan yüksek olduğu görülmektedir. Bu da ciddi çoklu doğrusal bağlantı olduğunu gösterir (Hair ve ark., 2009; Vu ve ark., 2015). Bunun yanı sıra VIF değerinin 20'den yüksek çıkması güçlü bir doğrusal bağlantının işaretidir (Pao, 2008). Çoklu doğrusal bağlantı bağımsız değişkenlerin sadece bağımlı değişken üzerinde değil bağımsız değişkenlerin birbiri üzerinde de etkilerinin

olduğunu göstermektedir. Bu da bağımsız değişkenlerin aynı dış kaynaklardan etkilendiğini dolayısıyla tek bir bağımsız değişken olarak ele alınabileceğini şeklinde yorumlanmaktadır.

Tablo 5.5. İleri seçim yöntemi VIF değerleri

Değişken	VIF	Değişken	VIF
C ₁	7,590	C ₉	1,850
C ₂	6,700	C ₁₀	4,660
C ₃	285,5	C ₁₁	338,1
C ₄	1105,3	C ₁₂	1,100
C ₅	350,3	C ₁₃	1105,3
C ₆	38,43	C ₁₄	74,41
C ₇	250,7	C ₁₅	1,220
C ₈	1,860		

Sonuç olarak C₃, C₄, C₅, C₆, C₇, C₁₁, C₁₃ ve C₁₄ kriterlerine ait VIF değerleri 10 değerinden yüksek çıktığı için doğrusal bağlantı sorunu olduğu görülmektedir. Bu nedenle talep tahmininde özellikle ridge regresyon gibi yapay zeka tabanlı tahmin yöntemlerine yer verilmiştir.

5.1.2. Uygulamada kullanılacak kan bileşeninin belirlenmesi

Uygulama için kan bileşenleri arasından talep miktarı en fazla ve özellikle acil hastaları tedavi eden hastanelerde tıbbi uygulama olarak kullanılan hayat kurtarıcı bir bileşen (Pi ve ark, 2019) olan eritrosit süspansiyonu seçilmiştir (Tablo 5.6.).

Tablo 5.6. 2018 yılına ait Batı Anadolu Bölge Kan Merkezi'nden talep edilen kan bileşeni miktarları

	Eritrosit süspansiyonu	Taze donmuş plazma	Trombosit süspansiyonu	Toplam kan bileşeni miktarı
Miktar	74449	33333	15443	123225
Yüzdelik	60,417	27,051	12,532	100

Eritrosit süspansiyonunun seçilmesinin diğer nedenleri ise; trombosit talebinin sadece özellikli hastanelerden talep edilmesi ve taze donmuş plazmanın saklama süresinin -18 ile -86 arasında çok uzun olması nedeniyle stok sorununun yaşanmamasıdır.

5.1.3. Uygulamanın yapılacağı transfüzyon merkezlerinin belirlenmesi

Elde edilen veriler doğrultusunda (Tablo 5.6.) BKM'den 2018 yılında 74449 birim eritrosit süspansiyonu talep edilmiştir. Bu nedenle tahmin yöntemlerinde kullanılacak veri grubuna ait örnek büyüklüğü %95 güven seviyesi ile en az 382 olarak öngörülmüştür (Cohen ve ark., 2000). Örneklem büyüklüğünün anakütleyi daha iyi temsil edilmesi için talebin 45000'lik kısmını içeren 5 TM ile çalışma yapılmıştır. Uygulamanın yapıldığı TM'lerden; Eskişehir Osmangazi Üniversitesi Sağlık Uygulama ve Araştırma Hastanesi ve Afyonkarahisar Sağlık Bilimleri Üniversitesi Hastanesi AI, Eskişehir Yunus Emre Devlet Hastanesi AII, Afyonkarahisar Devlet Hastanesi ve Kütahya Evliya Çelebi Hastanesi B rolüne sahip hastanelerdir.

5.2. Tahmin Yöntemlerinin Kullanılması

5.2.1. Mevcut sistemde kan bileşeni talep miktarının belirlenmesi

Mevcut sistemde kan bileşeni talep miktarı, kan bankasının uyguladığı stok yönetimi bölümünde açıklandığı gibi belirlenmektedir.

Örnek olarak 2018 yılına ait talepler göz önüne bulundurulursa ilk 26 haftalık toplam talep edilen eritrosit süspansiyonu miktarından bu dönemde gerçekleşen maximum miktar olan 643 birim azaltılıp 25 haftaya bölünmüş ve 27. haftanın kritik stok seviyesi 343,48 olarak belirlenmiştir (Tablo 5.7.). Benzer şekilde gelecek haftalara ait talep miktarları da tahmin edilmektedir.

Tablo 5.25.'de TM'lerin istediği ve BKM'nin gönderebildiği talep miktarı göz önünde bulundurularak 62 haftalık gözlem biriminde oluşan eksik veya fazla belirlenen talep miktarı; haftalık gözlem birimi sayısı ve miktarı açısından incelenmiştir. Kan bankasının uyguladığı stok politikasına göre eritrosit süspansiyonu 52 haftalık gözlem birimi boyunca talep edilen miktardan 2857 birim daha az gönderim sağlanmıştır. Aynı dönemde BKM'nin istenilen miktarda eritrosit süspansiyonu gönderdiği haftalık

gözlem birimi 10 iken; fazladan eritrosit süspansiyonu gönderdiği haftalık gözlem birimi mevcut değildir.

Tablo 5.7. Kritik stok seviyesinin belirlenmesi örneği

Hafta bazında talep edilen miktarlar		Hafta bazında talep edilen miktarlar		Tahmin edilen miktar
Hafta	Eritrosit süspansiyonu miktarı	Hafta	Eritrosit süspansiyonu miktarı	
1.	392	14.	314	
2.	412	15.	365	
3.	262	16.	411	
4.	371	17.	206	
5.	314	18.	152	
6.	291	19.	416	
7.	392	20.	262	
8.	278	21.	326	
9.	416	22.	456	
10.	328	23.	493	
11.	261	24.	605	
12.	313	25.	643	
13.	166	26.	385	
		27.		343,48

5.2.2. Yapay zeka tabanlı tahmin yöntemleri kullanarak kan bileşeni talep miktarının belirlenmesi

Çalışmada, yapay sinir ağı yöntemi için MATLAB R2014A programına ait Neural Network Toolbox (nntool) aracından, ridge regresyon yöntemi için NCSS 2019 programından ve diğer yapay zeka tabanlı tahmin yöntemleri ile için de RapidMiner Studio 9.4 programından yararlanılmıştır. Yöntemlerde optimum parametre seçimi yapabilme özellikleri göz önünde bulundurularak farklı programlar kullanılmıştır.

Yapay zeka tabanlı tahmin yöntemleri için farklı bir veri seti oluşturulmuştur. Veri seti; satırlarında talep edilen eritrosit süspansiyonu, sütunlarında ise talep edilen eritrosit süspansiyonu etki eden değişkenler bulunan 520x15 (haftalık gözlem birimi x talep miktarına etki eden değişkenler) boyutlu bir matristen oluşmuştur. Yöntemlerde girdi değişkeni olarak eritrosit süspansiyonu talep miktarına etki eden değişkenler (Tablo 5.3.), çıktı değişkeni olarak da TM'in BKM'den talep ettiği haftalık eritrosit süspansiyonu miktarı olarak belirlenmiştir (Tablo 5.8.). Yapay zeka tabanlı tahmin yöntemlerinin tamamında 520 haftalık gözlem biriminin 364 ($520 \times 0,70 = 364$) tanesi

eğitim, 94 ($520 \times 0,18 = 94$) tanesi de doğrulama ve 62 ($520 \times 0,12 = 62$) tanesi de test verisi olarak ayrılmıştır.

Tablo 5.8. Yapay zeka tabanlı tahmin yöntemlerinde kullanılan veri seti

Gözlem birimi (haftalık)	TM	Talep edilen eritrosit miktarına etki eden kriterler									
		C ₁	C ₂	C ₃	.	.	.	.	.	C ₁₄	C ₁₅
1. gözlem birimi	OGÜH 1. hafta	78	257	3363						2082	-7,1
2. gözlem birimi	OGÜH 2. hafta	60	288	3363						2082	4,1
3. gözlem birimi	OGÜH 3. Hafta	144	472	3363						2082	4,7
.	.										
.	.										
.	.										
518. gözlem birimi	KEÇH 50. hafta	19	209	1817						370	8,4
519. gözlem birimi	KEÇH 51. hafta	10	232	1817						370	3
520. gözlem birimi	KEÇH 52. hafta	11	223	1817						370	4,4

OGÜH: Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesi KEÇH: Kütahya Evliya Çelebi Hastanesi

5.2.2.1. Ridge regresyon kullanarak kan bileşeni talep miktarının belirlenmesi

İleri seçim yöntemine bağlı olarak belirlenen C₃, C₅, C₆, C₇, C₁₁ ve C₁₄ değişkenlerine ait VIF değerlerinin 10'dan yüksek çıkması nedeniyle ridge regresyon yöntemi kullanılmış böylece değişkenler arasındaki çoklu bağlantı sorunu azaltılmıştır. (Tablo 5.9.).

Tablo 5.9. RR sonucunda oluşan VIF değerleri


Değişken	P-değeri	VIF değeri	RR sonucunda VIF değeri (k=0.5)	Değişken	P-değeri	VIF değeri	RR sonucunda VIF değeri (k=0.5)
C ₁	0.112	7.5900	6.559	C ₉	0.000	1.8500	1.708
C ₂	0.008	6.7000	5.864	C ₁₀	0.000	4.6600	2.201
C ₃	0.000	285.54	8.482	C ₁₁	0.000	338.09	8.958
C ₄	0.000	34E+16	0.254	C ₁₂	0.002	1.1000	1.066
C ₅	0.000	350.32	9.029	C ₁₃	0.000	34E+16	0.254
C ₆	0.148	38.430	7.675	C ₁₄	0.000	74.4100	5.193
C ₇	0.000	250.71	8.488	C ₁₅	0.066	1.22000	1.168
C ₈	0.000	1.8600	1.364				

Yine korelasyon matrisi incelendiğinde 1'e yakın değerlerin olması bağımsız değişkenler arasında çoklu doğrusal bağlantının olduğunu ifade etmektedir (Tablo 5.10.).

