

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MODA TÜRÜ ÜRÜNLER İÇİN BASS YAYILIM MODELİ VE VERİ
KÜMELEME TABANLI BİR TALEP TAHMİN METODU
GELİŞTİRİLMESİ: BİR VAKA UYGULAMASI**

YÜKSEK LİSANS TEZİ

Abdurrahman YAVUZ

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Kadir ERTOĞRAL

ARALIK 2019

Fen Bilimleri Enstitüsü Onayı

.....
Prof.Dr. Osman EROĞUL

Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

.....
Prof.Dr.Tahir HANALİOĞLU

Anabilimdalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün **171311028** numaralı Yüksek Lisans öğrencisi **Abdurrahman YAVUZ**'nın ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**MODA TÜRÜ ÜRÜNLER İÇİN BASS YAYILIM MODELİ VE VERİ KÜMELEME TABANLI BİR TALEP TAHMİN METODU GELİŞTİRİLMESİ: BİR VAKA UYGULAMASI**" başlıklı tezi **13 Aralık 2019** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

Tez Danışmanı: **Doç.Dr. Kadir ERTOĞRAL**

TOBB Ekonomi ve Teknoloji Üniversitesi

Jüri Üyeleri: **Doç.Dr. Diyar AKAY (Başkan)**

Gazi Üniversitesi

Doç.Dr. Nilgün FESÇİOĞLU ÜNVER.....

TOBB Ekonomi ve Teknoloji Üniversitesi



TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Abdurrahman YAVUZ

İMZA

ÖZET

Yüksek Lisans Tezi

MODA TÜRÜ ÜRÜNLER İÇİN BASS YAYILIM MODELİ VE VERİ KÜMELEME TABANLI BİR TALEP TAHMİN METODU GELİŞTİRİLMESİ: BİR VAKA UYGULAMASI

Abdurrahman YAVUZ

TOBB Ekonomi ve Teknoloji Üniversitesi

Fen Bilimleri Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç.Dr. Kadir ERTOĞRAL

Tarih: ARALIK 2019

Yeni ürünlerin pazara sunumlarında talep tahmini söz konusu olduğunda başarımı kabul edilmiş modellerden birisi Bass Yayılım Modeli'dir (Bass diffusion model, BDM). Bu çalışmada gerçek büyük bir satış verisi kullanılarak, BDM'nin moda türü ürünlerin satış eğrisini yansıtmadaki başarımı incelenmiş ve sezon başında gözlemlenen kısmi veri ile sezon sonuna kadarki toplam talep tahmin edilmeye çalışılmıştır. Çalışma temelde iki ana kısımdan oluşur; ilk kısımda BDM modelinin performansı ve davranışı tüm ve kısmi veri kullanıldığı durumlarda incelenmiştir. İkinci kısımda ise kısmi veriye dayalı BDM ve geçmiş verinin kümelenip BDM uygulaması yaklaşımının entegre şekilde kullanılmasına dayalı talep tahmin yöntemleri geliştirilip, bu yöntemlerin performans analizi yapılmıştır. BDM'nin başarımı parametrelerin doğru tahminiyle büyük orantıda ilintilidir. Literatürde üç ana parametre tahmin yöntemi kabul görmektedir. Bunlar; en küçük kareler toplamı yöntemi, doğrusal olmayan en küçük kareler toplamı yöntemi ve en çok olabilirlik yöntemidir. Bu yöntemler çalışmamızın ilk kısmında kullanılmış olup performansları değerlendirilmiştir. Yine ilk kısımda bu parametre tahmin yöntemlerine ek olarak yeni bir yöntem olarak, rastgele çizgisel arama yöntemi geliştirilmiştir. Bu yöntem literatürde kabul gören diğer yöntemlerle kıyaslanabilir sonuçlar vermiştir. İlk kısımda yapılan çalışmalar sonucunda BDM'nin yeterince iyi parametre

tahminleri ile sezon içinde kalan talep tahmininde tatmin edici tahminler oluşturabildiği gözlemlenmiştir. Ancak sezon başında elde edilen kısmi veri söz konusu olduğunda BDM'nin tatmin edici sonuçlar verememesi sebebiyle çalışmamızın ikinci kısmında geçmiş ürünlerden elde edilen bilgilerin değerlendirildiği bir tahmin modeli oluşturulmuştur. Bu tahmin modeli geçmiş ürünler ile yeni ürünün kısmi verisi arasında bir bağlantı kurmaya dayanır. Geçmiş ürünlerin sergiledikleri satış eğrileri karşılaştırılarak kümelenir. Her bir küme farklı bir genel talep desenini temsil eder. Yeni ürünün pazara girişinden itibaren oluşan kısmi verisi ile geçmiş ürünler karşılaştırılır. Kısmi verisi itibariyle yeni ürüne en çok benzeyen ürün bilgisi, bu ürünün ait olduğu kümeye ait bilgiler ve parametre bilgileri kullanılarak tahmin oluşturulur. Bu şekilde ürünün kısmi verisi ile gelecekte sergileme ihtimali en çok olan desen arasında bir ilişki kurulur. Kurulan bu ilişkiye dayalı olarak farklı tahmin yöntemleri önerilmiş ve bu yöntemlerin tahmin hatası açısından performans değerlendirmesi yapılmıştır. Çalışmada ürünün sadece kısmi verisi kullanılarak ve geliştirilen model ile elde edilen tahminler kıyaslanmıştır. Önerilen yöntemlerin bazılarının oldukça tatmin edici bir tahmin performansına sahip oldukları gösterilmiştir.

Anahtar Kelimeler: Tahmin, Moda türü ürünler, Bass yayılım modeli, Veri kümeleme, Zaman serisi analizi

ABSTRACT

Master of Science

BASS DIFFUSION MODEL AND DATA CLUSTERING BASED FORECASTING METHOD FOR FASHION GOODS: A CASE STUDY

Abdurrahman YAVUZ

TOBB University of Economics and Technology

Institute of Natural and Applied Sciences

Department of Industrial Engineering

Supervisor: Assc.Prof. Kadir ERTOĞRAL

Date: December 2019

Bass diffusion model (BDM) is known as one of the successful models when it comes to new product adoption. In this study, using real world sales data, we analyzed the performance of BDM in reflecting sales curve of fashion type products. The study consists of two main parts; first we fit BDM by using all data points to investigate whether BDM is flexible enough to represent the pattern of sales or not. Then, we used products' partial data to find out the forecasting performance of BDM in forecasting the remaining demand of product in a season. We observed that BDM with partial data can not give satisfying results. Therefore, in the second part of our study, we focus on developing a successful forecasting approach and we developed methods based on BDM based on partially observed sales data in a current season, and clustering algorithm on full data sales data sets observed in the past. We analyzed the performance of several proposed forecasting methods. The performance of BDM is highly dependent on the accuracy of parameters estimation. Three main parameter estimation methods are used in the literature. These are the ordinary least squares method, the non-linear least squares method, and the maximum likelihood method. We utilized these methods in the study and compare them. In addition, we propose a new approach, we call randomized line search method. This method gives comparable results with the other parameter estimation techniques. As a consequence of first part of our work,

we observe that BDM is capable of representing the sales of fashion products regarding to remaining demand of a product in a season. But with partial data BDM does not produce accurate results, especially with limited data from early periods in a season. To handle this problem, we developed a new model which relates past products to the new products when creating forecasts for a new product. Clustering methods, regression analysis and time-series analysis are utilized in development of the new forecast model. First, past sales data of products are clustered according to their sales curves. Each cluster represents different sales pattern. New product with a partial data is compared with the past products and the cluster with the minimum dissimilarity is selected. Using the cluster information, the "closest" product information and the partial data of the new product, a forecast remaining sales in a season is created for the new product . We suggested different ways to set weights for the information gained from clusters, from the closest product and from the new product. We created forecasts with proposed model and the BDM, and compared the forecasting performance of the suggested methods. We showed that some of the suggested methods have satisfying forecasting performance.

Keywords: Forecasting, Fashion goods, Bass diffusion model, data clustering, Time series analysis

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren danıőman hocam Doç.Dr. Kadir ERTOęRAL'a, kıymetli tecrübelerinden faydalandıęım TOBB Ekonomi ve Teknoloji Üniversitesi Endüstri Mühendislięi Bölümü öğretim üyelerine ve destekleriyle her zaman yanımda olan aileme ve arkadaşlarıma çok teşekkür ederim. Ayrıca burs sağladıęı için TOBB Ekonomi ve Teknoloji Üniversitesi'ne şükranlarımı sunarım.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
ABSTRACT	viii
TEŞEKKÜR	x
İÇİNDEKİLER	xii
ŞEKİL LİSTESİ	xiv
ÇİZELGE LİSTESİ	xv
KISALTMALAR	xviii
SEMBOL LİSTESİ	xx
1. GİRİŞ	2
2. LİTERATÜR ARAŞTIRMASI	4
2.1 Bass Yayılım Modeli	4
2.2 Bass Difüzyon Modeli için Parametre Tahmini Yöntemleri	6
2.3 Bass Difüzyon Modelinin Kullanım Alanları	7
2.4 Moda Sektöründe Satış Tahmini	8
2.5 Literatürdeki Benzer Çalışmalar	11
3. BASS DİFÜZYON MODELİ'NİN MODA TÜRÜ ÜRÜNLERDE PERFORMANS ANALİZİ	14
3.1 Giriş	14
3.2 Veri Hazırlama	14
3.3 Literatürdeki Parametre Tahmini Yöntemleri ve Uygulanması	14
3.4 Önerilen Rassal Çizgisel Arama Metodu	18
3.5 Parametre Tahmini Yöntemlerinin Uygulanması ve Sonuçlar	21
3.5.1 Tüm sezonsal veri ile yapılan analizler	22
3.5.2 Kısmi veri ile yapılan analizler	26
3.5.3 Parametrelerin haftalara göre değişiminin incelenmesi	28
3.6 Sonuçların İrdelenmesi ve Çıkarımlar	31
4. ENTEGRE BASS DİFÜZYON MODELİ VE KÜMELEME AL- GORİTMASI TABANLI TAHMİN METODU	32
4.1 Giriş	32
4.2 Kümeleme Algoritmaları	32
4.2.1 K-medoids algoritması	33
4.2.2 Benzemezlik ölçüsü	34
4.3 Veri Üzerinde Kümeleme İşlemi	35
4.3.1 Silüet genişliği	36
4.3.2 Küme içi toplam mesafenin karesi	37
4.3.3 Verilerin Kümelenmesi	38
4.4 Tahminlerin Oluşturulması	39
4.4.1 α parametresi yardımıyla ağırlıklandırma işlemi	40
4.5 Önerilen Tahmin Yöntemleri	42

4.5.1 Yöntem 1	42
4.5.2 Yöntem 2	43
4.5.3 Yöntem 3	45
4.5.4 Yöntem 4	45
4.5.5 Yöntem 5	46
4.6 Sonuçlar ve Değerlendirme	47
4.7 Bütün Ürünler Kullanılarak Bulunan Sonuçlar	47
4.8 Uyumsuz Ürünlerin Belirlenmesi ve Çıkarılması	52
5. TARTIŞMA VE GELECEK ÇALIŞMALAR	60
5.1 Gelecek çalışmalar	61
KAYNAKLAR	62
EKLER	70
ÖZGEÇMİŞ	82



ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 3.1: Kesme noktasının belirlenmesi	15
Şekil 3.2: Kalan talep grafiği	24
Şekil 3.3: P değerleri için kutu grafiği	25
Şekil 3.4: Satışlar ve oluşturulan Bass Eğrisi	25
Şekil 3.5: Kategorilere göre APE değerlerinin değişimi	27
Şekil 3.6: Kısmi veri için periyotlara göre APE değerleri	28
Şekil 3.7: Haftalara göre parametrelerin mutlak yüzde değişimi	29
Şekil 3.8: P ve Q parametreleri için değişim katsayısı	30
Şekil 3.9: M parametresi için değişim katsayısı	30
Şekil 4.1: Temsili ürün eğrileri	36
Şekil 4.2: Farklı k değerleri için silüet genişliği değerleri	37
Şekil 4.3: Küme içi toplam mesafenin karesi	38
Şekil 4.4: Kümelenen ürünler	39
Şekil 4.5: Küme 1 içindeki ürünler için oturtulan Bass eğrileri	41
Şekil 4.6: Periyot ve kümelere göre α^* değerleri	42
Şekil 4.7: Yöntem 2 için periyotlara göre oturtulan eğriler	44
Şekil 4.8: Yöntem 5 için periyotlara göre oturtulan eğriler	46
Şekil 4.9: Yöntemler ve ortalama MAPE	48
Şekil 4.10: BDM ve metotların karşılaştırılması	49
Şekil 4.11: İyileştirme miktarları	50
Şekil 4.12: %35'in altındaki ürün sayısı	51
Şekil 4.13: %35'in altında hataya sahip ürünlerin kategorilere ve yöntemlere göre dağılımı	52
Şekil 4.14: Üçüncü kez piyasaya sürülen tasarımın satış deseni	53
Şekil 4.15: Küçük parça ürünlerin örnek satış deseni	53
Şekil 4.16: Basit ürünlere ait örnek satış grafiği	54
Şekil 4.17: Uyumsuz ürünler çıkarıldıktan sonra ortalama MAPE değerleri	54
Şekil 4.18: Uyumsuz ürünler çıkarıldıktan sonra medyan MAPE değerleri	55
Şekil 4.19: Uyumsuz ürünler hariç farkların kutu grafiği	55
Şekil 4.20: Uyumsuz ürünler hariç BDM ve metotların MAPE karşılaştırması	56
Şekil 4.21: Uyumsuz ürünler çıkarıldıktan sonra %35'in altındaki ürünlerin sayısı	57
Şekil 4.22: Kategorilere göre bilinen periyot sayısı ile MAPE ilişkisi	57
Şekil 5.1: Kategori ve yöntemlere göre dağılım	74
Şekil 5.2: Yöntem ve kategorilere göre dağılım	75
Şekil 5.3: Uyumsuz ürünler hariç kategori ve yöntemlere göre dağılım	76
Şekil 5.4: Uyumsuz ürünler hariç yöntem ve kategorilere göre dağılım	77
Şekil 5.5: Yöntem 1 için periyotlara göre oturtulan eğriler	78
Şekil 5.6: Yöntem 3 için periyotlara göre oturtulan eğriler	79
Şekil 5.7: Yöntem 4 için periyotlara göre oturtulan eğriler	80



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1: P değişimi fonksiyonu	19
Çizelge 3.2: RLS algoritmasının sözde kodu	20
Çizelge 3.3: Ürünlerin kategorilere göre dağılımı	22
Çizelge 3.4: Parametre tahmin yöntemleri MAPE değerleri	23
Çizelge 4.1: Yöntemlerin kullandıkları kaynaklar	42
Çizelge 4.2: Kullanılan Paketler	47
Çizelge 4.3: Test ürünlerinin kategorilere göre dağılımı	58
Çizelge 5.1: Moda sektöründe satış tahmini - 1	71
Çizelge 5.2: Moda sektöründe satış tahmini - 2	72
Çizelge 5.3: Moda sektöründe satış tahmini - 3	73

KISALTMALAR

BDM	: Bass yayılım modeli (Bass diffusion model)
OLS	: En küçük kareler yöntemi (Ordinary least squares method)
NLS	: Lineer olmayan kareler toplamı (Non-linear least squares method)
MLE	: En çok olabilirlik yöntemi (Maximum likelihood method)
RLS	: Rassal çizgi arama yöntemi (Randomized line search method)
GBDM	: Genelleştirilmiş Bass yayılım modeli (Generalized Bass diffusion model)
ELM	: Aşırı öğrenme makineleri (Extreme learning machines)
ARIMA	: Bütünleşik otoregresif hareketli ortalama (Autoregressive integrated moving average)
BFGS	: Broyden-Fletcher-Goldfarb-Shanno
SSE	: Hataların kareleri toplamı (Sum of squared errors)
APE	: Mutlak yüzde sapma (Absolute percent error)
MAPE	: Ortalama mutlak yüzde sapma (Mean absolute percent error)
ADI	: Ayarlanabilir benzemezlik indeksi (Adaptive dissimilarity index)
DTW	: Dinamik zaman bükme (Dynamic time warping)
LMA	: Levenberg-Marquardt Algoritması (Levenberg-Marquardt algorithm)
YSA	: Yapay sinir ağları (Neural networks)
SOM	: Özdüzenleyici haritalar (Self-organizing maps)
CORT	: Zamansal korelasyon katsayısı (Temporal correlation coefficient)



SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
p	İnovasyon katsayısı
q	İmitasyon katsayısı
m	Potansiyel market büyüklüğü
p_c	Küme için inovasyon katsayısı
q_c	Küme için imitasyon katsayısı
m_c	Küme için potansiyel market büyüklüğü
p_{cp}	En yakın ürünün nihai inovasyon katsayısı
q_{cp}	En yakın ürünün nihai imitasyon katsayısı
m_{cp}	En yakın ürünün nihai potansiyel market büyüklüğü
p_p	Kısmi veri ile inovasyon katsayısı
q_p	Kısmi veri ile imitasyon katsayısı
m_p	Kısmi veri ile potansiyel market büyüklüğü
m_n	Yeni ürün için iyi bir potansiyel market büyüklüğü tahmini
α_{cp}	En yakın ürün için belirlenen α değerleri
α_{cp}^*	En yakın ürünün ait olduğu küme için belirlenen α değerleri

1. GİRİŞ

Satış tahmini tedarik zincirinin etkin yönetiminin yapı taşlarından bir tanesidir. Başarım oranı yüksek tahminler firmanın elinde doğru zamanda doğru miktarda ürün bulunması açısından önemlidir. Yanlış tahminler yüksek envanter, acil üretim emirleri ve kaynakların verimsiz kullanımı gibi problemlere yol açabilir. Bu da tedarik zinciri boyunca maliyetlerin artmasına sebep olur. Tahminlerin tutarlılığının operasyonlar açısından kilit öneme sahip olması, satış tahmini konusunu üzerinde çok çalışılan bir araştırma konusu yapmıştır ve bu tahminlerin tutarlılığı firmanın finansal performansını doğrudan etkiler.

Ürün yaşam eğrisi ürünlerin pazarda geçirdikleri süre içerisindeki davranışlarını temsil eder. Bu davranışlar dört farklı aşamada incelenmektedir. Bunlar; giriş, büyüme, olgunluk ve düşüş olarak isimlendirilir. Her ürün kendine özgü bir ürün yaşam eğrisi sergiler. Bu sebeple her ürünün bu aşamalarda geçirdikleri süreler farklıdır. Ancak her yeni ürün farklı zamanlarda da olsa bu aşamaları geçirir. Bu ortak özellik ürün yaşam eğrisi yönetiminin efektif yapılmasının gerekliliğini doğurmuştur. İş dünyası, ürün yaşam eğrisi yönetimini karar verme mekanizmasının işleyişinde önemli bir enstrüman olarak kullanmaktadır. Yeni bir ürünün yaşam eğrisi boyunca hangi evrede olduğunun belirlenmesi önemli bir konudur. Örnek olarak giriş aşamasındaki bir ürünün tanıtımının yapılması gerekirken; doyumluk aşamasındaki bir ürünün türevlendirilmesi gerekebilir. Ürün yaşam eğrisi şirketler için pek çok açıdan önem arz etmektedir. Örneğin şirketler kaynak planlaması yaparken ürünlerinin yaşam eğrisinin hangi evresinde olduğunu göz önünde bulundururlar.

Yayılm bir başka adıyla difüzyon modelleri ürün yaşam eğrisinin dinamiklerinin belirlenmesinde kullanılır. Bu modeller sayesinde ürünün yaşam eğrisi ile ilgili bilgiler edinilebilir. İlk olarak Bass tarafından 1969 yılında pazarlama alanında kullanılan Bass difüzyon modeli (BDM), yeni on bir adet ürünün yaşam eğrisini tanımlamak amacıyla kullanılmıştır [2]. Bu ürünler teknolojik inovasyon içeren ürünler arasından seçilmiştir. Modelin bu ürünler üzerindeki başarımı hem iş dünyası hem de akademik dünya tarafından ilgi çekmiştir. Daha sonra model çeşitli ürünlerde de uygulanmış olup başarımı farklı ürün kümeleri üzerinde de kanıtlanmıştır. BDM'nin uygulandığı ürünlerden biri renkli televizyonlardır, renkli televizyon için oluşturulan Bass modeline göre renkli televizyonların 1968 yılında 6,7 milyon adet ile zirve yapacağı öngörülmüştür. Ancak endüstri bundan çok daha iyimser tahminlere sahiptir. Bass modeline göre yapılan tahmin doğrultusunda renkli televizyon

1968 yılında yaklaşık 6,7 milyon adet ile zirve yapmıştır. Televizyon endüstrisi tarafından yapılan yanlış tahmin yanlış kaynak planlamasına yol açmış ve 14 milyon adet üretim için kaynak ayrılmıştır [3]. Yeni ürünlerin satış tahmini yapılırken çok az veri noktası ile tahmin yapılması gerekir. BDM'nin az veri ile model oluşturabilme özelliğinden dolayı BDM yeni ürünlerin talep tahmininde ilk akla gelen modellerden bir tanesidir ve geniş bir kullanım alanına sahiptir.

Moda sektörü kıyafet üretimi ve satışı işini kapsayan büyük bir sektördür [40]. Türkiye moda sektöründe, özellikle üretim aşamasında, dünyada önde gelen ülkelerden birisidir. Türkiye'nin toplam ihracatının %18'ini moda ürünleri oluşturur. İstatistiksel olarak Türkiye dünyadaki en büyük altıncı, avrupada ise en büyük üçüncü tedarikçi konumundadır. Moda sektörü rekabetçi bir doğaya sahiptir. Rekabetçi ortamda tutunabilmek için firmalar operasyonlarını en az maliyetle gerçekleştirme arzusu içerisindeyler. Maliyetlerin düşürülmesinin yollarından birisi de her tedarik zincirinde olduğu gibi etkin talep tahmini olarak görülür. Temel olarak satış veya talep tahmini; ürünlerin geçmiş verisi, market eğilimi, ürün özellikleri veya diğer ilgili faktörlere dayalı olarak gelecekteki satış miktarının öngörülmesidir [15].

Çalışma sırasıyla literatür araştırması, BDM'nin performans analizi, geliştirilen tahmin yöntemi olan entegre BDM ve kümeleme algoritması tabanlı tahmin metodu, değerlendirme ve sonuç kısımlarını içermektedir. Literatür araştırması bölümünde BDM'nin literatürdeki gelişimi ve kullanım alanları açıklanmıştır. Ayrıca moda türü ürünlerin tahmininde kullanılan metotlar incelenmiş, son olarak literatürdeki benzer çalışmalar literatür araştırmasına dahil edilmiştir. BDM'nin performans analizi kısmında ise tüm veri noktaları kullanılarak elde edilen parametre tahminlerinin metodolojisi açıklanmış ve uygulanmıştır. Elde edilen parametre tahminleri ile oluşturulan Bass eğrilerinin pratik ve istatistiksel analizi yapılmıştır. Bunun yanı sıra kısmi veri ile elde edilen parametre tahminlerinin tahmin performansının analizi de bu kısma dahil edilmiştir. Geliştirilen tahmin yöntemlerini sunduğumuz bölümünde ise kısmi veri ile daha tutarlı parametre tahmini gerçekleştirebilmek amacıyla, temelini geçmiş ürünlerin yaşam eğrilerinin kümelenmesinin oluşturduğu bir yöntem gösterilmiştir. Bu yöntemin geliştirilmesi aşamasında kullanılan yaklaşımlar ve kaynaklar aynı bölümün içerisinde anlatılmıştır. Yöntem kendi içerisinde türevlendirilmiş ve bu türevlerin başarımı analiz edilmiştir. Son olarak elde edilen MAPE(Ortalama mutlak yüzde sapma, *Mean absolute percent error*) değerleri raporlanmış ve önerilen yöntemlerin tahmin başarımı incelenmiştir. Sonuçlar tablo ve grafiklerle yorumlanmıştır.

2. LİTERATÜR ARAŞTIRMASI

2.1 Bass Yayılım Modeli

Literatürde yayılım modeli adıyla yapılan ilk çalışma 1960 yılında yayımlanmıştır [17]. BDM bir popülasyon içerisindeki kişilerin yeni bir ürünü sahiplenme süreçlerini tanımlamak amacıyla kullanılır. BDM popülasyon içerisindeki bireyleri birbirleriyle etkileşim içerisinde olan bir ağ olarak ele alır ve bu bireyleri taklitçiler ve yenilikçiler olarak ikiye ayırır. Modelin yayımlanmasını takiben yapılan çalışmalar genellikle yeni teknolojik ürünlerin yayılımının tanımlanması üzerine yoğunlaşmıştır. Ancak Bass ve Woodlock ortaya koydukları çalışmada yayılım modellerini teknolojik yeniliklere sahip ürünlerle sınırlandırmamışlardır. [2, 17, 35]. Yayılım modelleri sade halleriyle ürünlerin yaşamları boyunca geçirdikleri evreleri ifade etmek için kullanılmıştır. Ürün yaşam eğrileri hakkında edinilen çıkarımlar ise pazarlama ile ilgili kararlarda değerlendirilmiştir. BDM, 1969 yılında Bass tarafından literatüre kazandırılmıştır [2]. Model akademi ve pratisyenler tarafından büyük ilgi görmüş ve BDM üzerinde birçok çalışma yapılmıştır. Bu çalışmalar iki ana başlıkta incelenebilir.

Bunlardan birincisi modelin esnekliğini arttırmaya yönelik çalışmalar, ikincisi ise modelin parametrelerinin tahmini ile ilgili geliştirilen yöntemlerdir. Modelin esnekliğini arttırmaya yönelik çalışmalar modele farklı bir değişkenin eklenmesi üzerinedir. Genel olarak fiyat değişkeni satış tahmini söz konusu olduğunda göz önünde bulundurulması gereken bir değişken olarak göze çarpar. Robinson ve Lakhani (1975) fiyat değişkeninin modele eklenmesi üzerine yapılan ilk çalışmadır. Diğer örnekler ise Mahajan & Peterson (1978), Bass (1980), Bass & Bultez (1982) olarak sıralanabilir. Fiyat değişkeninin dışında satış eğrisi üzerinde etkisi olabileceği düşünülen diğer değişkenlerin modele dahil edilmesi üzerine de çalışmalar olmuştur. Bunlardan bir tanesi Tanner (1978) tarafından yapılmıştır. Tanner gayri safi yurtiçi hasılayı modele dahil ederek modelin esnekliğini arttırmayı amaçlamıştır [42].

