

152380

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**BİR İLAÇ FİRMASINDA PAZAR BÖLÜMLENDİRME:
YAPAY SİNİR AĞLARI İLE KÜMELEME ANALİZİ
KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

End. Müh. Çağla KESİK

507011093

Tezin Enstitüye Verildiği Tarih: 26 Nisan 2004

Tezin Savunulduğu Tarih: 17 Mayıs 2004

152380

Tez Danışmanı:

Diğer Jüri Üyeleri:

Yrd. Doç. Dr. Cafer Erhan Bozdağ 16.6.04

Yrd. Doç. Dr. Şebnem Burnaz 16.6.2004

Yrd. Doç. Dr. Mehmet Mutlu Yenisey 16.6.2004

MAYIS 2004

ÖNSÖZ

Pazarlama alanında sıkça “segmentasyon ve hedefleme” kavramlarının sözü geçmektedir. Bu konularla ilgili yabancı dilde çok sayıda kaynak varken, ülkemizde bu konularla yeni ilgilenilmeye başlanmıştır. Birçok firmanın başarılı olmasında önemli rolü olan segmentasyon ile ilgili akademik alanda kendimi geliştirmek istediğim için bu konuyu tez konum olarak seçtim.

Bir yandan çalışırken, diğer yandan da tezimi yazarken bana destek veren ve teşekkürlerimi büyük bir onurla sunmak istediğim bazı kişiler var.

Çalışmalarına verdiği büyük destek ile birlikte tezim dışında başımın sıkıştığı anlarda da uzattığı eli için değerli Danışman Hocam Yrd. Doç. Dr. Cafer Erhan Bozdağ’a, data toplarken ve yorumlama aşamasına geldiğimde benden zamanını hiç esirgemeyen firma yetkilisi Sayın Müşfik Karadoğan’a ve her durumda bana destek olan annem, babam ve ağabeyime çok teşekkür ederim.

Haziran 2004

Çağla KESİK

İÇİNDEKİLER

TABLO LİSTESİ	v
ŞEKİL LİSTESİ	vi
SEMBOL LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
1 İŞLETMELERDE PAZARLAMA KAVRAMI	1
1.1 Pazarlamanın Değişen Rolü	2
1.2 Pazarlama Karması	3
1.3 Pazarlama Stratejisi	4
1.4 Pazar Bölümlendirmesi	5
1.4.1 Pazar Bölümlendirmesinin Temeli	6
1.4.2 Pazar Bölümlendirmesi Kriterleri	16
1.4.3 Pazar Bölümlerinin Değerlendirilmesi	17
1.5 Hedef Pazarın Seçimi	19
2 KÜMELEME ANALİZİ	23
2.1 Kümeleme Analizi Teknikleri	25
2.1.1 Hiyerarşik Kümeleme	25
2.1.2 Hiyerarşik Olmayan Kümeleme	26
2.2 Kümeleme Analizi ile İlişki Kuran İstatistikler	28
2.3 Geçerliliği ve Güvenirliği Tayin Etmek	34
2.4 Pazar Bölümlendirmesinde Kümeleme Yaklaşımı	34
3 YAPAY SİNİR AĞLARI	37
3.1 Yapay Sinir Ağlarının Temel Yapısı	41
3.2 Yapay Sinir Ağlarında Öğrenme	43
3.2.1 Gözetimli Öğrenme	44
3.2.1.1 Algılayıcılar (Perceptions)	44
3.2.1.2 İleri Beslemeli Ağlar	45
3.2.1.3 Geri Beslemeli Ağlar	46

3.2.2	Gözetimsiz Öğrenme	49
3.2.2.1	Özörgütlemeli Haritalar	50
3.2.3	Karma (Reinforcement) Öğrenme	61
3.3	Yapay Sinir Ağının Tahmin Modelleri İçin Kullanımı	61
3.4	Yapay Sinir Ağının Kümeleme Analizi İçin Kullanımı	65
3.5	Yapay Sinir Ağlarının Pazarlama Uygulamaları	66
4	UYGULAMA	70
4.1	Veri Toplama	72
4.2	Kümeleme Analizi	73
4.2.1	Kümeleme Analizi Sonuçları	73
4.2.2	Geçerlilik Testi	77
4.3	Yapay Sinir Ağları	88
4.3.1	Sonuçları	88
4.3.2	Geçerlilik Testi	90
4.4	Sonuçların Yorumlanması	91
5	SONUÇLAR	93
	KAYNAKLAR	98
	ÖZGEÇMİŞ	101

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 1-1. Pazarlama Anlayışlarının Gelişimi	3
Tablo 1-2. Tüketici Pazarları İçin Temel Pazar Bölümlendirmesi Değişkenleri.....	7
Tablo 1-3. Bir Bankanın Bireysel Müşterilerini Yaş ve Gelire Göre Bölümlemesi	10
Tablo 1-4. Pazar Bölümlendirmesi Kriterleri.....	13
Tablo 1-5. Pazar Bölümlendirmesi Prosedürü.....	14
Tablo 4-1. Aglomerasyon Şedülü.....	74
Tablo 4-2. Üç Kümelik-Ortalamaları Analizi Sonucu.....	75
Tablo 4-3. Dört Kümelik-Ortalamaları Analizi Sonucu.....	77
Tablo 4-4. Üç Sınıfa Göre Matlab Sonucu.....	89
Tablo 4-5. Dört Sınıfa Göre Matlab Sonucu.....	90
Tablo 4-6. Geçerlilik Testi Sonucu Segment Numaralarının Karşılaştırılması.....	91
Tablo 4-7. Matlab ile SPSS Çıktılarının Karşılaştırılması.....	92

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 1-1. Dinamik Etkileşimli Segmentasyon Modeli.....	6
Şekil 2-1. Kümeleme Metotlarının Sınıflandırılması.....	24
Şekil 2-2. Aglomerasyon Şedülü Örneği.....	29
Şekil 2-3. Dendrogram Örneği.....	30
Şekil 2-4. Buz Saçağı Diyagramı Örneği.....	31
Şekil 3-1. Basit Bir Sinir Hücresi.....	37
Şekil 3-2. Yapay Sinir Ağlarının Temel Yapısı.....	41
Şekil 3-3. Örnek Bir Yapay Sinir Ağı.....	42
Şekil 3-4. İleri Beslemeli Üç Katmanlı Yapay Sinir Ağları.....	45
Şekil 3-5. Geri Beslemeli İki Katmanlı Yapay Sinir Ağı.....	46
Şekil 3-6. İki Boyutlu Kohonen Ağı.....	51
Şekil 3-7. Özörgütlemeli Harita Ağı Örneği.....	54

SEMBOL LİSTESİ

w_{ij}	: Girdi-Gizli düzeyleri arasındaki bağlantılarının ağırlıkları
w_{jk}	: Gizli-Çıktı düzeyleri arasındaki bağlantılarının ağırlıkları
x_{ij}	: i. objenin j. kümede olma değeri
k	: Küme sayısı
m	: Çıktı sinir hücre sayısı
n	: Girdi sinir hücre sayısı
n_j	: j. kümedeki obje değeri
t_i	: Eşik derecesi
$x(t)$	: Girdi matrisi
$y(t)$	: Çıktı matrisi
$x_i(t)$	: t zamanında i. hücrenin girdi değeri
$y_i(t)$	: t zamanında i. hücrenin çıktı değeri
$w_{ij}(t)$	: t zamanında i. hücrenin girdi hücresinden j çıktı hücresine olan bağlantının ağırlık değeri
e	: Hata fonksiyonu
η	: Öğrenme oranı
α	: Momentum sabiti

ÖZET

Pazar bölümlendirmesi, heterojen büyük pazar ortamlarını, benzer gereksinimleri olan ya da aynı pazarlama karması etkinliklerine benzer şekilde cevap veren homojen alt gruplara ayırmaktır. İlaç sektöründeki en önemli kavramlardan bir tanesi pazar bölümlendirmesidir. Bunun nedeni, firmaların yoğun rekabet içinde, yasalarla belirlenmiş kaynak kullanımı ve tanıtım olanakları ile satış ve pazarlama aktiviteleri yürütmeleri, sektörde farklı özelliklere sahip çok sayıda doktor bulunması; bunlara karşılık belirli sayıda satış temsilcileri bulundurabilmeleridir. Dolayısıyla, hangi doktor segmentine hangi bilimsel hizmetlerin sunulması, hangi tanıtım faaliyetleriyle ulaşılması gerektiği, ilaç sektöründe önemli bir konu olarak karşımıza çıkmaktadır.

Bu tez çalışmasında, belirli bir ürüne ait pazar bölümlendirmesi yapılması hedeflenmiştir. Sürecin ilk aşamasında ürünle ilgili doktorlar listelenmiş ve doktorları bölümlenmek için datası elde edilebilecek ve sayısallaştırılabilecek değişkenler belirlenmiştir. Ardından doktor bazında bu değişkenlerin elde edilmesi için satış mümessillerine ve ilgili ürünün müdürüne danışılmıştır.

Analiz aşamasında, hiyerarşik kümeleme metodu ve hiyerarşik olmayan kümeleme metotlarından k-ortalamaları için SPSS 11.0 programı ve yapay sinir ağlarının özörgütlemeli haritaları metodu için Matlab 6.5 programı kullanılmıştır. Hiyerarşik kümeleme metoduna, yalnızca küme sayısını belirlemek için başvurulmuş ve aglomerasyon şedülüne göre üç sınıfın uygun olacağı bulunmuştur. Diğer yandan konuyla ilgili firma yetkililerine danışılmış; kendileri tarafından dört kümenin uygun olacağı belirtilmiştir. Hem üç küme için hem de dört küme için kümeleme analizi ve özörgütlemeli haritalar kullanılmıştır. Her iki tekniğin verdiği sonuçlar geçerlilik testlerine sokulmuş ve uyumlu sonuçlar elde edilmiştir. Kümeleme analizi ve özörgütlemeli haritalar ile elde edilen sonuçlar hem üç küme bazında hem de dört küme bazında karşılaştırılmış; her iki durumda da yapay sinir ağlarının firma hedeflerine daha uygun sonuçlar verdiği görülmüştür. Bu durum, literatürde yer alan diğer makalelerle de aynı doğrultudadır.

Pazarlama literatürüne göre, bu aşamadan sonra yapılması gereken, firmanın stratejileri ve kaynakları doğrultusunda, belirlenen pazar bölümlerinden hangilerini hedeflemesi gerektiğine karar vermektir. İlaç sanayinde bu karar, hangi doktor segmentinin ne sıklıkla ziyaret edileceği, hangi doktor segmentine ne tip aktiviteler yapılacağını içermektedir.

Anahtar Kelimeler: Pazar Bölümlendirme, Kümeleme Analizi, Yapay Sinir Ağları, Özörgütlemeli Haritalar
Bilim Dalı Sayısal Kodu: 605.01.00.00

MARKET SEGMENTATION BY USING NEURAL NETWORKS SUMMARY

In market segmentation, one distinguishes homogeneous groups of customers who can be targeted in the same manner because they have similar needs and preferences.

It is one of the most important concepts in pharmaceutical industry. One reason is that there is a limited number of sales representatives. Second reason is that there are strong competitors in an environment where resource utilization and sales and marketing activities are determined by regulations and laws. Third reason is that there are various kinds of doctors. Therefore, it is of vital importance to determine the kind of scientific services provided and promotional activities served to any doctor segment basis.