Tablo 5.10. Korelasyon matrisi


	C1	C2	C3	C4	C5	.	.	.	C10	C11	C12	C13	C14	C15
C1	1,00	0,17	0,01	0,55	0,54	.	.	.	0,11	0,11	0,01	-0,13	0,25	0,70
C2	0,17	1,00	0,02	-0,12	-0,23	.	.	.	0,88	0,00	0,02	-0,19	-0,02	0,17
C3	0,01	0,02	1,00	0,00	0,01	.	.	.	0,03	-0,02	0,98	0,03	-0,03	0,03
C4	0,55	-0,12	0,00	1,00	0,96	.	.	.	-0,13	0,18	0,00	-0,10	0,21	0,86
C5	0,54	-0,23	0,01	0,96	1,00	.	.	.	-0,21	0,15	0,01	-0,01	0,22	0,84
C6	0,53	0,01	-0,01	0,97	0,88	.	.	.	0,01	0,19	-0,01	-0,11	0,18	0,82
C7	-0,03	-0,03	-0,04	-0,09	-0,05	.	.	.	-0,17	-0,03	-0,04	-0,30	0,03	-0,03
C8	-0,30	0,19	-0,05	-0,20	-0,19	.	.	.	0,33	0,00	-0,05	0,32	-0,05	-0,31
C9	0,34	0,36	-0,02	0,38	0,29	.	.	.	0,33	0,09	-0,02	-0,14	0,04	0,42
C10	0,11	0,88	0,03	-0,13	-0,21	.	.	.	1,00	0,00	0,03	0,28	-0,07	0,10
C11	0,11	0,00	-0,02	0,18	0,15	.	.	.	0,00	1,00	-0,02	-0,01	0,20	0,12
C12	0,01	0,02	0,97	0,00	0,01	.	.	.	0,03	-0,02	1,00	0,03	-0,03	0,03
C13	-0,13	-0,19	0,03	-0,10	-0,01	.	.	.	0,28	-0,01	0,03	1,00	-0,12	-0,14
C14	0,25	-0,02	-0,03	0,21	0,22	.	.	.	-0,07	0,20	-0,03	-0,12	1,00	0,23
C15	0,70	0,17	0,03	0,86	0,84	.	.	.	0,10	0,12	0,03	-0,14	0,23	1,00

Ridge regresyonun parametresi olan k ; NCSS 2019 programı kullanılarak bulunmuştur. Şekil 5.7.'de standartlaştırılmış β katsayıları k değerinin 0,5 olduğu noktada durağan hale gelmeye başladığı görülmektedir. Bu nedenle optimum k değeri 0,5 olarak alınmıştır.



Şekil 5.7. Ridge regresyon grafiği

Şekil 5.8.'de ise k değerine karşılık gelen eritrosit süspansiyonu değişkeni için VIF değerleri 10 değerinin altında gözükmemektedir. Bu da ridge regresyon yöntemi ile bağımsız değişkenler arasındaki ilişkinin olmadığını göstermektedir.



Şekil 5.8. VIF grafiği

D_{ES} tahmin edilen eritrosit süspansiyonu miktarı olmak üzere elde edilen ridge regresyonu denklemi Denklem 5.2'de gösterilmiştir.

$$D_{ES} = -133.3704 + 0.1072 C_1 + 0.0654 C_2 + 0.1425 C_3 + 12.5531 C_4 + 0.0090 C_5 + 0.0108 C_6 + 0.1262 C_7 + 223.1024 C_8 - 64.5999 C_9 + 0.0018 C_{10} + 0.0005 C_{11} + 8.2669 C_{12} + 12.5531 C_{13} + 0.0236 C_{14} + 0.2882 C_{15} \quad (5.2)$$

Tahmin edilen eritrosit süspansiyonu miktarları Tablo 5.25’de yer almaktadır.

5.2.2.2. Gradyan artırma ağacı kullanarak kan bileşeni talep miktarının belirlenmesi

Uygulama için RapidMiner Studio 9.4 programı kullanılarak modelleme yapılmıştır. Programda öncelikle eğitim ve test verileri belirlenmiştir. Bu aşamada kullanılan gözlem birimleri; mevcut sistemdeki stok yönetiminde kullanılan eğitim ve test veri seti ile aynı seçilmiştir. Böylece yöntemlerin karşılaştırılması sağlanmıştır.

Model uygulamasında optimum parametreler program tarafından belirlenmiştir. Ağaç sayısı olarak 30, 90 ve 150; en fazla derinlik değeri olarak 2, 4 ve 7; öğrenme oranı olarak da 0,001, 0,010 ve 0,100 değerlerine ait tüm kombinasyonlar değerlendirilmiş ve optimum ağaç sayısı için 150, en fazla derinlik için 4 ve öğrenme oranı için 0,100 olarak % 7,1 hata oranı ile tespit edilmiştir (Tablo 5.11.).

Tablo 5.11. Gradyan artırma ağacı yönteminde optimum parametrelerin belirlenmesi


Ağaç sayısı	En fazla derinlik	Hata oranı %		
		Öğrenme oranı		
		0,001	0,010	0,100
30	2	29,7	25,4	11,5
	4	29,6	25	8,8
	7	29,6	25	8,7
90	2	28,6	19,8	8,3
	4	28,6	17,7	7,3
	7	28,5	17,5	7,7
150	2	27,7	16,9	7,8
	4	27,5	13,5	7,1
	7	27,5	13,1	7,7

Modelde program tarafından belirlenen kriterler ağırlıkları sırasıyla Tablo 5.12.’de görülmektedir.

Tablo 5.12. Gradyan artırma ağacı yönteminde bulunan kriter ağırlıkları

Kriterler	Ağırlıkları	Kriterler	Ağırlıkları
C ₅	0,6972	C ₈	0,0745
C ₇	0,3636	C ₄	0,0431
C ₃	0,2612	C ₁₄	0,0407
C ₁₀	0,2157	C ₁	0,0285
C ₁₅	0,1100	C ₁₁	0,0135
C ₉	0,0970	C ₁₃	0,0087
C ₂	0,0842	C ₁₂	0,0027
C ₆	0,0759		

Model sonunda elde edilen tahmin değerleri Tablo 5.23.'de, tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları da Şekil 5.9.'da verilmiştir.



Şekil 5.9. Gradyan artırma ağacı yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları

5.2.2.3. Derin öğrenme kullanarak kan bileşeni talep miktarının belirlenmesi

Derin öğrenmede de öncelikle eğitim ve test verileri normalize edilmiştir. Aktivasyon fonksiyonu olarak literatürde sıklıkla kullanılan düzeltilmiş lineer ünite (ReLU) fonksiyonu kullanılmıştır (Denklem 5.3).


$$f(x) = \max(0, x) \quad (5.3)$$

Model sonunda program tarafından belirlenen kriter ağırlık değerleri Tablo 5.13.'de verilmiştir.

Tablo 5.13. Derin öğrenme yönteminde bulunan kriter ağırlıkları

Kriterler	Ağırlıkları	Kriterler	Ağırlıkları
C ₁₃	0,5115	C ₁	0,0925
C ₆	0,5091	C ₁₄	0,0395
C ₅	0,4242	C ₂	0,0365
C ₇	0,1626	C ₈	0,0350
C ₁₅	0,1232	C ₉	0,0053
C ₁₂	0,1167	C ₄	0,0006
C ₃	0,1139	C ₁₀	0,0000
C ₁₁	0,1061		

Derin öğrenme modeli sonunda elde edilen tahmin değerleri Tablo 5.23.'de, tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları da Şekil 5.10.'de verilmiştir.



Şekil 5.10. Derin öğrenme yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları

5.2.2.4. Karar ağacı kullanarak kan bileşeni talep miktarının belirlenmesi

Karar ağacı yönteminde de girdi ve çıktı değişkenleri olarak yapay zeka tabanlı tahmin yöntemleri için oluşturulan veri seti kullanılmıştır.

Optimum ‘maksimum ağaç derinliği’ni belirlemek için 2 den 25 e kadar farklı değerler denenmiş ve en düşük hata oranını veren değer 10 olarak belirlenmiştir (Tablo 5.14.).

Tablo 5.14. Karar ağacı yönteminde optimum parametrelerin belirlenmesi


Maksimum ağaç derinliği	Hata oranı
2	21,7
4	16,8
7	11,8
10	10,5
15	10,5
25	10,5

Uygulamada kriter ağırlıkları için bulunan değerler Tablo 5.15.'de verilmiştir.

Tablo 5.15. Karar ağacı yönteminde bulunan kriter ağırlıkları

Kriterler	Ağırlıkları	Kriterler	Ağırlıkları
C ₇	0,4077	C ₁₃	0,0413
C ₅	0,4000	C ₁₄	0,0383
C ₃	0,2581	C ₄	0,0362
C ₁₀	0,1351	C ₁₁	0,0266
C ₁₅	0,0754	C ₁	0,0214
C ₉	0,0621	C ₈	0,0198
C ₂	0,0555	C ₁₂	0,0127
C ₆	0,0502		

Karar ağacı yöntemi sonunda elde edilen tahmin değerleri Tablo 5.23.'de, tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları da Şekil 5.11.'de verilmiştir.



Şekil 5.11. Karar ağacı yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları

5.2.2.5. Destek vektör makinesi kullanarak kan bileşeni talep miktarının belirlenmesi

Destek vektör makinesi yönteminde de; girdi ve çıktı değişkenleri olarak yapay zeka tabanlı tahmin yöntemleri için oluşturulan veri seti kullanılmıştır.

Destek vektör makinesine ait parametre seviyeleri kernel gamma parametresi için 0,000, 0,001, 0,010, 0,100, 1,000 ve 10,00; çekirdek değeri parametresi (C) için 10, 100 ve 1000 olarak belirlenmiştir. Yöntem uygulamasında optimum parametre seviyeleri; kernel gamma parametresi için 0,010 ve C parametresi için 1000 olarak %4,6 hata oranı ile tespit edilmiştir (Tablo 5.16.). Bunun yanı sıra tahminde kullanılan toplam destek vektör sayısı 218 olarak bulunmuştur.

Tablo 5.16. Destek vektör makinesi yönteminde optimum parametrelerin belirlenmesi


Gamma	Hata oranı (%)		
	C		
	10	100	1000
0,000	29	27	16,6
0,001	27	16,9	10,5
0,010	19	10,1	4,6
0,100	16,2	6,7	27,6
1,000	23,6	14,5	13,7
10,00	28,1	27,1	28,3

Uygulamada kriter ağırlıkları için bulunan değerler Tablo 5.17.'de verilmiştir.

Tablo 5.17. Destek vektör makinesi yönteminde bulunan kriter ağırlıkları

Kriterler	Ağırlıkları	Kriterler	Ağırlıkları
C ₅	0,6437	C ₁₄	0,0353
C ₆	0,6178	C ₄	0,0308
C ₃	0,2339	C ₉	0,0300
C ₁	0,1081	C ₁₃	0,0106
C ₁₅	0,0946	C ₂	0,0055
C ₁₁	0,0730	C ₇	0,0004
C ₁₂	0,0703	C ₁₀	0,0000
C ₈	0,0397		

Destek vektör makinesi yöntemi sonunda elde edilen tahmin değerleri Tablo 5.23.'de, tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları da Şekil 5.12.'de verilmiştir.



Şekil 5.12. Destek vektör makinesi yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları

5.2.2.6. Rassal orman kullanarak kan bileşeni talep miktarının belirlenmesi

Rassal orman yönteminde girdi ve çıktı değişkenleri olarak yapay zeka tabanlı tahmin yöntemleri için oluşturulan veri seti kullanılmıştır.

Model uygulamasında optimum parametreler; ağaç sayısı için 140 ve maksimum ağaç derinliği için 7 olarak, % 9,9 hata oranı ile tespit edilmiştir (Tablo 5.18.).