BDM genel olarak t zamanında ürünün sahiplenilme ihtimaline dayanır. Eşitlik 2.1, t zamanına kadar ürünü sahiplenmeyen müşterilerin t zamanında ürünü sahiplenme ihtimalini gösterir.

$$f(t)/1 - F(t) = p + qF(t) \quad (2.1)$$

$$F(t) = (1 - e^{-(p+q)t}) / (1 + (q/p)e^{-(p+q)t}) \quad (2.2)$$

$$f(t) = \frac{(p+q)^2}{p} \frac{e^{-(p+q)t}}{(1 + \frac{q}{p}e^{-(p+q)t})^2} \quad (2.3)$$

$$S(t) = m \times f(t) \quad (2.4)$$

Eşitlik 2.2'de yer alan parametreler p ve q , sırasıyla inovasyon katsayısını ve imitasyon katsayısını ifade eder. İnovasyon katsayısı dahili etki katsayısı olarak da isimlendirilir. İmitasyon katsayısının bir başka ismi de harici etki katsayısıdır. Sahiplenme zamanını belirten olasılık yoğunluk fonksiyonu $f(t)$ olarak gösterilmiştir. $F(t)$ ise kümülatif olasılık dağılım fonksiyondur. Eşitlik 2.4'de yer alan $S(t)$ ise t zamanındaki satış miktarını ifade eder.

Robinson ve Lakhani fiyat değişkenini eşitlik 2.5'deki gibi modele dahil etmiştir.

$$f(t)/(1 - F(t)) = (\beta_0 + \beta_1 F(t)) \exp(-\beta_2 P(t)) \quad (2.5)$$

Eşitlik 2.5'de $P(t)$, t zamanındaki fiyat değişkenini temsil eder. Bu eklenti ile birlikte fiyatlandırmanın satış grafiği üzerinde etkisinin incelenmesi amaçlanmıştır. Genel olarak eklentiler eşitlik 2.1 üzerinden yapılmıştır, literatürde bu eşitlik üzerine çeşitli eklentiler yapılarak modelin esnekliğinin arttırılması amacıyla çalışmalar mevcuttur. Modele yapılan eklentilerin modelin tutarlılığına olumlu etkisi birçok çalışma ile gösterilmiştir.

Üzerine araştırma yapılan bir diğer açıklayıcı değişken ise reklam harcamasıdır Horský ve Simon yaptıkları çalışmada koşullu sahiplenme fonksiyonu aşağıdaki eşitlik 2.6'daki gibi tanımlamışlardır [22].

$$f(t)/(1 - F(t)) = (\beta_0 + \beta_1 F(t)) + \beta_2 \ln(A(t)) \quad (2.6)$$

Eşitlik 2.6'te reklam harcaması modele $A(t)$ değişkeni ile dahil edilmiştir. Yazarlar çalışmalarında telefon bankacılığının yayılımını yansıtmada bu modeli kullanmış ve başarımını göstermişlerdir.

Bass ve ark. tarafından (1994) yılında önerilen model başarılı bir örnek olarak kabul edilebilir. Bu model "genelleştirilmiş Bass yayılım modeli" (Generalised Bass Diffusion Model, GBDM) olarak bilinir. Model pazarlama ve fiyat değişkenlerini de içerir. Fiyatta yapılan değişiklikler de pazarlama maliyeti olarak ele alınır ve bu iki değişken "mevcut pazarlama etkisi" olarak modele dahil edilir. Eşitlik 2.7, Bass tarafından oluşturulan fonksiyonu göstermektedir.

$$f(t)/(1 - F(t)) = [p + qF(t)]x(t) \quad (2.7)$$

$$x(t) = 1 + \beta_1 \frac{\delta P(t)}{\delta t} + \beta_2 \max \left(0, \frac{\delta A(t)}{\delta t} \right) \quad (2.8)$$

Eşitlik 2.7'te $x(t)$ mevcut pazarlama etkisini temsil eder. Bu etkinin sıfır olduğu durumda GBDM, BDM'ne indirgenir. Eşitlik 2.8'te $A(t)$ ise t zamanında yapılan reklam (*advertising* harcamalarını ifade eder.

Bass tarafından 1994 yılında yapılan çalışma GBDM'yi sunması dışında 1994 yılına kadar BDM üzerine yapılan çalışmaların kapsamlı bir incelemesini de literatüre kazandırmıştır. GBDM makalede kullanılmış ve GBDM'yi temel alan bir fiyatlama stratejisi geliştirilmiştir.

GBDM'nin performansı bir başka büyüme eğrisi modeli olan Gamma-Kaydırmalı Gompertz eğrisi ile 12 ürün üzerinden karşılaştırılmıştır. GBDM bir ürün dışındaki tüm ürünlerde tahmin performansı açısından Gamma-Kaydırmalı Gompertz eğrisinden daha yüksek başarıya sahip olduğu gösterilmiştir.[6].

2.2 Bass Difüzyon Modeli için Parametre Tahmini Yöntemleri

BDM'nin yeni ürünlerin satış eğrisinin temsilindeki başarısı birçok çalışma tarafından gösterilmiştir. Ancak, bu başarı parametrelerin doğru tahmini ile büyük oranda ilgilidir. Bu sebeple parametre tahmini için farklı yaklaşımlar geliştirilmiştir. Genel olarak kabul görmüş ve başarısı ispatlanmış dört farklı parametre tahmini yöntemi bulunmaktadır.

En küçük kareler yöntemi (Ordinary least square, OLS) Bass tarafından modellenen birlikte önerilen parametre tahmini yöntemidir [2]. Bass makalesinde ele aldığı ürünlere ait verilerde bu yöntemin kabul edilebilir parametre tahminleri verdiğini göstermiştir.

Bunun ardından Schmittlien ve Mahajan (1982) en çok olabilirlik yöntemi (Maximum likelihood estimator, MLE) ile parametre tahmini yöntemini kullanmış ve OLS ile karşılaştırılabilir parametre tahminleri elde etmişlerdir.

Lineer olmayan kareler toplamı yöntemi (Nonlinear least square, NLS) 1986 yılında Srinavasan ve Mason tarafından önerilmiştir [39]. Her ne kadar hangi yöntemin en iyi tahmin verdiğini konusunda kesin bir kanı olmasa da NLS ve MLE'nin OLS'den daha iyi olduğu gösterilmiştir. NLS optimizasyon için eğim tabanlı algoritmalarından faydalanır [9, 32]. Bu algoritmalar başlangıç çözümlerinden etkilenirler ve zaman zaman yerel en iyi çözümlerde algoritma sonlanabilir.

Yeni bir parametre tahmin yöntemi öneren her çalışma, önerilen yöntemin yukarıda bahsedilen parametre tahmini yöntemleri ile kıyaslamasını da içerir. Bunun yanı sıra yapay veya gerçek dünyaya ait veri setleri üzerinde bu parametre tahmini yöntemleri uygulanmış ve kıyaslanmıştır [21]. Meade ve Islam (2006) BDM'nin

tahmin gücü ile ilgili geniş çaplı bir inceleme makalesi ortaya koyarken, parametre tahmini yöntemlerinin de kıyaslamasını yapmışlardır. Son olarak Venkatesan ve ark. genetik algoritma (GA) yardımıyla parametre tahmini üzerine çalışmışlardır [46]. Önerdikleri parametre tahmini yönteminin NLS'den daha iyi sonuçlar verdiğini iddia etmektedirler. Ayrıca GA kendi içinde mutasyon oranı, popülasyon büyüklüğü gibi parametreler barındırır. Bu parametreler de başarıyı doğrudan etkiler. Bu kapsamda bu algoritma çalışma çerçevesinde değerlendirilmemiştir. Öte yandan NLS eğim tabanlı optimizasyon işlemi gerçekleştirdiğinden fonksiyon uzayının karmaşıklığının artması yerel en iyi çözümde takılma problemini ortaya çıkarır. Bu açıdan genetik algoritma fonksiyon uzayını uzun sürede de olsa arar ve yerel en iyi çözüm ihtimalini düşürür. Renkli televizyon, iklimlendirme cihazı ve ultrason aleti üzerinde yapılan analizlerde GA'nın NLS'den MAPE ölçüsüne göre daha iyi sonuçlar verdiği gösterilmiştir ancak önemli bir iyileşme getirdiği söylenemez. [46]. Ayrıca daha önce de değinildiği gibi GA parametrelere bağlı olarak çok uzun hesaplama sürelerine sahip olabilir. Çalışmamızda yaklaşık 400 farklı ürün bulunduğu ve GA'nın bariz bir üstünlüğü olmadığını düşündüğümüzden GA çalışmamıza dahil edilememiştir.

Yakın geçmişte parametre tahmini ile iki farklı çalışma yapılmıştır. Biri (2016) OLS ve NLS yöntemlerinin birlikte kullanımını göstermiştir [21]. İkincisi (2019) ise NLS, MLE ve OLS kullanılarak zirve satış miktarını içermeyen veri setlerinde doğru parametre tahminlerinin elde edilemeyeceğini savunmuş ve bayesci yaklaşımı benimseyerek parametre tahmini yapmıştır[20]. Geliştirdikleri parametre tahmini yöntemini GBDM üzerinde uygulamış ve diğer parametre tahmini yöntemleri ile kıyaslamışlardır.

2.3 Bass Difüzyon Modelinin Kullanım Alanları

BDM literatürde birçok farklı ürünün satış eğrisini yansıtmakta kullanılmıştır. Bu ürünler genellikle teknolojik inovasyonlar içerir. Örnek olarak CD, çelik ütü, yazıcı, telefon bankacılığı ve mamografi cihazı verilebilir. Meade ve Islam tarafından ortaya konulan inceleme makalesinde uygun bir Bass eğrisinin bulunabilmesi için çalışmaya konu olan ürünün, tüketilebilirden ziyade sahiplenilebilir olmasının gerekliliği savunulmaktadır [28]. Bu koşul tekrarlanabilir satın alımların olmamasının gerekliliğini gösterir. Bu çalışmada ele aldığımız ürünler sahiplenilebilir tipte ürünler olduğundan uygun bir Bass eğrisinin bulunabilmesi beklenir. Çalıştığımız veride fiyat, sezon içerisinde elle tutulur miktarda değişmediğinden ve pazarlama harcamaları bilgisi paylaşılmadığından BDM kullanılmıştır. Fiyatın periyotlar arasında keskin bir şekilde değiştiği durumlarda GBDM daha iyi tahminler verebilmektedir. Valle ve Furlan rüzgar enerjisinin yayılımını incelemiş ve

GBDM'yi tahmin için kullanmışlardır. Farklı büyüme eğrileri ve BM ile yaptıkları karşılaştırmada GBDM diğer modellerden daha başarılı sonuçlar vermiştir [45]. Yayılım modellerinin tahmin amacıyla kullanımına örnek olarak Bass v.d. (2000) ve Bemmaor ve Lee (2002) örnek verilebilir. Bu çalışmalarda BDM ve diğer yayılım modelleri kullanılarak tahmin yapılmıştır. Farklı tahmin periyotları için elde edilen tahminlerin başarımları karşılaştırılmıştır. Tahmin söz konusu olduğunda Bass tarafından önerilen yayılım modeli diğer yayılım modellerine genellikle üstünlük göstermektedir.

Lee ve ark. (2003) ortaya koydukları çalışmada piyasaya yeni çıkan müzik albümleri üzerinde bayesci yaklaşım ve büyüme eğrilerini temel alan hiyerarşik bir tahmin metodu geliştirmişlerdir. Geliştirdikleri model birçok dış etkeni birlikte kullanır (albüm özellikleri, sanatçı özellikleri vs.). Model her bir yeni veri noktası oluşturulduğunda tahminlerini günceller. Tahminler gelecek 12 haftalık satışlar için oluşturulmuştur. Oluşturulan tahminler ile gerçekleşen satışlar arasındaki hata MAPE üzerinden ölçülmüştür. Çalışmada 50 farklı ürün olduğundan bulunan MAPE değerlerinin medyan değeri tahmin başarımının ifadesi için kullanılmıştır. Geliştirilen model diğer büyüme eğrisi modelleri (GBDM ve genelleştirilmiş gamma modeli) ile MAPE değerleri üzerinden karşılaştırılmıştır.

2.4 Moda Sektöründe Satış Tahmini

Satış tahmini moda sektöründe büyük öneme sahiptir. Moda ürünleri uzun teslimat süresine ve kısa yaşam döngüsüne sahiptirler. Bu sebeple tahminler sezon öncesinde veya sezonun erken periyotlarında birçok yönetsel karara temel oluşturur ve firmanın rekabetçi ortama ayak uydurabilmesini sağlar [30]. Yanlış tahminler firmaya farklı maliyet kalemleri olarak geri döner. Sezonda satılmayan ürünler bir sonraki sezonda veya sezonun sonunda indirimli fiyattan satılmak durumunda kalır ve bu firma için istenmeyen bir durumdur. Bir sonraki sezon satılmak zorunda kalınan ürünler firma için lojistik açıdan da maliyetli olmaktadır. Bu doğrultuda moda ürünlerinin tutarlı tahminlerinin envanter planlama, fiyatlama gibi yönetsel kararlar açısından önemli olduğu söylenebilir [27].

Moda türü ürünlerin satış tahmini literatürde zor bir alan olarak nitelendirilir. Çünkü, talep sezon içerisinde büyük değişimler gösterir. Ayrıca sezon içerisinde birçok sifıra yakın ve/veya sıfır satış periyotları gözlemlenebilir. Moda türü ürünlerin satış grafiği literatürde kesikli ve düzensiz olarak tanımlanır. Tahmin periyodu da yönetsel kararlar açısından önem teşkil eder. Bunun sebebi ise araştırmaya konu olan ürünlerin yaşam döngüsünün kısa olmasıdır [11]. Genel olarak moda ürünlerinin tahmininin zor olmasından dolayı önde gelen giyim firmaları (ZARA, H&M, MANGO v.s) tedarik zincirlerini daha çevik hale getirip, ürün teslimat

süresini azaltmak amacıyla çalışmalar yapmaktadırlar. Bu çalışmalar sonucunda ZARA teslimat süresini 2 haftaya kadar indirebilmiştir [47]. Bu çalışmalar genel olarak ürün satışlarının gözlemlenmesi ve analiz edilmesine dayanır. Ürünlerin teslimat sürelerinin kısa olması sayesinde müşteri eğilimlerine hızlı cevap verebilmek mümkün olur. Bu temelde, tahmin oluşturulurken firmanın imkanları, ürün karakteristiği gibi etmenler göz önünde bulundurulmalıdır ve tahmin periyodu bunlara bağlı olarak belirlenmelidir [43]. Bunun yanı sıra veri üzerinde yapılan bütünleştirme (*aggregation*) de tahminin tutarlılığını etkileyen işlemlerden bir tanesidir. Bütünleştirme işlemi tahminin başarımını olumlu veya olumsuz etkileyebilir [51].

Giyim sektöründeki satış eğrilerine benzer şekilde kesikli ve düzensiz karaktere sahip verilerle tahmin yapılırken kullanılan modeller genellikle yüksek esnekliğe sahip modellerdir. Bu modeller akıllı ve geleneksel olarak iki sınıfta incelenebilir.

Geleneksel olarak nitelendirebileceğimiz modellerden bir tanesi Croston tarafından 1972 yılında önerilmiştir [13]. Croston yönteminde ortalama talep miktarının yanı sıra sıfır olmayan iki talep noktası arasındaki ortalama uzaklık ta modele dahil edilir ve talep miktarıyla birlikte ilgili periyotta talep olup olmayacağı da tahmin edilir. Kesikli talebe sahip ürünlerin gelecek talep miktarını tahmin etmek için geliştirilen bir diğer geleneksel olarak nitelendirilebilecek yaklaşım ise satış sürecini homojen olmayan Poisson süreci olarak ifade etmektir. İki satış noktası, bir diğer deyişle iki sıfır olmayan talep noktası, Poisson sürecinin olayları olarak ele alınır. Bu noktalardaki satış miktarının rassal olması ise Poisson sürecine homojen olmayan karakteri kazandırır.

Akıllı modeller olarak nitelendirebileceğimiz yapay sinir ağları (YSA) tabanlı modeller de talep tahmini amacıyla kullanılmıştır [41]. YSA tabanlı modellerden biri olan aşırı öğrenme makineleri (ELM, *Extreme learning machines*) bu kapsamda en çok kullanılan modellerden birisidir. Wong ve Guo (2010) tarafından yapılan çalışmada ELM kullanılmış olup parametreleri geliştirilmiş harmoni arama yöntemi ile belirlenmiştir. Çalışmada önerilen yöntemin bütünleşik otoregresif hareketli ortalama (ARIMA) ile kıyaslaması yapılmış ve önerilen modelin üstünlüğü gösterilmiştir. Leung ve ark. (2015) ise genel olarak kullanımda olan eğitim tabanlı algoritmalar yerine YSA'nın ve YSA yapısının optimizasyonu için çok amaçlı evrim tabanlı bir algoritma kullanmıştır. Amaçlardan biri YSA'nın karmaşıklığını mümkün olan en küçük düzeyde tutmaktır. Diğeri ise en yüksek başarıyı elde edecek yapıyı kurmaktır. Bu iki amaç birbiriyle çelişir; bunun sebebi nöron sayısı, katman sayısı gibi YSA'nın yapısını oluşturan parametreler çok büyük değerler aldıklarında modelin eğitim hatasını sıfıra yaklaştırabilmesidir. Ancak bu aşırı uyum problemini de beraberinde getirir. Aşırı uyum kısaca modelin öğrenmek yerine veri setini ezberlemesi olarak tanımlanabilir. Aşırı uyma probleminin üstesinden gelmek

amacıyla çok amaçlı bir optimizasyon problemi dizayn edilmiştir. Ancak bu çok amaçlı optimizasyon probleminin çözümünde kullanılan evrim tabanlı algoritma da parametrelere bağlı olarak farklı sonuçlar verebilir. Bu çalışma, ELM tabanlı çalışmalardan biri olan [49] 'i sadece hatayı enküçüklemesinden dolayı eleştirmiş ve böyle bir modelde aşırı uyumun kaçınılmaz olduğunu ileri sürmüşlerdir.

Bulanık çıkarım sistemi de moda ürünlerinin satış tahmininde YSA ile birlikte kullanılan metotlardan biridir. Bulanık çıkarım sistemi veri içerisindeki açıklayıcı değişkenlerin (hava durumu, tatil günleri, ürün özellikleri v.s.) etkilerini saptamak amacıyla kullanılmıştır. Bir temel tahmin üzerine bu etkiler dahil edilerek tahmin oluşturulmuştur [43].

Kümeleme yaklaşımı ise satış profillerinin belirlenmesinde kullanılan yöntemlerden biridir. Thomasse ve Hapiette 2007 yılında ortaya koydukları çalışmada moda sektörünün genel karakteristiklerinden olan her sezon çok sayıda yeni ürünün bulunması ve bu ürünlerin yaşam döngülerinin kısalığı sebebiyle ürünün satışı öncesinde belirlenebilecek bir satış profilinin öneminden bahsetmişlerdir. Bu doğrultuda ürün özellikleri ve özdüzenleyici haritalar (Self organizing maps) kullanılarak bir kümeleme işlemi yapılmış ve satış öncesinde ürünün satış profili hakkında bir öngörü elde edilmiştir. Yeni moda ürünleri söz konusu olduğunda genel olarak az sayıda veri ile tahmin yapılması gerekir. Bunu göz önünde bulunduran Choi ve ark. tarafından yapılan çalışmada, az sayıda veri noktası ile tahmin için iyi bir seçim olduğu savunulan gri tahmin metodu kullanılmıştır. Yapılan çalışmada 20 adet veri noktası yetersiz sayıda veri noktası olarak tanımlanmıştır. Gri tahmin metodu ise satışlar için baz bir tahmin oluşturmak amacıyla kullanılmıştır. Artıklar (*residuals*) için ise ELM modelinden faydalanılmıştır. Geliştirilen yöntemde verideki düzensizlikler ELM ile baz eğri ise gri tahmin metodu ile elde edilmiştir[10].

Farklı bir bakış açısı ise Fumi ve ark. (2013) tarafından geliştirilmiştir. Makalede ürünlerin satış eğrileri Fourier dönüşümü yardımı ile sinüzoidal eğrilerin toplamı olarak ifade edilmiştir. Bu kapsamda gerekli bütünleştirme işlemi algoritmanın sağlıklı işlemesi adına yapılmış olup, yukarıdan aşağıya bir tahmin yolu izlenmiştir. Öncelikle kategori, şube başına bütün talep bulunmuş, ardından sezgisel oranlarla toplam talep ürünlere paylaştırılmıştır. YSA'nın esnekliğinin yüksek olması sebebiyle genel olarak tahmin yapılırken YSA'dan faydalanılmıştır. Çalışmalar arasındaki farklılıklar YSA'nın parametreleri (gizli katman sayısı, öğrenme oranı vs.) belirlenirken kullanılan yöntemlerden ve YSA'nın optimizasyonu için kullanılan metotlardan kaynaklanmaktadır. Akıllı modellerin yüksek esnekliği bir avantajdır, ancak bu avantaj ile birlikte aşırı uyum (*overfitting*) tehlikesi birlikte gelir. Aşırı uymanın yeterince dikkate alınmış olması bir modelin başarımı değerlendirilirken göz önünde bulundurulması gereken önemli bir etkendir [1].

2.5 Literatürdeki Benzer Çalışmalar

Bildiğimiz kadarıyla BDM'nin moda türü ürünler üzerinde kapsamlı bir uygulaması bulunmamaktadır. BDM ile moda türü ürünleri birleştiren tek çalışma Namın ve ark. tarafından (2017) tarafından yapılmıştır. Bu çalışmada satış deseninin BDM'ye uygun olduğu "varsayılarak" bir fiyat politikası önerilmiştir. Çalışmada ana amaç iyi bir fiyat politikasının belirlenmesidir ve BDM'nin satış eğrisini yansıtmadaki başarısı üzerine detaylı bir çalışma yer almamaktadır. Bu çalışma sadece BDM'ni moda ürünlerinin satış desenini temsil etmekte kullanması açısından çalışmamızla benzerlik göstermektedir.

Hu ve ark. (2017) tarafından ortaya konulan çalışma, oturtulan satış eğrilerinin kümelenmesi ve bu kümeler yardımı ile tahminin oluşturulması açısından bizim çalışmamızla benzerlik göstermektedir. Çalışmada ürün yaşam döngüsünün ifadesi için Bass eğrisi dışında farklı eğrilerin (polinomsal, üçgensel v.b) başarımı da incelenmiştir. Ancak sözü edilen çalışmada normalize edilmiş ürün yaşam eğrileri ile çalışıldığından nihai tahminin oluşturulması için satış hacmi ve ürünün yaşam uzunluğu, bir başka değişle satışta kalma süresi gibi bilgiler gereklidir. Bu bilgilerin çalışmanın birlikte yürütüldüğü kurumdan elde edildiği söylenmiştir. Makalede ele alınan durum herhangi bir geçmiş verisi olmayan ürünlerdir. Bu sebeple yeni ürünün hangi kümeye ait olduğunun bilinmesi için yeni ürün de kümeleme işlemine dahil edilmiştir. Bütün ürünler kümelendikten sonra yeni ürünün yaşam döngüsü, ürün pazarda yerini almadan önce tahmin edilmiştir. Tahmin oluşturulurken yeni ürünün içinde bulunduğu kümede bulunan ve ömrünü yeni ürünün piyasaya çıkış tarihinden önce tamamlamış ürünlerden faydalanılmıştır. Bu ürünler ve sergiledikleri ortak satış deseninin belirlenmesi için bu noktalar üzerine uygun bir eğri oturtulmuştur. Bu şekilde elde edilen yaşam döngüsü normalize değerlerden oluştuğu için hacim ile ilgili tahmin kullanılarak ölçeklendirilmiştir. Tahmin, son şeklini sezonsal etkilerin eklenmesiyle almıştır. Bu tahmin firmanın ürün piyasaya çıkmadan önce ürün yaşam döngüsü üzerine yaptığı tahminlerle kıyaslanmıştır. Yapılan analizlerde önerilen tahmin metodunun, firmanın mevcut durumda uyguladığı tahmin metodundan daha başarılı olduğu gösterilmiştir [23]. Çalışmada farklı büyüme eğrilerinin ürün yaşam eğrisini temsil etmedeki performansı değerlendirilmiştir. Bu eğriler ikinci, üçüncü ve dördüncü dereceden polinom fonksiyonlar, üçgensel fonksiyonlar, trapezoidler ve Bass eğrileridir. Akaike bilgi kriteri kullanılarak yapılan analizlerde dördüncü dereceden polinom fonksiyon en küçük Akaike bilgi kriteri değerine sahiptir. Ancak tahmin amacıyla kullanım söz konusu olduğunda en yüksek başarımlı trapezoid fonksiyonlar elde edilmiştir. Çalışma kapsamında Bass eğrileri de değerlendirilmiştir. Ancak BDM ile oluşturulan modellerin tahmin başarımlı diğer eğrilerin altındadır. Bu çalışma ürün yaşam eğrileri ve kümeleme tabanlı olması

açısından çalışmamızla benzerlik göstermektedir.