Aim of this thesis is to realize a market segmentation of a product in a pharmaceutical industry. In the first stage of the process, doctors related with the product are listed and then quantitative variables are determined. To provide related data about each of the variables, in-depth interviews were held.

In the analysis stage; SPSS version 11.0 is used for hierarchical clustering method and k-means, as one of the non-hierarchical clustering methods and Matlab 6.5 is used for neural networks. Hierarchical clustering method is only used for determining the number of classes. According to the agglomeration schedule, three classes would be optimum; whereas according to the corporate authorities, number of classes should be four. Cluster analysis and self-organizing maps are used for both cases. Validation tests are completed successfully. Results of both cases in terms of market segmentation are compared. According to the corporate authorities, results of neural network are more appropriate in both three cluster and four cluster cases. These results are in accordance with the literature.

The next step should be “targeting”; where the decision of which segment to serve is given subject to the constraints of strategies and the resources available. This decision in pharmaceutical sector comprises of call frequency and kinds of activities of each segment.

Keywords: Market Segmentation, Cluster Analysis, Neural Networks, Self Organizing Maps

Science Code: 605.01.00.00

1 İŞLETMELERDE PAZARLAMA KAVRAMI

İşletmelerde yönetim, örgütün üst yönetimi tarafından belirlenmiş amaç ve hedeflerin gerçekleşmesi için çalışanlara yön belirlenmesi, harekete geçirilmesi ve sonuçların değerlendirilmesi sürecidir. Yönetim geçici ve anlık değildir. Bir yerde başlayıp bir yerde bitmez ve hep devam eder. Birbirini tamamlayan faaliyetler ve davranışlar dizisidir. Yönetici ise kar ve risk başkalarına ait olmak üzere, üretim faktörlerini tedarik eden, mal ve hizmetleri müşterilere sunmak için personeli yönlendiren ve belirli bir ihtiyacı karşılama amacına yönelten kişidir. Yönetim bilimci Peter Drucker yöneticiyi; "Bilginin uygulanmasından ve performansından sorumlu kişi" olarak tanımlamaktadır. Bugün profesyonel olarak adlandırılan bu kişiler, tıpkı bir orkestra şefi gibi sahip olduğu takımı yönetmekte, motive etmekte ve sistematik çalışma düzeni (planlama, denetleme vb.) kurmaktadır.

Yönetim kavramı konusunda birçok önemli isim, ortaya koyduğu fikirlerle yöneticilerin çalışmalarına önemli katkılarda bulunmuşlardır. Örneğin Fransız H. Fayol tarafından 1915 yılında ortaya atılan geleneksel yönetim anlayışı planlama, organize etme, koordinasyon ve denetleme gibi dört temel fonksiyonu ele almaktadır. Bu fonksiyonlar uzun yıllar yönetim kavramını ve yöneticilerin görevlerini açıklamaya yardımcı olmuştur. Bugün yönetim alanında yaşanan son gelişmeler nedeniyle, yeni unsurların da eklenmesi kaçınılmazdır. Çünkü günümüzde yöneticilerin görevleri her geçen gün daha da zorlaşarak karmaşılaşmaktadır. Bu nedenle de yöneticinin bir gün içinde ne tür sorunlarla karşılaştığı, vizyon, yaratıcılık ve değişim gibi temel konularda neler yapması gerektiğini ortaya koyan düşünceler de geliştirilmelidir. Bu temel noktalardan bir tanesi de pazarlamadır.

Pazarlama, tüketicileri ve örgütsel hedefleri tatmin ederek hedef kitlelerde değişimi sağlamak üzere, ürünlerin, hizmetlerin ve düşüncelerin yaratılmasını, fiyatlandırılmasını, dağıtımını ve tutundurma çabalarını planlama ve gerçekleştirme sürecidir [1]. İşletmelerde pazarlama faaliyetleri üretim sürecinden önce başlamakta

ve satış faaliyetinden sonra da devam etmektedir. Bu süreç içinde; tüketicilerin ihtiyaç ve taleplerini belirlemek ve ürünlerle tüketiciler arasında organik bir bağ oluşturabilmek için, ürünün geliştirilmesi, fiyatlandırılması, pazarlama iletişimi ve dağıtım faaliyetleri gerçekleştirilir.

Artık, mevcut pazar, klasik satış ve pazarlama tekniklerinde olduğu gibi üretici odaklı değil, çağdaş pazarlama tekniklerinde olduğu gibi tüketici odaklıdır. Çağdaş pazarlama ilkeleri, pazarlama yöneticileri tarafından çok iyi bilinmeli ve oluşturulması düşünülen işletme stratejilerine yön verebilmelidir.

Tüketici odaklı pazarlama uygulamalarında yöneticiler şu soruların cevaplarını aramaktadır:

- Hangi ürünü/hizmeti üretirsem satabilirim?
- Ürünü nereden üretirsem satabilirim ya da hangi satış noktalarını kullanarak ürünü nerelerde bulundurursam başarılı olurum?
- Tüketicilere hangi fiyattan satarsam başarılı olurum?
- Tüketicinin ilgisini çekebilmek için ne tip promosyonel aktivitelerle ürünü desteklemeliyim?

1.1 Pazarlamanın Değişen Rolü

Pazarlama yöneticileri, tüketicilerin sürekli değişen ve artan ihtiyaçlarını anlamak ve bu ihtiyaçlara yönelik ürünler ve hizmetler geliştirmek zorundadır, çünkü müşteriler, rekabetçi sunumların daha fazla farkındadırlar, fiyata duyarlıdırlar ve geçmişe göre istekleri değişmiştir. Çağdaş pazarlama faaliyetlerinde tüketicilerin ihtiyaçlarını tatmin eden ve onlara fayda sağlayan ürünler geliştirmek esastır [2]. Bu nedenle hangi ürünlerin tüketicilerin ihtiyaçlarına cevap verebileceği, tüketim sorunlarını çözebileceği ve fayda sağlayacağı iyi bilinmelidir.

Bunun yanında klasik pazarlama düşüncesi ise üreticilerin çok güçlü olduğu dönemlerde geçerli olan bir yaklaşımdır. Daha çok arz yönlü olup, tüketicilerin

beklenti ve taleplerini önemsemeyen bir yapı göstermektedir. Bu yapıda üreticiler, tüketicilerin ihtiyaç ve taleplerinin birbirine çok benzediğini ve hepsinin aynı satın alma davranışlarına sahip olduğunu düşünür. Ayrıca üretici, istediği ürünü, istediği yerde ve istediği koşullarda üreterek, tüketicilerinin beklentilerini hesaba katmadan fiyatlandırma hakkına sahiptir. Tüketicilerin düşüncelerini hiçbir şekilde hesaba katmadan üretim yapmayı ve satmayı hedefleyen bu yaklaşım zamanla yerini çağdaş pazarlama uygulamalarına bırakmıştır.

Tablo 1-1’de Kotler ve diğerlerine göre, yeni pazarlama paradigmasının aşamaları yer almaktadır [3].

Tablo 1-1. Pazarlama Anlayışlarının Gelişimi

Pazarlama Anlayışları	Başlangıç noktası	Odak noktası	Anlamı	Bitiş noktası
Satış Anlayışı	Üretim yeri	Ürün	Satış ve ilerleme	Satış hacmi yoluyla karlılık
Pazarlama Anlayışı	Müşterinin değişen gereksinimleri	Müşteri gereksinimlerine uygun sunumlar ve pazarlama karmaları	Pazar bölümlendirme, hedef pazarı seçme ve konumlama	Müşteri memnuniyeti yoluyla karlılık
Bütünsel (Holistic) Pazarlama Anlayışı	Bireysel müşteri gereksinimleri (talepleri)	Müşteri değeri, işletmenin ana yetenekleri ve işbirliği zincirleri	Veri tabanı yönetimi ve değer zinciri bütünleşmesi	Müşteri payına, müşteri bağlılığına ve müşterinin yaşam boyu değerine ulaşmak yoluyla karlılıkta büyüme

1.2 Pazarlama Karması

Gerçekte, şirketler tüketicilerine sınırsız sayıda yol ile değer kazandırabilirler. Ancak pazarlama aktivitelerini basitleştirmek amacıyla, temel olarak değer katan aktiviteler “pazarlama karması” olarak adlandırılmaktadır. Pazarlama karması (4 P kavramı)

ürün, fiyat, tutundurma ve dağıtımdan oluşmaktadır [2]. Bu kavramlara pazarlama konusunda çalışmalarıyla tanınmış Philip Kotler, iki eleman daha eklemektedir. Bunlar *politika* ve *kamuoyudur*. Yeni elemanlar, dünyadaki gelişen ekonomik koşullar, politikalar, globalleşme gibi birçok konunun etkisi ile ortaya çıkmaktadır. İşletmelerin bu yeni elemanları göz ardı etmesi düşünülemez. Bu nedenle pazarlama yöneticilerinin dünyadaki gelişmeleri de düşünerek etkin bir pazarlama karması oluşturması gerekmektedir.

Ürün kararları, bir ürünün tasarlanması ile ilgili ambalajı, garanti süresi, satış sonrası verilecek hizmetler, müşteri eğitimi gibi tüm spesifik aktiviteleri içerir. Fiyatla ilgili kararlar, fiyat indirimleri, tüketicinin markalar arasındaki fiyat değişikliklerinden farkındalığı, tüketicinin fiyat duyarlılıkları, ödeme koşulları gibi etmenleri göz önüne alır. Tutundurma kararları verilmeden önce, “tüketicilerin ilgisini, dikkatini çekmede ve onları eyleme geçirmede en uygun araçlar nelerdir?”, “tüketicilere ulaşmada en etkin medya aracı hangisidir?”, “mesajlar değişik kanallarda ne sıklıkla tekrarlanmalıdır?” gibi sorulara cevap aranır. Dağıtım kararlarında ise, dağıtım kanalları alternatifleri, dağıtım süresi, stok politikaları gibi etmenler söz konusudur. Pazarlama yöneticisi, her bir pazarlama karması elemanı için bir strateji oluşturmalıdır ve her bir eleman için verilen kararın, diğer elemanlar için verilen kararla tutarlı olmasına dikkat etmelidir [2].

1.3 Pazarlama Stratejisi

Strateji, bir firmanın varmak istediği yer ve bu yere ulaşmak için oluşturduğu planları içeren ifadedir. Başka bir anlayışa göre, bir firmanın uzun dönemli karlılığı için oluşturulan fikirler topluluğudur. Stratejiler, net tanımlanmış hedefler üzerine konumlandırılır; uzun dönemli ve esnektir. Strateji, daha geniş olarak “firma hedeflerine ulaşabilmek için, kaynak dağılımlarını ve organizasyon yapısını da içerecek şekilde tüm politikaların ve programların belirlenmesi” şeklinde tanımlanabilir [2].

Özellikle yüksek rekabet içinde bulunan sektör ve ekonomilerde işletme stratejileri geliştirmek ve uygulamak çok daha önem kazanmaktadır. Örneğin, son yıllarda dünyada mobil iletişim sektörünün ülke ekonomilerinde taşıdığı önem göz önüne

alındığında, bu işletmelerde strateji geliştirmenin gerekliliği bir kez daha vurgulanmış olacaktır. Çünkü en temel anlamda strateji, işletmenin çevresi ile arasındaki ilişkileri düzenleyen ve rakiplerine üstünlük sağlaması için iç çevresini ve kaynakları harekete geçirip kullanan bir disiplin olarak da tanımlanmaktadır.