Tablo 5.18. Rassal orman yönteminde optimum parametrelerin belirlenmesi


Ağaç sayısı	Hata oranı (%)		
	Maksimum ağaç derinliği		
	2	4	7
20	20,2	14,6	9,9
60	19,3	14,1	10,1
100	19,4	13,6	10,1
140	19,5	14,2	9,9

Uygulamada kriter ağırlıkları için bulunan değerler Tablo 5.19.'da verilmiştir.

Tablo 5.19. Rassal orman yönteminde bulunan kriter ağırlıkları


Kriterler	Ağırlıkları	Kriterler	Ağırlıkları
C ₅	0,5211	C ₁₄	0,0839
C ₇	0,4722	C ₁₅	0,0533
C ₁₀	0,3859	C ₄	0,0314
C ₆	0,2795	C ₁	0,0146
C ₃	0,2311	C ₁₃	0,0119
C ₂	0,1207	C ₁₂	0,0036
C ₈	0,1000	C ₁₁	0,0023
C ₉	0,0845		

Modelde oluşan ağaçlardan bir tanesi Şekil 5.13.'de örnek olarak verilmiştir.



Şekil 5.13. Rassal orman yönteminde oluşturulan ağaç örneği


Rassal orman yöntemi sonunda elde edilen tahmin değerleri Tablo 5.23.'de, tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları da Şekil 5.14.'de verilmiştir.



Şekil 5.14. Rassal orman yöntemiyle tahmin edilen ve gerçekleşen eritrosit süspansiyonu talep miktarları

5.2.2.7. Yapay sinir ağı kullanarak kan bileşeni talep miktarının belirlenmesi

YSA modelinde eritrosit süspansiyonu talebini etkileyeceği düşünülen değişkenler sistemin girdisini, talep edilecek optimum eritrosit süspansiyon miktarı da sistemin çıktısını oluşturmaktadır. Dolayısıyla YSA sisteminde, optimum eritrosit süspansiyon miktarı tahmininde 15 girişli 1 çıkışlı ileri beslemeli model kullanılacaktır. Oluşturulan modele ait YSA yapısı Şekil 5.15.'de verilmiştir.



Şekil 5.15. Kan bankası optimum eritrosit süspansiyon miktarı YSA yapısı

YSA'nın yapısı belirlendikten sonra girdi ve çıktı değerleri 'Min-Max Normalizasyon' formülü (Denklem 3.49) kullanılarak normalleştirilmiştir. Böylece verilerin eğitimi daha verimli hale getirilmiş ve eğitim süresinin kısaltılması sağlanmıştır.

Normalleştirmeden sonra toplanan veriler % 70'i eğitim, %18'i doğrulama ve % 12'si test verisi olmak üzere üçe ayrılmaktadır.

YSA uygulamasında talep belirlenmesi problemlerinde etkili olan çok katmanlı algılayıcı (MLP) tahminde kullanılmıştır (Öztemel, 2016). Bunun yanı sıra MLP modelinde en hızlı algoritma olarak belirlenen Levenberg-Marquardt algoritması tercih edilmiştir (Madić ve Radovanović, 2011). Ayrıca modelde gizli katman sayısı 1 olarak alınmıştır çünkü pratikte birden fazla gizli katman olmasının öğrenmeyi yavaşlattığı ortaya konulmuştur (Timothy, 1993).

YSA’da diğer yapay zeka tabanlı tahmin yöntemlerin aksine optimum parametreler, RapidMiner Studio 9.4 ile elde edilemediği ve performansına etki eden çok sayıda parametre olduğu için Taguchi deney tasarımı ile bulunmuştur. Bu nedenle öncelikle performansa etki eden parametreler; literatürde yer alan Madić ve Radovanović (2011), Moosavi ve ark. (2014), Bashiri ve ark. (2015) ve Datt ve ark. (2015)’nin çalışmaları temel alınarak belirlenmiştir. Uygulamada eğitim algoritması için 8 seviye; öğrenme fonksiyonu, çıktı ile ara katmandaki transfer fonksiyonu, nöron sayısı, iterasyon sayısı ve öğrenme katsayısı için 2 seviye belirlenmiştir (Tablo 5.20.). ANN performansına etki ettiği düşünülen parametrelere ait seviyeler ise literatürdeki çalışmalar baz alınarak belirlenmiştir (Yu, 2004; Singh ve ark., 2013; Yang ve ark., 2013; Kant ve Sangwan, 2015; Cao ve ark., 2016, Shamsavari ve ark., 2017; Nagarkar ve ark., 2019).

Tablo 5.20. YSA parametreleri ve seviyeleri


Parametre	Kodu	Seviye							
		1	2	3	4	5	6	7	8
Eğitim algoritmaları	A	BFG	BR	CBG	CGP	GDX	LM	RP	SCG
Öğrenme fonksiyonları	B	Learngdm	Learngd						
Ara katmandaki transfer fonksiyonu	C	Tansig	Purelin						
Nöron sayısı	D	10	20						
Çıktı katmanındaki transfer fonksiyon	E	Tansig	Purelin						
Maksimum hata	F	6	10						
İterasyon sayısı	G	250	1000						

Belirlenen seviyelere uygun olarak L_{16} mixed Taguchi deney tasarımı çalıştırılmış, elde edilen R^2 değerleri deney sonucu olarak verilmiştir (Tablo 5.21.).

Tablo 5.21. YSA Taguchi deney tasarımı ve sonuçları

Deney	A	B	C	D	E	F	G	R^2			
								Eğitim	Doğrulama	Test	Tümü
1	BFG	Learngdm	Tansig	10	Tansig	6	250	0,96	0,95	0,96	0,96
2	BFG	Learngd	Purelin	20	Purelin	10	1000	0,96	0,95	0,96	0,96
3	BR	Learngdm	Tansig	10	Tansig	10	1000	0,97	0,97	0,98	0,98
4	BR	Learngd	Purelin	20	Purelin	6	250	0,95	0,94	0,97	0,96
5	CGB	Learngdm	Tansig	20	Purelin	6	250	0,98	0,96	0,98	0,98
6	CGB	Learngd	Purelin	10	Tansig	10	1000	0,96	0,96	0,96	0,96
7	CGP	Learngdm	Tansig	20	Purelin	10	1000	0,98	0,95	0,93	0,96
8	CGP	Learngd	Purelin	10	Tansig	6	250	0,12	0,54	0,13	0,19
9	GDX	Learngdm	Purelin	10	Purelin	6	1000	0,94	0,93	0,94	0,94
10	GDX	Learngd	Tansig	20	Tansig	10	250	0,98	0,98	0,96	0,98
11	LM	Learngdm	Purelin	10	Purelin	10	250	0,96	0,97	0,97	0,96
12	LM	Learngd	Tansig	20	Tansig	6	1000	0,99	0,98	0,94	0,98
13	RP	Learngdm	Purelin	20	Tansig	6	1000	0,86	0,93	0,88	0,88
14	RP	Learngd	Tansig	10	Purelin	10	250	0,79	0,88	0,93	0,82
15	SCG	Learngdm	Purelin	20	Tansig	10	250	0,91	0,94	0,93	0,92
16	SCG	Learngd	Tansig	10	Purelin	6	1000	0,98	0,96	0,96	0,97

Optimum sonucu veren parametre seviyeleri $A_2B_1C_1D_2E_1F_2G_2$ şeklinde belirlenmiştir (Şekil 5.16.).




Şekil 5.16. Parametrelerin S/N oranları ortalaması

ANOVA uygulandığında % 5 anlam düzeyinde A, B, C, F ve G parametreleri model üzerinde etkili çıkmıştır (Tablo 5.22.). ANOVA testi sonucunda model üzerinde etkili çıkmayan D ve E parametrelerine ait seviyeler de Taguchi sonunda belirlenen seviyeler olarak alınmıştır. Elde edilen kombinasyon sonucunda bulunan düzenlemiş R^2 değeri % 98,60 olarak belirlenmiştir.

Tablo 5.22. ANOVA testi sonucu

Parametreler	DF	Düzenlenmiş SS	Düzenlenmiş MS	F-değeri	P-değeri
A	7	1606,94	229,563	44,000	0,022
B	1	151,190	151,193	28,980	0,033
C	1	708,340	708,335	135,76	0,007
D	1	22,3000	22,2970	4,2700	0,175
E	1	8,85000	8,85100	1,7000	0,323
F	1	130,040	130,042	24,920	0,038
G	1	416,440	416,439	79,810	0,012
Hata	2	10,4400	5,21800		
Toplam	15	3054,53			

Bulunan optimum kombinasyon YSA'da test edilince elde edilen test sonuçları Şekil 5.17.'deki gibidir.



Şekil 5.17. Optimum kombinasyona ait YSA sonuç ekranı

Bulunan R^2 değerleri Tablo 5.21.'de yer alan değerlerle karşılaştırıldığında optimum kombinasyon ile bulunan YSA sonuçların daha iyi olduğu görülmektedir.

5.3. Tahmin Yöntemlerinin Karşılaştırılması

Çalışma sonunda yapay zeka tabanlı tahmin yöntemleri karşılaştırılmıştır. Destek vektör makineleri; MSE, RMSE, MAPE, MAE ve R^2 istatistiksel performans kriter değerleri incelendiğinde tahmin sonuçlarını en iyi yansıtan yöntem olarak belirlenmiştir (Tablo 5.23.).

Bunun yanı sıra tahmin edilen ve gerçekleşen değerler aralarındaki maksimum fazla tahmin edilen miktar ve minimum eksik tahmin edilen miktar değerleri hesaplanmıştır. Hesaplamalarda hem minimum sapmanın hem de maksimum sapmanın destek vektör makineleri yönteminde en iyi değeri aldığı belirlenmiştir. Tabloda eksik stok ve fazla stok toplamının 62'den küçük çıkması bazı gözlem birimlerinde doğru talep tahmininde bulunulduğunu göstermektedir.