Ürün yaşam eğrilerinin kümelenmesi ve küme bilgilerinin tahmin aşamasında kullanılması moda türü ürünlerin satış tahmininde başvurulan yöntemlerden biridir [44, 23, 43]. Literatürde ise bu işlem prototip kümeleme olarak isimlendirilir. Kümeleme işlemi gözetimsiz öğrenme tekniklerinden bir tanesidir ve veri setinin yapısı hakkında bilgi edinmek için başvurulan bir yöntemdir. Bu çalışma kapsamında BDM yardımıyla belirlenen yaşam eğrilerinin kümelenmesi için k-medoids algoritması kullanılmıştır. K-medoids algoritması genel olarak veri setini k parçaya böler. Bölme işlemi ise belirlenen benzemezlik ölçüsünün enküçüklenmesi amacıyla ilerler [24]. K-medoids algoritması dışında özdüzenleyici haritalar (Self Organizing Maps) da ürün prototiplerinin kümelenmesi de kullanılan kümeleme algoritmalarından biridir. K-medoids algoritmasının işleyişi ve algoritmanın parametresi olan k değerinin belirlenmesi ilerleyen kısımlarda anlatılmıştır. Kümeleme konusunda bir başka önemli etken de benzemezlik ölçüsüdür. Benzemezlik ölçüsü kümeleme amacına hizmet edecek şekilde belirlenmelidir. Bu çalışmada benzemezlik ölçüsü olarak zaman serilerinin davranışlarını da göz önünde bulunduran bir metot kullanılmıştır. Metot 2007 yılında Nagabhushan ve Douzal tarafından önerilmiş olup, ayarlanabilir benzemezlik ölçüsü (ADI, *Adaptive dissimilarity measure*) olarak adlandırılmaktadır [14]. Benzemezlik ölçüsünün matematiksel ifadesi ve kullanımı ilerleyen bölümlerde anlatılmıştır.



3. BASS DİFÜZYON MODELİ'NİN MODA TÜRÜ ÜRÜNLERDE PERFORMANS ANALİZİ

3.1 Giriş

Bu kısımda her bir ürünün sezon içerisinde gösterdiği satış desenleri kullanılarak BDM'nin performansı incelenecektir. Performans değerlendirmesi yapılırken öncelikle verilerin ön işleme aşaması anlatılacak olup, daha sonra literatür tarafından kabul görmüş parametre tahmini yöntemleri ve bizim önerdiğimiz bir yöntem ile BDM'nin parametreleri tahmin edilecektir. Daha sonra BDM'nin tahmin modeli olarak uygunluğu tüm veri kullanılarak değerlendirilecektir. Modelin tahmin performansının analizi için ayrıca kısmi veri ile oluşturulan modellerin ürünün sezon içerisinde kalan talebinin tahmini üzerindeki başarımı incelenecektir.


3.2 Veri Hazırlama

İlk olarak, ürün satış eğrilerinde sezon sonu indirimli fiyattan satışlardan kaynaklanan anormalliklerin giderilmesi için eğriler belli bir noktadan kesilmiştir. Bu nokta belirlenirken toplam satış miktarının %90'ını kapsayacak olması ilk kesme noktası olarak belirlenmiştir. İkinci kısıt ise mevcut veri noktalarının sayısı olarak %90'ının kullanılması olarak belirlenmiştir. Bu kısıtlar sonucunda iki farklı kesme noktası belirleyerek bunların küçük olanı nihai kesme noktası olarak belirlenmiştir. Kesme işlemi Şekil 3.1'de örnek bir ürün üzerinden görselleştirilmiştir. Veri noktaları Türkiye'deki satışlar üzerinden haftalık olarak gruplanarak, ürün bazında dalgalı satış grafikleri anormalliklerden kısmi olarak arındırılmıştır. Haftalık satış verileri, genel eğilimin belirlenmesi açısından daha uygun bir veri seti olarak gözlemlenmiştir.

3.3 Literatürdeki Parametre Tahmini Yöntemleri ve Uygulanması

Bu çalışmada, BDM'nin kapsamlı etkinlik araştırması için farklı parametre tahmini yöntemleri kullanılmıştır. Yöntemler arası kıyaslama da çalışmaya dahil edilmiştir. Literatürde kabul gören OLS, NLS, MLE ve bizim geliştirdiğimiz yaklaşım olan RLS (Randomised line search) her bir veri üzerinde kullanılıp, parametreler tahmin edilmiştir. Bu yöntemlerin kısa açıklamaları ve önerilen yöntemin açıklaması bu kısımda verilecektir.

OLS, kümülatif satış miktarı ve kümülatif satış miktarının karesi bağımsız değişkenlerinin t zamanındaki satış miktarına eşitlenmesini temel alır. Bu eşitlik üzerin-



Şekil 3.1: Kesme noktasının belirlenmesi

den uygulanan doğrusal regresyon modeli sonucunda parametreler tahmin edilir. Bulunan parametreler direk olarak BDM'nin parametreleri olan p, q ve m değerlerini vermez. Gerekli cebir işlemlerinden sonra p, q ve m değerleri elde edilir.

$$S_t = \beta_1 + \beta_2 Y_{t-1} - \beta_3 Y_{t-1}^2 \quad (3.1)$$

Eşitlik 3.1, ilgili doğrusal regresyon modelini gösterir. Bu modelde Y_t , t zamanına (haftasına) kadar kümülatif satış miktarını temsil eder. S_t oluşturulan Bass eğrisinin t zamanındaki değerine, yani t haftasındaki satış tahminine eşitlenir. Yani eldeki veriden önce bu doğrusal regresyon modeli kurulur. Bu eşitlikte $\beta_1 = p \times m$, $\beta_2 = q - p$ ve $\beta_3 = q/m$ olduğundan, gerekli işlemler sonucunda parametre tahminleri bulunur.

Amaç fonksiyonu elde edilen regresyon eğrisi ile gerçek değerler arasındaki farkların karelerinin toplamı olarak belirlenir. Bu amaç doğrultusunda QR-ayrıştırması ile amaç fonksiyonu enküçüklenir. (QR-ayrıştırması A matrisi ile verilen eşitlik sisteminin, Q ortogonal matrisi ve R üst üçgensel matrisinin çarpımı olarak ifade edilmesiyle başlar. $Ax = b$ sisteminin çözümü A matrisinin tersinin bulunmasıyla

mümkündür. $Q \times R$ ifade edildikten sonra A matrisinin tersinin bulunması, ortogonal ve üst üçgensel matrislerinin özelliklerini kullanarak kolaylaşır. Sonuç olarak $\hat{x} = R^{-1}(Q^T b)$ bulunur.) Elde edilen β değerlerinin dönüşümü eşitlik dizisi 3.2 yardımıyla yapılır.

$$\hat{p} = \frac{-\beta_2 + \sqrt{\beta_2^2 - 4\beta_1\beta_3}}{2} \quad \hat{q} = \frac{\beta_2 + \sqrt{\beta_2^2 - 4\beta_1\beta_3}}{2} \quad \hat{m} = \frac{-\beta_2 + \sqrt{\beta_2^2 - 4\beta_1\beta_3}}{2\beta_3} \quad (3.2)$$

NLS'de S_t 'nin OLS'de olduğu gibi doğrusal regresyon şekilde ifade edilmesine gerek yoktur, doğrusal olmayan regresyon modelleri kullanılır. Bu yöntemde OLS'de olduğu gibi elde edilen Bass eğrisi ile gerçek değerler arasındaki farkın karesi Levenberg-Marquardt algoritması kullanılarak enküçüklenmiştir [32].

$$X(t_i) = m[F(t_i) - F(t_{i-1})] + \mu_i \quad (3.3)$$

$$F(t) = \frac{1 - e^{-(p+q)t}}{\left(1 + \frac{q}{p}e^{-(p+q)t}\right)}$$

Eşitlik 3.3'da p inovasyon katsayısını temsil ederken, q imitasyon katsayısını, t ise zaman periyodunu temsil eder. Yukardaki eşitliklerde de görüldüğü üzere t zamanındaki satış miktarı ($X(t_i)$), $X(t_i) = m \times f(t_i)$ olarak ifade edilebilir. $y(t_i)$ 'nin t_i zamanında gerçekleşen satış miktarı olduğu göz önünde bulundurulduğunda amaç fonksiyonu $\sum_{i=1}^T (y(t_i) - X(t_i))^2$ olarak tanımlanır. Amaç fonksiyonunu enküçüklenmesi Levenberg-Marquardt algoritması (LMA) ile yapılmıştır [32]. Algoritma sonucunda elde edilen değerler NLS ile elde ettiğimiz parametre tahminlerini oluşturur.

Levenberg-Marquardt algoritması doğrusal olmayan en küçük kareler toplamı problemlerinin çözümünde kullanılır. Eğri uydurma (*curve fitting*) amacıyla geniş bir kullanım alanına sahiptir. Bir uydurma (fit) fonksiyonu $\hat{y}(t;p)$ olarak tanımlansın. Bu fonksiyonda t bağımsız değişkenleri p ise n boyutlu olmak üzere parametreleri tanımlasın. Bu kapsamda her bir veri noktası i indeksi kullanılarak (t_i, y_i) şeklinde ifade edilebilir. Hata fonksiyonu ki-kare (χ^2) hata kriteri kullanılarak aşağıdaki gibi oluşturulur.

$$\chi^2(p) = \sum_{i=1}^m \left[\frac{y(t_i) - \hat{y}(t_i;p)}{\sigma_{y_i}} \right]^2 \quad (3.4)$$

Eşitlik 3.4'de σ_{y_i} , $y(t_i)$ için ölçüm hatasını gösterir. Daha iyi bir gösterim için W matrisini ölçüm hatası kovaryans matrisinin tersi olarak tanımlarsak ve i bağımlı

ifadeleri vektör olarak ifade edersek, eşitlik aşağıdaki hale indirgenebilir.

$$\chi^2(p) = y^T W y - 2y^T W \hat{y} + \hat{y}^T W \hat{y} \quad (3.5)$$

Amaç χ^2 değerini enküçükleyecek p değerlerini bulmaktır. Bu durumda türev alma işlemi uygulanır.

$$\frac{\delta}{\delta p} \chi^2 = 1(y - \hat{y}(p))^T W \frac{\delta}{\delta p} (y - \hat{y}(p)) \quad (3.6)$$

Gerekli cebir işlemleri sonrasında aşağıdaki eşitlik elde edilir.

$$\frac{\delta}{\delta p} \chi^2 = -w(y - \hat{y})^T W J \quad (3.7)$$

Eşitlik 3.7 içerisindeki J ifadesi $\delta \hat{y} / \delta p$ 'yi ifade eder. Bu aynı zamanda \hat{y} fonksiyonunun p parametrelerindeki değişimlere hassasiyetini gösterir ve *Jacobian* olarak adlandırılır. Levenberg-Marquardt algoritmasında parametre güncellemeleri aşağıdaki eşitliğe dayanılarak yapılır.

$$[J^T W J + \lambda I] h_{lm} = J^T W (y - \hat{y}) \quad (3.8)$$

Yukarıdaki eşitlikte h_{lm} parametre güncelleme miktarını ve yönünü ifade eder. λ parametresine bağlı olarak adım büyüklüğü ayarlanabilir. Algoritma büyük λ değerleri ile başlar (küçük adımlarla), çözüm geliştikçe λ değerleri düşürülür. Herhangi bir adımda daha büyük bir hata değeri elde edilirse λ arttırılır. Algoritma fonksiyonun tanımlı olduğu uzayı ararken başlangıç değerleri gerektirir. Başlangıç değeri olarak MLE yöntemi ile elde edilen parametre tahminleri verilmiştir. Ancak, yapılan deneyler sonucunda başlangıç değerlerinin nihai değerler üzerinde büyük bir etkisi olmadığı gözlemlenmiştir.

En çok olabilirlik yaklaşımı Schmittien ve Mahajan tarafından ortaya konulmuştur. Yazarlar t zamanına kadar toplam satış miktarını eşitlik 3.9'daki gibi ifade etmişlerdir [37].

$$F(t) = \frac{c(1 - e^{-bt})}{1 + ae^{-bt}} \quad (3.9)$$

Bu eşitlik kullanılarak eşitlik 3.10'daki olabilirlik fonksiyonu elde edilir.

$$L(a, b, c, x_i) = [1 - F(t_{T-1})]^{x_T} \prod_{i=1}^{T-1} [F(t_i) - F(t_{i-1})]^{x_i} \quad (3.10)$$

En çok olabilirlik yaklaşımında amaç olabilirlik fonksiyonunu enbüyüklemektir. Bu fonksiyonun oluşturulması yazarlar tarafından 1982 yılında yazılan makalede açıklanmıştır. Fonksiyonun içerisinde a , b gibi terimler içerdiği görülür. Fonksiyonda

$a = p/q$ ve $b = p + q$ eşitliklerini temsil eder. Bir başka terim olan c ürünü sahip-lenen müşteri sayısının potansiyel alıcıların toplamına oranını temsil eder. Olabilirlik fonksiyonun enbüyüklenmesi Broyden-Fletcher-Goldfarb-Shanno (BFGS) algoritması yardımıyla gerçekleştirilmiştir. Algoritma enküçükleme problemleri için olduğundan bizim vakamızda $-\log(L(a, b, c, x_i))$ enküçüklenmiş ve parametre tahminleri elde edilmiştir.

3.4 Önerilen Rassal Çizgisel Arama Metodu

Önerilen metot olan rassal çizgisel arama yöntemi (RLS), diğer parametre tahmini yöntemleri gibi gerçekleşen veri ile Bass eğrisi arasındaki farkın karesinin enküçüklenmesi temeline dayanır. Algoritma ilk olarak N farklı başlangıç noktası belirler. Bu başlangıç noktaları rastgele belirlenen p, q ve m üçlülerinden oluşur. p ve q parametreleri $[0, 1]$ aralığında tanımlı olduğundan bu aralıkta rastgele değerler oluşturulur. m parametresinin teorik olarak tanım aralığı $[1, \infty]$ 'dir. Önerdiğimiz metotta m parametresi için başlangıç noktası olarak oldukça gevşek bir aralık olan toplam satış miktarının yarısı ile iki katı arasında rastgele bir m değeri seçilir.

Algoritma içerisinde kullanılan *calcFitness* fonksiyonu, parametre olarak aldığı p, q ve m değerleri kullanılarak oluşturulan Bass eğrisi ile gerçekleşen satış noktaları arasındaki hataların kareleri toplamını hesaplar. Çizelge 3.1'de sözde kodu verilen *ChangeP* fonksiyonu p parametresi için *step()* fonksiyonu yardımıyla arama yapar ve daha iyi bir p değeri mevcut ise bu p değerini döner. Tanımlanan *step()* fonksiyonu aldığı parametre için rastgele bir adım uzunluğu döner. Örnek olarak *changeP* fonksiyonunda p parametresini alır ve bu parametre için belirlenen adım aralığından rastgele bir adım uzunluğu döner. Adım uzunluğu p ve q için $[0.001, 0.025]$ aralığında bir rastgele değer iken, m parametresi için $[10, 100]$ arasında tanımlıdır. Bu değerler belirlenirken literatürde BDM'nin parametreleri üzerine yapılan çalışmalar göz önünde bulundurulmuştur. Çalışmalar sonucunda bulunan p, q ve m değerleri incelenmiş ve makul adım büyüklükleri seçilmiştir. Adım büyüklüğü rastgele olarak seçildiği için çok küçük değerler adım büyüklüğü olarak oluşturulduğunda algoritmanın sonuçlanması uzun sürebilmektedir.

Algoritmanın sözde kodu Çizelge 3.2'de verilmiştir.

Çizelge 3.1: P değişimi fonksiyonu

```

function CHANGEP( $p, uygunluk_1$ )
     $p' \leftarrow p + step(p)$ 
     $p'' \leftarrow p - step(p)$ 
    if calcFitness( $p', q, m$ ) < calcFitness( $p'', q, m$ ) then
    | if calcfitness( $p', q, m$ ) <  $uygunluk_1$  then
    | |  $p \leftarrow p'$ 
    | | end
    | end
    | else
    | | if calcfitness( $p'', q, m$ ) <  $uygunluk_1$  then
    | | |  $p \leftarrow p''$ 
    | | end
    | end
    end
    return  $p$ 

```

Aşağıda sözde kodu verilen algoritma, her bir başlangıç noktası için sırasıyla p, q ve m parametrelerini hataların kareleri toplamını (SSE, *Sum of squared errors*) küçültmek amacıyla rastgele oranlarda değiştirir. Algoritma ilk olarak p parametresini değiştirerek başlar, p parametresi için $p' \leftarrow p + step$ ve $p'' \leftarrow p - step$ atamaları *ChangeP* fonksiyonu yardımıyla yapılır. Bu fonksiyon atamalar sonrasında SSE değeri küçülmüşse, SSE değerini küçülten p' değerini döner ve $p \leftarrow p'$ ataması yapılır. Aynı işlem q ve m parametreleri için de yapılır. Bu parametreler için de sırasıyla, *ChangeQ* ve *ChangeM* fonksiyonları tanımlanmıştır. Her bir parametre için daha iyi değerler bulunduktan sonra algoritma tekrar başa döner ve yeni q ve m değerleri için p parametresi üzerinden tekrar arama yapar, daha iyi bir çözüm olup olmadığını kontrol eder. Bu işlem de q ve m parametreleri için tekrarlanır. Algoritma döngü sonunda elde edilen SSE değerinin değişip değişmediğine bakar, eğer SSE değeri değişmediyse $deneme \leftarrow deneme + 1$ ataması yapılır. Deneme sayısı k (maksimum deneme sayısı) değerinden düşükse algoritma devam eder. Büyük ise algoritma sonlanır ve o başlangıç noktası için elde edilen p, q ve m değerleri havuza eklenir.

Çizelge 3.2: RLS algoritmasının sözde kodu

```

Data: Haftalık satışlar
Result:  $p$ ,  $q$  ve  $m$  parametrelerinin tahmini
Başlangıç;
Rastgele  $N$  adet  $(p, q, m)$  üçlüsü (başlangıç noktası) oluştur.
forall Başlangıç noktaları do
     $deneme \leftarrow 1$ ;
     $uygunluk_1 \leftarrow calcFitness(p, q, m)$ ;
    while  $n < iterasyonSınırı$  &  $deneme < k$  do
        while  $p \neq ChangeP(p, uygunluk_1)$  do
             $p' \leftarrow ChangeP(p, uygunluk_1)$ ;
             $p \leftarrow p'$ ;
             $uygunluk_1 \leftarrow calcFitness(p, q, m)$ ;
        end
        while  $q \neq ChangeQ(q, uygunluk_1)$  do
             $q' \leftarrow ChangeQ(q, uygunluk_1)$ ;
             $q \leftarrow q'$ ;
             $uygunluk_1 \leftarrow calcFitness(p, q, m)$ ;
        end
        while  $m \neq ChangeM(m, uygunluk_1)$  do
             $m' \leftarrow ChangeM(m, uygunluk_1)$ ;
             $m \leftarrow m'$ ;
             $uygunluk_1 \leftarrow calcFitness(p, q, m)$ ;
        end
         $n \leftarrow n + 1$ ;
         $uygunluk_2 \leftarrow calcFitness(p, q, m)$ ;
        uygunluk2 çözüm havuzuna ekle
        if  $uygunluk_1 = uygunluk_2$  then
             $deneme \leftarrow deneme + 1$ ;
        end
    end
    if  $uygunluk_2 \leq$  havuzda mevcut en küçük uygunluk değeri then
         $p^* \leftarrow p$ ;
         $q^* \leftarrow q$ ;
         $m^* \leftarrow m$ ;
    end
end
return  $p^*$ ,  $q^*$  ve  $m^*$ ;

```

Havuz ekleme işlemi sırasında, eğer elde edilen SSE havuzdaki bütün SSE değerlerinden küçük ise ilgili başlangıç noktasından elde edilen parametre tahminleri için $p^* \leftarrow p$, $q^* \leftarrow q$ ve $m^* \leftarrow m$ atamaları yapılır.

Her bir başlangıç noktasından elde edilen nihai çözüm havuza eklenir. Havuzda algoritma sonunda N farklı çözüm bulunur. Bu N çözüm arasından en küçük SSE değerine sahip çözüm p^* , q^* ve m^* değerlerini verir. Algoritmanın rastgele N farklı noktadan başlamasının sebebi, yerel olarak iyi bir değerde takılıp kalmasının önüne geçmektir. Rastgele oranlarda adım büyüklüğü belirlemenin sebebi de en iyi çözümü atlama ihtimalinin azaltılmasıdır. Bu şekilde tanım aralığında farklı alanlarının da taranması amaçlanmıştır.

Arama tabanlı bir algoritma olan GA'nın da çalışmaya dahil edilmesi çalışmayı daha kapsamlı hale getirebilirdi ancak daha önceden bahsedilen hesaplama zamanının uzunluğu ve GA'nın fazla parametre içeren bir metot olması nedeniyle çalışmamıza dahil edilememiştir. Bunun yerine arama tabanlı başka bir algoritma olan rassal çizgi arama metodu ile kapatılmaya çalışılmıştır. Algoritma GA'dan daha kısa sürede ve diğer parametre tahmini yöntemleriyle (NLS, OLS, MLE) kıyaslanabilir başarımda sonuçlar vermiştir.

3.5 Parametre Tahmini Yöntemlerinin Uygulanması ve Sonuçlar

Öncelikle, verilerin modellenenebilir hale getirilmesi amacıyla bir ön işleme gerçekleştirilmiştir. Ön işleme aşamasında veriler belli ölçütlere göre filtrelenmiştir. Veri noktası sayısı 10 veya daha az olan ürünler ve özel olarak üretilen ürünler (toplam satış miktarı çok az (< 20) olan ürünler) çalışmaya dahil edilmemiştir. BDM'nin tüm sezonsal veri kullanılarak ve kısmi veri ile oluşturulduğunda olmak iki farklı durumda başarımları incelenmiş ve raporlanmıştır. Bu kapsamda 409 adet ürün üzerinden BDM'nin performans analizi yapılmıştır. Her bir ürünün satış verisi haftalık olarak gruplanmış ve ürün ailelerine göre kategorilere ayrılmıştır.

Çizelge 3.3, ürünlerin kategorilere göre dağılımını göstermektedir. Kategoriler pantolon, etek, kaban v.b. karşılık gelmektedir. Firma tarafından rastgele ürünlerin satış verileri sağlandığından, ürünlerin kategorilere dağılımında bir düzensizlik söz konusudur. Kategori bazında derinlemesine bir analiz yürütülmek istenirse en azından daha dengeli bir veri kümesi oluşturulması gerekebilir.

3.5.1 Tüm sezonsal veri ile yapılan analizler

Çizelge 3.3: Ürünlerin kategorilere göre dağılımı

Kategoriler	Ürün Sayısı
Kategori 1	23
Kategori 2	41
Kategori 3	39
Kategori 4	22
Kategori 5	14
Kategori 6	44
Kategori 7	28
Kategori 8	54
Kategori 9	24
Kategori 10	43
Kategori 11	77
Toplam	409

Bu kısımda BDM'nin moda türü ürünlerin satış eğrisini ne ölçüde yansıtabildiği incelenecektir. Bu kapsamda verinin tümü kullanılarak uygun bir Bass eğrisi bulmak amaçlanmaktadır. BDM genel olarak ürünün satış eğilimi hakkında bilgi verdiği için, nokta tahmini yerine sezonda belli bir t zamanından ürünün mevcut verisinin sonuna kadar (sezon sonuna kadar, bir başka deyişle kesme noktasına kadar) kalan talebin tahmini ile ilgilenilmiştir. Bu doğrultuda oturtulan Bass eğrileri ile gerçek ürün verisi arasındaki fark yüzde ortalama mutlak sapma (MAPE) ölçüsü kullanılarak ifade edilmiştir.

Çizelge 3.4, her bir kategori için kategorideki tüm ürünler üzerinden bulunan MAPE değerlerini gösterir. Çizelge incelendiğinde NLS'nin diğer yöntemlerden çoğu durumda üstün olduğu gözlemlenebilir. Bazı durumlarda MLE daha iyi sonuç vermiştir. Bizim önerdiğimiz metod olan RLS ise diğer yöntemlerle oldukça kıyaslanabilir sonuçlar vermektedir.


Çizelge 3.4: Parametre tahmin yöntemleri MAPE değerleri

Kategori	OLS	NLS	MLE	RLS
Kategori 1	6.87	6.44	6.71	7.23
Kategori 2	8.24	7.31	7.11	7.84
Kategori 3	8.96	6.49	7.18	7.66
Kategori 4	12.74	7.54	8.52	8.33
Kategori 5	7.67	7.72	7.2	8.66
Kategori 6	7.84	6.15	6.39	6.87
Kategori 7	8.27	6.89	7.05	8.13
Kategori 8	11.46	6.93	8.2	8.18
Kategori 9	9.2	7.07	7.63	7.85
Kategori 10	9.02	6.64	7.22	7.91
Kategori 11	7.1	5.98	6.62	6.63
Ortalama	8.85	6.83	7.26	7.75
Standart Sapma	1.79	0.55	0.64	0.62

Çizelge 3.4’de görüldüğü üzere genel olarak MAPE değerleri itibariyle son üç metod oldukça benzer performans göstermiş ve yaklaşık olarak %5.5 – 8.5 arası değerler vermiştir.


Bu sonuca dayanarak BDM’nin moda türü ürünlerin satış eğilimini yansıtmada etkin olduğunu söyleyebiliriz. Sonuç olarak doğru parametreler bulunduğu BDM moda türü ürünlerin satış eğrisini tutarlı bir şekilde yansıtabilir diyebiliriz.

Ürün karakteristiği ve firma olanakları göz önünde bulundurularak performans göstergesi, kalan talebin tahminindeki yüzde ortalama mutlak hata olarak belirlenmiştir. Şekil 3.2, tüm veri noktaları kullanılarak oluşturulan Bass eğrisinin kalan talep açısından gerçekleşen satış eğrisine ne ölçüde yakın olabildiğine dair bir örnek göstermektedir.




Şekil 3.2: Kalan talep grafiği

Oluşturulan Bass eğrilerinin istatistiksel olarak veriye uygun olup olmadığının araştırılması için oluşturulan model ile gerçek değerler arasındaki farklar (*residuals*) analizi için iki farklı teste tabi tutulmuştur. Bunlardan birincisi farkların normal dağılıp dağılmadığını kontrol etmek amacıyla uygulanan Kolmogorov-Smirnov ve Shapiro-Wilk testleridir. Sıfır hipotezi olarak kalanların normal dağılıma sahip olduğu bir hipotez testi uygulanmış, elde edilen p değerleri ($\alpha = 0.05$) sıfır hipotezini reddetmek için güçlü bir kanıt olmadığını göstermiştir ($\bar{p} = 0.689$). İkinci durum ise kalanların arasında oto-korelasyon olup olmadığını kontrol etmek amacıyla ele alınmıştır. Bunun test edilmesi için ise Durbin-Watson testi uygulanmıştır [16]. Bu testten elde edilen sonuçlar ile kalanlar arasında oto-korelasyon olmadığı gösterilmiştir $\bar{p} = 0.325$. Elde edilen \bar{p} değeri sıfır hipotezini reddetmek için yeterince güçlü bir kanıt olmadığını göstermektedir. Şekil 3.3, hipotez testleri sonucunda elde edilen p değerlerinin kutu grafiğini göstermektedir. Kolmogorov-Smirnov testinde sıfır hipotezi kalanların normal dağıldığı iken, Durbin-Watson testinde sıfır hipotezi kalanlar arasında otokorelasyon olmadığıdır.