Bugün işletme yöneticilerinin en sık yaptıkları hata, strateji kavramını her yerde ve cümlelerin başında kullanmaları ve böylece taşıdığı anlamı yitirmesine neden olmalarıdır. Kimi zaman da anlamını tam olarak bilmemeleri nedeniyle de misyon, politika, taktik, program, yöntem ve plan kavramları ile çok sık karıştırılarak kullanılmaktadırlar. Ancak iyi bir pazarlama yöneticisi, günümüzde tüketicilerin çağdaş pazarlamanın odak noktasını oluşturması nedeniyle kavramlara daha da hakim olmak zorundadır.

Bugün bir işletmede pazarlama stratejisi geliştirmek için önce pazar bölümlenmeli; ardından hedef pazar belirlenmeli sonra ise bu hedef pazara yönelik olarak pazarlama karması oluşturulmalıdır.


1.4 Pazar Bölümlendirmesi

Bugün dünyada birbirinden farklı talepleri ve istekleri olan milyarlarca insan yaşamaktadır. Bu talepler ülkeden ülkeye değişebildiği gibi, aynı ülke içinde yaşayan insanlarda da çeşitli nedenlerden (yaş, cinsiyet, gelir, eğitim, statü vb.) dolayı değişebilmektedir. Bu nedenle bir işletme yöneticisi, tüketicilerin birbirinden çok farklı beklentileri olabileceğini hiçbir zaman unutmamalıdır. Pazar bölümlendirmesi başarılı bir pazarlama stratejisi oluşturmada en önemli adımdır, ancak pazarı bölümlendirmede ölçütün iyi belirlenmesi gerekmektedir.

Pazar bölümlendirmesi, *“heterojen büyük pazar ortamlarını, benzer gereksinimleri olan ya aynı pazarlama karması etkinliklerine benzer şekilde cevap veren homojen alt gruplara ayırmaktır”* şeklinde tanımlanmaktadır.

Pazar bölümlendirmesi, hedef pazarın belirlenmesinde *hedef pazar seçimi* ve *pazar konumlandırma* aşamalarından önceki basamaktır. Hedefe giden ilk adım olması sebebiyle pazarlama stratejisinin oluşturulmasında ve pazarlama çabalarının başarıya ulaşmasındaki etkisi de büyüktür.

Bir pazar bölümü, genellikle, tanımlanması, seçilmesi ve pazarlama karması ile hedeflenmesi gereken bir şey olarak tanımlanır. Bu durum, müşterilerin istek ve ihtiyaçlarını kendi tedarikçileriyle görüşerek belirledikleri statik (dinamik olmayan) bir segmentasyon yapısı olarak düşünülebilir. Pazar bölümleri, satan ve satın alan firmalar arasındaki etkileşim süreci sonucunda oluşurlar. Hangi tarafın güçlü olduğu, durumdan duruma değişebilir. Bazı durumlarda, satın alan daha güçlüdür çünkü ters pazarlama kavramı söz konusudur. Bazen ise satan taraf daha güçlüdür. Dolayısıyla, ihtiyaç ve isteklerin satan ve satın alan tarafların etkileşimleriyle ortaya çıktığını söylemek hatalı olmayacaktır. Buradan yola çıkarak Freytag ve Clerk, bir segmentasyon modeli çıkarmışlardır. [6]



Şekil 1-1. Dinamik Etkileşimli Segmentasyon Modeli

1.4.1 Pazar Bölümlendirmesinin Temeli

Tablo 1-2, pazar bölümlendirmesinin temelini göstermektedir [1].

Genel uygulama ikiye ayrılmaktadır:

A -Tüketici ile ilgili değişkenlere göre bölümlendirme

Coğrafi Bazda Pazar Bölümlendirmesi:

Şehir, ülke, bölge, millet vs. bazında pazar bölümlendirmesi yapılabilir. Örneğin bir firma, sadece bir ya da birkaç coğrafya alanında hizmet vermeyi amaçlayabilir; ya da coğrafya bazında oluşan farklı ihtiyaçlara önem vermek isteyebilir. Maxwell House,

tüm ülkede satılan bir üründür; ancak aroması bölge bazında çeşitlilik göstermektedir. Batı kesimlerde, doğu kesimlere oranla aroması daha serttir. Campbell Soup Company, bölge müdürleri atamış ve kendilerine bölgesel ihtiyaçları analiz etmeleri ve bölge bazında özel promosyonlar yapmaları için bütçe ayırmıştır.

Tablo 1-2. Tüketici Pazarları İçin Temel Pazar Bölümlendirmesi Değişkenleri

Değişken	Tipik Bölümlendirmesi
COĞRAFİ	
Ülke	Türkiye, İngiltere, Fransa..
Bölge	Doğu Anadolu, Marmara, Ege, Karadeniz, Güneydoğu Anadolu
Yerleşim Büyüklüğü	Şehir, kasaba, köy..
Nüfus yoğunluğu	Nüfusu 5000'den az; 5000-20000 arası,...
İklim	Güney, kuzey
DEMOGRAFİK	
Yaş	6 yaş altı, 6-11, 12-19...
Cinsiyet	Bay, bayan
Aile Büyüklüğü	1-2-3-4-5+
Aile hayat çevrimi	Genç ve bekar, genç ve bekar ve çocuksuz, genç ve bekar ve en küçük çocuğu 6 yaşın altında....
Gelir	5000 doların altı, 5000-10000 dolar arası...
Meslek	Yönetici, emekli, öğrenci, işsiz..
Eğitim	İlköğretim, lise, üniversite mezunu..
Din	Müslüman, Hristiyan..
İrk	Beyaz, siyah, Asyalı..

Değişken	Tipik Bölümlendirmesi
Millet	Türk, Fransız, İngiliz..
Medeni Durum	Evli, bekar
PSİKOĞRAFİK	
Sosyal sınıf	Alt sınıf, orta sınıf, üst sınıf..
Kişilik	Hırslı, otoriter, tutucu..
DAVRANIŞSAL	
Seyahat etme	Düzenli seyahat, özel durumlarda seyahat
Üründen beklenen yarar	Kalite, hız, fiyat
Kullanıcı statüsü	Kullanmıyor, eski kullanıcı, potansiyel kullanıcı, ilk kullanıcı, düzenli kullanıcı
Kullanım sıklığı	Düşük, ortalama, yüksek
Farkında olma	Farkında değil, farkında, ilgili, satın almaya eğilimli
Ürüne yönelik tutum	Meraklı, pozitif, diğer ürünlerden farksız, negatif

Demografik Bazda Pazar Bölümlendirmesi:

Demografik bölümlendirmesi, yaş, cinsiyet, aile büyüklüğü, aile hayat çevrimi, gelir, meslek, eğitim, din, ırk ve uyruk gibi demografik özelliklere göre pazarı gruplamaktır. Müşteri grupları yaratmak için en sık kullanılan değişkenlerdir. Bunun nedeni, tüketici talepleri, tercihleri ve kullanım oranları, demografik değişkenlerle yüksek oranda ilişkilidir. Diğer bir nedeni ise, diğer değişkenlere göre daha kolay ölçülebilir olmasıdır. Aşağıda, demografik değişkenlere göre örnek segmentasyonlar yer almaktadır:

- Yaş ve Hayat Çevrimi Aşaması: Bir bebek oyuncakları üreticisi, üç aylık bebekten bir yaşındaki bebeğe kadar farklı aşamalar için farklı oyuncaklar üretmektedir.

Örneğin bazı oyuncaklar, bebeğin belirli şeylere ulaşma aşaması için tasarlanmışken, bazı oyuncaklar, bebeğin tutma kabiliyetinin geliştiği aşama için tasarlanmıştır. Diğer yandan yaş değişkeni her zaman doğru yaklaşımı getiren bir değişken olmayabilir. Örneğin, Ford spor arabalar üretirken gençleri hedeflemiştir; ancak tüketicilerinin kendilerini genç hissedenler olduğunu fark etmiştir. Neugartens' araştırmasına göre, yaş, hayat aşamalarını belirlemede zayıf bir değişken olduğu gibi, kişilerin sağlık durumları, çalışma durumları, aile durumları ve dolayısıyla ilgileri ve ihtiyaçlarını belirlemede de zayıftır; 70 yaşında tekerlekli sandalyede olan bir kişi olabileceği gibi 70 yaşında tenis oynayan bir kişi de olabilir. Aynı şekilde, 35 yaşında bir kişi, çocuklarını okula gönderirken, 35 yaşındaki diğer bir kişi, yeni doğmuş bebeği ile ilgileniyor olabilir.

- Cinsiyet: Cinsiyet bazlı segmentasyon, tekstil, kuaför, kozmetik ve magazin alanlarında uzun zamandır uygulanmaktadır. Diğer alanlarda da cinsiyet bazlı segmentasyonun getireceği fırsat fark edilecektir. Örneğin sigara pazarında, baylar ve bayanların tercih ettiği birçok sigara markasının farklı olduğu anlaşılmış ve Eve gibi bayanlara yönelik markalar çıkarılmaya başlanmıştır.

- Gelir: Otomobil, tekne, tekstil, kozmetik ve seyahat gibi alanlarda yapılan segmentasyon için kullanılan bir değişkendir. Belirli bir ürün için gelir seviyesi, en iyi müşterileri her zaman belirlemiyor olabilir. Örneğin, renkli televizyonlar ilk çıktığında, ilk satın alıcılar mavi yakalıları olmuştur; bunun nedeni, televizyon satın almanın, sinemaya ve restoranta gitmekten daha ekonomik olmasıdır. Coleman her bir sosyal sınıf için "önceliği yüksek" ve "önceliği düşük" segmentler arasında fark olduğunu bulmuştur. Ekonomik otomobiller, gerçekten maddi olanağı düşük kişilerce satın alındığı gibi, ait olduğu sosyal sınıfa göre kendisini daha aşağıda gören kişilerce de satın alınmaktadır; daha pahalı bir araba almak, giyime ya da eve harcayacakları miktarı azaltacaktır.

Birden Fazla Demografik Değişken ile Segmentasyon:

Birçok firma, iki ya da daha fazla demografik değişkeni birleştirerek segmentasyon yapmaktadır. Örneğin, bir banka kurumsal müşterilerini yaş ve gelir değişkenlerini baz alarak Şekil 1-2'de görüldüğü gibi bölümlendirilebilir [1].

Tablo 1-3. Bir Bankanın Bireysel Müşterilerini Yaş ve Gelire Göre Bölümlendirmesi

		Yaş		
		39 altı	40-64	65 üstü
Gelir	16.000 USD'nin altında	Genç, düşük gelirli	Orta yaşlı, düşük gelirli	Emekli, düşük gelirli
	16.000 USD-44.000 USD	Genç, orta gelirli	Orta yaşlı, orta gelirli	Emekli, orta gelirli
	44.000 USD'nin üzerinde	Genç, yüksek gelirli	Orta yaşlı, yüksek gelirli	Emekli, yüksek gelirli

Psikografik Bazda Pazar Bölümlendirmesi:

Tüketiciler, sosyal sınıf, yaşam biçimi ve/veya kişilik bazında farklı gruplara ayrılırlar. Aynı demografik gruptaki kişiler farklı psikografik profillere sahip olabilir.

- Sosyal Sınıf: Kişilerin bulunduğu sosyal sınıf, kişinin araba, giyim, ev eşyası, boş zaman aktiviteleri, okuma alışkanlıkları gibi birçok tercihinde güçlü etkiye sahiptir. Birçok firma, belirli sosyal sınıflar için ürün ya da hizmet tasarlamaktadır.