Tablo 5.23. Yapay zeka tabanlı tahmin yöntemleri ile tahmin edilen eritrosit süspansiyonu miktarları

GB	TEES	Tahmin edilen eritrosit süspansiyonu miktarı						
		RR	GAA	DÖ	KA	DVM	RO	YSA
1	144	146	142	163	148	148	155	149
2	194	203	199	173	187	194	192	194
3	184	190	192	157	187	184	185	184
4	163	176	178	129	159	166	169	167
5	212	216	209	156	197	212	209	212
6	116	122	142	96	112	122	136	118
7	149	159	142	113	148	152	163	154
8	287	292	268	258	265	281	276	296
9	494	493	638	514	589	478	513	476
10	478	497	675	442	589	467	437	462
11	882	890	675	910	998	848	786	844
12	248	280	244	221	243	249	251	252
13	333	339	336	315	294	325	305	323
14	103	117	142	93	112	115	139	113
15	237	225	239	177	243	232	228	231
16	249	264	245	213	243	247	238	248
17	341	367	329	329	343	332	319	331

Tablo 5.23. (Devamı)


GB	TEES	Tahmin edilen eritrosit süspansiyonu miktarı						
		RR	GAA	DÖ	KA	DVM	RO	YSA
18	190	191	197	191	187	190	188	191
19	205	208	206	189	201	204	201	201
20	182	189	192	174	187	183	184	182
21	138	145	142	149	112	144	141	146
22	175	177	184	156	164	176	173	175
23	290	282	271	307	265	284	271	236
24	159	170	168	184	159	162	165	166
25	218	189	232	215	220	219	217	222
26	149	125	163	153	159	149	162	149
27	266	248	264	261	265	266	267	266
28	179	156	190	166	177	178	185	182
29	186	161	203	174	201	187	195	187
30	260	235	266	258	265	260	267	259
31	152	132	172	141	159	154	168	154
32	273	248	271	280	265	273	275	273
33	321	294	329	311	343	321	319	320
34	297	278	327	296	294	297	289	297
35	418	411	638	410	407	421	346	423
36	206	166	218	199	210	203	211	203
37	227	205	244	224	232	226	232	226
38	235	223	243	238	232	236	240	236
39	150	137	163	143	159	151	165	151
40	219	196	230	213	220	218	221	218
41	131	103	142	136	112	131	140	131
42	155	125	172	163	159	156	167	156
43	194	167	204	183	197	195	198	195
44	82	54	142	105	112	84	132	88
45	241	223	246	228	232	242	231	242
46	158	152	166	161	159	162	175	161
47	192	180	200	184	187	193	195	193
48	245	238	252	228	265	244	240	246
49	237	222	242	223	232	236	231	236
50	227	214	233	214	232	226	226	226
51	197	189	205	190	201	200	200	199
52	260	243	266	242	265	259	264	259
53	197	190	205	189	201	200	201	203
54	313	293	302	311	294	310	283	311
55	158	160	172	220	159	169	191	172
56	276	282	275	266	265	278	275	278
57	246	246	258	238	265	247	242	247

Tablo 5.23. (Devamı)


GB	TEES	Tahmin edilen eritrosit süspansiyonu miktarı						
		RR	GAA	DÖ	KA	DVM	RO	YSA
58	148	144	148	150	148	153	168	151
59	223	207	230	214	220	222	223	222
60	164	157	169	161	159	169	178	172
61	232	220	237	218	232	231	227	231
62	223	211	230	210	220	223	224	223
MSE		282,90	2626,22	419,44	687,79	36,983	439,44	97,076
RMSE		16,820	51,2466	20,480	26,226	6,0814	20,963	9,8527
MAPE		7,8907	7,02645	8,1671	4,8044	1,3831	5,4210	2,0254
MAE		14,024	22,2787	15,403	13,037	3,2411	12,455	4,7481
R ²		0,984	0,974	0,977	0,996	0,999	0,985	0,986
Eksik stok (GB)		38	13	46	29	21	25	20
Fazla stok (GB)		23	48	16	30	29	36	31
Max sapma		32	220	62	116	12	50	14
Min sapma		-40	-207	-60	-39	-34	-96	-54

GB: Haftalık gözlem birimi TEES: Talep edilen eritrosit sayısı RR:Ridge regresyon GAA: Gradyan artırma ağacı DÖ: Derin öğrenme KA: Karar ağacı DVM: Destek vektör makinesi RO: Rassal orman YSA: Yapay sinir ağı


Bunun yanı sıra TM'lere sadece talep edilebilecekleri miktar kadar eritrosit süspansiyonu gönderilmeli ve eksik/fazla tahminde bulunmaktan kaçınılmalıdır. Şekil 5.18.-Şekil 5.24.'de yer alan 62 haftalık eritrosit süspansiyon miktarlarından negatif olan değerler eksik tatmin edilen eritrosit süspansiyon miktarlarını gösterirken, pozitif olan değerler de fazla miktarda tahmin edilen eritrosit süspansiyon miktarlarını göstermektedir.




Şekil 5.18. Destek vektör makinası yöntemi ile tahmin edilen ve talep edilen eritrosit süspansiyonu farkı




Şekil 5.19. Gradyan artırma ağacı yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları




Şekil 5.20. Derin öğrenme yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları




Şekil 5.21. Karar ağacı yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları



Şekil 5.22. Rassal orman yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları




Şekil 5.23. Yapay sinir ağı yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları



Şekil 5.24. Ridge regresyon yöntemi kullanılarak eksik veya fazla tahmin edilen eritrosit süspansiyonu miktarları

Bunun yanı sıra Şekil 5.25. incelendiğinde destek vektör makinesinin kullanılan diğer yöntemlere göre daha iyi sonuç verdiği görülmektedir. Test için kullanılan 62 veriden talep edilen ve tahmin edilen miktarlar arasındaki fark 0 değerine daha yakın olan yöntem destek vektör makineleri olarak belirlenmiştir.



Şekil 5.25. Talep tahmin yöntemleri ile belirlenen eksik ve fazla tahmin miktarları

Talep tahmin yöntemleri incelendiğinde gradyan artırma ağacı yöntemi ile 13 haftalık gözlem biriminde eksik miktarda tahminde bulunulduğu, derin öğrenme yönteminde de 16 haftalık gözlem biriminde fazla miktarda tahminde bulunulduğu görülmektedir. Ancak miktarlar bazında incelediğimizde destek vektör makinesi yönteminde 24 haftalık gözlem biriminde eksik miktar tahmininde bulunulmasına rağmen toplam eksik eritrosit süspansiyonu miktarı 111'dir. Benzer şekilde destek vektör makinesi yönteminde 38 haftalık gözlem biriminde fazla miktarda tahminde bulundurulmasına rağmen sadece 88 birim eritrosit süspansiyonu fazla tahminde bulunulmuştur (Tablo 5.24.). Bu değerlerin haftalık gözlem birimi bazında ortalaması alınırsa; sadece 2,32 birim fazla, 4,63 birim eksik tahmin söz konusudur. Diğer yapay zekalı tahmin yöntemleri ile karşılaştırılırsa bu değerlerin gerçekleşen değerlerle daha yakın sonuçlar verdiği görülmektedir. Bu nedenle geliştirilen modelde stokastik stok modellerinde destek vektör makinesi ile tahmin edilen değerler kullanılmıştır.

Tablo 5.24. Haftalık gözlem birimi ve miktarlar baz alınarak talep tahmin yöntemlerinin karşılaştırılması

	Tahmin Yöntemleri						
	RR	GAA	DÖ	KA	DVM	RO	YSA
Eksik tahmin (GB)	39	13	46	30	24	25	20
Fazla tahmin (GB)	23	49	16	32	38	37	31
Eksik tahmin (miktar)	656	294	720	281	111	393	169
Fazla tahmin (miktar)	213	1087	235	527	88	379	122
Ortalama fazla miktar	9,26	22,2	14,7	16,5	2,32	10,2	3,94
Ortalama eksik mktar	18,8	22,6	15,7	9,37	4,63	15,7	8,45

RR: Ridge regresyon, GAA: Gradyan artırma ağacı, DÖ: Derin öğrenme, KA: Karar ağacı, DVM: Destek vektör makinesi, RO: Rassal orman, YSA: Yapay sinir ağı, GB: Gözlem birimi

5.4. Stokastik Stok Modellerinin Oluşturulması

Geliştirilen modelde öncelikle, yapay zeka tabanlı tahmin yöntemleri kullanılarak kan bileşeni miktarları belirlenmiş ve gerçekleşen talep miktarları ile en yakın değer veren yöntem tespit edilmiştir. Elde edilen bu tahmin değerleri stokastik stok modellerinde talep girdisi olarak alınmış ve verilecek siparişin büyüklüğünün, zamanının ve modelin sürekli mi yoksa periyodik olarak mı takip edileceğinin belirlenmesi amaçlanmıştır.

Oluşturulan stokastik stok modellerinde; s değeri 24 birim (Denklem 3.3) ve Q değeri 307 birim (Denklem 3.4) kullanılarak hesaplanmıştır (Hillier ve Lieberman, 2001). Bunun yanı sıra kan bankasına ait stok politikasına göre R değeri 1 hafta ve S değeri 1500 birim olarak belirlenmiştir.

(s,Q) stokastik stok modelinde stokta kalan kan bileşeni miktarı 24 birim ve altına düştüğünde 307 birim kan bileşeni siparişi verilmelidir. Örnek olarak 10 haftalık gözlem biriminde (s,Q) stokastik stok modeli incelenmiştir (Tablo 5.25.). Modelde tahmini talep miktarının belirlenmesinde istatistiksel performans kriterleri açısından en iyi değeri veren destek vektör makinesi kullanılmıştır. Stokta kalan miktarın 24 birimden az olduğu 1., 3., 5., 7., 8., 9., ve 10. haftalara ait gözlem biriminde tahmini talep miktarları göz önünde bulundurularak 307 ve katları şeklinde sipariş verilmiştir.

Tablo 5.25. On haftalık gözlem biriminde (s,Q) stokastik stok modeli

Gözlem birimi (haftalık)	Başlangıç stok miktarı	Tahmini talep miktarı	Stokta kalan miktar	Gelen sipariş	Elde kalan miktar
1	144	144	0	307	307
2	307	194	113	0	113
3	113	184	-71	307	236
4	236	163	73	0	73
5	73	212	-139	307	168
6	168	116	52	0	52
7	52	149	-97	307	210
8	210	287	-77	307	230
9	230	494	-264	307	43
10	43	478	-435	614	179

(s,S) stokastik stok modelinde yine kritik stok seviyesi 24 birim ve altına düştüğü zaman maksimum stok seviyesi ile stokta kalan kan bileşeni miktarı kadar sipariş verilmelidir. Tablo 5.26.'da 10 haftalık gözlem biriminde 1. ve 9. haftalarda stokta kalan miktar 24 birimin altına düştüğü için '1500- bir dönem önceki dönemde elde kalan miktar' kadar sipariş verilecektir.

Tablo 5.26. On haftalık gözlem biriminde (s,S) stokastik stok modeli

Gözlem birimi (haftalık)	Başlangıç stok miktarı	Tahmini talep miktarı	Stokta kalan miktar	Gelen sipariş	Elde kalan miktar
1	144	144	0	1500	1500
2	1500	194	1306	0	1306
3	1306	184	1122	0	1122
4	1122	163	959	0	959
5	959	212	747	0	747
6	747	116	631	0	631
7	631	149	482	0	482
8	482	287	195	0	195
9	195	494	-299	1305	1006
10	1006	478	528	0	528

Periyodik olarak gözden geçirme yöntemlerinde ise gözden geçirme periyodunda (R,S) stokastik stok modelinde kritik stok seviyesine bakılmaksızın; (R,s,S) stokastik stok modelinde ise kritik stok seviyesi 24 birim ve altına indiğinde maximum stok seviyesine ulaşacak kadar sipariş verilecektir.

(R,S) stokastik stok modelinde her gözlem döneminde ‘1500 - bir dönem önceki dönem elde kalan miktar’ kadar sipariş verilecektir (Tablo 5.27.).