(a) Kolmogorov-Smirnov p değerleri



(b) Durbin-Watson p değerleri

Şekil 3.3: P değerleri için kutu grafiği

Sonuç olarak BDM'nin istatistiksel olarak uygun bir model olduğu gösterilmiştir. Ayrıca sezonun erken periyotlarında kalan sezon talebi için iyi bir tahminin yönetsel kararlar açısından değerli bir bilgi olacağı düşünülmektedir. Şekil 3.4 örnek bir ürün ve oluşturulan Bass eğrisini göstermektedir.



Şekil 3.4: Satışlar ve oluşturulan Bass Eğrisi

Grafikte de görüldüğü üzere her ne kadar düzensiz bir satış grafiği olsa da Bass

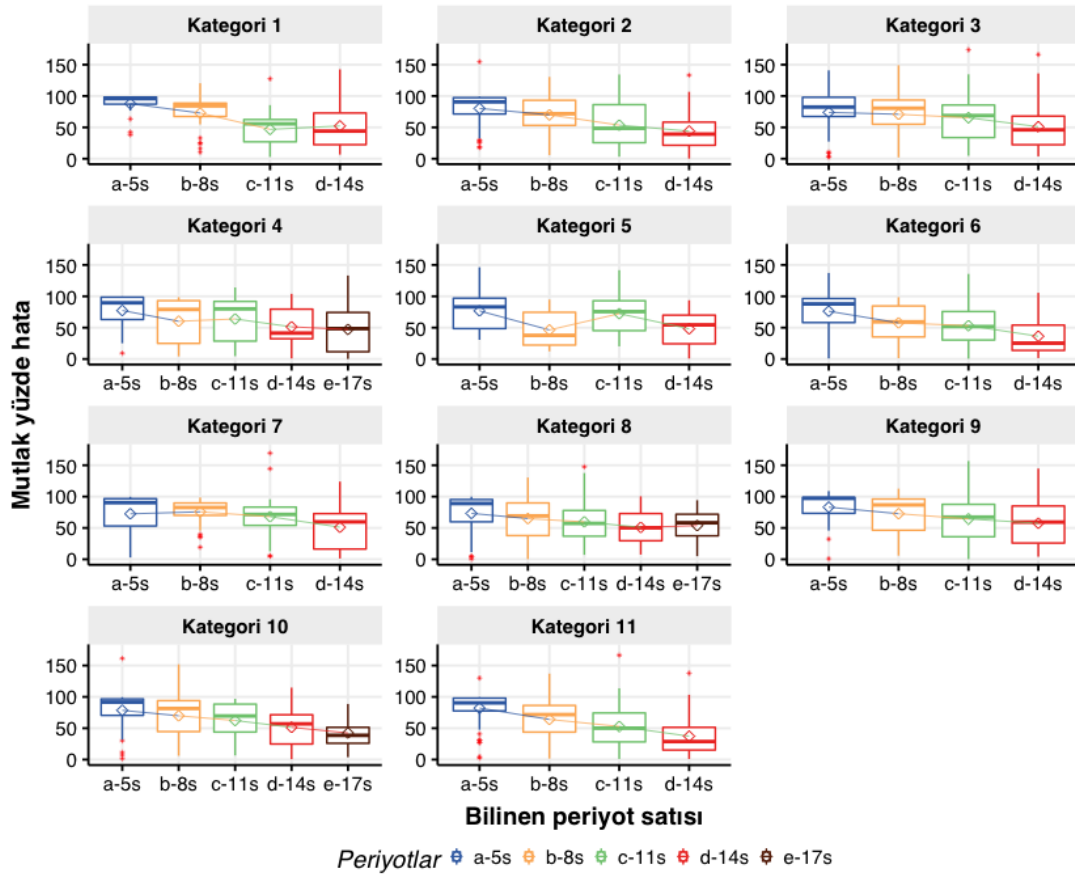
eğrisi genel eğilimi göstermekte başarılıdır. Bu düzensiz satış eğrisini tüm ürünlerde gözlemlediğimizden, bir sezondaki kalan talep ile ilgili tahmin oluşturma yoluna gidilmiştir.

3.5.2 Kısmi veri ile yapılan analizler

Pratikte Bass eğrisi ürünün satış verisinin bir kısmı ile oluşturulacak olduğundan BDM'nin kısmi veri ile gösterdiği performans da çalışma kapsamında analiz edilmiştir. BDM'nin doğru parametrelerle satış eğrisini kabul edilebilir ölçüde yansıtabildiği yukarıda gösterilmiştir. Ancak, yeterince iyi parametre tahminlerinin elde edilmesi için ne miktarda veriye ihtiyacımızın olduğu bu kısımda cevaplanması amaçlanan ana sorudur.

Bu kapsamda kısmi veri noktalarıyla oluşturulan Bass eğrilerinden ürünün sezonun geri kalanındaki talebine dair tahminler yapıp, bu tahminlerin başarımı MAPE değerleri üzerinden incelenmiştir. Bass eğrileri oluşturulurken ürünün t zamanına (haftasına) kadar gösterdiği satış verileri kullanılmıştır. Tek bir t değeri yerine farklı t değerleri (5, 8, 11, 14 hafta) kullanılarak kısmi veri ile oluşturulan Bass eğrilerinin başarımı ile elde edilen veri noktası sayısı arasındaki ilişki incelenmiştir. Sonuçlar Şekil 3.5 de kutu grafiği olarak sunulmuştur. Grafiklerdeki verisi bilinen hafta sayısı (x eksen) her grafikte farklılık göstermektedir. Bunun sebebi her bir grafik, o kategorideki ürünlerden bilinen nokta sayısı en küçük olan baz alınarak oluşturulmuş olmasıdır (14 veya 17 hafta). Şekil 3.5 oluşturulurken t zamanına kadar elde edilen veriler için bir parametre tahmini yapılmış ve $t + 1$ zamanından en son periyoda (T) kadar gerçekleşen satış miktarları toplanıp, elde edilen toplam ve Bass eğrisinden elde edilen kalan satış toplamı karşılaştırılmıştır.


Elde edilen sonuçlar kutu grafiği ile görselleştirilmiştir. Grafik incelendiğinde periyot sayısı ile mutlak yüzde sapma (APE, *Absolute percent error*) arasında sürekli azalan bir ilişki her kategoride gözlenlenmemiştir. Ürün sayısı diğer kategorilere oranla daha az olan kategorilerde beklenildiği üzere daha dalgalı bir karakter gözlemlenmektedir. Ürün sayısı fazla olan kategoriler (örnek olarak, 11 ve 8) haftalara göre APE bakımından haftalara göre azalan bir eğilim sergilemektedirler. Şekil 3.5, kategori bazında gruplanmış kutu grafiklerini göstermektedir. Grafiklerde bulunan kırmızı noktalar aykırı veri noktalarını ifade etmektedir.



Şekil 3.5: Kategorilere göre APE değerlerinin değişimi

Bunun bir sebebi kalan periyot sayısı azaldıkça verideki düzensizliğin artmasıdır. Beklenildiği üzere veri noktası sayısı arttıkça daha tutarlı Bass eğrileri elde ederiz, ancak kalan periyot sayısı azaldıkça verideki düzensizlik tahminin tutarlılığını olumsuz etkiler. Genel eğilimin daha açık görülebilmesi için Şekil 3.6 incelenmelidir.

BDM'nin performans analizi çerçevesinde oluşturulan grafiklerde NLS yöntemi parametre tahmini için kullanılmıştır.

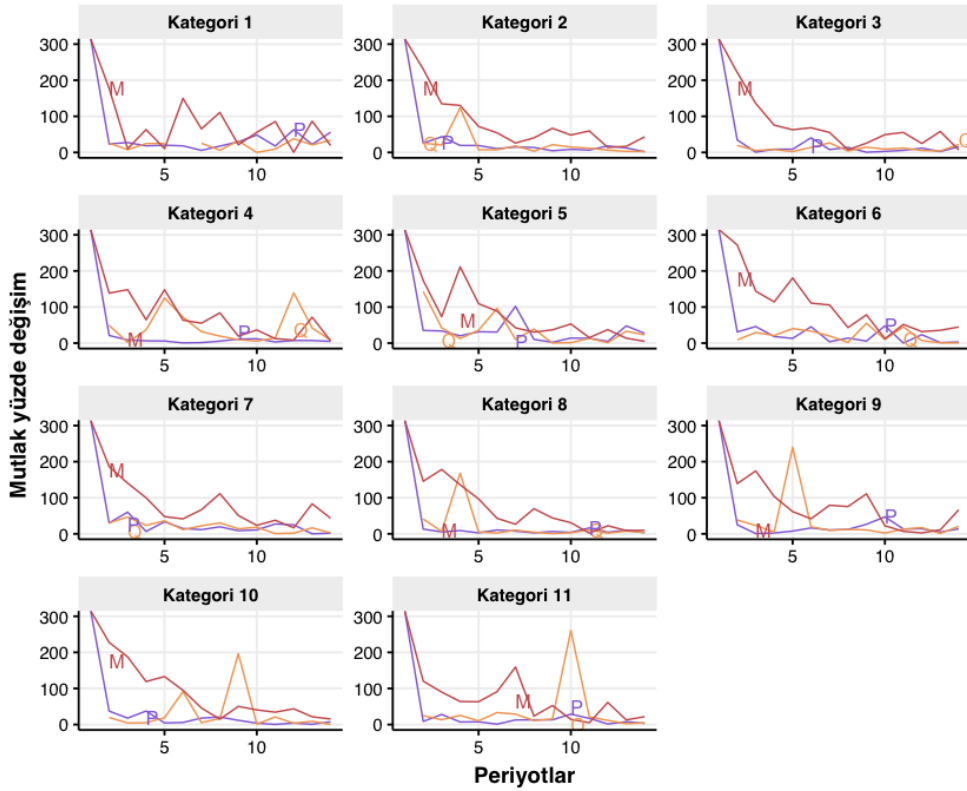


Şekil 3.6: Kısmi veri için periyotlara göre APE değerleri

Şekil 3.6’te modele dahil edilen periyot sayısı, tahminin başarımı ve kalan periyot sayısı arasındaki ilişki daha açık bir şekilde görülmektedir. Genel olarak periyot sayısı arttığında başarımın da ona bağlı olarak arttığı söylenebilir. Her bir ürün için periyotlara göre başarı oranı farklı olduğundan, kutu grafiği ile gösterim uygun görülmüştür. Şekilde de gözlemlendiği üzere başarımın kabul edilebilir düzeye gelmesi için gerekli süre uzundur. Grafikte 14 haftalık veri oluştuğunda dahi medyan APE değerinin %40’ın üzerinde olduğu görülmektedir. Bu durum sadece kısmi veriyle kurulacak BDM nin tahmin başarısının çok iyi olmayacağı sonucuna varmamızı sağlamıştır.

3.5.3 Parametrelerin haftalara göre değişiminin incelenmesi

Parametrelerin zamana göre değişimi hangi periyotlardan sonra doğru parametre tahminlerine yaklaştığımızın gösterilmesi açısından önemlidir. Şekil 3.7 parametrelerin haftalara göre yüzde değişimini göstermektedir. Oluşturulan grafikte; yatay eksen periyotları ifade ederken, dikey eksen mutlak yüzde değişimi göstermektedir. Grafiklerdeki değerler ilgili kategori içindeki tüm ürünlerin mutlak yüzde değişimlerinin ortalamasını ifade eder.




Şekil 3.7: Haftalara göre parametrelerin mutlak yüzde değişimi

Şekil 3.7’de y eksenini, parametrelerin mutlak yüzde değişimlerini gösterirken, x eksenini periyotları temsil eder. Grafik incelendiğinde belli bir sayıda veri noktasına ulaşıldığında parametrelerin daha az değiştiğini söyleyebiliriz. Bu p ve q için daha açık bir şekilde gözlemlenebilirken, m parametresinin daha keskin değişimler gösterdiği söylenebilir. Her bir kategori için oluşturulan grafikler için belli bir periyot sayısına erişildikten sonra bir yakınsama olduğundan bahsedebiliriz.


Cevabının önemli olduğunu düşündüğümüz bir diğer soru da BDM model parametrelerinin bir kategori içinde ne kadar değişkenlik gösterdiğidir. Sınıflandırma işleminin aynı zamanda birbirine benzer parametreleri olan ürünleri aynı sınıfa koyup koymadığını kontrol etmek amacıyla her bir kategori ve parametre için değişim katsayıları hesaplanmıştır. Şekil 3.8, kategori bazında p ve q parametreleri için değişim katsayılarını göstermektedir.

$$\text{Değişim Katsayısı} = \sigma/\mu \times 100 \quad (3.11)$$



Şekil 3.8: P ve Q parametreleri için değişim katsayısı

Şekil 3.8 incelendiğinde, değişim katsayısının bazı kategoriler için çok büyük değerler aldığı görülmektedir. Ancak bazı kategoriler için değişim katsayısı değeri düşüktür, bu da o ürün ailesine ait bir yeni ürün söz konusu olduğunda kategori ortalamasının p ve q değerleri için iyi bir başlangıç tahmini elde edilebileceğini gösterir. Aynı kategorideki ürünlerin potansiyel pazar büyüklüklerinin benzer olup olmadığı bilgisi ise m değeri için oluşturulan ve kategori içerisinde değişim katsayısını gösteren Şekil 3.9'de görülebilir.



Şekil 3.9: M parametresi için değişim katsayısı

Şekil 3.9’da görüldüğü üzere m parametresi için hesaplanan değişim katsayıları yüksek değerler almıştır. Bu, aynı kategoride olan ürünlerin farklı potansiyel pazar büyüklüklerine sahip olabileceğini göstermektedir.

3.6 Sonuçların İrdelenmesi ve Çıkarımlar

Çalışmada bu aşamaya kadar yapılan deneyler sonucunda bazı çıkarımlar yapılmıştır. Öncelikle BDM için farklı parametre tahmini yöntemleri kullanılmış ve bu parametre tahmini yöntemleri birbirleriyle karşılaştırılmıştır. Kesin olarak her bir veri öbeği için ortak en iyi parametre tahmini yöntemi bulunamamasına rağmen, genel olarak NLS yöntemi diğer parametre tahmini yöntemlerine üstünlük sağlamıştır. Bu kapsamda grafikler oluşturulurken NLS yöntemi ile elde edilen değerler kullanılmıştır.

Oluşturulan Bass eğrileri ile sezonun farklı periyotlarında kalan talep tahmin edilmiştir. Her ne kadar tüm veri kullanıldığında BDM kabul edilebilir derecede başarı gösterse de, parçalı veri söz konusu olduğunda sonuçlar yeterince tatmin edici değildir. Parker tarafından 1994 yılında yapılan çalışmada gösterildiği gibi, parametreler yeterince iyi olana kadar geçen süre uzundur. Her ne kadar bu parametreler zaman zaman daha erken periyotlarda nihai değerlerine yakınsasa da bu parametreleri tahmin için kullanmak risklidir [31]. Bu nedenle geçmiş ürünlerin ürün yaşam eğrilerinden ve kümeleme yönteminden faydalanarak geliştirdiğimiz talep tahmini yöntemi bir sonraki kısımda anlatılacaktır.

4. ENTEGRE BASS DİFÜZYON MODELİ VE KÜMELEME ALGORİTMASI TABANLI TAHMİN METODU

4.1 Giriş

Moda sektöründe faaliyet gösteren tedarik zincirleri göz önünde bulundurulduğunda, erken periyotlarda sezon içerisinde kalan talebin ürün bazında tutarlı bir şekilde tahmin edilebilmesi firma açısından yararlı olacaktır. Çünkü genel olarak bu çalışmada ele alınan ürünler uzun teslimat sürelerine sahiptir. Erken periyotlarda kalan talep için başarılı bir tahmin üretim planlama, envanter planlama ve sevkiyat planlama gibi operasyonlarda kullanılabilir. Bu doğrultuda sadece kısmi veri ile oluşturulan Bass eğrilerinin kalan talep hakkında tutarlı tahminler vermemesi farklı bir tahmin modeli geliştirilmesi gerekliliğinin göstergesidir.

Bu kısımda tahmin yönteminin kullandığı kaynaklar ve yöntemler açıklanmıştır. Yöntem bütün satış verilerini birer zaman serisine dönüştürmek ile başlar. Zaman serisine dönüştürülen ürün satış verileri; $(0,1)$ aralığına normalize edilerek miktardan bağımsız, eğilim bazlı bir kümeleme yapılmıştır. Kümeleme sırasında ürünlerin birbirine benzerliğinin matematiksel ifadesi için Chouakria-Douzal ve Nagabhushan tarafından 2007 yılında önerilen yöntemden faydalanılmıştır. Bu yöntem ile ürünlerin arasındaki benzerlik matematiksel olarak ifade edilmiştir. Ayarlanabilir benzemezlik ölçüsü (ADI, *Adaptive dissimilarity measure*) olarak adlandırılan benzemezlik ölçüsü zaman serilerinin davranış bağımlı kümelenmesi söz konusu olduğunda kullanımı uygun olan bir ölçüdür. Daha sonra elde edilen kaynaklar farklı şekilde değerlendirilmiş, metot türevlendirilmiştir. Geliştirilen metot kapsamında yeni ürünün sezonun erken periyotlarındaki yayılımı gözlemlenmiş ve bu gözlemden elde edilen bilgi de tahmin oluşturulurken değerlendirilmiştir. Her bir hafta sonunda yeni ürünün sahip olduğu veri noktası sayısı değişir ve buna bağlı olarak ürünün kısmi verisi itibarıyla en çok benzerlik gösterdiği küme ve/veya ürün değişiklik gösterebilir. Bu değişiklik oluşturulan talep tahmini de değişir. Türevlendirilen metotlar bu kaynakları kullanım şekilleri ve ağırlıkları bakımından birbirinden ayrılır. Türev metotların başarımı birbirleriyle ve kısmi veri kullanılarak oluşturulan BDM ile karşılaştırılmış ve sonuçlar değerlendirilmiştir.

4.2 Kümeleme Algoritmaları

Kümeleme algoritmaları birbirine benzer özellik gösteren veri noktalarının belirlenmesine dayanır. Bu çalışmada k-medoids algoritması kümeleme amacıyla kulla-

nılmıştır. Kümeleme işlemi yapılırken algoritmalar genel olarak küme içi mesafeyi enküçüklemek ve kümeler arası mesafeyi enbüyüklemek üzerine çalışır. Bizim vaka-mızda veri noktaları ürünlerin haftalık satış miktarlarından oluşur. Bir başka kümeleme algoritması olan K-means de çalışma kapsamında değerlendirilmiştir. Ancak K-means korelasyon bazlı mesafe ölçüleri söz konusu olduğunda problemlili olabilmektedir. Bu kapsamda mesafe ölçüleri konusunda daha esnek olan k-medoids algoritması değerlendirilmiştir.

4.2.1 K-medoids algoritması

K-medoids algoritması k-Means algoritmasına benzer olarak çalışır. Ancak K-medoids algoritmasının aykırı verilere hassaslığı daha azdır. Bunun sebebi temsili olarak belirlenen noktanın veri içerisinde bulunması gerekliliğidir. K-means algoritmasında ise belirlenen merkezin veri içerisinde bir noktaya karşılık gelmesi gerekmez. K-medoids ile temsili olarak belirlenen noktanın, temsil ettiği kümenin diğer elemanlarına olan uzaklığının enküçüklenmesi algoritmanın amacını oluşturur[24]. K-Medoids algoritması temel olarak aşağıdaki matematiksel modelin çözümüne dayanır.

K-medoids algoritmasının matematiksel modeli

Karar Değişkenleri

$$y_i = \begin{cases} 1 & , \text{Eğer } i \text{ temsili nesne ise} \\ 0 & , \text{Eğer } i \text{ temsili nesne değil ise} \end{cases} \quad (4.1)$$

$$z_{ij} = \begin{cases} 1 & , \text{Eğer } j \text{ nesnesi } i \text{ kümesine dahil ise} \\ 0 & , \text{Eğer } j \text{ nesnesi } i \text{ kümesine dahil değil ise} \end{cases} \quad (4.2)$$

Matematiksel Model

$$\begin{aligned} \min \quad & \sum_{i=1}^n \sum_{j=1}^n d(i,j) \\ \text{Öyle ki;} \quad & \sum_{i=1}^n z_{ij} = 1 \quad \forall j \in N \\ & \sum_{i=1}^n y_i = k \\ & z_{ij} \leq y_i \quad \forall i, j \in N \\ & z_{ij}, y_i \in \{0, 1\} \end{aligned} \quad (4.3)$$

Yukarıdaki sıfır-bir matematiksel programlama modelinin çözümüyle kümeleme işlemi yapılır. Ancak burada önemli nokta $d(i,j)$ olarak belirtilen benzemezlik

matrisi tanımlanırken kullanılan ölçü birimidir. Ürünlerin verileri bir zaman serisini gösterir. Bizim ilgilendiğimiz ise bu ürünlerin satışı başladığı andan itibaren nasıl bir eğri gösterdiğidir. Kümeleme algoritması ile benzer yayılım eğrisi gösteren ürünlerin aynı kümede toplanması amaçlanmaktadır. Bu doğrultuda zaman serileri arasındaki uzaklık belirlenirken geniş kullanım alanına sahip olan, veri noktaları arasındaki zamana bağlı korelasyonu ve veri noktalarının birbirine olan uzaklığını aynı zamanda değerlendirerek bir benzemezlik ölçüsü veren ayarlanabilir benzemezlik indeksi (ADI) yöntemi kullanılmıştır[14]. Bu yöntemin bileşenleri ve matematiksel ifadesi gelecek bölümde anlatılacaktır.

4.2.2 Benzemezlik ölçüsü

İki zaman serisinin zamana bağlı davranışları kıyaslanırken Chouakria(2003) tarafından önerilen yöntem olan zamansal korelasyon katsayısı (CORT, *temporal correlation coefficient*) kullanılmıştır. Bu yöntem ile iki zaman serisi arasındaki davranış benzerliği matematiksel olarak ifade edilir. Bizim vakamızda ürünün satış eğrisinin davranışı veya ürünün yaşam döngüsü olarak ifade edilebilir.

$$CORT(x, y) = \frac{\sum_{t=1}^T (x_{t+1} - x_t)(y_{t+1} - y_t)}{\sqrt{\sum_{t=1}^T (x_{t+1} - x_t)^2} \sqrt{\sum_{t=1}^T (y_{t+1} - y_t)^2}} \quad (4.4)$$

Eşitlik 4.4, iki zaman serisi arasındaki davranış benzerliğinin matematiksel olarak ifadesidir. Ayarlanabilir olması özelliği mesafe ifadesine $\Phi[u]$ fonksiyonun eklenmesi ile gerçekleştirilir.

$$\Phi[u] = \frac{2}{1 + e^{ku}} \quad (4.5)$$

Bu fonksiyon geleneksel mesafe ölçüm yöntemlerine dayanan $\delta(x, y)$ fonksiyonu ile davranış benzerliğini belirten $CORT$ fonksiyonu arasındaki ağırlıklandırmayı k terimi ile belirler.

$$d(x, y) = \Phi[CORT(x, y)]\delta(x, y) \quad (4.6)$$

Uzaklık değerini veren $d(x, y)$ fonksiyonu içerisindeki $\delta(x, y)$ fonksiyonu iki zaman serisi arasındaki Öklit (Frechet[18]) mesafeleridir. $\delta(x, y)$ aynı zamanda dinamik zaman bükme (DTW, *Dynamic time warping*) algoritmasının sonucu olarak bulunan mesafe olarak da belirlenebilir [36]. Eşitlik 4.5'te görüldüğü üzere $k = 0$ olduğu durumda tüm ağırlık $\delta(x, y)$ fonksiyonundan bulunan mesafe birimine verilecektir. İlgili eşitlik k değerinin tanım aralığı $[0, \infty]$ olmalıdır. Çalışmamızda $k = 2$ olarak belirlenmiştir. δ fonksiyonu ise Euclid mesafesi olarak belirlenmiştir. Eşitlik 4.7'de

öklit mesafesinin hesaplanması gösterilmiştir.

$$d(p, q) = d(q, p) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} \quad (4.7)$$


Bu kapsamda geleneksel ölçü birimi olarak Frechet ve DTW'nin denenmesi ve sonuçların çalışmaya dahil edilmesi çalışmayı daha kompakt bir hale getirebilirdi. Ancak bu iki ölçü biriminin de hesaplanması karmaşıktır ve çalışmaya dahil edilememiştir.

4.3 Veri Üzerinde Kümeleme İşlemi

Elimizdeki ürünlerin 380 tanesi modelin geliştirilmesi ve test edilmesi için kullanılmıştır, bu ürünlerden 323 tanesi kümelemeye tabi tutulmuştur. Kalan 57 tane ürün modelin başarımının testi için ayrılmıştır. Bu oran toplam ürünlerin %85'ine denk gelmektedir. Bu oran elimizde satış eğrisi bulunan ürün miktarının çok fazla olmaması dolayısıyla yüksek tutulmuştur. Ürün sayısı arttırıldığında bu oran düşürülebilir.

K-medoids kümeleme algoritmasının bir diğer avantajı da farklı mesafe fonksiyonları ile çalışabilmesidir. Bizim vakamızda mesafe ölçüsü ADI olarak belirlenmiştir. Bu kapsamda her bir ürünün diğer bir ürüne olan mesafesi bu ölçü birimi kullanılarak bulunmuş ve mesafe matrisi oluşturulmuştur. Ardından K-medoids algoritması ile temsili ürünler belirlenerek, temsili ürünlere benzer ürünler aynı küme içerisinde gruplanmıştır. Bu aşamada her ürün için bulunan Bass eğrileri kümeleme işlemine tabi tutulmuştur. Ürünlerin birbirine olan mesafesinin bulunabilmesi için her ürünün eşit sayıda veri noktasına sahip olması gerekir. Bu sebeple her bir ürün için elde edilen parametre tahminleri ve $t = [1, 2, \dots, 30]$ kullanılarak her ürün için otuz adet veri noktası oluşturulmuş ve bu veri noktaları ile kümeleme işlemi yapılmıştır. Her bir küme için bir merkez ürün belirlenmiş, bu ürünlere benzer davranışa sahip ürünler aynı kümede toplanmıştır.