- Yaşam Biçimi: Kişilerin ürünlere olan ilgileri, yaşam biçimlerinden etkilenmektedir. Aslında, tükettikleri ürünler, yaşam biçimlerini yansıtmaktadır.

Volkswagen, “iyi vatandaş” için ekonomiyi, güvenliği ve ekolojiye olan saygıyı vurgulayan araçlar pazarlamaktadır. Diğer yandan “otomobile ilgisi” olan kişiler için de manevra ve hız kabiliyeti ve sportif özelliklerini ön plana koyan arabalar pazarlamaktadır.

Kozmetik, alkollü içecekler ve ev eşyası satan firmalar, yaşam biçimini baz alarak yapılan segmentasyonlardan yararlanmaktadır. Diğer yandan, yaşam biçimini baz alarak yapılan segmentasyon da her zaman doğru sonuca ulaştırmayabilir; örneğin Nestle uyku problemi çeken kişiler için Amerika’da kafeinsiz kahve piyasaya sunmuş ancak başarılı olamamıştır.

- Kişilik: Firmalar, ürün kişiliklerini tüketici kişilikleri ile özdeşleştirmeye çalışmaktadırlar. Örneğin Ford tüketicileri “bağımsız, maskulin, değişime açık ve kendine güvenen” kişiler olarak algılanırken, Chevrolet tüketicileri “prestij öncelikli,

tutucu, daha az maskulin, aşırı uçlardan kaçınan” kişiler olarak algılanmaktadır. Nike, reklamlarında basketbol yıldızı Michael Jordan’ı kullanarak, Michael Jordan fanatiklerini Nike ayakkabılar almaya yönlendirmeyi hedeflemiştir.

B-Ürünlerle ilgili değişkenlere göre bölümlendirme

Kişiler, bilgi, davranış, bir ürünü kullanma bazında da bölümlendirilebilirler. Birçok pazarlamacı, pazar segmentleri yaratmak için davranışsal segmentasyonun en iyi başlangıç noktası olduğunu düşünmektedir.

- Kullanım Alanları: Firma, bir ürüne ne zaman ihtiyaç duyulduğu, ürünün ne zaman satın alındığı ve ne zaman kullanıldığı bilgilerine göre bölümlendirmesi yapabilir. Örneğin, portakal suyu yoğunlukla sabah kahvaltılarında tüketilmektedir. Firma, portakal suyunun öğle yemeği, akşam yemeği gibi diğer zamanlarda da kullanımı için promosyonlar gerçekleştirebilir.

- Faydalar: Tüketiciler, üründen bekledikleri farklı faydalara göre bölümlendirilebilir. Fayda baz alınarak yapılmış en başarılı pazar bölümlendirmesi Haley tarafından diş macunu pazarında yapılmıştır. Araştırma, 4 adet fayda kategorisi kapsamaktadır: ekonomik, tıbbi, kozmetik, tat. Her bir fayda arayan tüketicinin farklı demografik, davranışsal ve psikografik özellikleri vardır. Her bir bölüm, aynı zamanda belirli markalar tercih etmektedir.

- Kullanım Statüsü. Kullanıcılar; hiç kullanmayanlar, eski kullanıcılar, potansiyel kullanıcılar, ilk kullanıcılar ve düzenli kullanıcılar olmak üzere bölümlendirilebilir. Örneğin kan bankaları, düzenli kan bağışlayıcılara güvenmemeli, daha önceden kan bağışlamış kişilerle iletişim kurmalı, ilk defa kan verecek kişiler için farklı stratejiler geliştirmelidir. Pazar payı için mücadele eden firmalar, potansiyel kullanıcıları da hedef alırken, küçük firmalar, sadece mevcut kullanıcıları hedef alırlar.

- Kullanım Oranı. Ürünü az/orta/çok kullanma oranına göre de bölümlendirmesi yapılabilir. Ürünü sıklıkla kullanan tüketicilerin oranı oldukça düşüktür. Ürünü sık kullanan kullanıcıların genellikle demografik, psikografik vb. alanlarda ortak özellikleri vardır. Örneğin sıklıkla bira içenler 20 ile 50 yaş arası, çalışan sınıfta yer alan ve çok televizyon – ve özellikle spor programları – seyreden bir profile sahiptir. Bu tip profiller, pazarlama stratejilerini hazırlayan kişilere fiyat, mesaj ve medya stratejileri konusunda ipuçları vermektedir.

- Sadakat Durumu. Tüketiciler, belirli bir markaya (Coca Cola), belirli bir alışveriş merkezine (Sears) vs. sadık olabilir. Sadakat durumu dört şekilde görülür:

- Çok sadık tüketici: Her zaman aynı ürün satın alınmaktadır. Bu tip satın alma davranışının, tüketicinin memnuniyetinden mi yoksa alışkanlık, diğer ürünlerden farksızlık, düşük maliyet, yüksek ürün değiştirme maliyeti ya da diğer ürünlere ulaşamama etkenlerinden mi kaynaklandığı araştırılmalıdır.
- Kısmi sadakat: Tüketici iki ya da daha fazla ürüne birden sadıktır. Birçok tüketicinin aklında, eşdeğer ürün yargısı mevcuttur.
- Değişken sadakat: Tüketici, tercih ettiği bir ürünün başka bir ürüne geçebilir.
- Geziciler: Tüketiciler, hiçbir markaya sadakat göstermemekte; her satın alma döneminde farklı bir ürünü tercih etmektedir.

- Farkında Olma. Pazar, satın almanın değişik evrelerinde olan tüketicilerden oluşmaktadır. Bazı tüketiciler, üründen haberdar, bazıları haberdar değil, bazıları almak için isteklidir. Hangi durumda kaç adet tüketicinin olduğunun bilinmesi pazarlama programı oluşturulması açısından önemlidir. Örneğin, bir özel hastanede az sayıda mamografi çektiren bayan varsa; bayanların ilgisini çekmek ve bilgi düzeyini artırmak için bir takım eğitici ve bilgilendirici aktiviteler yapılabilir.

- Tutum. Politik kampanyalar nedeniyle kapı kapı gezen çalışanlar, karşısındaki kişinin tutumuna göre, ilgili kişiye zaman ayırırlar. Olumsuz kişilerin tutumlarını hiç değiştirmemeye çalışırken, hevesli kişilere teşekkür eder ve oy kullanmaları yolunda hatırlatma yaparak yetinirler [1].

Görüldüğü gibi işletmeler pazar bölümlendirmesi kriterlerini kullanarak önemli hedef pazar fırsatları yakalamaktadırlar. Ürettikleri mal ya da hizmetler açısından rekabetin derecesini, gücünü, tüketici isteklerini ve tatmin derecelerini daha iyi belirleme imkanı bulmaktadırlar. Farklı pazar bölümlerinin pazarlama çabalarına karşı gösterdikleri tepkiler de daha iyi belirlenebildiğinden, toplam pazarlama çabaları ve bütçesi daha iyi bölüştürülmekte ve planlanabilmektedir.

Sözü geçen başlıklar altında yer alanlardan bazıları gözlemlenebilir, bazıları gözlemlenemez değişkenlerdir. Bu kriter de göz önüne alındığında pazar bölümlendirmesi sürecinin değişkenleri Tablo 1-3'te yer aldığı gibi gruplanabilir [4]:

Tablo 1-4. Pazar Bölümlendirmesi Kriterleri

	Tüketici spesifik	Ürün spesifik
Gözlemlenebilir	Kültürel, coğrafik, demografik ve sosyoekonomik değişkenler	Kullanım durumu, kullanım sıklığı, ürün sadakati
Gözlemlenemez	Psikografik, değerler, kişilik ve yaşam tarzı	Psikografik, faydalar, algılamalar, tercihler, içsel eğilim

Bir firma, her tüketici için farklı ürün ya da pazarlama aktivitesi sunmak isteyebilir. Örneğin Boeing, kısıtlı sayıdaki havayolu müşterisi için uçak üretmektedir ve her bir müşterisinin talebi doğrultusunda, ürününü yenilemektedir. Bu tip pazar bölümlendirmesine talep bazlı pazarlama (customized marketing) denilmektedir.

Çok sayıda firma, her bir müşterisinin talebi doğrultusunda ürününü özelleştirmeyi karlı bulmamaktadır. Bunun yerine tüketicileri sınıflandırmaktadır. Örneğin, satıcı, farklı gelir seviyesindeki insanların farklı ihtiyaçları olduğunu keşfedebilir. Bu durumda gelir seviyesine göre müşterilerini üç bölümde (alt-orta-üst gelir seviyeli) ayırabilir. Diğer yandan, firma, genç ve yaşlı satın alıcılar arasında farklılıklar olduğunu keşfedebilir; bu durumda yaş sınıfına göre 2 sınıf oluşturarak pazar bölümlendirmesi yapabilir. Hem gelir seviyesi hem de yaş, satın alıcının bir ürünü satın alma eğilimini etkileyebilir. Bu durumda, pazar 6 bölüme ayrılabilir [1].

Herhangi bir global pazarlama stratejisinin başarısı, pazarın nasıl bölümlendiğine bağlıdır. Tüketici psikolojisi ve davranışları ile ilgili araştırma, farklı müşterilerin aynı sunuşa farklı değerler kattığını göstermiştir. Ürünler, stratejiler, hedefler, belirli bir hedef pazara yönelik olarak geliştirilmelidir. Geçmiş çalışmaların çoğu, hizmetlerin değil ürünlerin pazarlarının bölümlendirmesinde, tüketici karakterlerinin belirlenmesi üzerine odaklanmıştır [5].

Pazar, Pazar Bölümü ve Niş Pazar

Pazar bölümleri, bir pazar içinde, özellikleri tanımlanabilir yüksek sayıda gruplardır. Niş pazarlar ise, özel fayda kombinasyonlarına sahip daha dar kapsamlı, tanımlanmış gruplardır. Bir satıcı, pazarı tanımladığı özellikleri artırdıkça, pazar bölümleri niş kümelerine dönüşmeye eğilim gösterir.

Pazar bölümleri, çok sayıda rakibin ilgisini çekerken, niş pazarlar daha az sayıda rakibin ilgisini çekmektedir. Niş pazarlar, müşterilerin ihtiyaçlarını daha net tanımlayabildiği için, müşteriler fiyat farkı ödemeyi göze almaktadırlar. Örneğin, Porsche otomobil müşterileri yüksek fiyat ödemeyi kabul etmektedir çünkü başka hiçbir otomobil firmasının Porsche kadar yüksek oranda ürün-hizmet-üyelik kombinasyonu sunamayacağını düşünmektedirler.

Değişik ihtiyaçları, özellikleri, davranışlarıyla pazarın bölümlendirilmesi firmalara bir çok yarar sağlamaktadır. Bu yararlar şunlardır:

- Kaynakların daha etkin kullanımını sağlar.
- Tüketici istek ve ihtiyaçlarının daha iyi kullanılmasını sağlar.
- Pazar bölümlendirme ile pazardaki rakipler daha iyi tanınmış olur.
- Pazara girerken amaçlar daha net belirlenmiş olur.
- Pazarda faaliyet sırası ya da sonrasında performans daha iyi değerlendirilir.

Tablo 1-4, pazar bölümlendirmesi sürecinde izlenmesi gereken aşamaları göstermektedir [2].