Tablo 5.27. On haftalık gözlem biriminde (R,S) stokastik stok modeli

Gözlem birimi (haftalık)	Başlangıç stok miktarı	Tahmini talep miktarı	Stokta kalan miktar	Gelen sipariş	Elde kalan miktar
1	144	144	0	1356	1356
2	1356	194	1162	144	1306
3	1306	184	1122	194	1316
4	1316	163	1153	184	1337
5	1337	212	1125	163	1288
6	1288	116	1172	212	1384
7	1384	149	1235	116	1351
8	1351	287	1064	149	1213
9	1213	494	719	287	1006
10	1006	478	528	494	1022

(R,s,S) stokastik stok modelinde ise; her gözlem döneminde stokta kalan miktar kontrol edilecek ve miktar 24 birime eşit veya 24 birimden düşükse ‘1500 - bir dönem önceki dönem elde kalan miktar’ kadar sipariş verilecektir (Tablo 5.28.).

Tablo 5.28. On haftalık gözlem biriminde (R,s,S) stokastik stok modeli

Gözlem birimi (haftalık)	Başlangıç stok miktarı	Tahmini talep miktarı	Stokta kalan miktar	Gelen sipariş	Elde kalan miktar
1	144	144	0	1356	1356
2	1356	194	1162	0	1162
3	1162	184	978	0	978
4	978	163	815	0	815
5	815	212	603	0	603
6	603	116	487	0	487
7	487	149	338	0	338
8	338	287	51	0	51
9	51	494	-443	1449	1006
10	1006	478	528	494	1022

Stok modelleri incelenirken kan bankasının uyguladığı mevcut stok yönetimi ile tahmin yöntemleri arasından en iyi değeri veren DVM'leri kullanılarak oluşturulan (s,Q), (s,S), (R,S) ve (R,s,S) stokastik stok modelleri karşılaştırılmıştır. Kan bankasının uyguladığı mevcut stok modelinde 62 haftalık gözlem biriminden sadece 10 haftalık gözlem biriminde stokların tam yettiği, 52 haftalık gözlem biriminde ise TM'lerde eksik stok bulunduğu görülmektedir.

Ayrıca eksik stok ve fazla stok miktarları gözlem birimleri bazında incelendiğinde kan bankasının uyguladığı stok modelinde elde edilen ortalama eksik stok miktarı 54,94 birim, fazla stok miktarı 0 birim olarak hesaplanmıştır.

Tahmin yöntemleri arasından en iyi değeri veren DVM'leri kullanılarak oluşturulan (s,Q), (s,S), (R,S) ve (R,s,S) stokastik stok modellerinde ise (s,S) stokastik stok modelinde 24 dönemde 111 adet eksik talep tahmin edildiği, 38 dönemde 88 adet fazla talep tahmini edildiği görülmektedir. Modelde; ortalama eksik stok miktarı 4,625, fazla stok miktarı 2,315 olarak hesaplanmıştır. Bu değerler kan bankasının uyguladığı ve diğer stokastik stok modelleri değerlerden daha az eksik/fazla talepte bulunulduğunu göstermektedir (Tablo 5.29.).

Tablo 5.29. Stok modelleri baz alınarak hesaplanan stok durumları

		Kan bankasının uyguladığı	s,Q stok modeli	s,S stok modeli	R,S stok modeli	R,s,S stok modeli
Haftalık	Eksik stok	52	26	24	25	23
Gözlem Birimi	Fazla stok	0	36	38	37	39
Miktar	Eksik stok	2857	2887	111	138	153
	Fazla stok	0	4343	88	595	465
Ortalama	Eksik stok	54,94	111,0	4,625	5,520	6,652
	Fazla stok	0	120,6	2,315	16,081	11,923

5.5. Maliyet Modelinin Oluşturulması

Uygulamada, toplam maliyeti en aza indirmek için incelemeler yapılmıştır. Çalışmada kullanılan alt maliyet bileşenlerinin birim değerleri Tablo 5.30.'da verilmiştir.

Tablo 5.30. Alt maliyet bileşenleri birim değerleri

Notasyon	Maliyet türleri	Değeri (\$/birim)	Referans
C_w	Toplam imha	150	Hajima ve ark. (2007)
C_o	Toplam sabit sipariş açma	225	
C_s	Toplam stoksuz kalma durumunda yok satma ceza	M (Big M)	
C_t	Toplam diğer TM veya BKM'lerden karşılama	2	*
C_h	Toplam elde bulundurma	1,25 (Günlük)	Günpınar ve ark. (2014)
C_v	Toplam işleme ve test etme	180	Nagurney ve ark. (2012)

* Benzinli bir araçla kat edilen mesafe göz önünde bulundurularak hesaplanmıştır.

Modelde; elde bulundurma maliyeti kan merkezine ait depo giderleri ve kira ile kanın ürün bütünlüğünün bozulmaması için kullanılan soğutma işlemleri, şoklama gibi giderlerini kapsar.

Yok satma ceza maliyeti, kan merkezinin elde bulundurmadığı her birim kan bileşeni için toplam maliyete yansıtılan alt maliyet miktarıdır. Yok satma ceza maliyeti söz konusu olduğunda kan bankalarında sonradan karşılama mümkün olmadığı için farklı TM'lerden veya BKM'lerden karşılama gerçekleşir. Bu durumda karşılama maliyeti oluşmaktadır. Ancak yok satmanın gerçekleştiği TM kan bağışı kabul etmede yetkili

ise kanı işleme ve test etme maliyeti karşılığında donörlerden kan bağışı kabul edebilir. Bu maliyet; elde etme, kan bileşeni ayrıştırma ve kanı tranfüzyona uygun hale getirmek için yapılan işlem ve test maliyetinden oluşmaktadır.

Kan bankası fazladan stoğunda kan veya kan bileşeni bulundurup; stoğundaki ürünler ortam koşulları veya son kullanım süresinin bitmesinden dolayı imha edilirse bu durumda imha maliyetine katlanılır.

Sipariş verme maliyeti ise sipariş miktarı belirleme, talebi işleme koyma gibi sipariş sayısına bağlı olarak değişen maliyetleri içeren alt maliyet bileşenidir.

Maliyet modelinde öncelikle, kan bankasının uyguladığı talep belirleme modeli ile dönemsel beklenen maliyeti belirlemek için 2017-2018 yıllarına ait haftalık bazda talep edilen ve TM'lere gönderilen eritrosit süspansiyon miktarı kullanılmıştır. Tablo 5.31.'de Eskişehir Osmangazi Üniversitesi Sağlık, Uygulama ve Araştırma Hastanesi'nin 27-30. haftalarda talep ettiği ve Batı Anadolu Bölge Kan Merkezi'nin gönderdiği eritrosit süspansiyonu göz önünde bulundurularak hesaplanan haftalık beklenen maliyetler örnek olarak verilmiştir. Diğer haftalara ait haftalık beklenen maliyetler de Denklem 4.12 kullanılarak hesaplanmaktadır.

Tablo 5.31. Önerilen model ile hesaplanan eritrosit süspansiyon talepleri beklenen maliyetler

Hafta No	C_w	C_s	C_t	C_h	C_v	TC
27	0	392540	0	0	108180	500720
28	0	345780	0	0	108360	454140
29	0	558760	0	0	111420	670180
30	0	360820	0	0	92520	453340

Tabloya göre tahmin etme konusunda en iyi sonucu veren destek vektör makinesi yöntemi ile talep tahmini yapılırsa; stokastik stok modelinde; elde bulundurma stok maliyeti, yok satma ceza maliyeti, farklı TM'lerden veya BKM'den karşılama maliyeti ve sabit sipariş açma maliyeti azalacağı için toplam maliyet de azalacaktır.

Daha sonra dönemsel olarak belirlenen maliyetler toplanarak toplam maliyet değerleri hesaplanmaktadır. Kan bankasının uyguladığı stok modelinde; (Denklem 4.12) kullanılarak hesaplanan toplam maliyet miktarı 62 haftalık gözlem biriminde 1902151 \$ olarak bulunmuştur (Tablo 5.32.). Uygulamada destek vektör makinası tahminleri baz alınarak oluşturulan (s,Q) stokastik stok modeli toplam maliyeti 1883884 \$, (s,S) stokastik stok modeli toplam maliyeti (104568 \$), (R,S) stokastik stok modeli toplam maliyeti 112512 \$ ve (R,s,S) stokastik stok modeli toplam maliyeti 129747 \$ olarak hesaplanmaktadır. Bu nedenle (s,S) stokastik stok modelinin diğer stok modellerine göre daha uygun sonuçlar verdiği görülmüştür. Tablo 5.32.'de test için ayrılmış 62 haftalık gözlem biriminin ilk 10 ve son 10 haftalık maliyetleri yer almaktadır.

Tablo 5.32. Stok modelleri baz alınarak hesaplanan maliyetler

Gözlem birimi (Haftalık)	Kan bankasının uyguladığı	(s,Q) stok modeli	(s,S) stok modeli	(R,S) stok modeli	(R,s,S) stok modeli
1	1337	1079	410	687	1429
2	1406	1220	468	756	570
3	7242	6999	455	742	499
4	716	520	432	716	520
5	2082	1714	490	782	814
6	659	494	377	659	794
7	2008	1766	415	708	466
8	77589	77258	4399	3889	14558
9	204599	203933	10989	11149	10483
10	254625	254219	7674	8125	7719
.	.	.	.	.	.
.	.	.	.	.	.
.	.	.	.	.	.
53	565	428	476	565	428
54	41000	40720	2344	3700	4420
55	27142	27031	436	492	381
56	37682	37311	572	632	1261
57	44782	44538	534	582	538
58	1748	1836	416	448	536
59	7684	7566	1077	834	1716
60	3699	3686	436	449	436
61	7026	7030	952	537	530
62	7654	7560	616	504	410
TOPLAM (\$)	1902151	1883884	104568	112512	129747

Stokastik stok modelleri sonunda elde edilen sonuçlara göre hem stok miktarları açısından hem de toplam maliyet açısından en iyi sonucu veren stok modelinin destek vektör makinasını baz alan (s,S) stokastik stok modelinin olduğu görülmektedir. Ancak diğer tahmin yöntemlerinin kullanılması ile maliyet sonuçlarının nasıl değiştiğini görmek için diğer yapay zeka tabanlı tahmin yöntemleri baz alınarak da (s,S) stokastik stok modeli oluşturulmuştur (Tablo 5.33.). Tabloya göre 62 haftalık gözlem biriminde en az maliyeti veren tahmin yöntemi yine destek vektör makinası yöntemi olmuştur. Destek vektör makinası yöntemini sırasıyla karar ağacı, gradyan artırma ağacı, yapay sinir ağı ve rassal orman yöntemlerini baz alan (s,S) stokastik stok yönetimi izlemiştir.