Şekil 4.1, merkez olarak belirlenen eğrileri göstermektedir. Grafik incelendiğinde merkez olarak belirlenen ürünlerin birbirinden farklı davranışlar sergilediği açıkça gözlemlenebilmektedir.



Şekil 4.1: Temsili ürün eğrileri

K-medoids algoritması k değerini (merkez sayısı) parametre olarak alır. Bu parametrenin değerinin belirlenmesi kümelemenin başarımı için büyük önem arz etmektedir. Bu çalışmada k parametresi belirlenirken silüet genişliği ve küme içi mesafenin karesi ölçüleri baz alınmıştır.

4.3.1 Silüet genişliği

Silüet genişliği hesaplanırken i ürününün bulunduğu küme içerisindeki diğer ürünlere yakınlığı ve diğer kümelere olan uzaklığı göz önünde bulundurulur.

$$a(i) = \frac{1}{|A|-1} \sum_{j \in A, i \neq j} d(i, j) \quad (4.8)$$

$$d(i, C) = \frac{1}{|C|} \sum_{j \in C} d(i, j) \quad (4.9)$$

$$b(i) = \min_{C \neq A} d(i, C) \quad (4.10)$$


$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (4.11)$$

Eşitlik 4.8'deki A , i ürününün atandığı kümeyi gösterir. Bu eşitlik yardımıyla i ürününün bulunduğu küme içerisindeki diğer ürünlere olan ortalama uzaklığı bulunur. Eşitlik 4.9'deki C ifadesi i ürünün diğer kümelerdeki ürünlere olan ortalama uzaklığı hesaplanır, $b(i)$ i ürününe en yakın kümenin i ürününe olan ortalama uzaklığı olarak ifade edilir. Silüet değeri olan $s(i)$ eşitlik 4.10'daki gibi hesaplanır. $s(i)$

değeri $[-1, 1]$ aralığında değer alabilir.

$$s(i) = \begin{cases} s(i) \approx 1 \Rightarrow & i \text{ ürünü doğru kümededir.} \\ s(i) \approx 0 \Rightarrow & i \text{ ürünü iki kümenin kesişimine yakın bir noktadır.} \\ s(i) \approx -1 \Rightarrow & i \text{ ürünü kötü kümelendi.} \end{cases}$$

Bu kapsamda k parametresine karar vermek için Şekil 4.2 deki grafik oluşturulmuştur. Bu doğrultuda uygun k parametresi dört olarak belirlenmiştir.



Şekil 4.2: Farklı k değerleri için silüet genişliği değerleri

Silüet genişliğinin $k = 4$ değerinden sonra bir azalma gösterdiğini ve bir daha o seviyelere çıkamadığı Şekil 4.2’te gözlemlenmektedir. Sonuç olarak k parametresi dört olarak belirlenmiş ve kümeleme işlemi yapılmıştır. Kümeleme işlemi için ürünlerin bütün veri üzerinden bulunan parametreleri kullanılmıştır ve bu parametreler kullanılarak oluşturulan her bir Bass eğrisi 30 periyotluk veri içerecek şekilde ölçeklendirilmiştir. Şekil 4.4’te kümelenen ürün eğrileri gösterilmektedir.

4.3.2 Küme içi toplam mesafenin karesi


Kümeleme algoritmasında k parametresinin karar verilmesinde kullanılan bir diğer metot ise küme içi toplam mesafenin karesine dayanır. Küme içi toplam mesafe ise eşitlik 4.12’deki gibi hesaplanır.

$$\text{Küme içi toplam mesafenin karesi} = \sum_{k=1}^K \sum_{i \in S_k} \sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2 \quad (4.12)$$

Eşitlik 4.12'deki K küme sayısını, S_k o küme içerisindeki elemanları ve p kümenin içerisindeki elemanların değişken sayısını ifade eder. \bar{x}_{kj} ise temsili küme elemanının k kümesindeki temsili elemanın j değişkenini ifade eder. Bizim verimizde mesafe matrisi ADI kullanılarak oluşturulduğu için eşitlik 4.13'teki gibi güncellenmiştir.

$$\sum_{k=1}^K \sum_{i \in S_k} (\Phi[\text{CORT}(x_i, y_k)] \delta(x_i, y_k))^2 \quad (4.13)$$

Eşitlik 4.13'teki y terimi k kümesinin temsili nesnesidir. Farklı k değerleriyle gerçekleştirilen kümeleme işlemi sonucunda elde edilen küme içi toplam mesafenin karesi grafiği Şekil 4.3'te görülmektedir.

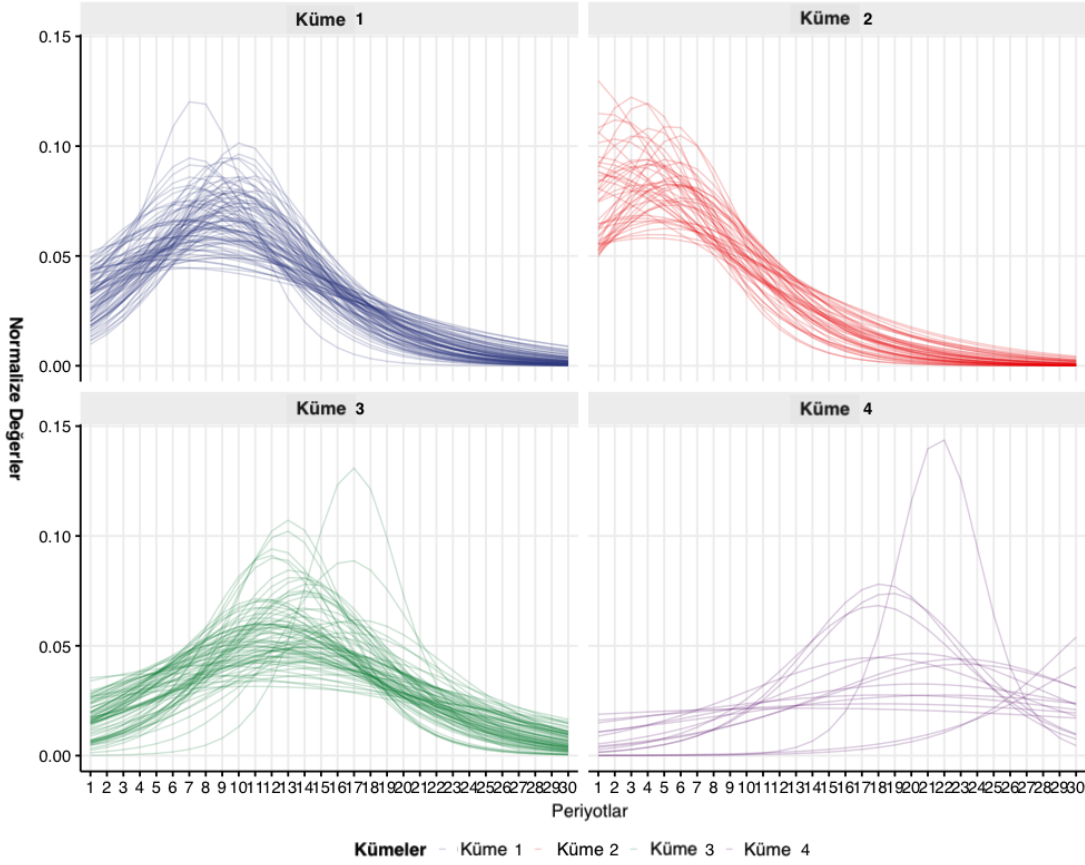


Şekil 4.3: Küme içi toplam mesafenin karesi

Şekil 4.3 incelendiğinde, $k = 4$ şeklinde belirlenmesi küme içi mesafenin enküçülenmesi için en makul çözümdür. Öngörüldüğü üzere k değeri veri satırı sayısına eşit olduğu durumda küme içi mesafe sifıra eşit olur. Ancak bu aşırı uyma problemine yol açar. Bu sebeple küme içi mesafenin karesi ile k değerleri kullanılarak oluşturulan grafiğin diz verdiği noktadaki k değeri uygun k değeri olarak belirlenir.

4.3.3 Verilerin Kümeleneşmesi

K-medoids algoritmasında k belirlendikten sonra kümeleme işlemi yapılmıştır. Şekil 4.4'te kümeleme işleminin sonucu görülmektedir.



Şekil 4.4: Kümelenen ürünler

Şekil 4.4'te görüldüğü üzere benzer yayılım desenleri gösteren ürünler mümkün olduğunca aynı kümede bulunmaktadır. Ancak bu kümeleme işleminde kullanılan benzeme ölçüsü yukarıda açıklandığı üzere sadece ürünün satış davranışını göz önünde bulundurmaz. Ayrıca geleneksel ölçüler olan (Euclid, Fréchet mesafesi) gibi mesafe ölçülerini de göz önünde bulundurmaz. Bu sebeple az da olsa davranış olarak aykırı ürünlerin aynı kümede bulunduğunu görebiliriz. Bu, geleneksel ölçüler bakımından birbirine yakın ürünler olduklarını göstermektedir ki geleneksel ölçü olarak öklit mesafesi kullanılmıştır.

4.4 Tahminlerin Oluşturulması


Tahmin oluşturulurken ürünün kısmi verisi girdi olarak alınmıştır. Bu veri kullanılarak ürünün hangi ürüne veya kümeye yakın olduğu belirlenmiştir. En yakın küme ve/veya ürünün özellikleri ve ürünün kısmi verisi kullanılarak yeni ürün için tahminde kullanılacak bir Bass eğrisi oluşturulmuştur. Geçmiş ürünlerin satış deseninden edinilen bilgiden faydalanabilmek için geçmiş ürünlerin nihai parametre değerleri ile yeni ürünün kısmi verisinden elde edilen parametre değerleri α parametresi yardımıyla ağırlıklandırılarak birleştirilmiştir.

4.4.1 α parametresi yardımıyla ağırlıklandırma işlemi

Ürünün en yakın olduğu küme için bir Bass eğrisi oluşturulmuştur. Ürünün kısmi verisi erken periyotlarda iyi parametre tahminleri oluşturamamaktadır. Ancak ürünün kısmi verisi belli sayıda veri noktası sonrasında o ürün için nihai parametre değerlerine yakınsamaktadır. Çalışmamızda ürünün kısmi verisi ile ürüne en yakın kümenin bilgisi kullanılarak, küme parametreleri ile ürünün kısmi verisi ile bulunan parametreler ağırlıklandırılmıştır. Bu ağırlıklandırma işlemi yapılırken kümelenen ürünlerden elde edilen bilgiler kullanılmıştır. Bütün verisi gözlemlenmiş ürünler kullanılarak farklı n değerleriyle ($n \in 4, 5, \dots, 12$) n haftalık kısmi veriler oluşturulmuş ve bu kısmi veriden elde edilen parametre değerleri ve küme için bulunan parametre değerleri arasında (α) değerine bağlı olarak ağırlık değerler aşağıdaki gibi hesaplanmıştır;

$$\min_{\alpha_{1,2,3} \in [0,1]} \sum_{i \in r} \left[S^i - f_{bass}^i(\alpha_1 * p_c + (1 - \alpha_1) * p_p, \alpha_2 * q_c + (1 - \alpha_2) * q_p, \alpha_3 * m_c + (1 - \alpha_3) * m_p) \right]^2 \quad (4.14)$$


Yukarıdaki eşitlikte S^i , i periyodundaki gerçekleşen satış miktarını göstermektedir. p_p, q_p ve m_p kısmi veri ile elde edilen parametre tahminlerini ifade ederken, p_c, q_c ve m_c ürünün ait olduğu küme için oluşturulan Bass eğrisinin parametreleridir. f_{bass}^i ise oluşturulan Bass eğrisinin i periyodundaki değerini göstermektedir. Terimlerde indis olarak kullanılan i değeri r aralığında değer alır. Örnek olarak 17 haftalık ürün yaşam eğrisi bulunan bir üründe 5 haftalık veri kullanılarak parametre tahmini yapılmışsa, $r = [6, 17]$ olur. Oluşturulan optimizasyon probleminde kalan periyotlar (r) göz önünde bulundurulduğunda, kalan veri noktalarını en iyi temsil eden Bass eğrisini bulmak amaçlanmaktadır. Bu kapsamda $\alpha_{1,2,3}$ karar değişkenleri olarak belirlenmiş ve her ürün ve n için, en iyi $\alpha_{1,2,3}$ değerleri bulunmuştur. Eşitlik 4.14'de gösterilen enküçükleme işlemi Levenberg-Marquardt algoritması ile yapılmıştır. Daha sonra bu α değerlerinin ortalaması alınarak her bir küme için ve n için $\alpha_{1,2,3}^*$ değerleri bulunmuştur. Şekil 4.5'de küme 1 içindeki veri noktaları ve bu noktalara oturtulan Bass eğrisi görülmektedir.



Şekil 4.5: Küme 1 içindeki ürünler için oturtulan Bass eğrileri

α^* değerleri her küme ve periyot için farklılık göstermektedir. Bunun sebebi kısmi verideki veri noktası sayısı arttıkça kısmi veri ile yapılan parametre tahminleri kalan talebi yansıtmakta daha başarılı hale gelmesidir. Şekil 4.6, α^* değerlerinin periyotlara ve kümelere göre değişimini göstermektedir. Beklendiği üzere hesaba katılan periyot sayısı az olduğunda, α^* değerleri yüksek değerler almaktadır (küme parametrelerinin ağırlığının artması). Periyot sayısı arttığında ise α değerleri buna bağlı olarak azalmaktadır.

Genel olarak p ve q parametreleri arasındaki ağırlıklandırmayı sağlayan α_1 ve α_2 değerleri erken periyotlarda 1 ve ya 1'e yakın değerler almaktadırlar. Öte yandan m parametresinin ağırlıklandırılması için kullanılan α_3 değeri ise diğer α değerlerine göre daha küçük değerlerden başlar ve daha durağan bir karakter gösterir. Kümeler bazında oluşturulan grafik incelendiğinde küme 1 ve küme 4, periyotlara göre α değerleri en fazla değişiklik gösteren kümeler olarak gözlemlenmektedir.



Şekil 4.6: Periyot ve kümelere göre α^* değerleri

4.5 Önerilen Tahmin Yöntemleri

Tahminler oluşturulurken 5 farklı yöntem geliştirilmiştir. Bu yöntemler tahmin oluşturulurken faydalandıkları kaynaklar bakımından birbirinden ayrılır. Geliştirilen yaklaşım bu şekilde türevlendirilmiş ve türev modellerin başarımları periyotlar bazında test ürünleri üzerinde analiz edilmiştir. Yöntemlerde k kullanılan kısmi verideki hafta sayısını gösterir. Çizelge 4.1'de yöntemlerin kullandıkları kaynaklar belirtilmiştir.

Çizelge 4.1: Yöntemlerin kullandıkları kaynaklar

Yöntem	α	Kısmi	Küme	En yakın ürün
Yöntem 1	α^*	✓	✓	×
Yöntem 2	α_{cp}	✓	✓	✓
Yöntem 3	α_{cp}^*	✓	×	✓
Yöntem 4 _{rm}	×	×	×	✓
Yöntem 5	×	×	×	✓

4.5.1 Yöntem 1

Adım 1. Ürünün kısmi k haftalık verisi ile parametre tahmini yap. $k \in [5, 12]$

Adım 2. Ürünün kısmi k haftalık verisi itibarıyla kümelere olan ortalama benzemezlik miktarını bul.

Adım 3. Ürüne en yakın kümedeki veri noktalarını en iyi temsil eden Bass eğrisinin ve bu eğrinin parametre değerlerini (p_c, q_c, m_c) bul.

Adım 4. En yakın kümenin k periyot için olan α^* değerlerini belirle.

Adım 5. Kısmi veri ile elde edilen parametre tahminleri ile küme parametrelerini α^* değerleri yardımıyla ağırlıklandır.

Adım 6. Bulunan parametre değerlerini kullanan BDM ile kalan satış miktarı için tahmin oluştur.

Yöntem 1 ile elde edilen Bass eğrileri aşağıdaki eşitlikler kullanılarak elde edilmiştir. p_c, q_c ve m_c kümenin elemanlarını en iyi temsil eden Bass eğrisinin parametreleridir.

$$f_{bass}(\alpha_1^* \times p_c + (1 - \alpha_1^*) \times p_p, \alpha_2^* \times q_c + (1 - \alpha_2^*) \times q_p, \alpha_3^* \times m_c + (1 - \alpha_3^*) \times m_p, t) \quad (4.15)$$

Eşitlik 4.15'te t Bass eğrisi oluşturulacak zaman aralığını ifade eder. Örnek olarak eğer 5 haftalık gerçekleşen satış göz önünde bulundurularak bir tahmin oluşturulacak ise $t \in 6, 7, 8 \dots T$ olur, ifadedeki T terimi sezonun sonunu ifade eder. Sonuç olarak t aralığı için yapılan tahminin toplamı 5 hafta itibariyle kalan talep için yapılan tahmini oluşturur.

$$f_{bass}(p, q, m, t) = m \times f(p, q, t) \quad (4.16)$$

$$f(p, q, t) = \frac{(p+q)^2}{p} \frac{e^{-(p+q)t}}{(1 + \frac{q}{p}e^{-(p+q)t})^2} \quad (4.17)$$

4.5.2 Yöntem 2

Adım 1. Ürünün kısmi k haftalık kısmi verisi ile parametre tahmini yap. $k \in [5, 12]$

Adım 2. Ürüne kısmi k haftalık veri itibariyle en çok benzeyen ürünü ve kümeyi bul.

Adım 3. Küme içindeki ürünleri en iyi temsil eden Bass eğrisinin parametrelerini (p_c, q_c, m_c) bul.

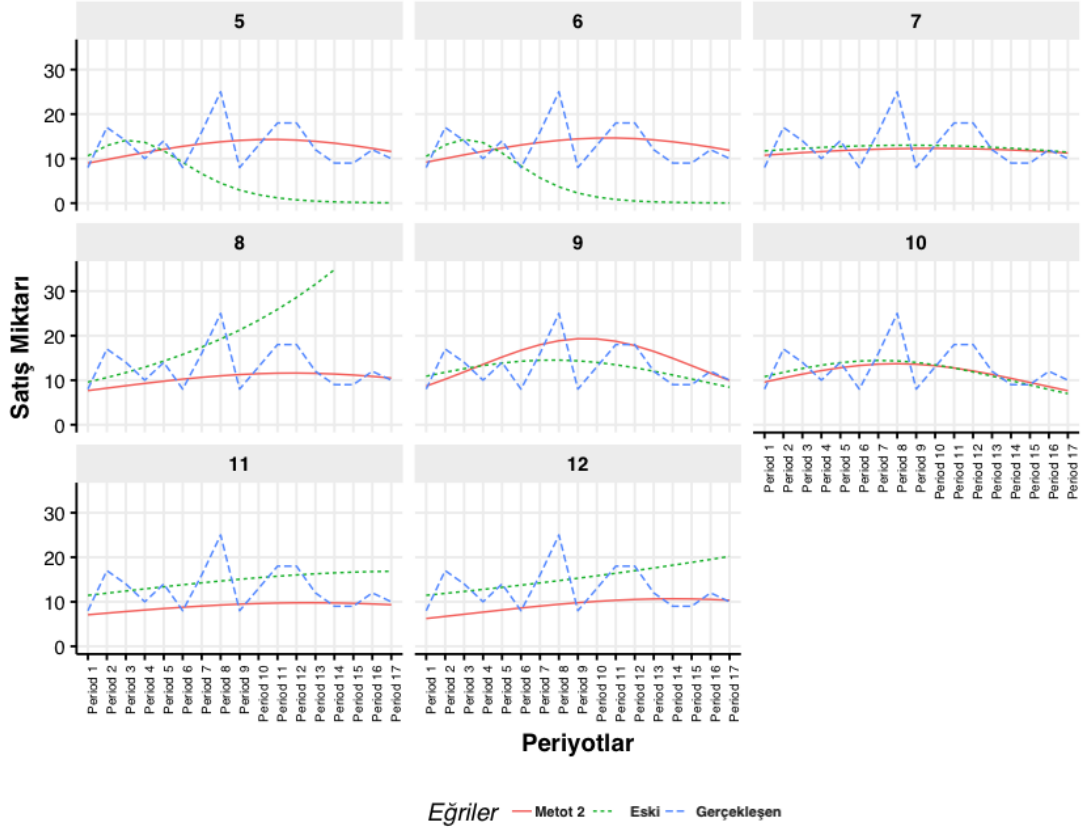
Adım 4. En yakın ürünün $\alpha_{1,2,3}$ değerlerini belirle.

Adım 5. Kısmi veri ile elde edilen parametre tahminleri ve küme parametrelerini α değerleri yardımıyla ağırlıklandır.

Adım 6. Kalan satış miktarı için tahmin oluştur.

$$f_{bass}(\alpha_1 \times p_c + (1 - \alpha_1) \times p_p, \alpha_2 \times q_c + (1 - \alpha_2) \times q_p, \alpha_3 \times m_c + (1 - \alpha_3) \times m_p, t) \quad (4.18)$$

Yöntem 2 ile elde edilen Bass eğrisi yöntem 1'den farklı olarak kümeler için bulunan α^* değerleri yerine, ağırlıklandırmayı ürüne mevcut verisi itibariyle en yakın ürünün $\alpha_{1,2,3}$ değerlerini kullanarak yapar. Bu metot ile elde edilen parametre değerleriyle oluşturulan eğriler ve kısmi veri ile elde edilen parametre değerleriyle oluşturulan eğrilerin kıyaslaması Şekil 4.7'de görselleştirilmiştir.



Şekil 4.7: Yöntem 2 için periyotlara göre oturtulan eğriler

Oluşturulan grafiklerde bilinen periyot sayısı [5,12] aralığında değer almaktadır. Gözlemlenen periyot sayısındaki her bir artışta metot adımları tekrar gerçekleştirir. Ele alınan durumda ürün kısmi veri itibariyle farklı periyotlarda farklı küme ve ürünlere en yakın hale gelmiş olabilir. Bu sebeple periyotlar geçtikçe farklı eğriler elde edilmiştir. Genel olarak gözlemlenen periyot sayısı arttığında tahminin iyileştiği söylenebilir.

4.5.3 Yöntem 3

1. **Adım 1.** Ürünün kısmi k haftalık verisi ile ($k < n$ adet veri ile) parametre tahminini yap. $k \in [5, 12]$
2. **Adım 2.** Ürüne kısmi veri itibariyle en çok benzeyen ürünü ve kümeyi bul.
3. **Adım 3.** En çok benzeyen ürünün tüm verisini kullanarak p , q ve m parametrelerini tahmin et.
4. **Adım 4.** Yeni ürüne en yakın kümenin ilgili periyotlar için bulunan α^* değerlerini belirle.
5. **Adım 5.** En yakın ürünün parametre bilgisi ve yeni ürünün kısmi parametre değerlerini α^* değerleri yardımıyla ağırlıklandır.
6. **Adım 6.** Kalan satış miktarı için tahmin oluştur.

$$f_{bass}(\alpha_1^* \times p_{cp} + (1 - \alpha_1^*) \times p_p, \alpha_2^* \times q_{cp} + (1 - \alpha_2^*) \times q_p, \alpha_3^* \times m_{cp} + (1 - \alpha_3^*) \times m_p, t) \quad (4.19)$$

Yöntem 3'te Bass eğrisi oluşturulurken en yakın ürünün nihai parametre değerleri ile en yakın ürünün ait olduğu küme için bulunan $\alpha_{1,2,3}^*$ değerleri kullanılmıştır.

4.5.4 Yöntem 4

1. **Adım 1.** Yeni ürünün kısmi k haftalık verisi ($k < n$) itibariyle en yakın ürünü belirle.
2. **Adım 2.** Yeni ürünün tüm veri noktaları kullanılarak, m parametresini belirle.
Pratikte yeni ürünün tüm veri noktalarına sahip olunamayacaktır. Bu durum m için çok iyi bir tahmin olduğunda modelin nasıl sonuç vereceğini gözlemlemek amacıyla incelenmiştir.
3. **Adım 3.** Yeni ürüne en yakın ürün ve bu ürünün nihai parametre değerlerini belirle.
4. **Adım 4.** En yakın ürünün p ve q parametreleri ve yeni ürünün m parametresini kullanılarak tahmin oluştur.

$$f_{bass}(p_{cp}, q_{cp}, m_n, t) \quad (4.20)$$

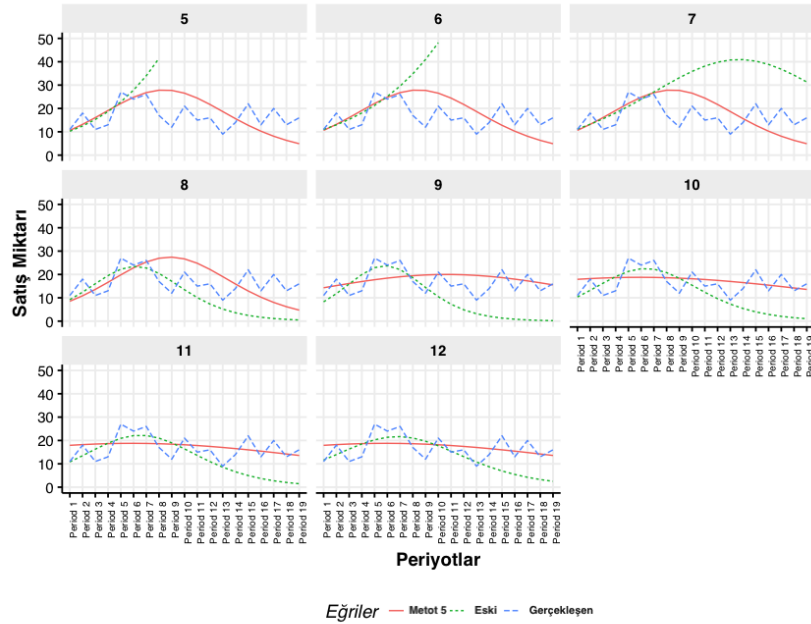
Yöntem 4, m parametresinin iyi bir şekilde tahmin edilebildiği varsayımı ile oluşturulmuştur. Yeni ürün için yapılan m_n tahmini ile, yeni ürüne kısmi verisi itibariyle en yakın olan ürünün p_{cp} ve q_{cp} parametreleri kullanılarak Bass eğrisi oluşturulur.