Tablo 1-5. Pazar Bölümlendirmesi Prosedürü

Pazar Bölümlendirmesi	Pazar Hedefleme	Ürün/Hizmet Konumlandırma
1. Pazar bölümlendirmesi değişkenlerini belirle	3. Her bir bölümün çekiciliğini değerlendir.	5. Her bir hedef pazar bölümü için olası konumlandırma kavramlarını belirle
2. Homojen Gruplar Belirle	4. Hedef pazar bölümlerini seç.	6. Seçilen konumlandırma kavramını geliştir ve gözlemle

1. Pazar bölümlendirmesi değişkenlerini belirleme: Pazar bölümlendirmesinin çıkış noktası, tüm pazarın incelenmesidir. Pazarı bölümlendirmesik için demografik, coğrafik vs. gibi farklı değişkenler kullanmak söz konusu olabilir. Tüketici pazarlarında genellikle demografik özellikler ve ürün tercih nedenleri baz alınarak pazar bölümlenir. Belirlenen bölümler altında yaşa, cinsiyete, tüketim kapasitesine vs. gibi değişkenlere göre alt gruplar oluşturulması da mümkündür [2]. Bu aşamada tutumlar ve önem sıraları, ürün kullanım alanları, ürün kategorisine olan yaklaşım, marka farkındalığı ve markaların önem sırası ve anketi yanıtlayanların demografik, psikografik ve medyagrafik özellikleri gibi bilgileri toplamak amacıyla anket yapılabilir [1].
2. Homojen Gruplar Belirle: Belirlenen gruplar içinde yer alan üyeler birbirleriyle homojen özelliklere sahip olmalıdır. Gruplar arasında ise heterojenlik söz konusu olmalıdır. Belirlenen grupların profillerinin belirlenmesi de önemli bir adımdır. Her bir küme, davranış, demografik vs. gibi ayırt edici özelliklere göre oluşturulur. Her bir bölüm, sahip olduğu baskın özelliğe göre isimlendirilebilir.
3. Her bir bölümün çekiciliğini değerlendir: Bu değerlendirme, firmanın finansal, pazarlama ve teknolojik hedefleri doğrultusunda gerçekleştirilir. Pazar çekiciliği, genel anlamda, uzun dönemli karlılığı ifade etmektedir. Pazarlama araştırması ya da tahmin yöntemleri kullanılarak, her bir pazar bölümünün toplam büyüklüğü ve firmanın ilgili bölümdeki pazar payı hesaplanabilir. Ardından, bölümler, göreceli çekicilikleri bazında sıralanabilirler.
4. Hedef pazar bölümlerini seç: Firma, kaç yıllık planlama yapıyorsa, o kadar dönem için hangi pazar bölümüne ya da bölümlerine kaynak aktaracağına karar vermelidir. Hedefleme yapıldıktan sonra, seçilen pazar bölümlerinin özgün özelliklerini belirlemek için tekrar pazarlama araştırması yapılabilir. Bu araştırma, rakiplerin güçlü ve zayıf yanlarını da ortaya koymalı; böylece firmanın rekabet fırsatlarını belirlemede yardımcı olmalıdır.
5. Her bir hedef pazar bölümü için olası konumlandırma kavramlarını belirle: Konumlandırma kavramlarını belirlemede, firmanın ürün hattı, fiyatlandırma

politikası, satış yöntemleri vs. önemli rol oynamaktadır. Firmalar tarafından sıklıkla yapılan hata, tüm müşterileri için aynı stratejiyi uygulamaktır. Pazar bölümlendirmesi ve hedefleme programları ile, farklı ihtiyaçları olan tüketici kitlelerine farklı pazarlama programları uygulanmaktadır.

6. Seçilen konumlandırma kavramını geliştir ve gözlemle: Gözlemleme yaparken, sadece firmanın pazar payına değil, diğer firmaların da pazar dinamiklerine de bakılmamalıdır. Bazı pazar bölümleri, sabit kalmamaktadır; sıklıkla müşteriler girebilir ya da çıkabilir.

Tablo 1-3'te, bir pazar, gelir ve yaş bilgilerini baz alarak farklı demografik segmentlere ayrılmıştı. Müşterilere ihtiyaçları sorulduğunda amaç, farklı tercihleri gruplamaktır.

Homojen tercihler: Pazardaki tüm tüketiciler yaklaşık benzer tercihlere sahiptir. Bu bilgiden yola çıkarak, mevcut markaların da benzer olduğu tahmin edilebilir.

Dağınık (diffused) tercihler: Tüketici tercihleri birbirinden çok farklıdır.

Gruplanan tercihler: Pazar, birbirinden farklı gruplar altında toplanabilen tercihlere sahiptir. Buna doğal pazar bölümleri denilmektedir.

1.4.2 Pazar Bölümlendirme Kriterleri

Etkin bir pazar bölümlendirmesi yapabilmek aşağıdaki temel koşulların varolması gerekmektedir.

- Pazar bölümlendirmesinin, firmanın pazarlama stratejisine uygunluğu: Bazı firmalar için, pazar bölümlendirmesi yapmak, mevcut pazarlama stratejilerine uygun değildir. Firma, tek bir ürün ile pazarlamasını devam ettirmek isteyebilir. Böyle bir durum, genellikle uzun dönemli bir ya da iki büyük firmayla satış anlaşması imzalandığında görülmektedir [2].
- Ölçülebilirlik: Hedef gruplar belirlenmeden önce, pazar bölümünde yer alan firma sayısı, bu firmaların satış potansiyeli ve diğer ilişkili değişkenlerin ölçülebilir olması gerekmektedir. Teknolojik alanda yaratıcılık gibi bazı değişkenlerin ölçülebilmesi zordur.

- Ulaşılabilirlik: Tek bir pazarlama programı ile bir pazar bölümüne ulaşımı ifade eder. Örneğin, firmanın satış teşkilatı ya da dağıtım kanalı ile şehir merkezine uzak bazı yerlere erişim mümkün olmayabilir. Bazı durumlarda, tüketicilere yüksek bir maliyet ile ulaşım söz konusu olabilir.
- Yeterlilik (Büyüklik): Seçilecek pazar bölümünün ayrı bir pazarlama çabası göstermeye degecek kadar büyük ve karlı olup olmadığı belirlenmelidir.
- Homojen Yapı: Oluşturulan grup içerisinde yer alan tüketici ihtiyaçlarının birbiriyle homojen, diğer gruplarla heterojen özellikler göstermesi gerekmektedir. Ancak böyle bir durumda, bir bölüm için belirlenen pazarlama programına, ilgili bölümde yer alan tüketiciler benzer tepkiler verecektir [2].
- Hareket Planı Oluşturulabilir: Bölümlere hizmet etmek için etkin pazarlama programları formüle edilebilir. Küçük bir havayolu şirketi, yedi adet pazar bölümü tanımlayabilir; ancak bu yedi pazara hizmet edebilecek kadrosu yoksa, her bir bölüm için ayrı bir pazarlama planı oluşturamayacaktır [1].

1.4.3 Pazar Bölümlerinin Değerlendirilmesi

Oluşan pazar bölümlerinin çekiciliğinin değerlendirilmesi için göz önünde bulundurulması gereken bir takım kriterler vardır:

Bölüm büyüklüğü ve büyümesi. Sorulması gereken ilk soru potansiyel pazarın doğru büyüklüğe ve büyüme karakteristiklerine sahip olup olmadığıdır. “Doğru büyüklük” farklı firmalara farklı anlamlar ifade edebilecek bir terminolojidir. Örneğin büyük firmalar yüksek satış hacimleri olan bölümleri tercih eder, küçük bölümlerden kaçınırken; daha küçük firmalar büyük bölümlerden kaçınmaktadırlar, çünkü büyük bölümler fazla kaynak gerektirmektedir.

Bölümün Yapısal Çekiciliği. Bir bölüm istenilen pazar büyüklüğüne ve büyümesine sahip olabilir; ancak istenilen derecede karlı bir pazar olmayabilir. Porter, bir bölümün uzun dönemli kar çekiciliği için beş güç tanımlamıştır:

Bölüm İçindeki Rekabet Tehdidi: Bir bölüm içerisinde güçlü ve çok sayıda rakip varsa, bu bölüm çekici değildir. Bu çekicilik; bölüm durağan ya da daralma

eğilimindeyse, sabit maliyetler yüksekse, pazardan çıkış bariyerleri yüksekse ya da mevcut firmalar, ilgili bölümde kalma konusunda çok istikrarlıysa, daha da azalmaktadır. Bu durumlar, fiyat, reklam savaşlarına, yeni ürünlere ve firmalar için rekabetin daha maliyetli hale gelmesine neden olmaktadır.

Yeni Giriş Tehdidi. Eğer bir bölüm, yeni rakipleri çekmekteyse, çekici değildir. Burada esas soru, pazarın girmenin ne kadar kolay olduğudur. En çekici bölüm, giriş bariyerleri yüksek, çıkış bariyerleri düşük olan bölümdür. Az sayıda yeni firma pazar bölümüne girecek, düşük performanslı firmalar kolaylıkla pazardan çıkacaktır. Hem giriş bariyerleri hem de çıkış bariyerleri yüksek olduğunda kar etme potansiyeli daha yüksektir; ancak bu aynı zamanda yüksek riski de beraberinde getirir. Çünkü güçlü firmalar hayatta kalmaya ve savaşmaya eğilim gösterirler. Hem giriş hem de çıkış bariyerleri düşük olduğunda ise, firmalar pazara kolaylıkla girer ve çıkar; bu da elde edilen karın düşük ya da sabit olmasına neden olmaktadır. En kötü durum, giriş bariyerleri düşük, çıkış bariyerleri yüksek olan pazardır; bu durumda firmalar, iyi zamanlarda pazara girer ve zor dönemlerde pazardan çıkmakta zorlanmaktadırlar. Her üç durum da, kapasite üzerinde çalışma ve kazançların düşük olması ile sonuçlanır.

İkame Ürünlerin Tehdidi. Bir ürüne ait mevcut ya da potansiyel ikame ürünler varsa, o pazar bölümü çekici değildir. İkameler, potansiyel fiyatlar ve elde edilecek karlar üzerinde bir limit belirlerler. Firma, ikame ürünlerin fiyatlarını yakından takip etmelidir. Eğer teknoloji ve rekabet artarsa, fiyatlar ve karlar daha da düşme eğilimi gösterecektir.

Satın Alıcıların Artan Pazarlık Gücü Tehdidi. Bir bölümde, satın alıcıların pazarlık gücü yüksekse, o bölüm çekici değildir. Satın alıcılar, fiyatları aşağıya çekmeyi ve daha yüksek kalitede ürün ve hizmet talep edeceklerdir.

Tedarikçilerin Artan Pazarlık Gücü Tehdidi. Bir pazar bölümünde, firma tedarikçileri fiyat artırabiliyor ya da kalite düşürebiliyorsa, o pazar bölümü çekici değildir. Tedarikçilerin ikameleri yoksa – az sayıda tedarikçi varsa – , tedarik edilen ürün önemli bir ürünse, bir tedarikçiden diğer bir tedarikçiye geçme maliyeti yüksekse ve tedarikçiler son ürüne doğru genişleyebiliyorsa (integrate forward) tedarikçiler, pazarda güç sahibidir. Bu duruma karşı en iyi savunma, birden fazla tedarikçi ile çalışma ve tedarikçi ile kazan-kazan ilişkisi kurmaktır.