Tablo 5.33. Tahmin yöntemleri baz alınarak hesaplanan maliyetler

GB	Tahmin Yöntemleri						
	GAA	DÖ	KA	DVM	RO	YSA	RR
1	1821	428	410	410	418	2212	407
2	474	14263	5009	468	1656	5702	478
3	465	17662	459	455	456	3385	462
4	448	22237	2862	432	436	1958	446
5	2155	36577	10221	490	2748	4151	496
6	402	13496	3243	377	395	379	378
7	5071	23972	1276	415	428	5335	423
8	12822	19265	14949	4399	7809	6182	590
9	1023	868	961	10989	866	7672	1263
10	1069	24457	961	7674	27670	963	846
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
53	481	5929	476	476	476	579	4839
54	7971	1788	12943	2344	20048	1618	13464
55	440	499	424	436	463	460	424
56	1096	7070	7799	572	946	1730	578
57	547	5745	556	534	3146	607	842
58	411	413	626	416	435	1574	2760
59	513	6291	2288	1077	504	588	10647
60	436	2440	3512	436	448	575	4674
61	521	9534	515	952	3721	583	8167
62	513	8926	2288	616	504	575	8303
Toplam	223977	499275	215091	104568	287682	227699	458155

GAA: Gradyan artırma ağacı, DÖ: Derin öğrenme, KA: Karar ağacı, DVM: Destek vektör makinesi, RO:Rassal orman, YSA: Yapay sinir ağı, RR:Ridge regresyon.

Geliştirilen toplam maliyete ait amaç fonksiyonu (Denklem 4.12) MATLAB R2014A programı kullanılarak hesaplanmıştır.



BÖLÜM 6. TARTIŞMA VE SONUÇ

Kan bileşenlerinin hasta veya yaralı kişilere nakli hayatî bir önem taşımaktadır. Bunun yanı sıra kan bağışının miktarı ve kan bağışı yapma zamanları tamamen değişkendir. Bu nedenle stokta bulunan kan bileşenleri gerekli duyulan transfüzyon merkezinde, gerekli olan zamanda, istenilen miktarda ve uygun olarak hastaya veya yaralıya nakledilmelidir.

Kan bankasının uyguladığı mevcut sistemde transfüzyon merkezinin bölge kan merkezinden talep ettiği kan bileşeni miktarı üç ana karar değişkeni ile hesaplanmaktadır. Bu değişkenler; MCKBİÇ, kritik stok seviyesi ve transfüzyon merkezlerinde stokta bulunan kan bileşen miktarıdır. Kritik stok seviyesinin hesaplanması için hareketli ortalamalar yöntemi kullanılmaktadır. Bu sistemin dezavantajı sadece özel bir durum ortaya çıktıktan sonra önlem alınabilmesidir. Örneğin; kan bileşeni imha oranı arttıktan sonra kritik stok seviyesinin azalması gündeme gelmektedir. Bu da zaten stokastik bir ortamda kabul edilen kan bağışının hastaya veya yaralıya nakil edilmeden imha edilmesi anlamına gelmektedir.

Önerilen sistemde ise kan bileşeni talebine etki edebilecek değişkenler düşünülerek öncelikle gelecek dönemde meydana gelecek kan bileşeni talebi tahmin edilip; tahmin edilen miktarlara bağlı olarak stokastik stok modeli seçilmesi planlanmaktadır. Böylece talep miktarına etki edebilecek herhangi bir özel durum ortaya çıkmadan model bunu hesaba katarak her bir transfüzyon merkezi için talep edilecek kan bileşeni miktarı belirlenecektir. Örneğin stokastik stok modeli, resmi tatilin olduğu bir dönemde talep edilecek kan bileşeni miktarını daha az; hastane yatak kapasitesi arttırıldığı zaman talep edilecek kan bileşeni miktarını daha fazla hesaplayacaktır. Bu da transfüzyon merkezlerindeki fazla istemde bulunma eğilimlerini azaltacak, imha

edilecek kan bileşenleri farklı bir TM’de hastaya nakil edilerek değerlendirilmiş olacaktır.

Önerilen stokastik stok modelinde öncelikle talep edilecek kan bileşeni miktarına etki eden değişkenler belirlenmiştir. Bu değişkenler ile yapay zeka tabanlı tahmin yöntemleri kullanılarak gelecek dönemlerde gerçekleşecek talep miktarları tahmin edilmiştir. İstatistiksel performans kriterleri baz alınarak belirlenen en iyi performansı gösteren destek vektör makinesi stokastik stok modellerinin oluşturulmasında kullanılmıştır. Destek vektör makinesi baz alınarak oluşturulan (s,Q) , (s,S) , (R,S) ve (R,s,S) stokastik stok modelleri sayesinde; verilecek siparişin büyüklüğü, zamanı ve modelin sürekli mi yoksa periyodik olarak mı takip edileceği belirlenmektedir. Stokastik stok modeli oluşturulduktan sonra geliştirilen toplam maliyet modeli sayesinde de kan bankasında maliyeti en küçükleyecek modelin kullanılması sağlanmıştır.

Sonuç olarak; kullanılan destek vektör makinesi ile talep edilen eritrosit süspansiyon miktarını öğrenen model sonraki dönemlerde talep edilecek eritrosit süspansiyon miktarlarını hastaneler bazında tahmin edebilecektir. Talep edilecek eritrosit süspansiyon miktarı belli olduğu için transfüzyon merkezlerin stokta bekletmek için istedikleri miktarın önüne geçecek böylece gerçekten ihtiyacı olan transfüzyon merkezlerin ihtiyacı karşılanacaktır. Bu durumda transfüzyon merkezinin diğer transfüzyon merkezlerinden veya bölge kan merkezlerinden talepte bulunulması ve stoksuz kalma ceza maliyetine katlanması; stokta fazla eritrosit süspansiyonu bulunduran TM’nin de stok maliyeti ve son kullanma süresi biterse imha maliyetine katlanması engellenmiş olacaktır.

Önerilen model, eritrosit süspansiyonu dışındaki kan bileşenleri olan taze donmuş plazmanın ve trombosit süspansiyonunun toplam maliyetini azaltacak şekilde tasarlanmıştır. Bu nedenle model farklı kan bileşenleri için de kullanılabilirliği yeteneğine sahiptir. Bunun yanı sıra, farklı kan merkezlerinde de yazılım kullanılarak uygulanabilirliği özelliğine sahiptir. Yazılım kullanımıyla veriler değişse bile model,

toplam maliyeti en az yapan tahmin yöntemini ve stokastik stok modelini belirlenebilecektir.



KAYNAKLAR

- Abbasi, B. Hosseinifard, S.Z. 2014. On the issuing policies for perishable items such as red blood cells and platelets in blood service. *Decision Sciences*, 45 (2014): 995-1020.
- Abdulwahab, U. Wahab, M.I.M. 2014. Approximate dynamic programming modeling for a typical blood platelet bank. *Computers & Industrial Engineering*, 78 (2014): 259–270.
- Ahmad, T. Chen, H., Shair, J. 2018. Water source heat pump energy demand prognosticate using disparate data-mining based approaches. *Energy*, 152: 788-803.
- Akita, T. Tanaka, J., Ohisa, M., Sugiyama, A., Nishida, K., Inoue, S., Shirasaka, T. 2016. Predicting future blood supply and demand in Japan with a Markov model: Application to the sex- and age-specific probability of blood donation. *Transfusion*, 56: 2750-2759.
- Al-Musaylh, M.S. Deo, R.C., Adamowski, J.F., Li, Y. 2018. Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia. *Advanced Engineering Informatics*, 35: 1-16.
- Anand, A. Suganthi, L. 2018. Hybrid GA-PSO optimization of artificial neural network for forecasting electricity demand. *Energies*, 11, 728.
- Arslan ,Ş. 2015. Sağlık Sektöründe (s,S) Stok Kontrol Modeli Uygulaması. Dicle Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Bölümü, Yüksek Lisans Tezi.
- Asllani, A. Culler, E., Ettkin, L. 2014. A simulation-based apheresis platelet inventory management model. *Transfusion*, 54:2730-2735.
- Ayanoğlu, M. 2006. Üretim Yönetimi, Sakarya Kitapevi, 1-324.
- Ayaru, L. Ypsilantis, P-P., Nanapragasam, A., Choi, RC-H., Thillanathan, A., Min-Ho, L., Montana, G. 2015. Prediction of outcome in acute lower gastrointestinal bleeding using gradient boosting. *PLoS ONE*, 10(7): e0132485.
- Basak, D. Pal, S., Patranabis, D.C. 2007. Support vector regression. *Neural Information Processing – Letters and Reviews*, 11(10):203–224.
- Baesler, F. Nemeth, M., Martínez, C. Bastias, A. 2014. Analysis of inventory strategies for blood components in a regional blood center using process simulation. *Transfusion*, 54(2): 323-330.
- Basheer, I. Hajmeer, M. 2000. Artificial neural networks: Fundamentals, computing, design and application. *Journal of Microbiological Methods*, 43(1): 3-31.

- Bashiri, M. Rezaei, H.R., Farshbaf Geranmayeh, A., Ghobadi, F. 2015. A comparison of regression and neural network based for multiple response optimization in a real case study of gasoline production process. *Journal of Industrial and Systems Engineering*, 8(3): 77-94.
- Bedi, J. Toshniwal, D. 2019. Deep learning framework to forecast electricity demand. *Applied Energy*, 238 (2019): 1312–1326.
- Beliën, J. Forcé, H. 2012. Supply chain management of blood products: A literature review. *European Journal of Operational Research*, 217(1): 1–16.
- Breiman, L. Friedman, J., Stone, C.J., Olshen, R.A. 1984. *Classification and Regression Trees*, Chapman & Hall CRC Press.
- Breiman, L. 2001. Random forests, *Machine learning*, 45(1): 5-32.
- Brentan, B.M. Meirelles, G., Herrera, M., Luvizotto, E., Izquierdo, J. 2017a. Correlation analysis of water demand and predictive variables for short-term forecasting models. *Mathematical Problems in Engineering*. 2017:1-10.
- Brentan, B.M. Luvizotto, E., Herrera, M., Izquierdo, J., Pérez-García R. 2017b. Hybrid regression model for near real-time urban water demand forecasting. *Journal of Computational and Applied Mathematics*, 309, 532-541.
- Brentan, B.M. Meirelles, G.L., Manzi, D., Luvizotto, E. 2018. Water demand time series generation for distribution network modeling and water demand forecasting. *Urban Water Journal*, 15(2): 150-158.
- Boehmke, B. Greenwell, B. 2019. *Hands-On Machine Learning with R*, Chapman and Hall/CRC Press.
- Borgelt, C. Rudolf, K. 2006. *Artificial Intelligence Methodologies*. İçinde: *Methods, Algorithms, and Software*, in *CIGR Handbook of Agricultural Engineering*.
- Cao, F. Wang D., Zhu, H., Wang, Y. 2016. An iterative learning algorithm for feedforward neural networks with random weights. *Information Sciences* 328: 546-557.
- Chen, S. Wang, C. 2019. Incorporating a Bayesian Network into Two-Stage Stochastic Programming for Blood Bank Location-Inventory Problem in Case of Disasters. *Discrete Dynamics in Nature and Society*, 2019(1):1-28.
- Civelek, İ. Karaesmen, I., Scheller-Wolf A. 2015. Blood Platelet Inventory Management With Protection Levels. *European Journal of Operational Research*, 243(3): 826–838.
- Cohen, L. Manion, L., Morrison, K. 2000. *Research Methods in Education* (6th Edition), London: Routledge.
- Cortes, C. Vapnik, V. 1995. Support-Vector Networks. *Machine Learning*, 20: 273-297.
- Cristianini, N. Shawe-Taylor, J. 2000. *An Introduction to Support Vector Machines: and Other Kernel-Based Learning Methods*, Cambridge University Press.