4.5.5 Yöntem 5

1. **Adım 1.** Yeni ürünün kısmi verisi itibariyle en yakın olduğu ürünü belirle.
2. **Adım 2.** Yeni ürüne en yakın ürünün tüm veri noktalarını kullanarak p, q ve m değerlerini belirle.
3. **Adım 3.** En yakın ürünün nihai parametre değerlerini kullanarak kalan satış miktarı için tahmin oluştur.

$$f_{bass}(p_{cp}, q_{cp}, m_{cp}, t) \quad (4.21)$$

Yöntem 5'te ise yeni ürüne kısmi veri itibariyle en yakın ürünün parametre tahminleri kullanılarak Bass eğrisi oluşturulur. Bu parametre değerleri (p_{cp}, q_{cp}, m_{cp}) ürüne kısmi veri itibariyle en yakın ürünün bütün verisi kullanılarak elde edilir. Şekil 4.8'de örnek olarak alınan bir ürün için oluşturulan eğrilerin bilinen periyot sayısına göre değişimleri gösterilmektedir. Yöntem 5 olarak ele alınan durumda kullanılan metoda göre grafik incelendiğinde, bilinen periyot sayısı 5, 6, 7 ve 8 iken en yakın ürün aynıdır. Daha sonra gözlemlenen verilere dayalı yapılan analizde ürüne en çok benzeyen ürün değişmiştir. Buna bağlı olarak oluşturulan eğri de farklılık gösterir. Diğer durumlar için oluşturulan eğrilerin zamana göre değişimi grafikler ekte sunulmuştur.



Şekil 4.8: Yöntem 5 için periyotlara göre oturtulan eğriler

4.6 Sonular ve Deęerlendirme

Gerekleřtirilen analizler Intel[®] Core i5 3.1 GHz iřlemci ve 8 GB RAM donanımlı, MacOS Catalina[®] iřletim sistemli bir bilgisayar ile gerekleřtirilmiřtir. alıřmanın tamamı Rstudio[®] yardımıyla kodlanmıřtır. Kullanılan paketlerden bařlıcaları ve kullanım amaları izelge 4.2’de gsterilmektedir.

izelge 4.2: Kullanılan Paketler

Paket	Ama
base [®]	Genel R programlama
dplyr [®]	Veri maniplasyonu
ggplot2 [®]	Veri grselleřtirme
minpack.lm [®]	Lineer olmayan optimizasyon
lubridate [®]	Zaman serisi elleleme
TSclust [®]	Ayarlanabilir benzemezlik ls
reshape2 [®]	Veri maniplasyonu
stringR [®]	Metin dzenleme


Sonular ve deęerlendirme kısmında; geliřtirilen metot ve trevlerinin bařarımı MAPE zerinden deęerlendirilecektir. ok sayıda rn ve beř farklı yntem olduęundan grafiklerle ile grselleřtirmenin anlaşılrlık aısından daha faydalı olacaęı dřnlmřtir. Toplam 380 adet rn alıřmaya konu olmuřtur ve bu rnlerin rastgele %85’i inřa ařaması iin gemiř veri olarak ayrılmıřtır. Geri kalan %15’i ise metotların test edilmesi amacıyla yeni rn olarak kullanılmıřtır. Farklı test kmeleri zerinde yapılan analizlerde bařarımın farklı test kmelerinde benzer olduęu gzlemlenmiřtir. Test kmesi iin belirlenen 57 rnn tahmin yntemlerinin analizi iin yeterli olacaęı dřnlmř ve bu rnler zerinden sonular incelenmiř ve raporlanmıřtır.

Sonular iki farklı durumda incelenmiřtir. Bunun sebebi bazı rnlerin BDM’nin aksiyomlarına uymamasıdır. Bukapsamda iki farklı deęerlendirme yapılmıřtır. Bunlardan birincisi, elimizde verisi olan btn rnlerin modele dahil edilmesiyle oluřturulmuřtur. İkincisi ise uyumsuzluęu belirlenen rnlerin veri kmesinden ıkarılmasıyla elde edilmiřtir. İlk olarak birinci durum ele alınacak olup daha sonra ikinci durum ile ilgili sonular ele alınacaktır.

4.7 Btn rnler Kullanılarak Bulunan Sonular

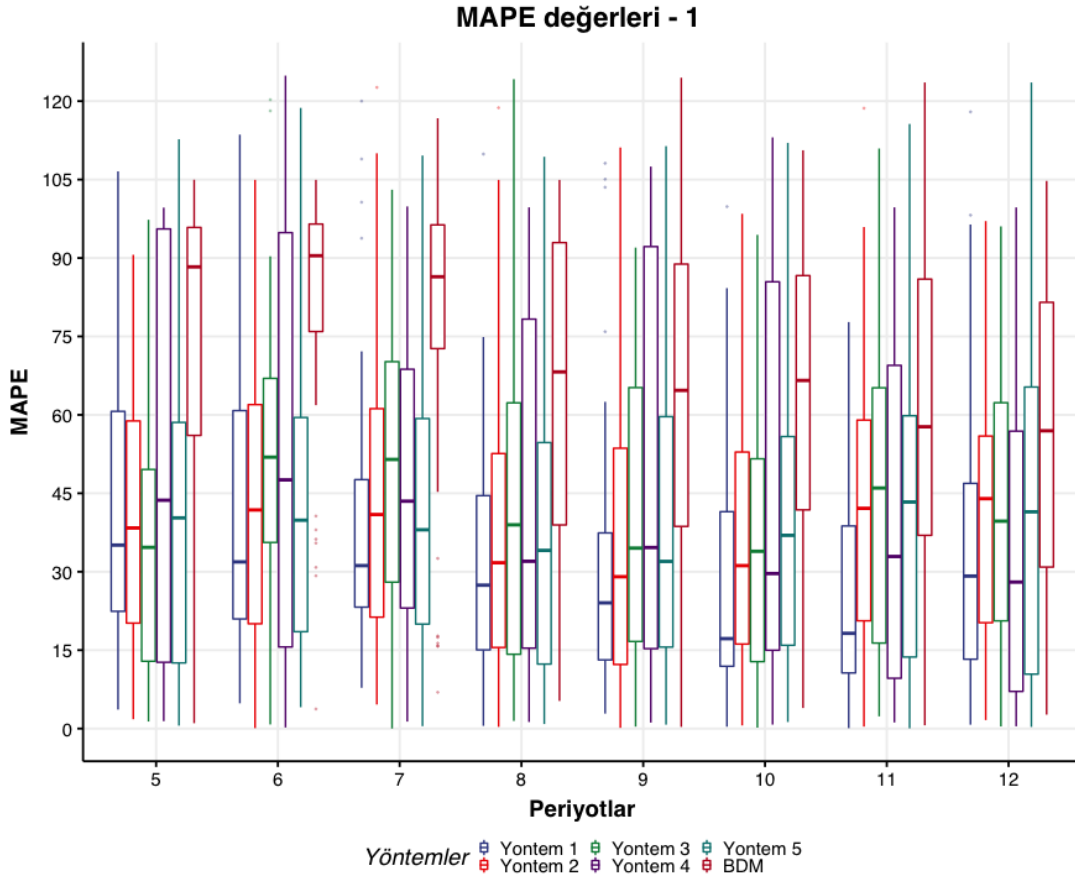
Btn rnler modele dahil edildięinde MAPE deęerleri Őekil 4.9’deki gibi elde edilmiřtir. Her bir renkteki eęri farklı bir yntemin tm test kmesi ierisindeki rnler iin oluřturulan tahminlerin MAPE deęerlerinin periyotlara gre ortalamasını gstermektedir. Grafikten yntem 4 ve 5’in ilk bakıřta yntem 1’e karřı stnlk gsterdięi grlebilir. Genel olarak elde edilen MAPE deęerlerinde farklı

şiddetlerde de olsa sekizinci haftada bir düşüş gözlemlenmesi ilginç bir sonuçtur. Yöntem 5 en iyi yöntem olarak belirmektedir.



Şekil 4.9: Yöntemler ve ortalama MAPE

Yöntemlerin geliştirilmesinin gerekliliği BDM'nin az sayıda veri noktası ile tutarlı parametre tahminleri yapamaması temeline dayanır. Bu kapsamda amacımıza ne ölçüde ulaşabildiğimizin analizi için Şekil 4.10 oluşturulmuştur. Grafikte geliştirilen metotlarla elde edilen MAPE değerlerinin periyotlara göre değerleri ve kısmi veri ile yapılan parametre tahminleri ile oluşturulan BDM ile yapılan tahminlerin MAPE değerleri kutu grafiği yardımıyla görselleştirilmiştir. Şekil incelendiğinde önerilen yöntemlerin kısmi veri ile oluşturulan BDM'den üstün bir tahmin performansına sahip oldukları söylenebilir.

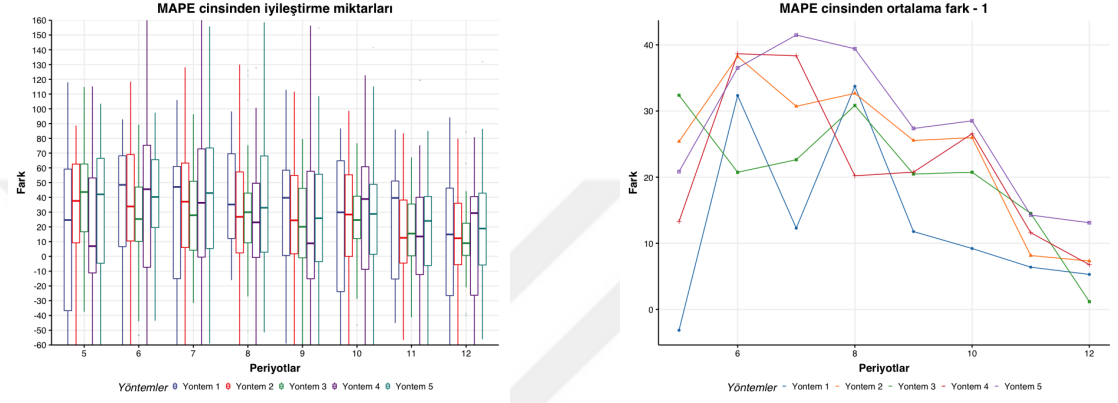


Şekil 4.10: BDM ve metotların karşılaştırılması

Önerilen yöntemlerin, sadece kısmi veri kullanılması durumuna göre tahmin performansına sağladığı iyileşmenin gösterilmesi için BDM'nin kısmi veri ile sergilediği tahmin performansı ile karşılaştırma yapılmıştır. Bu karşılaştırmanın sonucu Şekil 4.11a'da gösterilmiştir. Grafikte farklı kısmi veri senaryoları için önerilen yöntemlerin sadece kısmi veri kullanılması durumuna göre MAPE anlamında getirdiği iyileşmeler gösterilmektedir. Oluşturulan kutu grafiğinde de görüldüğü üzere medyan değerleri pozitif değerler almaktadır. Farklar, BDM ile metotların MAPE değerlerinin farklarından elde edilmiştir. Örnek olarak BDM ile elde edilen değer %80 ise ve metot ile elde edilen değer %60 ise fark değeri 20 olarak hesaplanmıştır. Genel olarak, Yöntem 5'in iyileştirme miktarının diğer metotlara göre daha fazla olduğu gözlemlenmektedir. Ancak stabilite göz önünde bulundurulduğunda Yöntem 3 daha stabil bir karaktere sahiptir.

Her bir yöntem için ortalamadaki değişim miktarı da önemli bir indikatördür. Bu kapsamda ortalama değişim miktarlarının gösterilmesi açısından Şekil 4.11b oluşturulmuştur. Farklar ile periyot sayısı arasında ters orantıdan bahsedilebilir. Bunu sebebi ise BDM'nin periyot sayısı arttıkça daha iyi tahminler verebilmesidir. Yön-

temlerin ortalama fark değerlerinin önce artan sonra ise azalan bir karaktere sahip olduğu söylenebilir. Özellikle yöntem 1’de ele alınan yaklaşım az veri ile başarısız sonuçlar vermektedir. Bunun sebebi bazı ürünlerde kısmi veri ile kötü parametre tahminlerinin yapılması ve ağırlıklandırma değerlerinin bu uygun olmayan parametre tahminini kullanmaya zorlamasıdır. İnşa aşamasındaki ürün sayısı arttırılırsa ilk periyotlarda küme parametrelerine verilen ağırlığın artması öngörülmektedir. Bu da yöntem 1 özelinde ilk periyotlardaki başarımın arttırılması adına bir çözüm önerisi olabilir.

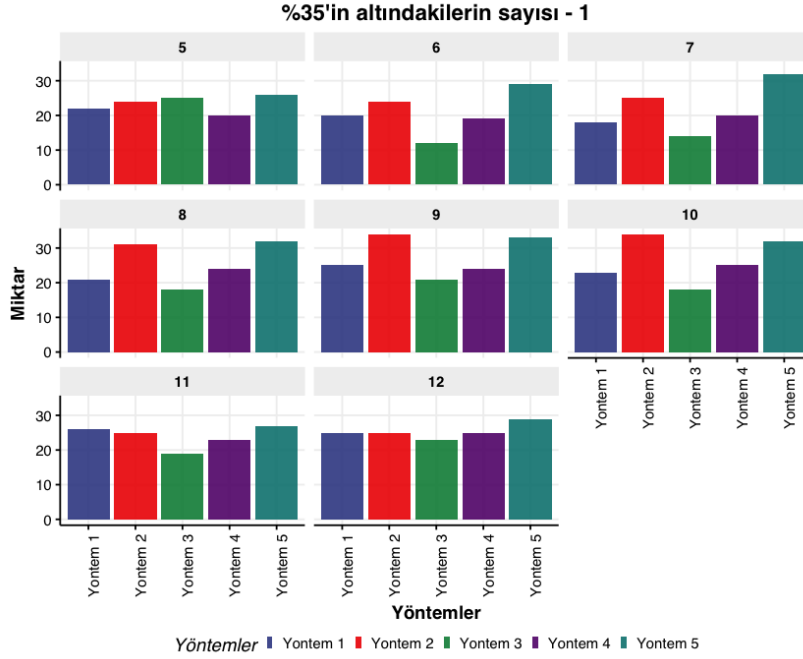


(a) Farkların kutu grafiği

(b) Ortalama fark miktarları

Şekil 4.11: İyileştirme miktarları

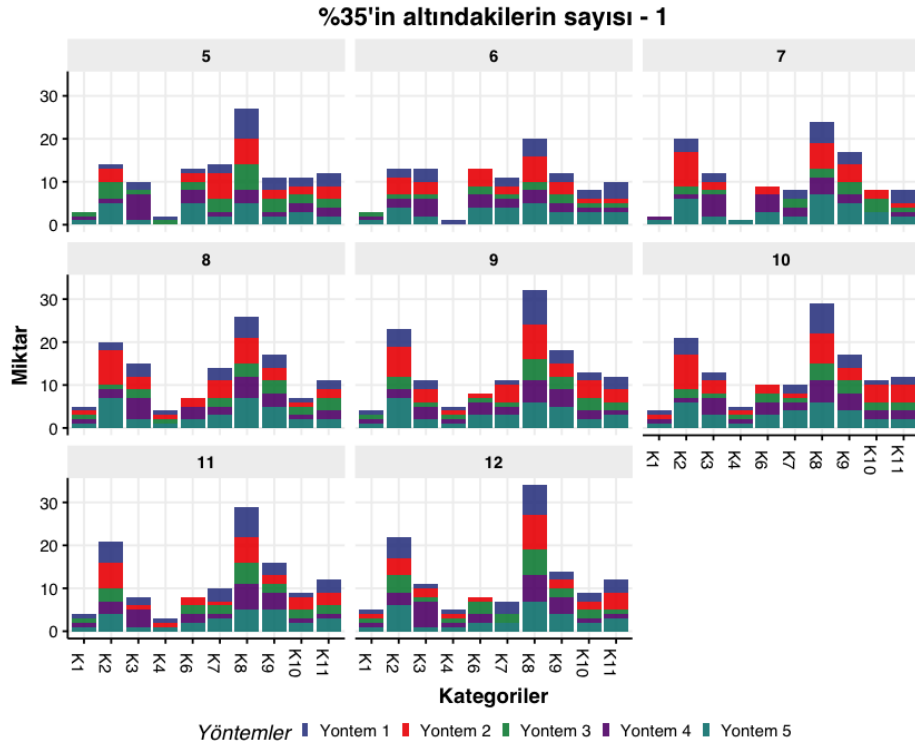
Az sayıda veri ile tahmin yeni bir alan olarak nitelendirilebilir. Az sayıda veri noktası ile moda ürünlerinin satış tahmini ise literatürde eksikliği olan bir konudur. Bu sebeple ne ölçüde bir başarım değerinin kabul edilebilir olduğu literatürde bulunmamaktadır. Ancak firma çalışanları ile yapılan görüşmeler sonucunda ürün bazında kalan talebe dair %35 oranında bir hatanın kabul edilebilir olduğu kanısına varılmıştır. Bu doğrultuda test ürünlerimiz (57) içerisinde kaç ürünün bu hata oranının altında olduğunun gösterimi için Şekil 4.12 oluşturulmuştur. Yöntem 5’in diğer yöntemlerden daha üstün olduğu görülebilir. Yöntem 2’nin de iyi performans verdiği söylenebilir. Altı çizilmesi gereken bir nokta Yöntem 3’ün test ürünlerinin hemen hemen yarısından fazlasında hedeflenen %35’ten daha düşük MAPE değerleri üretmesi ve ortalama performans itibarıyla da oldukça tatmin edici olmasıdır.



Şekil 4.12: %35'in altındaki ürün sayısı

Ürünler firma tarafından oluşturulan kategorizasyon işlemi dahilinde de incelenmiştir. Bu kapsamda %35'in altındaki ürün sayısının kategorilere göre dağılımı da görselleştirilmiştir. Şekil 4.13 bu amaçla oluşturulmuştur. Şekilde yatay eksen kategorileri ifade ederken, dikey eksen ise her bir kategoride koşulu sağlayan ürün sayısını ifade eder. Her bir grafik farklı bilinen periyot sayısı ile oluşturulmuştur. Grafiklerin üstündeki sayılar (5,6,7...12) bilinen periyot sayısını ifade eder. Grafikteki renkler ise koşulu sağlayan ürün sayısının yöntemlere dağılımını belirtmek amacıyla kullanılmıştır.

Ancak test ürünleri rastgele seçildiğinden her kategoride eşit sayıda ürün bulunmamaktadır. Kategori 8'in diğer kategorilere üstünlüğü açık bir şekilde görünmektedir. Kategori 1 ve kategori 4 ise başarısız kategoriler olarak göze çarpmaktadır. Bu amaçlar oluşturulan bir başka görsel de ek olarak sunulmuştur. Daha önce de bahsedildiği üzere kategoriler üzerinden daha kapsamlı bir analiz için kategori başına düşen ürün açısından daha dengeli bir veri kümesi hazırlanması gerekir. Her bir kategoride bulunan ürün miktarı farklı olması, sonuçların genelleştirilebilmesini zorlaştırır.



Şekil 4.13: %35'in altında hataya sahip ürünlerin kategorilere ve yöntemlere göre dağılımı

4.8 Uyumsuz Ürünlerin Belirlenmesi ve Çıkarılması

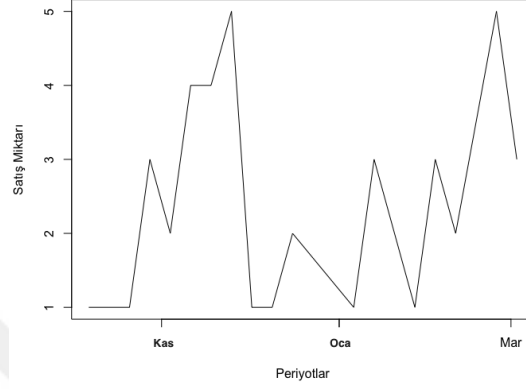
Yapılan analizler sonucunda bazı ürünlerin kabul edilebilir olmaktan çok uzakta tahmin hatalarına sahip oldukları görülmüştür. Bu doğrultuda bu ürünler belirlenmiş ve bu ürünlerin sergiledikleri satış deseni incelenmiştir. Bu ürünlerin ortak özellikleri üçüncü veya dördüncü seri ürünler olmalarıdır. Özet olarak bu ürünler piyasa için yeni ürün değildirler, önceden piyasaya çıkmış ve yaşam döngüsünün belli bir evresine gelmiş ürünlerdir. Ancak farklı bir ürün kodu ile veriye dahil edildiğinden model kapsamında yeni ürün olarak değerlendirilmiştir. Bu farkındalık firma ile sonuçların değerlendirilmesi amacıyla bu ürünlerin ürün kodlarının paylaşılması sonucunda sağlanmıştır.

Modelin kötü performans gösterdiği bir başka ürün tipi de küçük parça ürünlerdir. Bunlara örnek olarak atkı, şal veya çorap gibi ürünler verilebilir.

Bir başka ürün tipi de moda sektöründe *basic* ürünler olarak nitelendirilen ürünlerdir. Bu ürünler de modadan bağımsız bir şekilde belli bir satış desenine sahiplerdir. Bu nedenle bu tip ürünlerde de geliştirilen model erken periyotlarda yüksek hata değerleri verebilmektedir.

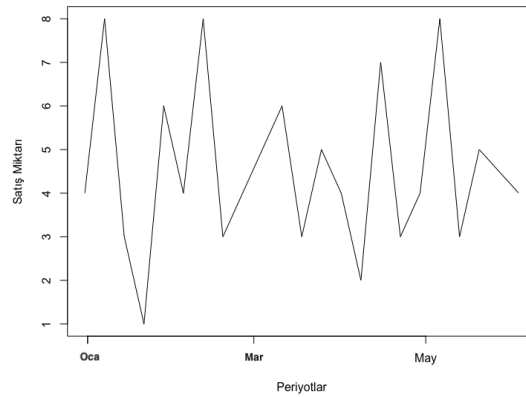
Aynı modelin üçüncü serisinin sergilediği bir satış deseni Şekil4.14'de görülmek-

tedir. Kış sezonu için üretilen bir ürünün satış eğrisinin kasım ayında başlaması beklenmez. Ürünün kesme noktası belirlenirken ilgili ürün koduna ait satışın %90'ı alındığından, ürünün sezon sonu indirimleri sebebiyle mart ayında satış miktarının arttığı görülmektedir.




Şekil 4.14: Üçüncü kez piyasaya sürülen tasarımın satış deseni

Küçük parçaların sergilediği satış deseninin gözlemlenmesi açısından Şekil 4.15 oluşturulmuştur. Şekilde de görüldüğü üzere ürün yaşam eğrisi normalden farklı seyretmektedir. Giriş, büyüme, olgunluk veya düşüş evrelerinden bahsetmek mümkün değildir. Bunun sebebi küçük parçalarda tekrarlı alımların mümkünlüğü olabilir. Tekrarlı alımların olmamasının gerekliliği BDM'nin başarımı için önemli bir etkidir.



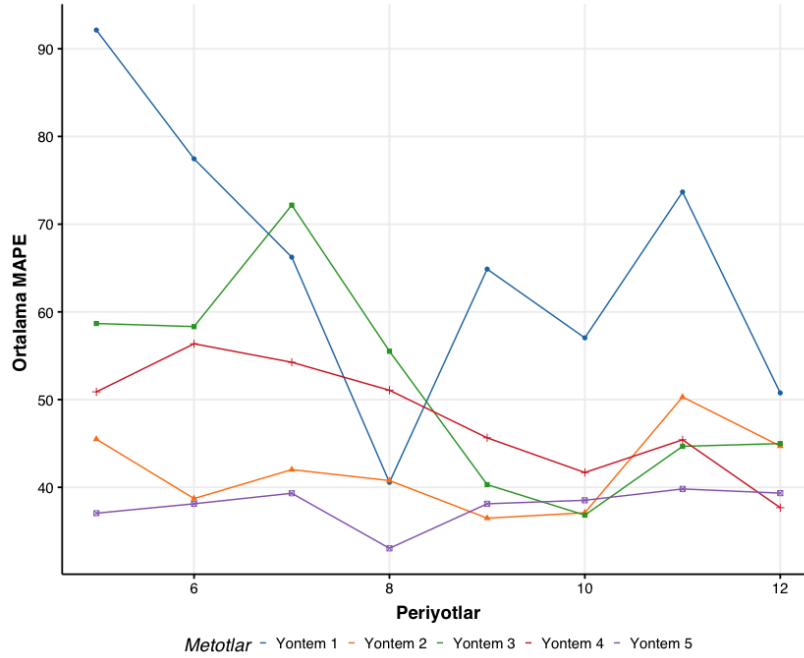
Şekil 4.15: Küçük parça ürünlerin örnek satış deseni

Bir başka iyi tahmin performansına erişemediğimiz ürünler ise *basic* ürünlerdir. Bu ürünlerin sabit bir müşteri kitlesi bulunmaktadır ve genellikle satışlar sezonsal olmamaktadır. Bu ürünlerin satış deseni Şekil4.16'da gösterilmiştir.



Şekil 4.16: Basit ürünlere ait örnek satış grafiği


Bahsedilen ürünler test ürünleri arasından çıkarıldıktan sonra modelin başarımı üzerinden yapılan analizler kalan kısımda anlatılacaktır. İlk olarak metotların ortalama MAPE değerleri Şekil 4.17’de gösterilmiştir. Şekilde de görüldüğü üzere bütün yöntemler için ortalama hatada bir azalma gözlenmektedir. Çıkarım olarak kötü performansa sebep olan ürünlerin ortalamayı farklı şiddetlerde de olsa bütün yöntemleri etkiledikleri yapılabilir.