Firma Hedefleri ve Kaynakları. Bir pazar bölümü hizmet edilebilecek kadar büyük, büyüme potansiyeline sahip ve yapısal olarak çekici olabilir. Bu kriterler, firmanın belirli bir pazar bölümüne girmesi için yeterli değildir. Firmanın kendi hedeflerini ve kaynaklarını gözden geçirmesi gerekmektedir. Bazı çekici pazar bölümlerine firmalar girmez çünkü bu durum firmanın uzun dönemli hedeflerine uymamaktadır. Pazar bölümü, firmanın hedeflerine uysa bile, ilgili bölümde başarılı olabilmek için gerekli kaynak ve yetkinliklere sahip olup olmadığını ortaya koymalıdır. Her pazar bölümü, bir takım başarı kriterlerine sahiptir.

1.5 Hedef Pazarın Seçimi

Firmalar, belirledikleri tüm pazar bölümlerine ürün ya da hizmet sunacak kadar kaynağa sahip olmayabilirler. Yeterli kaynak olduğunda bile, bazı bölümlere hizmet etmek karlı olmayabilir. Bu tip durumlar için, firma hedeflediği bölümleri ortaya koymalı ve her bir bölüm için ayrı bir strateji belirlemelidir. Bazı durumlarda, firmaların tüm pazar bölümleri için aynı stratejiyi uyguladığı görülmektedir. Böyle bir durumda, pazarı bölümlendirmiş olmanın bir faydası kalmamış olacaktır.

Hedef pazar seçiminde aşağıdaki yollardan biri izlenebilir:

Tek Bir Bölüme Odaklanmak. En basit anlamda, firma tek bir bölüme odaklanır. Örnek olarak Volkswagen'ın, küçük arabalara odaklanması verilebilir. Bölümün ihtiyaçları hakkında net bilgilere sahip olması, firmayı güçlü bir üne kavuşturacaktır. Ürünü, dağıtımı ve promosyonu üzerine uzmanlaşıldığından, ekonomiklik ön plana çıkacaktır. Firma, pazarda liderliği elde ederse, yatırımlarına yüksek oranda geri dönüş alacaktır. Riski yüksek bir stratejidir; çünkü hedeflenen pazar bölümünde olabilecek herhangi bir tehditten ya da olumsuzluktan direkt olarak ve büyük boyutlarda etkilenilecektir.

Seçici uzmanlaşma (selective specialization): Firma her biri hedeflerine uygun ve çekici pazar bölümlerini seçer. Bölümler arasında az sinerji olabilir ya da hiç sinerji olmayabilir; ancak her bir bölüm kar getirici görünmektedir. Bu strateji ile risk, pazarlar arasında bölünmüş olur. Bir bölüm, firma için çekiciliğini yitirse de, firma diğer bölümlerle karlılığına devam edebilecektir.

Üründe uzmanlaşma (product specialization): Firma, çok sayıdaki pazar bölümlerine satılmak üzerine belirli bir ürün üzerine odaklanır. Üniversite, resmi ve özel laboratuarlara mikroskop satan firma örnek olarak verilebilir. Bu örnekte, farklı firmalar için farklı mikroskoplar üretilmekte; ancak laboratuvarların ihtiyacı olabilecek diğer ürünler üretilmemektedir. Bu strateji ile firma yüksek bir üne sahip olacaktır. Mikroskoplar, farklı bir teknoloji ile ikame edilmesi durumunda bu stratejinin riski ortaya çıkacaktır.

Pazarda Uzmanlaşma (market specialization): Firma, belirli bir müşteri grubunun birçok ihtiyacına yönelmektedir. Üniversite laboratuvarları için mikroskop, osiloskop vs. gibi malzemeler yapan firma örnek olarak verilebilir. Böyle bir konumdaki firma, güçlü bir üne sahiptir ve hizmet verdiği alandaki yeni ürünler için bir ulaşım kanalı halini almaktadır. Üniversite laboratuvarları aniden bütçelerini kısarlar ve satın almalarını azaltırlarsa, bu stratejide risk oluşur.

Tüm pazarı kapsama(full market coverage): Firma tüm müşteri gruplarına hizmet vermeyi amaçlamaktadır. Sadece büyük firmalar, tüm pazarı kapsayabilir. Örnek olarak IBM (bilgisayar pazarı); Coca-Cola (içecek pazarı) verilebilir.

Hedef pazar seçimine uygulanabilecek adımlar aşağıda belirtilmiştir:

1. Pazar Bölümlerinin Geliştirilmesi: Her bir pazar bölümünün başarısını etkileyen bir takım dış faktörler mevcuttur. Bu faktörlere odaklanılması gerekmektedir. Bu faktörlerden bazıları, firma için beklenen talep miktarı, pazar bölümünün büyüklüğü ve beklenen büyüme miktarı, risk ile karşılaştırıldığında potansiyel kar, rekabet, rakiplerin sayısı, rakiplerin güçlü ve zayıf oldukları yönler, tüketici talepleri, teknoloji ve devlet uygulamalarıdır.
2. Kaynaklar: Firmanın, pazarın talebini karşılayıp karşılayamayacağı belirlenmelidir. Hem içinde bulunulan durum hem de gelecekteki durum açısından tüketici ihtiyaçları, teknoloji, talepler vs. gibi alanların göz önünde bulundurulması gerekir. Firma, bir pazar bölümünü hedeflerken, finansal durumunu, insan kaynağı durumunu ve kurumsal imajının bugünkü ve gelecekteki durumunu belirlemelidir. Güvenilir bir resmi yakalamak için, firmanın pazarlama, satış, üretim gibi tüm bölümlerinin kaynak altyapısına

teker teker bakılmalıdır. Bu deęerlendirmeler, pazar blmlerinin ihtiya duyduęu kaynaklar doęrultusunda yapılmalıdır. Bugnk ve gelecekteki kaynaklar arasında bir bořluk varsa, bu bořluk nedenleriyle birlikte deęerlendirilmeli, bu bořluęun giderilmesi zerine alıřılmalıdır. Eęer, bořluk giderilemeyecek kadar fazlaysa, bařka bir pazar blmne ynlenmekte fayda vardır.

3. Ynetim: Pazar blmnn, firma zerinde yarattıęı talep ile ynetimin beklentileri ve tercihleri karřılařtırılmalıdır. Arada bořluklar varsa, bu bořlukların giderilmesi zerine alıřılmalı, byk bořluklar sz konusuysa bařka bir pazar blmne ynlenilmelidir.
4. Organizasyon: Firma, pazar blmnde ihtiya duyulan ve kaynak ve ynetim seviyesinde bulunan bořlukların minimize edilmesi iin gerekli olan organizasyonel yetkinlikleri belirledikten sonra, bu yetkinliklerle mevcut yetkinliklerini karřılařtırmalıdır. Eksik yetkinlikler bazında, řirketin kltr, yapısı, ynetimi ya da politikalarında ne tip deęiřikliklerin yapılması gerektięi deęerlendirilmelidir. Genellikle deęiřimlerin birden fazla organizasyon zellięinde yapılması gerekmektedir. Yapılması gereken deęiřiklikler belirlendikten sonra, bu deęiřikliklerin gerekli zaman ierisinde yapılıp yapılamayacaęı ve kabul edilebilir bir risk ierip iermedięine bakılmalıdır. Belirlenen zaman iinde gerekleřmesi mmkn deęilse ya da yksek risk iermekteyse, bařka bir pazar blmne ynlenmek gerekecektir.

Wind ve Thomas, segment arařtırması modellerinde bir takım dinamiklerin de gz nne alınması gerektięini belirtmiřlerdir. Plank, geri besleme dnglerinde ve dinamik faktrlerde, limitli alıřmalar olduęunu; Hlavacek ve Reddy ise, literatrn, endstriyel pazar blmlerinin dinamik ve deęiřen doęasını ihmal ettięini gstermiřtir. Hlavacek ve Reddy, pazar blmlerinin uygulama ihtiyalarına bakılarak, rekabet aktivitelerinin ve teknolojik deęiřimlerin yaratacaęı etkinin belirlenebileceęini nermiřler; ancak bu sre iin izlenmesi gereken bir yol belirtmemiřlerdir.

Stratejik ynetimin amacı, srekli bir rekabet avantajına sahip olmaktır. Bu; deęiřen kořullara ayak uydurmakla mmkndr. Pazarın srekli olarak gzlenmesi, deęiřimlerin farkına varılması iin řarttır. Segmentasyon iřlemi sonulandıktan ve

stratejiler oluřturulduktan sonra, firmanın bařarısı iin kritik olan segment faktrlerini belirlemek nemlidir. Bu kriterlerden bazıları, segmentleri belirlerken kullanılan deėiřkenler olacaktır. Diėer kritik faktrler, teknolojik geliřimler, rakiplerin sundukları fırsatlar olabilir [6].



2 KÜMELEME ANALİZİ

Kümeleme analizi, dağınık bir halde bulunan verileri benzerliklerine göre bir araya getirip sınıflandırarak işlenebilir hale getiren çok değişkenli istatistiksel bir yöntemdir. Kümeleme analizi ayrıca “sınıflandırma analizi” ya da “sayısal taksonomi” olarak da adlandırılır.

Kümeleme analizinin iki özelliği aşağıdaki gibidir:


1. Oluşan her bir küme ya da grup, belirli bazı değişkenler bazında homojen özellikler göstermektedir; diğer bir deyişle, küme içindeki gözlemler birbirine benzerdir.
2. Belirli bazı değişkenler bazında, kümeler birbirinden farklı olmalıdır; diğer bir deyişle, kümeler arası gözlemler birbirinden farklıdır [7].

Benzerlik ya da homojenlik, analizden analize farklılık gösterebilir ve çalışmanın hedeflerine bağlıdır. Kümeleme analizi sübjektif özelliği çok fazla olan bir yöntem olması sebebiyle, sübjektifliği en aza indirmek amacıyla – literatürde bir çok araştırmacının ortak görüşü olarak- farklı kümeleme yöntemlerinin bir arada kullanılması ve beraber değerlendirilmesi gerekmektedir.

Kümeleme analizi ile kümelerin aldığı durum, değişkenler ile kümeler arasındaki ilişkilere basit ve kesin bir yapı kazandırmaktadır. Kümeleme işleminin sonucunda elde edilen kümeler gözlenen değişkenler üzerine oturtulmuş anlamlı hipotezlerdir.

Kümeleme analizi genel olarak, hiyerarşik kümeleme ve hiyerarşik olmayan kümeleme olmak üzere ikiye ayrılır. Hiyerarşik kümeleme, direkt olarak kümeleri oluşturmaz. Benzerlik ölçütü bakımından N adet gözlem arasında hiyerarşik ilişkiler kurar. Hiyerarşik olmayan kümeleme metodu ise, kaç adet kümenin çıktı olarak elde edileceği önceden bilindiği durumlarda kümeleme yapmaktadır.

Şekil 2-1’de, daha detaylı bir kümeleme metotları sınıflandırılması görülmektedir [4]. Bir tüketicinin birden fazla pazar bölümüne ait olduğu durumlarda çakışan kümeleme (overlapping clusters) söz konusudur. Bulanık kümelemede (fuzzy clusters) ise, tüketicinin bir pazar bölümüne “ait olma olasılığı” söz konusudur. Bulanık kümelemenin iki tekniği vardır: Karışık prosedürler (mixture procedures), kümelerin birbirleriyle örtüşmediğini varsayar; ancak elde bulunan verinin yetersizliği nedeniyle, herhangi bir gözlemin hangi kümeye kesin olarak ait olduğu bulunamamaktadır. Bu durumda her bir gözlem için, toplamı “1” olacak şekilde üyelik oranları belirlenir. Bulanık küme prosedürlerinde (fuzzy set procedures) ise, bir gözlemin birden fazla kümeye ait olması kesin bir özellik taşımaktadır.