- Currie, C.J. Patel, T.C., McEwan, P., Dixon, S. 2004. Evaluation of the future supply and demand for blood products in the United Kingdom National Health Service. *Transfusion Medicine*, 14(1):19-24.
- Datt, G. Bhatt, A.K., Saxena, A. 2015. An Investigation of Artificial Neural Network Based Prediction Systems in Rain Forecasting. *International Journal on Recent and Innovation Trends in Computing and Communication*, 3(8): 5338 – 5349.
- Drackley, A. Newbold, K.B., Paez, A., Heddle, N. 2012. Forecasting Ontario's blood supply and demand. *Transfusion*, 52(2):366-374.
- de Kort, W. Janssen, M., Kortbeek, N., Jansen, N., van der Wal, J., van Dijk, N. 2011. Platelet pool inventory management: theory meets practice. *Transfusion*, 51(11):2295-303.
- Dillon, M. Oliveir, F., Abbasi, B. 2017. A Two-Stage Stochastic Programming Model For Inventory Management in The Blood Supply Chain. *International Journal of Production Economics*, 187: 27–41.
- Duan, Q. Liao, T. 2013. A new age-based replenishment policy for supply chain inventory optimization of highly perishable products. *International Journal of Production Economics*, 145: 658–671.
- Duan, Q. Liao, T. 2014. Optimization of Blood Supply Chain With Shortened Shelf Lives and ABO Compatibility. *International Journal of Production Economics*, 153: 113–129.
- Dunbar, N.M. Yazer, M.H. 2018. O- product transfusion, inventory management, and utilization during shortage: the OPTIMUS study. *Transfusion*, 58(6): 1348-1355.
- Duong, L. Wood, L., Wang, W. 2015. A Multi-Criteria Inventory Management System For Perishable & Substitutable Products. *Procedia Manufacturing*, 2: 66–76.
- Firouzi Jahantigh, F. Fanoodi, B., Khosravi, S. 2018. A demand forecasting model for the blood platelet supply chain with Artificial Neural Network approach and ARIMA models. *Scientific Journal of Iran Blood Transfusion Organ*, 14(4): 335-345.
- Fontaine, M. Chung, Y., Erhun, F., Goodnough, L. 2010. Age of blood as a limitation for transfusion: potential impact on blood inventory and availability. *Transfusion*, 50(10), 2233–2239.
- Fortsch, S. 2014. Optimal Forecasting and Ordering Methods to Match Demand & Supply, and Reduce Waste in Blood Supply Chains.
- Fortsch, S.M. Khapalova, E.A. 2016. Reducing uncertainty in demand for blood. *Operations Research for Health Care*, 9:16–28.
- Golas, S.B. Shibahara, T., Agboola, S., Otaki, H., Sato, J., Nakae, T., Hisamitsu, T., Kojima, G., Felsted, J., Kakarmath, S., Kvedar, J., Jethwani, K. 2018. A machine learning model to predict the risk of 30-day readmissions in patients with heart failure: a retrospective analysis of electronic medical records data. *BMC Medical Informatics and Decision Making*, 18(1): 4.

- Gunpinar, S. Centeno, G. 2015. Stochastic Integer Programming Models For Reducing Wastages And Shortages of Blood Products at Hospitals. *Computers & Operations Research*, 54: 129–141.
- Gurgel, J.L.M. Carmo, B.B.T. 2014. Sizing inventory of blood products in a blood bank at Brazil based on a model of inventory management and a demand forecast. *Revista Produção Online*, 14(1): 264-293.
- Haghani, S. Sedehi, M., Kheiri, S. 2017. Artificial Neural Network to Modeling Zero-inflated Count Data: Application to Predicting Number of Return to Blood Donation. *Journal of Research in Health Sciences*, 17(3): e00392.
- Haijema, R. van der Wal, J., van Dijk, N.M. 2007. Blood platelet production: optimization by dynamic programming and simulation. *Computers & Operations Research*, 34 (3): 760–779.
- Haijema, R. Van DerWal, J., Dijk, N., Sibinga, C. 2008. Blood platelet production with breaks: Optimization with SDP and simulation. *International Journal Production Economy*, 49(3): 412–420.
- Haijema, R. 2013. A New Class Of Stock-Level Dependent Ordering Policies For Perishables With A Short Maximum Shelf Life. *International Journal of Production Economics*, 143: 434–439.
- Haijema, R. 2014. Optimal ordering, issuance and disposal policies for inventory management of perishable products. *International Journal of Production Economics*, 157(2014) :158–169.
- Hair, J.F. Black, W.C., Babin, B.J., Anderson, R.E. 2009. *Multivariate data analysis*. Prentice Hall.
- Hamzaçebi, C. Es H.A., Çakmak R. 2019. Forecasting of Turkey's monthly electricity demand by seasonal artificial neural network. *Neural Computing and Applications*, 31(2019): 2217–2231.
- Han, J. Kamber, M., Pei, J. 2012. *Data Mining: Concepts and Techniques*. Morgan Kaufmann, 740.
- Hax, A.C. Candea, D. 1984. *Production And Inventory Management*. New Jersey: Prentice Hall.
- Hemmelmayr, V. Doerner, K., Hartl, R., Savelsbergh, M. 2010. Vendor Managed Inventory For Environments With Stochastic Product Usage. *European Journal of Operational Research*, 202: 686–695.
- Hess, J. R. Grazzini, G. 2011. *Chemistry And Biochemistry Of Oxygen Therapeutics: From Transfusion To Artificial Blood*. içinde: *Transfusion: Political, administrative and logistic issues*. *Chemistry and Biochemistry of Oxygen Therapeutics: From Transfusion to Artificial Blood*. John Wiley & Sons.
- Hillier, FS. Lieberman, GJ. 2001. *Introduction to Operations Research*, McGraw-Hill Higher Education, 935- 1008.
- Ho, W-H. Chang, C-S. 2011. Genetic-algorithm-based artificial neural network modeling for platelet transfusion requirements on acute myeloblastic leukemia patients. *Expert Systems with Applications*, 38(5): 6319-6323.

- Hoerl, A.E. Kennard, R.W. 1970. Ridge regression: Biased estimation for non-orthogonal problems. *Technometrics*, 12: 55-67.
- Hosseinfard, Z. Abbasi, B. 2018. The inventory centralization impacts on sustainability of the blood supply chain. *Computers and Operations Research*, 89: 206–212.
- <http://industryolog.com/deeplearning>., Erişim Tarihi: 17.09.2019.
- Hyndman, R.J. Koehler, A.B. 2006. Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 22(4): 679-688.
- Ivanin, O.A. Direktor, L.B. 2018. The Use of Artificial Neural Networks for Forecasting the Electric Demand of Stand-Alone Consumers. *Thermal Engineering*, 65(5): 258–265.
- Janssen, L. Claus, T., Sauer, J. 2016. Literature Review of Deteriorating Inventory Models by Key Topics From 2012 to 2015. *International Journal of Production Economics*. 182: 86–112.
- Johannesen, N.J. Kolhe, M., Goodwin, M. 2019. Relative evaluation of regression tools for urban area electrical energy demand forecasting. *Journal of Cleaner Production*, 218 (2019): 555-564.
- Kant, G. Sangwan, K. S. 2015. Predictive Modelling and Optimization of Machining Parameters to Minimize Surface Roughness using Artificial Neural Network Coupled with Genetic Algorithm. *Procedia CIRP* 31: 453 – 458.
- Kingsman, B.G. Tarim, S.A. 2004. The Stochastic Dynamic Production/Inventory Lot-Sizing Problem with Service Level Constraints. *International Journal of Production Economics*, 88 (15): 105-119.
- Kingsman, B.G. Tarim, S.A. 2006. Modelling and Computing (Rn,Sn) Policies for Inventory Systems with Non-Stationary Stochastic Demand. *European Journal of Operational Research*, 174(1): 581-599.
- Kopach, R. 2004. Finding the optimal switchover level between two levels of demand in a blood bank. University of Toronto, Yüksek Lisans Tezi.
- Kopach, R. Balcıoğlu, B., Carter, M. 2008. Tutorial On Constructing A Red Blood Cell Inventory Management System With Two Demand Rates. *European Journal of Operational Research*, 185: 1051–1059.
- Kouki, C. Sahin, E., Jemai, Z., Dallery, Y. 2013. Assessing The Impact Of Perishability And The Use Of Time Temperature Technologies On Inventory Management. *International Journal of Production Economics*, 143:72–85.
- Küçük, O. 2009. Stok Yönetimi Amprik Bir Yaklaşım, Seçkin Yayıncılık.
- Lang, C. 2010. *Production and Inventory Management with Substitutions*, Springer-Verlag Berlin.
- Lau, E.H.Y. He, X-Q., Lee, C-K., Wu, J.T. 2013. Predicting future blood demand from thalassemia major patients in Hong Kong. *PLoS ONE*, 8(12): e81846.
- Law, R. Li, G., Fong, D.K.C., Xin, H. 2019. Tourism demand forecasting: A deep learning approach. *Annals of Tourism Research*, 75 (2019): 410–423.

- LeCun, Y. Bengio, Y., Hinton, G. 2015. Deep learning. *Nature*, 521: 436–444.
- Liu, L. Adan, I., Perry, D. 2016. Two Perishable Inventory Systems With One-Way Substitution. *Annals of Operations Research*, 1–22.
- Lowalekar, H. Ravi, R. 2017. Revolutionizing Blood Bank Inventory Management Using The TOC Thinking Process: An Indian Case Study. *International Journal of Production Economics*, 186: 89–122.
- Lowalekar, H. Ravichandran, N. 2017. A combined age-and-stock-based policy for ordering blood units in hospital blood banks. *International Transactions in Operational Research*, 24(2017): 1561–1586.
- Ma, J. Powell, W. 2008. Convergence proofs of least squares policy iteration algorithm for high-dimensional infinite horizon markov decision process problems. *IEEE Symposium on Adaptive Dynamic Programming and Reinforcement Learning*, 1–53.
- Madić, M.J. Radovanović, M.R. 2011. Optimal selection of ANN training and architectural parameters using Taguchi method: A case study. *FME Transactions*, 39: 79–86.
- Marsland, S. 2014. *Machine Learning An Algorithmic Perspective*, CRC Press, 1–452.
- Marziali, A. Fabbiani, E., Nicolao, G.D. 2019. Short-term forecasting of Italian residential gas demand. *Project: Gas Demand Forecasting*, 2019:1–16.
- Moon, S. 2013. Predicting the Performance of Forecasting Strategies for Naval Spare Parts Demand: A Machine Learning Approach. *Management Science and Financial Engineering*, 19(1): 1–10.
- Moosavi, V. Vafakhah, M., Shirmohammadi, B., Ranjbar, M. 2014. Optimization of Wavelet-ANFIS and Wavelet-ANN Hybrid Models by Taguchi Method for Groundwater Level Forecasting. *Arabian Journal For Science And Engineering*, 39(3): 1785–1796.
- Mouatadid, S. Adamowski, J. 2017. Using extreme learning machines for short-term urban water demand forecasting. *Urban Water Journal*, 14(6): 630–638.
- Nagarkar, P., El-Gohary, M.A, Bhalariao, Y. J. Patil, G J. V., Patil, R.N. Z. 2019. Artificial neural network predication and validation of optimum suspension parameters of a passive suspension system. *SN Applied Sciences* 1(569).
- Nagurney, A. Masoumi, A.H., Yu, M. 2012. Supply chain network operations management of a blood banking system with cost and risk minimization. *Computational Management Science*, 9(2): 205–231.
- Nahmias, S. 2013. *Production & Operations Analysis*, New York: McGraw Hill Education, 1–736.
- Najafi, M. Ahmadi, A., Zolfagharini, H. 2017. Blood inventory management in hospitals: Considering supply and demand uncertainty and blood transshipment possibility. *Operations Research for Health Care*, 15(2017): 43–56.
- Nieto, P.J.G. Garcia-Gonzalo, E., Arbat, G., Duran-Ros, M., de Cartagena, F.R., Puig-Bargues, J. 2018. Pressure drop modelling in sand filters in micro-irrigation using gradient boosted regression trees. *Biosystems Engineering*, 171: 41–51.