Şekil 4.17: Uyumsuz ürünler çıkarıldıktan sonra ortalama MAPE değerleri

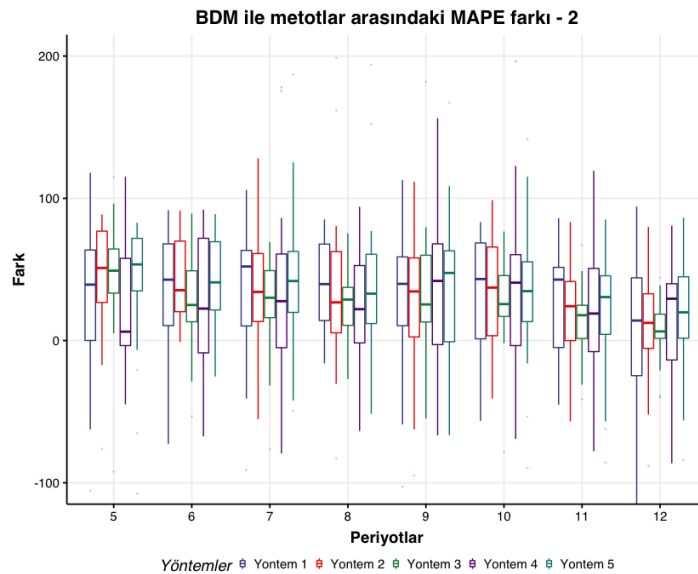
Modelin başarımını gösteren bir başka indikatör de medyan değerleridir. Bunun sebebi ortalamalar üzerinden yapılan analizlerde aykırı verilerin ortalamayı çok yükseltmesidir. Bu sebeple medyanlar üzerinden Şekil 4.18 oluşturulmuştur. Şekil

4.18 incelendiğinde aykırı verilerden ortalaması en çok etkilenen metot Yöntem 1 olarak görülmektedir. Genel olarak önerilen yöntemlerle elde edilen medyan değerlerinin kısmi veriyle oluşturulan BDM'den daha düşük olduğu görülür.



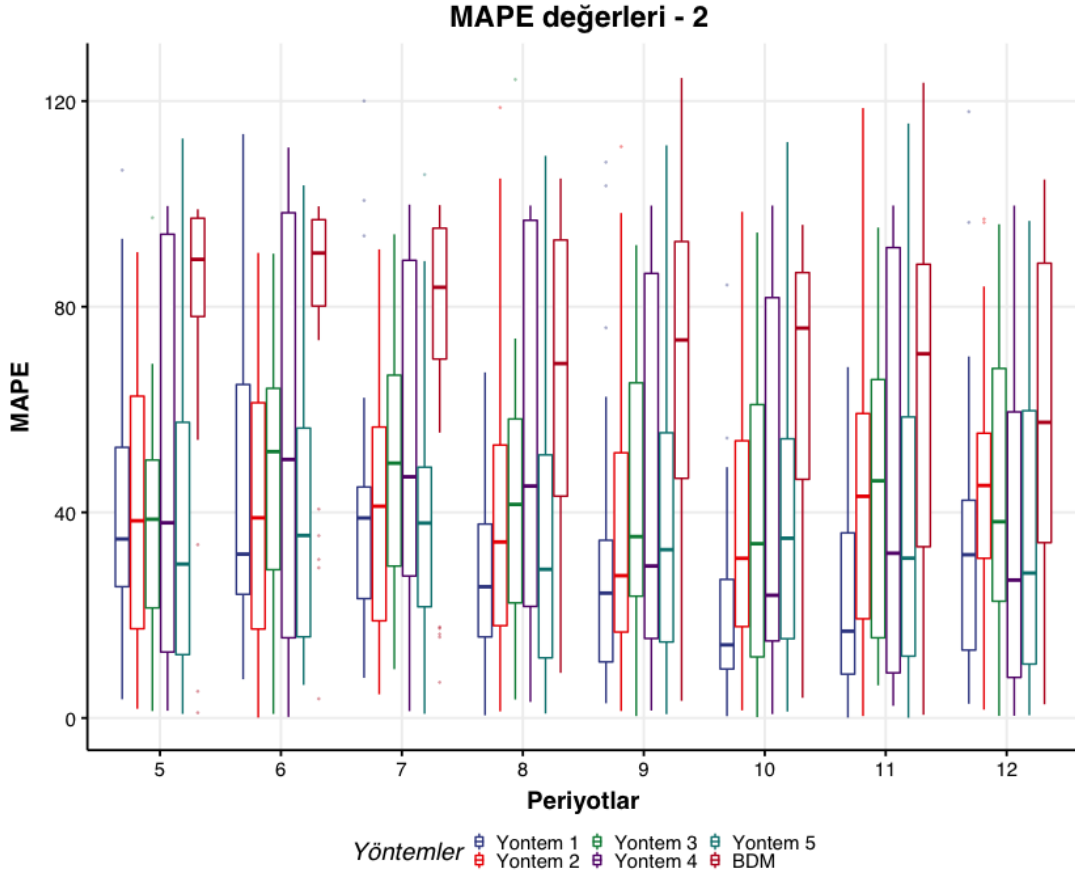
Şekil 4.18: Uyumsuz ürünler çıkarıldıktan sonra medyan MAPE değerleri

Bir önceki bölümde yapılan analizler, uyumsuz ürünler çıkarıldıktan sonra da yapılmıştır. Bunun sebebi uyumsuz ürünlerin etkileri test kümesinden çıkarıldıktan sonra modelin başarımı ile daha sağlıklı çıkarımlar yapılabileceği düşüncesidir. Bu kapsamda kısmi veri ile oluşturulan BDM ile önerilen metotlar arasındaki MAPE farkı Şekil 4.19'de gösterilmiştir.



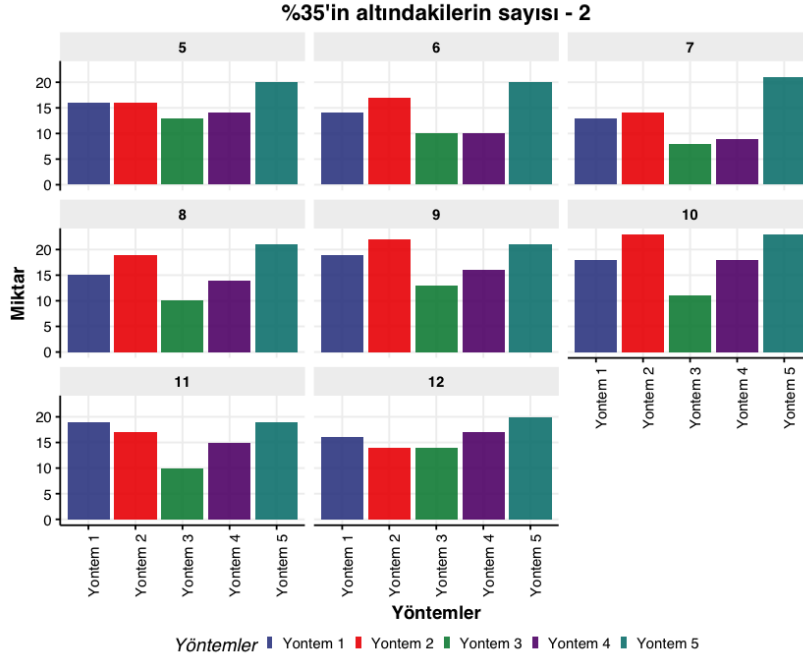
Şekil 4.19: Uyumsuz ürünler hariç farkların kutu grafiği

Uyumsuz ürünlerde kısmi veri ile oluşturulan BDM'nin de daha kötü sonuçlar vermesi beklenir. Şekil 4.20, metotlar ile BDM'yi MAPE üzerinden karşılaştırabilmek amacıyla oluşturulmuştur. Beklenildiği üzere hata oranlarındaki düşüş iki grafikte de gözlemlenebilmektedir. Ancak uyumsuz ürünler kutu grafiklerine genel olarak aykırı noktalar olarak tanımlandığı için kutu grafiklerindeki etkileri Şekil 4.20'ten açık bir şekilde gözlemlenememektedir.



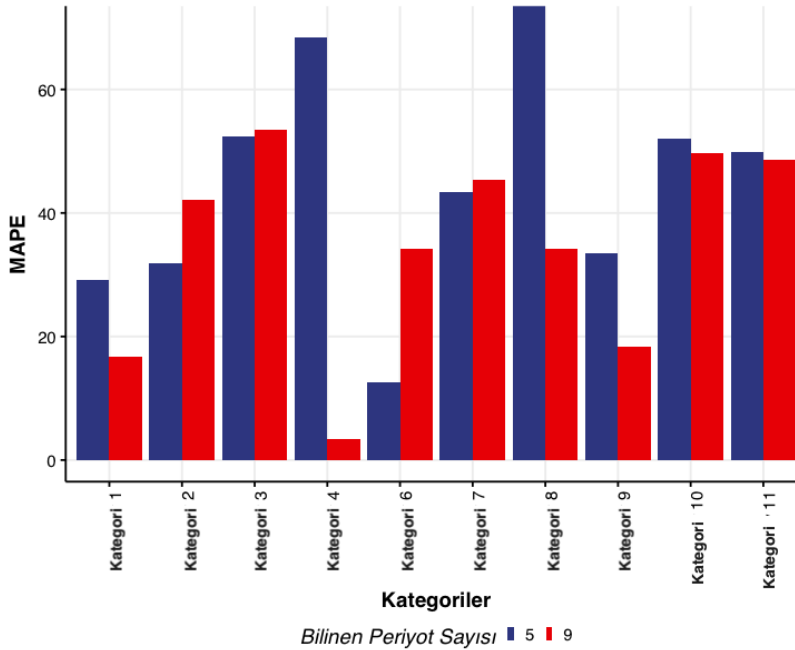
Şekil 4.20: Uyumsuz ürünler hariç BDM ve metotların MAPE karşılaştırması

Uyumsuz ürünlerin çıkarıldığı test kümesindeki ürünlerin (35) %35'in altında hata ile tahmin edilenlerin sayısı Şekil 4.21'te gösterilmiştir. Yöntem 1'in uyumsuz ürünlerden en çok etkilenen grup olduğu çıkarımı yapılabilir. Yöntem 2 ve yöntem 5 ise genelde başarıyı yüksek metotlar olarak göze çarpar.



Şekil 4.21: Uyumsuz ürünler çıkarıldıktan sonra %35'in altındaki ürünlerin sayısı

Ürünlerin kategorileri ile başarımların arasındaki ilişkinin gözlemlenebilmesi için Şekil 4.22 oluşturulmuştur. Genel olarak periyot sayısı arttığında MAPE değerlerinde bir düşüş gözlenmektedir. Ancak test ürünleri rastgele seçildiğinden dolayı her kategorideki ürün sayısı aynı değildir. Şekil 4.22 oluşturulurken yöntem 5 olarak isimlendirilen yaklaşım kullanılmıştır.



Şekil 4.22: Kategorilere göre bilinen periyot sayısı ile MAPE ilişkisi

Bilinen periyot sayısı arttığında sezonun kalanı için yapılan tahminlerin başarımı genel olarak artmaktadır. Ancak bazı kategorilerdeki ürün sayısının azlığı Şekil 4.22'ye bakılarak kategoriler hakkında kesin bir genelleme yapılmasının önüne geçer.

Çizelge 4.3: Test ürünlerinin kategorilere göre dağılımı

Kategoriler	Ürün Sayısı
Kategori 1	1
Kategori 2	4
Kategori 3	4
Kategori 4	1
Kategori 6	4
Kategori 7	4
Kategori 8	8
Kategori 9	4
Kategori 10	2
Kategori 11	5
Toplam	37

Uyumsuz ürünler çıkarıldıktan sonra ürünlerin kategorilere göre dağılımı çizelge 4.3'de gösterilmiştir. Test ürünleri rastgele seçildiğinden dolayı ürünler kategorilere düzensiz bir şekilde dağılmışlardır. Bu sebeple kategoriler arasında bir sıralama yapmak zordur.



5. TARTIŞMA VE GELECEK ÇALIŞMALAR

Problem tanımı, erken periyotlarda kısmi veri ile BDM oluşturulduğunda elde edilen parametre tahminlerinin tutarsız olması temeline dayanmaktaydı. Bu probleme çözüm önerisi olarak veri analizi, kümeleme ve BDM tabanlı bir metot geliştirilmiştir. Geliştirilen metot türevlendirilmiş ve metotlar ile elde edilen başarımlar görselleştirilmiştir. Grafikler üzerinden analizler yapılmıştır. Önerilen metotların kısmi veri ile oluşturulan BDM'den ürünün sezon içerisindeki kalan talebinin tahmininde daha başarılı olduğu gösterilmiştir. Sonuçlar üzerinden firmanın kategorizasyonu kullanılarak yapılan analizlerde, metotların büyük parça ürünlerde (manto, kap, parka v.s) daha iyi bir performans sergilediği gözlemlenmiştir.

Model oluşturulurken BDM için gerek şart olan çevre ve ürün koşulları başarımlar için önemli bir etkidir. Modelin hem inşaa hem de test aşamasında seçilen modellerin basit ürünlerden ziyade moda ürünler olması modelin başarımlar üzerinde etkilidir. Ayrıca inşaa aşamasındaki ürünler yeni tasarımlardan oluşmalı ve ürünün satış verisi ürünün pazardaki ilk gününden sezonun sonuna kadar olan satışlardan oluşmalıdır. Difüzyon modelleri yeni ürünlerin pazardaki yayılımını incelemek üzere oluşturulduğundan, pazarın aşına olduğu ürünler modelin karakteristiğine ters gelebilmektedir.

Yeni ve büyük parça ürünlerin fiyatları sezon içerisinde sert kırılımlar göstermediğinden BDM seçilmiştir. Ancak sezon içerisinde fiyatı önemli derecede değişen ürünler için bir metot oluşturulmak istenirse, daha esnek bir model olan GBDM kullanılabilir. Ancak bu durumda da her ürünün satış eğrisinin fiyattaki değişikliklere gösterdiği tepki farklı olacağından, ürünlerin fiyata olan hassasiyetleri de bir başka analiz konusu olarak ortaya çıkacaktır.

Oluşturulan metotlar üzerinden yapılan analizde yöntem 2 ve yöntem 5 olarak adlandırılan metotların başarımlarının daha yüksek olduğu gözlemlenmiştir. Yöntem 2'de kullanılan metot en yakın ürünün bulunması ve en yakın ürünün ait olduğu kümenin p_c , q_c ve m_c değerlerinin belirlenmesiyle başlar. Daha sonra en yakın ürün için belirlenen ağırlıklandırma (α) değerleri kullanılarak tahmin oluşturulur. Yöntem 5'te ise direkt olarak yeni ürüne en yakın olan ürünün parametre değerleri kullanılır. Bu doğrultuda en yakın ürünün yeni ürünlerin tahmini konusunda önemli bir bilgi kaynağı olduğu söylenebilir.

Bu çalışmada, moda türü ürünlerde ilk defa BDM nin detaylı bir performans analizi

yapılmıştır. Ayrıca yine ilk defa BDM ve veri kümele tabanlı tahmin yaklaşımı geliştirilmiş ve önerilen yöntemin başarısı gösterilmiştir. Önerilen yöntemler pratikte kullanılabilir ve etki yaratabilecek kalitede yöntemlerdir. Bu anlamda literatüre önemli katkılar yapılmıştır.

5.1 Gelecek çalışmalar

Bu çalışma Türkiye'nin çeşitli illerinde yaklaşık 150 mağazası bulunan bir firmadan alınan veriler ile gerçekleştirilmiştir. Çalışmada bir veri toplama yöntemi geliştirilmediğinden, firmada halihazırda bulunan veriler kullanılmıştır. Ürün satış desenleri bölgeden bölgeye farklılık gösterebilir. Her bölgedeki müşterilerin yeni ürünlere reaksiyonu farklı olabilir. Bu sebeple ürün yaşam eğrileri de farklı bölgelerde farklı desenler gösterebilir. Bu doğrultuda alıcıların alışveriş alışkanlıklarına göz önünde bulunduran bir metod geliştirilebilir ve tahmin yapılırken bölgenin özellikleri de dışsal bir faktör olarak ele alınabilir.

Bir başka çalışma konusu da diğer yayılım modellerinin (Gompertz, Sharif-Kabir (1976)) de uygunluk analizinin yapılması ve BDM ile karşılaştırılması olabilir. Daha uygun bir yayılım eğrisinin bulunması durumunda, model o yayılım eğrisi temel alınarak yeniden geliştirilebilir [38].

Çalışmada ürün kodları verinin oluşturulmasında kullanılmıştır. Bir ürün kodu tarafından temsil edilen ürün model olarak aynı olsa da farklı renklerde olabilir. Üretim kararları göz önünde bulundurulduğunda veri noktaları oluşturulurken renk kodları da veriye dahil edilip, sadece ürün kodu üzerinden değil aynı zamanda renk kodları üzerinden de bir gruplama yapılırsa daha kapsamlı bir analiz yapılabilir.

Firmanın sahip olduğu yurtdışı mağazalarında gerçekleşen satışlar bu çalışma dahilinde incelenmemiştir. Farklı ülkelerdeki satışlar dahil edildiğinde ülkelerin sosyoekonomik özellikleri de dikkate alınmalıdır.

BDM üzerine oluşmuş sağlam bir literatür bulunmaktadır. BDM üzerinden elde edilen eğrilerin, rekabetçi sayısının çok olduğu ortamlardaki karakteristiği farklıdır. Gatignon ve Robertson (1986) yaptıkları çalışmada rekabetçi ortam etkisini açıklayıcı bir değişken olarak modellerine dahil etmişlerdir.

BDM'nin esnekliğini arttırmak üzere yapılan çalışmalardan biri de birden fazla jenerasyona sahip ürünlerin yaşam eğrisini tanımlayabilmek üzeredir. Bu kapsamda yapılan çalışmalar, bu çalışmada genel olarak düşük başarımlı gösteren basit ürünlere uyarlanabilir. Çünkü birden fazla jenerasyona sahip ürünler gibi basit ürünlerin de belli bir alıcı kitlesi bulunmaktadır. Bu ürünler her sezon küçük değişikliklerle piyasaya tekrar sürülür. Bu açıdan her bir yeni basit ürün yeni bir jenerasyon olarak tanımlanabilir [25].

Çalışmada önemli unsurlardan bir tanesi de benzemezlik ölçüsüdür, çünkü bu benzemezlik ölçüsü hem kümeleme işlemine temel oluşturur hem de metotlar içerisinde kullanılır. Benzemezlik ölçüsü üzerinde yapılacak değişiklikler metotlarda ciddi değişikliklere yol açabilir. Zaman serilerinin davranışları üzerinde kullanılan farklı benzemezlik ölçüleri ile model modifiye edilebilir. Bu çalışmada kullanılan metot olan ADI da kendi içerisinde parametreler içermektedir. Modellerin başarımının bu parametrelerle olan ilişkisi de ayrı bir inceleme konusu olabilir.





KAYNAKLAR

- [1] **Au, K.-F., Choi, T.-M., & Yu, Y.** Fashion retail forecasting by evolutionary neural networks. *International Journal of Production Economics*, 114, 2 (2008), 615–630.
- [2] **Bass, F.M.** A New Product Growth for Model Consumer Durables. *Management Science*, 15, 5 (1969), 215–227.
- [3] **Bass, F.M.** Comments on “A New Product Growth for Model Consumer Durables The Bass Model. *Management Science*, 50, 12 (2004), 1833–1840. DOI: 10.1287/mnsc.1040.0300.
- [4] **Bass, F.M.** The relationship between diffusion rates, experience curves, and demand elasticities for consumer durable technological innovations. *The Journal of Business*, 53, 3 (1980), 51–67.
- [5] **Bass, F.M. & Bultez, A.V.** A note on optimal strategic pricing of technological innovations. *Marketing Science*, 1, 4 (1982).
- [6] **Bass, F.M., Jain, D., & Krishnan, T.** *New product diffusion models*. London Kluwer Academic Publishers, 2000.
- [7] **Bass, F.M., Krishnan, T.V., & Jain, D.C.** Why the Bass Model Fits without Decision Variables. *Marketing Science*, 13, 3 (1994), 203–223.
- [8] **Bemmar, Albert C. & Lee, Janghyuk.** The Impact of Heterogeneity and Ill-Conditioning on Diffusion Model Parameter Estimates. *Marketing Science*, 21, 2 (2002), 209–220. ISSN: 07322399, 1526548X. URL: <http://www.jstor.org/stable/1558068>.
- [9] **Björk, A.** *Numerical methods for least squares problems*. 1st ed. Philadelphia: Society for Industrial and Applied Mathematics, 1996.
- [10] **Choi, T.-M., C-L., Hui, Liu, N., Ng, S-F., & Yu, Y.** Fast fashion sales forecasting with limited data and time. *Decision Support Systems*, 59 (2014), 84–92. ISSN: 0167-9236. DOI: 10.1016/j.dss.2013.10.008.
- [11] **Choi, T.-M. & Sethi, S.** Innovative quick response programs: A review. *International Journal of Production Economics*, 127 (Feb. 2010), 1–12. DOI: 10.1016/j.ijpe.2010.05.010.

- [12] **Chouakria-Douzal, A.** “Compression Technique Preserving Correlations of a Multivariate Temporal SeqFuence”. *Advances in Intelligent Data Analysis V*. Springer Berlin Heidelberg, 2003, 566–577.
- [13] **Croston, J.D.** Forecasting and stock control intermittent demands. *Operational Research Quarterly*, 23, 3 (1972), 289–303.
- [14] **Douzal, A. & Nagabhushan, P.** Adaptive dissimilarity index for measuring time series proximity. *Advances in Data Analysis and Classification*, 1 (2007), 5–21. DOI: 10.1007/s11634-006-0004-6.
- [15] **Du, W., Leung, S.Y.S., & Kwong, C.K.** A Multiobjective Optimization-Based Neural Network Model for Short-Term Replenishment Forecasting in Fashion Industry. *Neurocomputing*, 151 (2015), 342–353.
- [16] **Durbin, J. & Watson, G.S.** Testing for Serial Correlation in Least Squares Regression. II. *Biometrika*, 38, 1/2 (1951), 159–177. ISSN: 00063444. URL: <http://www.jstor.org/stable/2332325>.
- [17] **Fourt, L.A. & Woodlock, J.W.** Early Prediction of Market Success for New Grocery Products. *Journal of Marketing*, 25, 2 (1960), 31–38. DOI: 10.1177/002224296002500206.
- [18] **Fréchet, M.M.** Sur quelques points du calcul fonctionnel. *Rendiconti del Circolo Matematico di Palermo (1884-1940)*, 22, 1 (Dec. 1906), 1–72. ISSN: 0009-725X. DOI: 10.1007/BF03018603.
- [19] **Fumi, A., Pepe, A., Scarabotti, L., & Schiraldi, M.** Fourier Analysis for Demand Forecasting in a Fashion Company. *International Journal of Engineering Business Management*, 5 (2013). DOI: 10.5772/56839.
- [20] **Hassan, A.R. & Montoya-Blandón, S.** Forecasting from others’ experience: Bayesian estimation of the generalized Bass model. *International Journal of Forecasting* (2019). ISSN: 0169-2070. DOI: <https://doi.org/10.1016/j.ijforecast.2019.05.016>.
- [21] **Hong, J., Koo, H., & Kim, T.** Easy reliable method mid-term demand forecasting based on the Bass Model: A hybrid approach of NLS and OLS. *European Journal of Operational Research*, 248 (2016), 681–690.
- [22] **Horsky, D. & Simon, L.S.** Advertising and the Diffusion of New Products. *Marketing Science*, 2, 1 (1983), 1–17. ISSN: 1526-548X. DOI: 10.1287/mksc.2.1.1.
- [23] **Hu, K., Acimovic, J., Erize, F., Thomas, D.J., & Van Mieghem, J.A.** Forecasting Product Life Cycle Curves: Practical Approach and Empirical Analysis. *Manufacturing & Service Operations Management*, Forthcoming (2017). DOI: <http://dx.doi.org/10.2139/ssrn.2867528>.

- [24] **Jin, X. & Han, J.** K-Medoids Clustering. *Encyclopedia of Machine Learning*. Ed. by C. Sammut & G.I. Webb. Boston, MA: Springer US, 2010, 564–565. ISBN: 978-0-387-30164-8. DOI: 10.1007/978-0-387-30164-8_426.
- [25] **Jun, D.B. & Park, Y.S.** A Choice-Based Diffusion Model for Multiple Generations of Products. *Technological Forecasting and Social Change*, 61, 1 (1999), 45–58.
- [26] **Lee, J., Boatwright, P., & Kamakura, W.A.** A Bayesian Model for Prelaunch Sales Forecasting of Recorded Music. *Management Science*, 49, 2 (2003), 179–196. DOI: 10.1287/mnsc.49.2.179.12744.
- [27] **Liu, N., Ren, Shuyun, Choi, Tsan-Ming, Hui, Patrick, & Ng, Sau-Fun.** Sales Forecasting for Fashion Retailing Service Industry: A Review. *Mathematical Problems in Engineering*, 2013 (Nov. 2013), 1–9. DOI: 10.1155/2013/738675.
- [28] **Meade, N. & Islam, T.** Modelling and Forecasting the Diffusion of Innovation. *International Journal of Forecasting*, 22 (2006), 519–545.
- [29] **Namin, A., Ratchford, B.T., & Soysal, G.P.** An Empirical analysis of demand variations and markdown policies for fashion retailers. *Journal of Retailing and Consumer Services*, 38 (2017), 126–136.
- [30] **Nenni, M.E., Giustiniano, L., & Pirolò, L.** Demand forecasting in fashion industry: A review. *International Journal of Engineering and Business Management*, 5 (Special Issues in Fashion Industry 2013).
- [31] **Parker, P.M.** Aggregate diffusion forecasting models in marketing: A critical review. *International Journal of Forecasting*, 10, 2 (1994). Special Issue Forecasting with Market Response Models, 353–380. ISSN: 0169-2070. DOI: 10.1016/0169-2070(94)90013-2.
- [32] **Philip, E.G. & Walter, M.** Algorithms for the Solution of the Nonlinear Least-Squares Problem. *SIAM Journal on Numerical Analysis*, 15, 5 (1978), 977–992. ISSN: 00361429.
- [33] **Robertson, T.S. & Gatignon, H.** Competitive Effects on Technology Diffusion. *Journal of Marketing*, 50, 3 (1986), 1–12.
- [34] **Robinson, B. & Lakhani, C.** Dynamic Pricing Models New Product Planning. *Management Science*, 10 (1975), 1113–1122.
- [35] **Rogers, E.M.** *Diffusion of innovations*. New York: The Free Press, 1995.
- [36] **Sankoff, D. & Kruskal, J.** Time Warps, String Edits, and Macromolecules – The Theory and Practice of Sequence Comparison. *Genetical Research*, 76, 3 (2000), 327–329. DOI: 10.1017/S0016672300219320.
- [37] **Schmittli, D.C. & Mahajan, V.** Maximum likelihood estimation for an innovation diffusion model of new product acceptance. *Marketing Science*, 1, 1 (1982), 57–78.