Şekil 2-1. Kümeleme Metotlarının Sınıflandırılması

Kümeleme analizleri bir çok sebeple pazarlamada kullanılırlar; bu alanlardan iki tanesi:

1. Yeni Ürün Fırsatlarını Tanımlamak: Markalar ve ürünler kümelenecek pazardaki rakip gruplar belirlenebilir. Aynı kümedeki markalar birbirleriyle, başka kümelerdeki markalardan daha şiddetli şekilde yarışır. Bir firma yeni ürün fırsatlarını tanımlamak için halihazırdaki sunumlarını diğer rakiplerle karşılaştırarak gözden geçirebilir.
2. Pazar Bölümlendirmesi: Tüketiciler, bir ürünün satın alımından duyulan faydayı temel alarak kümelenebilir. Her küme ihtiyaç duydukları fayda

bakımından nispeten homojen olan tüketicilerden meydana gelir. Bu metot “fayda bölümlenmesi” adını taşır.

2.1 Kümeleme Analizi Teknikleri

Veri kümelerinin örtüşmediği durumda, iki adet kümeleme analizi tekniği vardır: Hiyerarşik ve hiyerarşik olmayan. Aşağıda, her iki yöntem de açıklanmaktadır:

2.1.1 Hiyerarşik Kümeleme

Hiyerarşik kümeleme genellikle gözlemler arasındaki ilişkileri gösteren bir ağaç yapısı ile sonlanır. Hiyerarşik kümelenin ilk amacı, hayvan türlerinin sınıflandırılması gibi veriler arası hiyerarşik ilişki kurmaktır. Ardından uygulama alanı genişletilerek pazarlamaya kadar uzanmıştır. Hiyerarşik küme, farklı benzerlik düzeyleri için farklı küme sayıları önermektedir.

Kümeler arası farklılıkları ölçmek için çok sayıda metot vardır. Bu metotlardan en sık kullanılanlar, merkezleme metodu (centroid method), en yakın komşu (nearest neighbourhood) ya da tek bağlantı metodu (single-linkage method), en uzak komşuluk (farthest neighborhood) ya da komple bağlantı metodu (complete-linkage method), ortalama bağlantı metodu (average-linkage method) ve Ward’s metodudur.

Merkezleme metodunda, iki küme arasındaki mesafe, merkezleri (tüm değişkenlerin ortalamaları) arasındaki mesafedir. Her defasında objeler gruplanır, yeni bir merkez hesaplanır. Tek bağlantı metodunda oluşan kümelerin merkezleri, minimum mesafe ya da en yakın komşu temelindedir. Kümelenen ilk iki obje, aralarında en az mesafe olmalıdır. Oluşan kümenin merkezi, kümede yer alan objelerden en az mesafeli olmalıdır. Her basamakta, iki küme arasındaki mesafe ikisinin en yakın noktalarının arasındaki mesafedir. İki küme aralarındaki en yakın tek bağlantı tarafından her hangi bir basamakta birleştirilirler. Süreç, tüm objeler bir kümede oluncaya kadar devam eder. Komple bağlantı metodu maksimum mesafe ya da en uzak komşu yaklaşıma temel olması dışında tekli bağlantıya yakındır. Komple bağlantıda, iki küme arasındaki mesafe aralarındaki en uzak iki noktanın mesafesi olarak hesaplanır. Bu metot, Hruschka ve diğerleri tarafından, ev aletlerinin, fiyat, promosyon ve marka

sadakati boyutlarını içererek satın alınma esnekleri bazında pazar bölümlendirmesi çalışmalarında kullanılmıştır [8]. Ortalama bağlantı metodunda iki küme arasındaki mesafe, iki kümede yer alan tüm obje çiftleri arasındaki ortalama mesafe alınarak bulunur. Görülebildiği gibi ortalama bağlantı metodu sadece minimum ve maksimum mesafelerde değil tüm mesafe çiftlerinde bilgi kullanır. Bu sebepten, tek ve komple bağlantı metotlarına tercih edilir.

Varyans metotları, küme içinde varyansı (within-cluster variance) minimize etmek için kümeler oluşturma çabasıdır. Çoğunlukla kullanılan varyans metodu Ward's prosedürüdür. Bu metotta, kümeler arası mesafeler ölçülmemektedir. Küme içi karelerin toplamı homojenliğin ölçümü için kullanılmaktadır. Tüm olası küme çiftleri için kümenin kareli Öklit mesafesi hesaplanır ve bu mesafeler tüm objeler için toplanır. Her basamakta küme içi mesafelerdeki kareler toplamı en küçük olan iki küme birleştirilir. Küme içi en düşük karelerin toplamı aynı zamanda hataların kareleri toplamı olarak da bilinmektedir.

$$\text{Hataların kareleri toplamı} = \sum_{k=1}^K \sum_{x_i \in C_k} \sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2 \quad (2.1)$$

$$\bar{x}_{kj} = \frac{1}{n_k} \sum_{x_i \in C_k} x_{ij} \quad (2.2)$$

ve x_{ij} i. objenin j. kümede olma değerini ifade eder. k, her bir aşamadaki toplam küme sayısıdır. n_j , j. kümedeki obje sayısıdır.

Analizin başlangıcında, her gözlem bir sınıftır; dolayısıyla hataların kareleri toplamı sıfıra eşittir.

2.1.2 Hiyerarşik Olmayan Kümeleme

İkinci tip kümeleme prosedürü hiyerarşik olmayan kümeleme metodudur ve çoğunlukla k-ortalamları kümelemesi kullanılır.

Hiyerarşik olmayan prosedürlerin ana dezavantajları küme sayılarının daha önceden belirlenmesi gerekliliği ve küme merkezlerinin seçiminin keyfi olmasıdır. Bu kümeleme metodu, ağaç şeklinde bir çıktı vermemektedir. Teknik, aşağıdaki adımları izler:

1. k başlangıç küme merkezleri seç; k istenilen küme sayısıdır.
2. Her bir gözlemi, kendisine en yakın kümeye at.
3. Önceden belirlenmiş durma kuralına göre, her bir gözlemi, merkezleri yeniden belirlenmiş k kümelerine tekrar dağıt.
4. Veri noktaları arasında değişim yoksa ya da verilerin tekrar kümelere dağıtılması, önceden belirlenmiş durma kriterini sağlıyorsa dur. Diğer takdirde 2 numaralı basamağa dön.

Hiyerarşik olmayan kümeleme metotları, (1) ilk belirlenen merkez değerleri; (2) gözlemlerin tekrar dağıtılması ile ilgili kural, bakımından farklılık göstermektedir.

Hiyerarşik olmayan kümeleme, hiyerarşik metotlardan daha hızlıdır ve objelerin ya da gözlemlerin sayısı büyük olduğunda değeri vardır. Hiyerarşik olan ve hiyerarşik olmayan metotların beraber kullanılması önerilir. İlk olarak, ortalama bağıntılı ya da Ward's metodu gibi birincil kümeleme çözümü hiyerarşik prosedür kullanılarak elde edilir. Elde edilen kümelerin sayısı ve küme merkezlemeleri sayısı hiyerarşik olmayan kümeleme metoduna girdi olarak kullanılır [7].

Bu çalışmada ortalama bağıntılı hiyerarşik kümeleme prosedürü ve ardından hiyerarşik olmayan kümelemenin k -ortalamaları metodu kullanılmıştır. K -ortalamaları metodu, her bir objeyi, objeye en yakın merkezde bulunan kümeye atar. Analizin başlangıcında, k rastsal merkezlerle başlanır ve tüm objeler belirli sayıdaki kümelere dağıtılır. Ardından küme merkezleri tekrar hesaplanır ve aynı işlem artık kümeler arasında değişiklik olmayana kadar devam eder. Aynı zamanda küme içindeki varyansların da minimize edilmesi gerekmektedir.

2.2 Kümeleme Analizi ile İlişki Kuran İstatistikler

Aglomerasyon şedülü: Bir aglomerasyon şedülü, hiyerarşik bir kümeleme yönteminde her aşamada birbirine bağlanmış objeler veya durumlar üzerine bilgi verir. Şekil 2-2’de, uygulamada kullanılan 650 adet veriden 40 tanesi alınarak elde edilen aglomerasyon şedülü gösterilmiştir. Birinci basamakta, on altıncı veri ile otuz yedinci verinin birleştirildiği görülmektedir. “Next stage” kolonunda 12 sayısının görülmesinin sebebi, on ikinci basamakta bu iki değerin birinci veriyle birleşiyor olmasıdır. Bu durum, “Stage” kolonunda “12” rakamı varken, “Cluster 1” kolonunda “1”, “Cluster 2” kolonunda “16” rakamının görülmesinden yorumlanmaktadır.

Küme merkezleri: Hiyerarşik olmayan kümelerde ilk başlangıç noktalarıdır. Kümeler bu merkezlerin etrafında oluşurlar.

Dendrogram: Bir dendrogram, ya da ağaç grafiği, kümeleme sonuçlarını gösteren grafiksel bir araçtır. Dikey çizgiler bir araya gelmiş kümeleri temsil ederler. Üzerindeki çizginin pozisyonu kümeler bir araya geldiğinde uzaklıkları gösterir. Dendrogram soldan sağa okunur. Şekil 2-3’de, uygulamada kullanılan 650 adet veriden 40 tanesi alınarak elde edilen dendrogram gösterilmiştir. Dendrograma göre, 16, 37, 1, 9 ve 15 numaralı veriler, birbirlerine yakın mesafede oldukları için analizin başında birleşmişlerdir. Bu küme daha sonra 27 numaralı veriyle mesafe 5 olduğunda birleşmiştir. Bu da, 27 numaralı verinin, 16, 37, 1, 9 ve 15 numaralı verilere uzak olduğunu göstermektedir. Diğer yandan, 17 numaralı verinin, diğer tüm verilere uzak olduğu, yine dendrogramdan anlaşılmaktadır.

Küme üyeliği: kümelerin hangi obje ya da durumlara sahip olduğunu gösterir.

Küme merkezleri arasındaki uzaklık: Bu uzaklıklar kümelerin bireysel çiftlerinin nasıl ayrıldığını gösterir.