- Nguyen, X. Goebel, M., Schober, M., Klüter, H., Panzer, S. 2010. The detection of platelet antibodies by simultaneous analysis of specific platelet antibodies and the monoclonal antibody specific immobilization of platelet antigens: An interlaboratory comparison. *Transfusion*, 50(7): 1429–1434.
- Osowski, S. Siwekand, K., Markiewicz, T. 2004. MLP and SVM Networks – a Comparative Study. *Proceedings of the 6th Nordic Signal Processing Symposium*, 37-40.
- Öztemel, E. 2016. *Yapay Sinir Ağları*. 4. Baskı, Papatya Bilim Üniversite Yayıncılığı, İstanbul.
- Pal, M. 2005. Random Forest Classifier For Remote Sensing Classification. *International Journal Of Remote Sensing*, 26(1): 217-222.
- Pao, H.T. 2008. A comparison of neural network and multiple regression analysis in modeling capital structure. *Expert Systems with Applications*, 35: 720–727.
- Pereira, A. 2004. Performance of time-series methods in forecasting the demand for red blood cell transfusion. *Transfusion*, 44(5): 739-746.
- Perry, D. Stadje, W. 2001. Disasters in a Markovian Inventory System for Perishable Items. *Advances in Applied Probability*, 33(1): 61-75.
- Pi, D. Shih, AW., Sham, L., Zamar, D., Roland, K., Hudoba, M. 2019. Establishing performance management objectives and measurements of red blood cell inventory planning in a large tertiary care hospital in British Columbia, Canada. *ISBT Science Series*, 14: 226–238.
- Privett, N. Gonsalvez, D. 2014. The top ten global health supply chain issues: Perspectives from the field. *Operations Research for Health Care*, 3(4): 226–230.
- Puranam, K. Novak, D., Lucas, M., Fung, M. 2017. Managing Blood Inventory With Multiple Independent Sources Of Supply. *European Journal of Operational Research*, 259: 500–511.
- Ramanathan, R. Mathirajan, M., Ravindran, A.R. 2017. Big Data Analytics Using Multiple Criteria Decision-Making Models. 1. Baskı, CRC press, 1-370.
- Sarhangian, V. Abouee-Mehrizi, H., Baron, O., Berman, O., Heddle, N.M., Barty, R. 2016. Reducing the age of transfused red blood cells in hospitals: ordering and allocation policies. *Vox Sanguinis*. 110(4): 385-392.
- Shahsavari, S, Shirmard, L.R., Amini M., Dokoosh, F.A. 2017. Application of Artificial Neural Networks in the Design and Optimization of a Nanoparticulate Fingolimod Delivery System Based on Biodegradable Poly(3-Hydroxybutyrate-Co-3-Hydroxyvalerate). *Journal of Pharmaceutical Sciences* 106:176-182.
- Shao, Y.E. Lu, C.-J., Hou, C-D. 2014. Hybrid Soft Computing Schemes for the Prediction of Import Demand of Crude Oil in Taiwan. *Mathematical Problems in Engineering*, 2014: 1-14.
- Shi, L. Wang, J.-X., Stevens, L., Ness, P., Shan, H. 2014. Blood safety and availability: continuing challenges in China's blood banking system. *Transfusion*, 2014(54):471-482.

- Silver, E. A. Pyke, D., Peterson, R. 2001 . Inventory Management and Production Planning and Scheduling. *Journal of the Operational Research Society*, 52(7): 845-845.
- Singh, A. Saxena, P., Lalwani, S. 2013. A Study Of Various Training Algorithms On Neural Network For Angle Based Triangular Problem. *International Journal of Computer Applications* 71(13):30-36.
- Singaravel, S. Suykens, J., Geyer, P. 2018. Deep-learning neural-network architectures and methods: Using component based models in building-design energy prediction. *Advanced Engineering Informatics*, 38 (2018):81–90.
- Smola, A.J. Schölkopf, B. 2004. A tutorial on support vector regression. *Statistics and Computing*, 14(3):199–222.
- Stanger, S.H.W. Yates, N., Wilding, R., Cotton, S. 2012. Blood Inventory Management: Hospital Best Practice. *Transfusion Medicine Reviews*, 26(2):153-163.
- Şencan İ, Koç O, Bayraktar O.G. 2009. Hastane Roller, T.C. Sağlık Bakanlığı Tedavi Hizmetleri Genel Müdürlüğü, Hastane Hizmetleri Daire Başkanlığı.
- Theodoridis, S. Koutroumbas, K. 2003. *Pattern Recognition*. 2. Baskı. Elsevier Academic Press.
- Timothy, M. 1993. *Practical Neural Network Recipes in C++*. Academic Press, 174-175.
- Toner, Richard W. Pizzi, L., Leas, B., Ballas, S.K., Quigley, A., Goldfarb, N.I. 2011. Costs to Hospitals of Acquiring and Processing Blood in the US: A Survey of Hospital-Based Blood Banks and Transfusion Services. *Applied Health Economics And Health Policy*, 9 (1): 29-37.
- Touzani, S. Granderson, J., Fernandes, S. 2018. Gradient Boosting Machine for Modeling the Energy Consumption of Commercial Buildings. *Energy and Buildings*, 158:1533-1543.
- Vapnik, V. Golowich, S., Smola, A. 1996. Support vector method for function approximation, regression estimation, and signal processing. *Advances in Neural Information Processing Systems*, 9: 281–287.
- Vu, D.H. Muttaqi, K.M., Agalgaonkar, A.P. 2015. A variance inflation factor and backward elimination based robust regression model for forecasting monthly electricity demand using climatic variables. *Applied Energy*, 140: 385–394.
- Watts, J. D. Powell, S.L., Lawrence, R. L., Hilker, T. 2011. Improved Classification of Conservation Tillage Adoption Using High Temporal And Synthetic Satellite Imagery. *Remote Sensing of Environment* 115(1): 66–75.
- Wijayanayake, A. Dandunna, M. 2017. An efficient model to improve the performance of platelet inventory of the blood banks. *Advances in Science, Technology and Engineering Systems Journal*, 2(3): 839-844.
- Wild, T. 2002. *Best Practice in Inventory Management*, 2. Baskı. Butterworth-Heinemann Press.

- Witten, I. H. Frank, E., Hall, M. A. 2011. Data Mining: Practical machine learning tools and techniques. 3. Baskı. Morgan Kaufmann.
- Woo, J.S. Suslow, P., Thorsen, R., Ma, R., Bakhtary, S., Moayeri, M., Nambiar, A. 2019. Development and Implementation of Real-Time Web-Based Dashboards in a Multisite Transfusion Service. *Journal of Pathology Informatics*,10(3): 1-7.
- Woodrum, C.L. Wisniewski, M., Triulzi, D.J., Waters, J.H., Alarcon, L.H., Yazer, M.H. 2017. The effects of a data driven maximum surgical blood ordering schedule on preoperative blood ordering practices. *Hematology*, 22(9): 571-577.
- Wu, Q. Law, R., Xu, X. 2012. A sparse Gaussian process regression model for tourism demand forecasting in Hong Kong. *Expert Systems with Applications*, 39 (2012): 4769–4774.
- www.kizilay.org.tr, Erişim Tarihi: 19.03.2018.
- www.khgm.saglik.gov.tr, Erişim Tarihi: 23.09.2018.
- www.goc.gov.tr, Erişim Tarihi:23.09.2018.
- www.mgm.gov.tr/veridegerlendirme, Erişim Tarihi: 04.08.2018.
- www.tuik.gov.tr, Erişim Tarihi: 04.08.2018.
- Yıldız M.S. 2017. Hastane Yatak Kullanım Verimliliğinin Değerlendirmesinde Pabon Lasso Metodu: Literatür Taraması, *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, 3(1):152-163.
- Yang S., Ting T.O., Man K.L., Guan S.-U. 2013. Investigation of Neural Networks for Function Approximation. *Procedia Computer Science* 17:586 – 594.
- Yang, J. Nguyen, M. N., San, P. P., Li, X., Krishnaswamy, S. 2015. Deep Convolutional Neural Networks on Multichannel Time Series for Human Activity Recognition. In *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence*, 3995-4001.
- Ying, W. 2011. First-time blood donors: Demographic trends. *Transfusion*, 41(3): 360–364.
- Yu, J. 2004. Artificial Neural Network: Assignment Leuven Katolik Üniversitesi, Yüksek Lisans Tezi.
- Zhou, D. Leung, L., Pierskalla, W. 2011. Inventory management of platelets in hospitals: Optimal inventory policy for perishable products with regular and optional expedited replenishments. *Manufacturing and Service Operations Management*, 13(4): 420–438.
- Zhou, C. Yu, H., Ding, Y., Guo, F., Gong, X-J. 2017. Multi-scale encoding of amino acid sequences for predicting protein interactions using gradient boosting decision tree. *PLoS ONE* 12(8): 1-18.

ÖZGEÇMİŞ

Seda Hatice GÖKLER, 06.06.1986'da Eskişehir'de doğdu. İlk, orta ve lise eğitimini Eskişehir'de tamamladı. 2005 yılında Eskişehir Fatih Anadolu Lisesi'nden mezun oldu. Lisans eğitimini Eskişehir Osmangazi Üniversitesi Endüstri Mühendisliği Bölümü'nde, yüksekisans eğitimini Sakarya Üniversitesi Endüstri Mühendisliği Ana Bilim Dalı'nda tamamladı. Yüksek lisans eğitimi sırasında Sakarya Üniversitesi'nde Araştırma Görevlisi olarak göreve başladı. 2014 yılında ise ÖYP kapsamında halen görev yaptığı Kahramanmaraş Sütçü İmam Üniversitesi'ne Araştırma Görevlisi olarak atandı.