- [38] **Sharif, M.N & Kabir, C.** Systems Dynamics Modelling for Forecasting Multilevel Technological Change. *Technological Forecasting and Social Change*, 8 (1976), 353–364.
- [39] **Srinivasan, V. & Mason, C.H.** Technical Note— Nonlinear least squares estimation of new product diffusion models. *Marketing Science*, 5, 2 (1986), 169–178.
- [40] **Steele, V. & Major, J.S.** Fashion industry. *Encyclopedia Britannica* (2019). URL: <https://www.britannica.com/art/fashion-industry> (visited on 06/21/2019).
- [41] **Sun, Z-L., Choi, T-M., Au, K-F., & Yu, Y.** Sales Forecasting Using Extreme Learning Machine with Applications in Fashion Retailing. *Decision Support Systems*, 46 (2008), 411–419.
- [42] **Tanner, J.C.** Forecasts of vehicles and traffic in Great Britain. *Transport and Road Research Laboratory Report*, 650 (1978).
- [43] **Thomassey, S.** Sales forecasts in clothing industry: The key success factor of the supply chain management. *International Journal of Production Economics*, 128 (Dec. 2010), 470–483. DOI: 10.1016/j.ijpe.2010.07.018.
- [44] **Thomassey, S. & Happiette, M.** A neural clustering and classification system for sales forecasting of new apparel items. *Applied Soft Computing*, 7, 4 (2007). *Soft Computing for Time Series Prediction*, 1177–1187. ISSN: 1568-4946. DOI: 10.1016/j.asoc.2006.01.005.
- [45] **Valle, A.D. & Furlan, C.** Forecasting accuracy of wind power technology diffusion models across countries. *International Journal of Forecasting*, 27, 2 (2011), 592–601. ISSN: 0169-2070. DOI: 10.1016/j.ijforecast.2010.05.018.
- [46] **Venkatesan, R., T.V., Krishnan, & Kumar, V.** Evolutionary estimation of macro-level diffusion models using genetic algorithms: an alternative to nonlinear least squares. *Marketing Science*, 23, 3 (2004), 451–464.
- [47] **Vertica, B. & Fairhurst, A.** Fast fashion: response to changes in the fashion industry. *The International Review of Retail, Distribution and Consumer Research*, 20, 1 (2010), 165–173. DOI: 10.1080/09593960903498300.
- [48] **Vijay, M. & Peterson, A.R.** Innovation diffusion in a dynamic potential adopter population. *Management Science*, 24, 15 (1978), 1557–1676.
- [49] **Wong, W.K. & Guo, Z.X.** A Hybrid Intelligent Model for Medium-Term Sales Forecasting in Fashion Retail Supply Chains Using Extreme Learning Machine and Harmony Search Algorithm. *International Journal of Production Economics*, 128 (2010), 614–624.

- [50] **Yu, Yong, Choi, Tsan-Ming, & Hui, Chi-Leung.** An intelligent fast sales forecasting model for fashion products. *Expert Systems with Applications*, 38, 6 (2011), 7373–7379. ISSN: 0957-4174. DOI: 10.1016/j.eswa.2010.12.089.
- [51] **Zotteri, G., Kalchschmidt, M., & Caniato, F.** The impact of aggregation level on forecasting performance. *International Journal of Production Economics*, 93-94 (2005), 479–491. DOI: 10.1016/j.ijpe.2004.06.044.





EKLER

EK 1: Literatürde Moda Sektöründe Satış Tahmini

EK 2: Kategori ve yöntemlere göre dağılım

EK 3: Yöntem ve kategorilere göre dağılım

EK 4: Uyumsuz ürünler hariç kategori ve yöntemlere göre dağılım

EK 5: Uyumsuz ürünler hariç yöntem ve kategorilere göre dağılım

EK 6: Yöntem 1 için periyotlara göre oturtulan eğriler

EK 7: Yöntem 3 için periyotlara göre oturtulan eğriler

EK 8: Yöntem 4 için periyotlara göre oturtulan eğriler

Çizelge 5.1: Moda sektöründe satış tahmini - 1

Makalenin Adı - Yılı	Kullanılan Metot	Açıklama
Fast fashion sales forecasting with limited data and time.- 2014 [10]	ELM, grey modeli.	ELM tek katmanlı ileri beslemeli yapay sinir ağı mekanizmasından oluşur. ELM diğer eğim tabanlı algoritmaların dezavantajı olan ve tahmin edilmesi gereken parametreler olan öğrenme oranı, durma koşulu gibi parametreleri barındırmaz. Grey metodu ise genel olarak veri sayısı az olduğunda kullanılan bir metottur. Çalışmada 20 adet veri noktası yetersiz veri noktası olarak tanımlanmıştır. Grey metodu satışlar için baz bir tahmin oluşturmak amacıyla kullanılmış olup, artıklar üzerine bir ELM modeli uydurulmuştur. Bu doğrultuda veri-deki düzensizlikler ELM ile baz eğri ise Grey metodu ile elde edilmiştir.
Fourier analysis for demand forecasting in a fashion company. - 2013 [19]	Fourier dönüşümü.	Fourier dönüşümü periyodik serileri, sinüzoidal eğrilerin toplamı olarak ifade edebilmektedir. Bu özellik kullanılarak satış verileri Fourier dönüşümüne tabi tutulmuştur. Bu kapsamda gerekli gruplama işlemi algoritmanın sağlıklı işlemesi adına yapılmıştır. Yukarıdan aşağıya bir tahmin yolu izlenmiştir, öncelikle kategori, şube başına bütün talep bulunmuş, ardından sezgisel oranlarla toplam talep ürümlere paylaştırılmıştır.

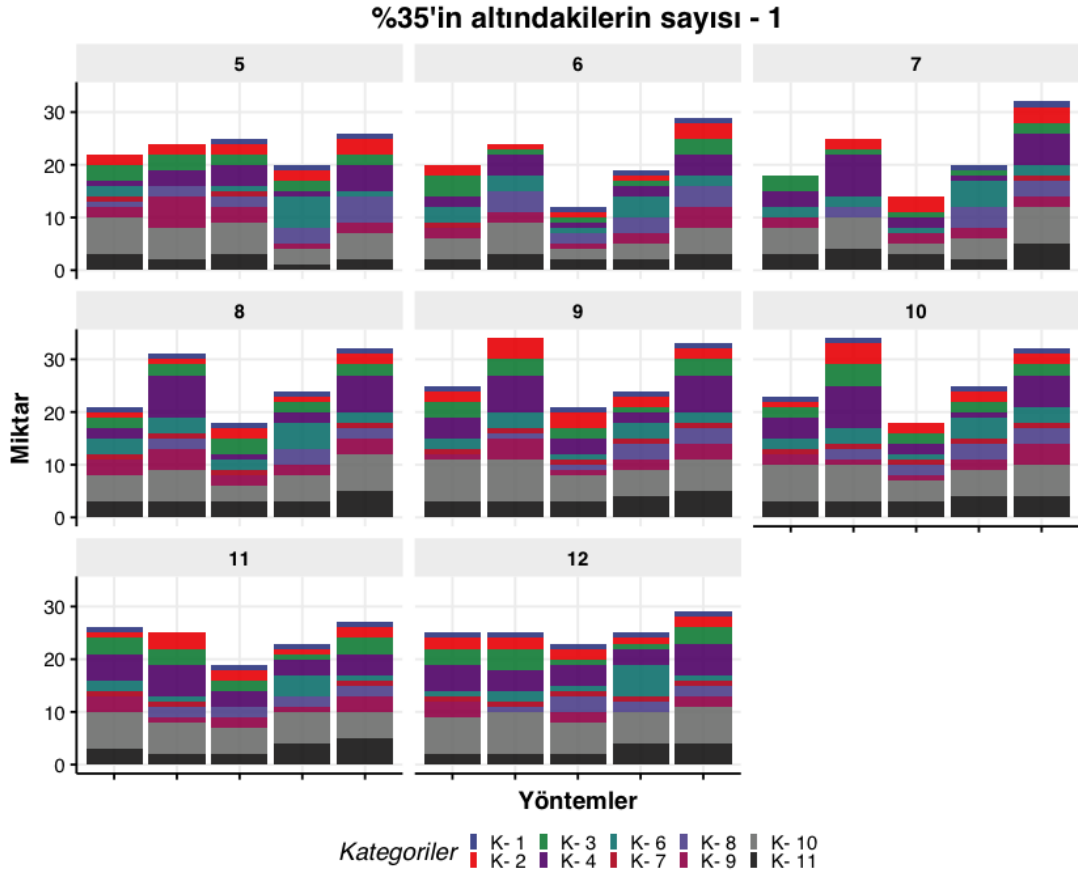
Çizelge 5.2: Moda sektöründe satış tahmini - 2

Makalenin Adı - Yılı	Kullanılan Metot	Açıklama
<p>A multi-objective optimization based neural network model for short term replenishment forecasting in fashion industry. -2015 [15]</p>	<p>YSA, çok amaçlı optimizasyon.</p>	<p>Eğim tabanlı algoritmalar yerine YSA'nın ve YSA yapısının optimizasyonu için çok amaçlı evrim tabanlı bir algoritma kullanılmıştır. Amaçlardan biri YSA'nın karmaşıklığını mümkün olan en küçük düzeyde tutmaktır. Diğer ise en yüksek başarıyı elde edecek yapıyı kurmaktır. Aşırı uyuma problemi yüzünden bu çok amaçlı optimizasyon problemi dizayn edilmiştir. Ancak evrim tabanlı algoritma da parametrelere bağlı olarak farklı sonuçlar verebilir. ELM tabanlı çalışmalardan biri olan [49] 'yi sadece hatayı enküçüklemesinden dolayı eleştirirler ve böyle bir modelde aşırı uymanın kaçınılmaz olduğunu ileri sürerler.</p>
<p>A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. - 2010 [49]</p>	<p>ELM, Harmoni arama algoritması.</p>	<p>Daha önce de bahsettiğimiz gibi ELM'nin dezavantajı rastgele değerler ile algoritmanın başlaması sonucunda birbirinden farklı sonuçlar elde edilebilmektedir. Bu kapsamda bu rastgeleliği ortadan kaldırmak ve daha akıllı bir başlangıç değeri verebilmek amacıyla harmoni arama algoritması kullanılmıştır. Bu şekilde modelin genelleştirebilme performansının artırılması amaçlanmıştır.</p>


Çizelge 5.3: Moda sektöründe satış tahmini - 3

Makalenin Adı - Yılı	Kullanılan Metot	Açıklama
Fashion retail forecasting by evolutionary neural networks - 2008 [1]	Yapay sinir ağı (YSA)	YSA, lineer olmayan desenleri temsil etmede etkili bir modeldir. Ancak modelin parametrelerinin belirlenmesi önemli bir husustur. Makalede ideal ağ yapısını bulmak amacıyla evrimsel algoritmalar kullanılmıştır.
Sales forecasts in clothing industry: The key success factor of the supply chain management- 2010 [43]	Bulamık mantık, YSA, veri madenciliği.	Bulamık çıkarım sistemi, veri içerisindeki açıklayıcı değişkenlerin (hava durumu, tatil günleri, ürün özellikleri v.s.) etkilerini saptamak amacıyla kullanılmıştır. Bir temel tahmin üzerine bu etkiler dahil edilerek tahmin oluşturulmuştur.
An intelligent fast sales forecasting model for fashion products. - 2011 [50]	YSA, Aşırı öğrenme makineleri (ELM)	Tahminin oluşturulması sürecinin çok hızlı olması gerektiğini savunan makalede, YSA'nın bir türü olan ELM kullanılmıştır. Modelin parametreleri sezgisel yardımcıyla bulunmuştur. Model oluşturulurken; renk, boyut, fiyat gibi özelliklerden faydalanılmıştır. ELM rastgele başlangıç ağırlıklarıyla başladığından her bir koşulda farklı sonuçlar verebilir. Bu sebeple modelde P farklı koşurunun ortalaması değerlendirilmiştir.
A neural clustering and classification systems for sales forecasting of new apparel items.- 2007 [44]	YSA tabanlı karar destek sistemi.	Moda sektörü birçok zorluğu içerisinde barındırır. Bu zorluklar her sezonda çok fazla yeni ürünün bulunması, kısa yaşam ömrü ve sürekli değişen müşteri beğeni algısından süregelir. Bu kapsamda ürün yaşam eğrisi büyük anlam ifade eder. Makalede özdüzenleyici haritalar (SOM) kullanılarak bir kümeleme yapılıp daha sonra ise YSA yardımıyla bir sınıflandırma yapılmıştır. Bu kapsamda ürünün yaşam döngüsü hakkında bir öngörü elde edilmiştir.

EK 2




Şekil 5.1: Kategori ve yöntemlere göre dağılım



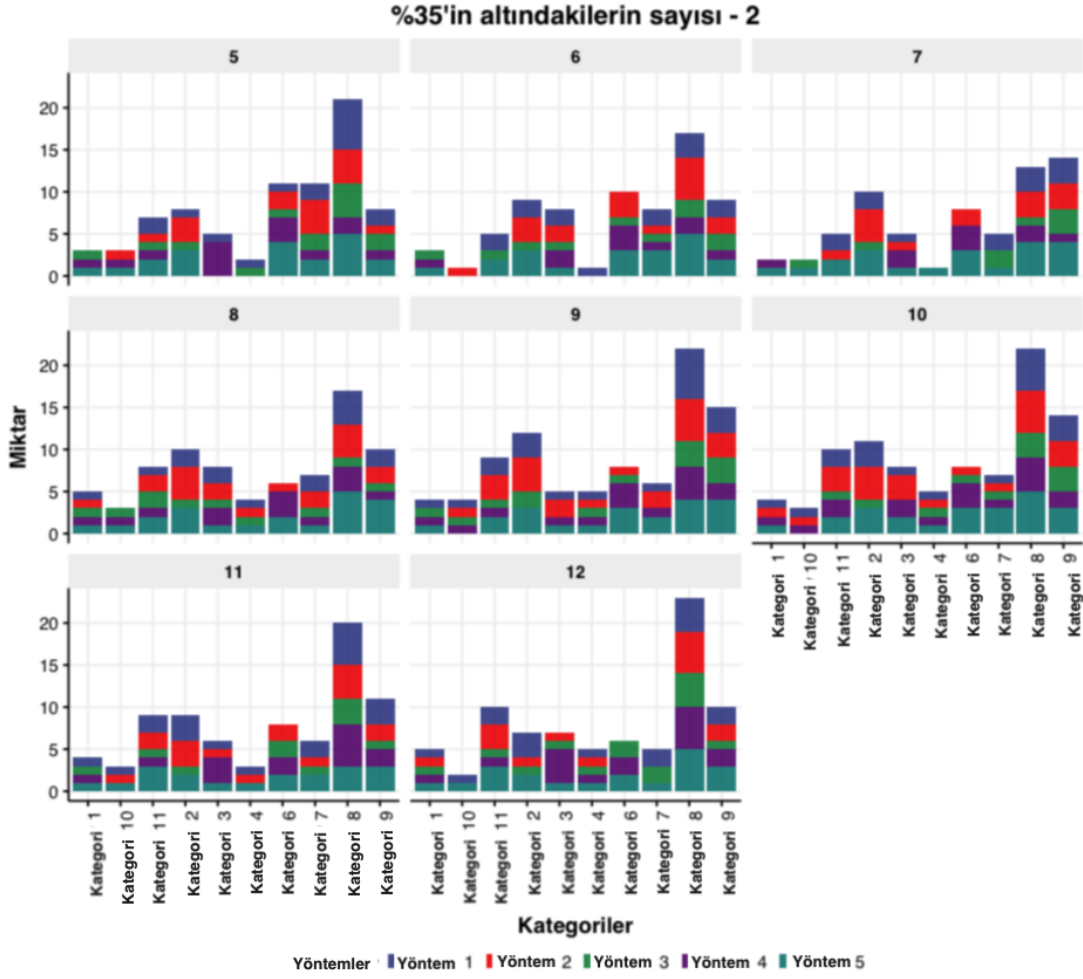
Şekil 5.2: Yöntem ve kategorilere göre dağılım

EK 4



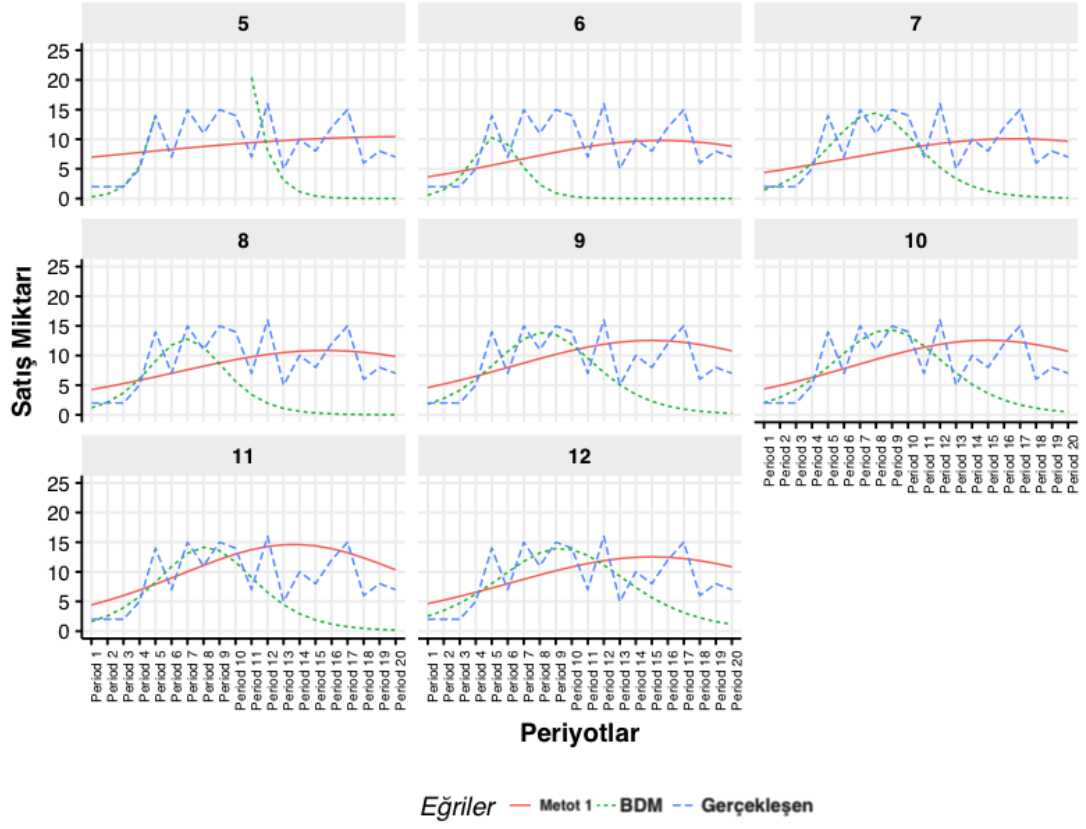
Şekil 5.3: Uyumsuz ürünler hariç kategori ve yöntemlere göre dağılım

EK 5



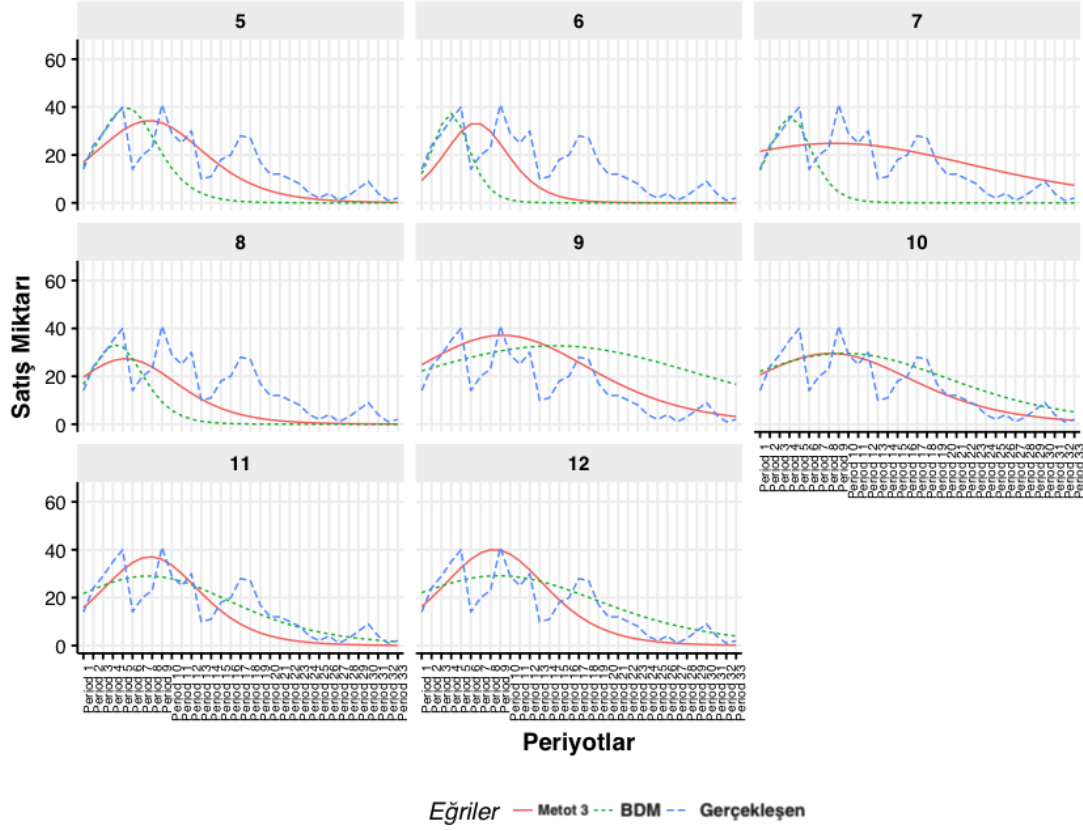
Şekil 5.4: Uyumsuz ürünler hariç yöntem ve kategorilere göre dağılım

EK 6



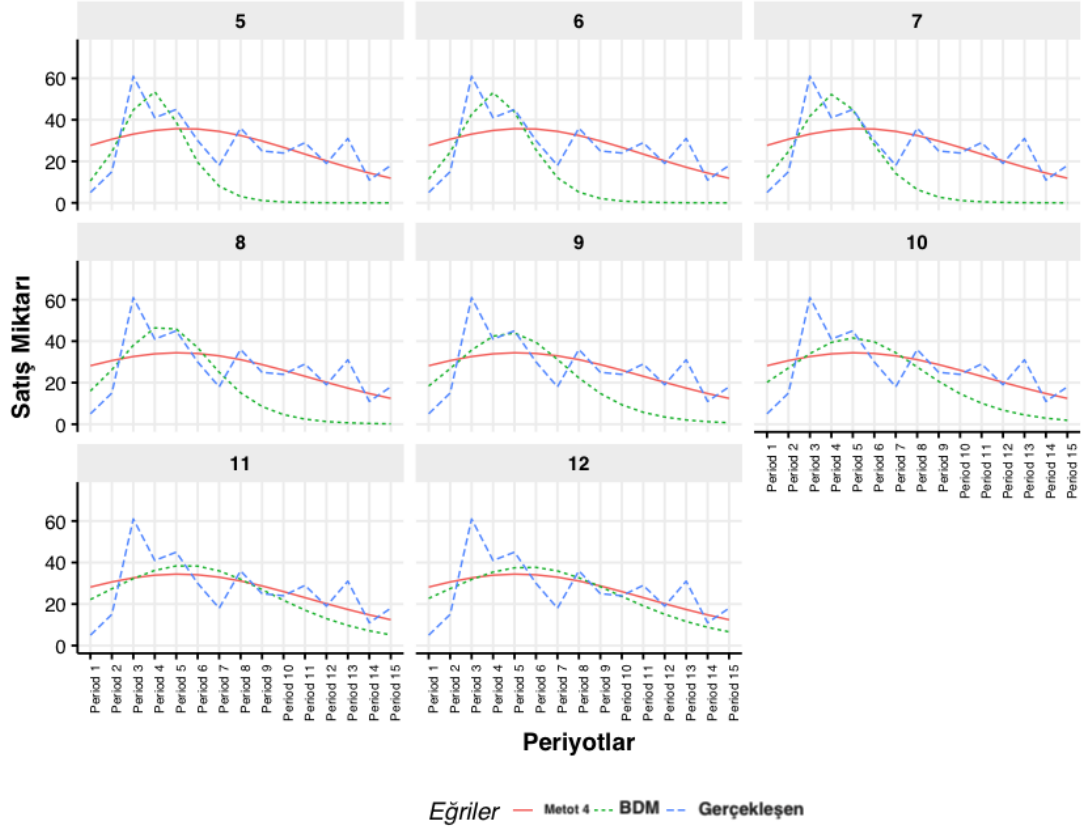
Şekil 5.5: Yöntem 1 için periyotlara göre oturtulan eğriler

EK 7



Şekil 5.6: Yöntem 3 için periyotlara göre oturtulan eğriler

EK 8



Şekil 5.7: Yöntem 4 için periyotlara göre oturtulan eğriler



ÖZGEÇMİŞ

Ad-Soyad : Abdurrahman YAVUZ
Uyruđu : T.C.
Dođum Tarihi ve Yeri : 25.04.1995 / Ankara
E-posta : ayavuz@etu.edu.tr

ÖĐRENİM DURUMU:

- **Lisans** : 2017, TOBB Ekonomi ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliđi
- **Yüksek Lisans** : 2019, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliđi

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2017-2019	TOBB Ekonomi ve Teknoloji Üniversitesi	Tam Burslu Yüksek Lisans Öğrencisi

YABANCI DİL: İngilizce, İspanyolca

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- Yavuz, A., Ertogral, K., 2019. Analysis of the performance of Bass Diffusion Model in forecasting demand for fashion goods; A case study, 5th International Conference on Management Studies, May 24, Istanbul, Turkey.