Agglomeration Schedule

Stage	Cluster Combined		Coefficients	Stage Cluster First Appears		Next Stage
	Cluster 1	Cluster 2		Cluster 1	Cluster 2	
1	16	37	.000	0	0	12
2	31	34	.000	0	0	4
3	20	33	.000	0	0	10
4	3	31	.000	0	2	8
5	18	30	.000	0	0	11
6	8	29	.000	0	0	17
7	24	26	.000	0	0	8
8	3	24	.000	4	7	23
9	14	23	.000	0	0	14
10	11	20	.000	0	3	19
11	2	18	.000	0	5	18
12	1	16	.000	0	1	16
13	9	15	.000	0	0	16
14	5	14	.000	0	9	26
15	6	13	.000	0	0	31
16	1	9	.000	12	13	20
17	4	8	.000	0	6	22
18	2	7	.000	11	0	25
19	11	36	1.000	10	0	28
20	1	27	1.000	16	0	24
21	12	25	1.000	0	0	31
22	4	19	1.000	17	0	32
23	3	10	1.000	8	0	24
24	1	3	1.333	20	23	30
25	2	40	2.000	18	0	29
26	5	32	2.000	14	0	34
27	22	28	2.000	0	0	29
28	11	21	2.250	19	0	32
29	2	22	2.400	25	27	35
30	1	38	2.500	24	0	34
31	6	12	2.500	15	21	36
32	4	11	2.850	22	28	35
33	17	35	3.000	0	0	39
34	1	5	3.154	30	26	36
35	2	4	3.206	29	32	37
36	1	6	3.838	34	31	38
37	2	39	4.375	35	0	38
38	1	2	5.048	36	37	39
39	1	17	5.447	38	33	0

Şekil 2-2. Aglomerasyon Şedülü Örneği

Dendrogram

*** H I E R A R C H I C A L C L U S T E R A N A L Y S I S ***
Dendrogram using Average Linkage (Between Groups)



Şekil 2-3. Dendrogram Örneği

Buz saçağı diyagramı; Kümeleme sonuçlarının grafik gösterimidir. Böyle adlandırılmasının sebebi saçaklardan sarkan buz sıralarına benzemesidir. Sütunlar kümelenen objelere, sıralar (diziler) kümelerin sayılarına karşılık gelir. Buz saçağı diyagramı aşağıdan yukarıya okunur. Şekil 2-4'te uygulamada kullanılan 650 adet veriden 40 tanesi alınarak elde edilen buz saçağı diyagramı gösterilmiştir. Örneğin üç sınıf olması istenirse, 35 numaralı veri ile 17 numaralı verinin bir küme; 39, 21, 36, 33, 20, 11, 19, 29, 8, 4, 28, 22, 40, 7, 30, 18 ve 2 numaralı verilerin başka bir küme, geriye kalan tüm verilerin de ayrı bir küme oluşturacağı şeklinde yorumlanır.

Vertical Icicle

Number clust	Case																																						
	35	17	39	21	36	33	20	11	19	29	8	4	28	22	40	7	30	18	2	25	12	13	6	32	23	14	5	38	10	26	24	34	31						
1	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
2	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
3	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
4	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
5	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
6	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
7	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
8	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
9	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
10	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
11	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
12	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
13	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
14	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
15	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
16	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
17	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
18	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
19	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
20	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
21	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
22	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
23	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
24	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
25	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
26	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
27	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
28	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
29	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
30	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
31	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
32	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
33	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
34	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
35	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
36	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
37	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
38	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					
39	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x					

Şekil 2-4. Buz Saçağı Diyagramı Örneği

Kümeleme Analizinde Adımlar

İlk basamak kümelemenin temel alacağı değişkenlerin tanımlanarak kümeleme problemlerinin formüle edilmesidir. Sonra, uygun bir mesafe ölçüsü seçilmelidir. Mesafe ölçüsü kümelenen objelerin ne kadar benzer ya da benzer olmadıklarına karar

vermekte kullanılır. Birçok kümeleme prosedürü geliştirilmiştir ve araştırmacı elindeki problem için uygun olan birini seçmelidir. Kümelerin sayısına, araştırmacının karar vermesi gerekir. Oluşturulmuş kümeler değişkenlerin kümelenmesi bakımından yorumlanmalı ve güvenli değişkenler bakımından profile edilmelidir. Sonuç olarak, kümeleme yönteminin geçerliliği tayin edilmelidir [7].

Problemi formüle etmek:

Bir kümeleme problemini formüle etmenin en önemli tarafı, kümelemenin temel alındığı değişkenleri seçmektir. Bir ya da iki konu dışı değişkenin kapsanması bile başka türlü bir kümeleme çözümünü önerir. Temel olarak, seçilen değişken grubu pazarlama araştırmaları problemine uygun olması bakımından objeler arasındaki benzerliği tarif etmelidir. Değişkenler; geçmiş araştırmalar, teori ya da test edilen hipotezlerin karara bağlanması temelinde seçilmelidir.

Mesafe ya da benzerlik ölçüsü seçimi;

Kümelemenin amacı benzer objeleri bir araya getirip gruplamak olduğundan objelerin ne kadar benzer ya da farklı olduğunu tayin edebilmek için bazı ölçülere ihtiyaç vardır. Hiyerarşik kümeleme algoritmaları, verilerin göreceli benzerlikleri üzerine kurulmaktadır. Kullanılacak benzerlik ölçüsü, analizi yapan kişi tarafından seçilir ve ölçümlerin metrik ya da metrik olmamasına ve istenilen benzerlik tipine bağlıdır. Hangi benzerlik ölçüsünün seçilmesi gerektiğine dair net kurallar mevcut değildir.

En sık kullanılan yöntem obje çiftleri arasındaki mesafe bakımından benzerliğin ölçülmesidir. Birbirleriyle arasındaki mesafe az olan objeler birbirlerine daha benzerken, birbirinden uzak olanlar daha ayrıdır. İki obje arasındaki mesafeyi hesaplamanın bir çok yolu vardır. En fazla kullanılan yakınlık ölçüsü “Öklid mesafesi” ya da onun karesidir. Öklid mesafesi her değişken için kare farklarının toplamının kare köküdür. Diğer yakınlık ölçüleri de mevcuttur. “Şehir bloğu” (city-block) ya da “Manhattan mesafesi” (Manhattan distance) iki obje arasındaki her bir değişken için olan mutlak farkın toplamıdır. İki obje arasındaki “Chebychev mesafesi” de herhangi bir değişken için olan maksimum mutlak farktır.

Bazı durumlarda, kümelemeden önce “O” ortanca ve bir birleşme standart sapması için her bir değişkeni yeniden ölçeklendirerek verileri standartlaştırmak

gerekmektedir. Standartlaştırma, ölçü etkisini kaydırabilmesi nedeniyle grupları ve kümeleri en iyi ayırabilen değişkenler üzerindeki gruplar arasındaki farkı azaltabilir.

Değişik mesafeli ölçümler değişik kümeleme sonuçlarına erişebilir. Bu yüzden değişik ölçümleri kullanmak ve bunların sonuçlarını karşılaştırmak mümkündür. Mesafe ya da yakınlık ölçüsünü seçtikten sonra kümeleme prosedürü seçilmelidir.

Bir kümeleme prosedürü seçimi ;

Kümeleme prosedürleri hiyerarşik olabilir veya hiyerarşik olmayabilir. Hiyerarşik kümeleme bir hiyerarşinin ya da ağaç benzeri bir yapının geliştirilmesi ile karakterize edilebilir. Toplaşım kümeleme (Agglomerative) ayrı bir kümedeki her bir obje ile başlar. Kümeler objelerin büyük, daha büyük kümelere gruplanmasıyla oluşur. Bu yöntem; tüm objeler tek bir kümenin üyesi oluncaya kadar devam eder. Bölünür (Divisive) kümeleme tüm objelerin tek bir kümede gruplanması ile başlar. Kümeler her obje ayrı bir kümeye gidinceye kadar bölünür.

Kümeleme metodu seçimi ile mesafe ölçümü seçimi birbiriyle bağlantılıdır. Örnek olarak karelenmiş Öklid mesafeleri ile Ward's metodu beraber kullanılmalıdır. Bir çok hiyerarşik olmayan prosedürde karelenmiş Öklid mesafeleri kullanılır.

Kümelerin sayısına karar verme

Kümeleme analizindeki ana konu kümelerin sayısına karar vermedir. Kesin ve hızlı kurallar olmamasına karşın bazı bilgi verici, rehberlik eden bilgi mevcuttur.

Kuramsal ve pratik düşünceler belirli bir küme sayısını önerebilir. Örneğin, kümelemenin amacı pazar bölümlerini tanıtmaksa, yönetim bölümü belirli bir küme sayısı isteyebilir.

Hiyerarşik kümelemede kümelerin birleştiği mesafeler kriter olarak kullanılabilir. Aglomerasyon şedülünde katsayı, değerin ani sıçradığı basamağın sayısının bir fazlası küme sayısı olarak ele alınır. Hiyerarşik olmayan kümelemede toplam grup içi varyansın gruplar arası varyansa oranı, küme sayısı olarak kullanılabilir. Kümelerin nispi sayısı anlamlı olmasına dikkat edilmelidir.

Kümeleri Yorumlama ve Profilleme

Her bir küme, belirli bazı değişkenler açısından ortak ya da benzer özelliklere sahiptir. Her bir bölüm, sahip oldukları bu baskın özelliklere göre isimlendirilebilir.

Kümeleri profile etmek genellikle demografik, psikolojik, ürün kullanımı, medya kullanımı vb. gibi değişkenleri belirlemek bakımından yararlıdır. Baskın olan özellikler doğrultusunda firma gerekli kaynaklarını belirler ve kaynak aktarımı yapar.

2.3 Geçerliliği ve Güvenirliği Tayin Etmek

Kümeleme Analizi ile elde edilen sonuçların geçerliliğini ve güvenirliliğini test etmek için farklı metotlar vardır:

- i-) Farklı mesafe ölçüleri kullanılarak aynı veri üzerinde kümeleme analizi uygulayın. Çözümlerin sağlamlığını karşılaştırmak için ölçülere karşı sonuçları karşılaştırın.
- ii-) Değişik kümeleme metotlarını ve sonuçları karşılaştırın.
- iii-) Veriyi rastsal olarak yarıya bölün. Her iki yarıyı da ayrı ayrı kümeleme yapın. İki alt model karşısında küme merkezleştirmelerini karşılaştırın.
- iv-) Değişkenleri rastsal olarak seçin. Azaltılmış değişken grubu temelinde kümeleme yapın sonuçları tüm değişken grubu temelinde yapılan kümeleme ile karşılaştırın.

2.4 Pazar Bölümlendirmesinde Kümeleme Yaklaşımı

Pazar bölümlendirmesine kümeleme analizi uygulaması Singh (1990) tarafından yapılmıştır. Analizin amacı, verilen bir hizmet karşılığında tatmin olmayan ve bu nedenle farklı şikayet tutumları gerçekleştiren tüketici bölümlerini belirlemektir. 4 alanda araştırma yapılmıştır: manav alışverişi, otomobil tamir hizmeti, tıbbi bakım hizmeti ve banka hizmeti. Rastsal bir seçimle telefon yoluyla kullanılabilir 465

kişinin verisine ulaşılmıştır. 10 adet şikayet tutumu, onaylayıcı faktör analizi (confirmatory factor analysis) yöntemi ile 3 faktöre indirilmiştir. Faktörlerin isimleri Gürültü (satıcıya yönlendirilen şikayetler), Özel (arkadaşlara/akrabalara yapılan şikayetler) ve Üçüncü Taraf (alışverişe dahil olmayan gruba yapılan şikayet). İlk analizde verilerin yarısı alınmıştır. Hiyerarşik metot (Ward's metodu) kullanılmış ve hiyerarşik yapı üç ile yedi segment arası bir segment sayısı önermiştir. Hiyerarşik olmayan k-ortalamaları metodu, üç segmentten yedi segmente kadar her bir segment için uygulanmıştır. Benzer bir analiz, ilk analizde dışarıda tutulan veriler için de yapılmış; iki örneklem arası ilişkiye bakılarak geçerlilik testi gerçekleştirilmiştir. Dört segment, en fazla uyuşmayı göstermiştir. Buna göre, Pasifler (passives) – örneklemin % 14'ü – her üç faktör bakımından da ortalamanın altında şikayet davranışı sergileyen tüketicilerdir. Gürültücüler (voicers) – örneklemin % 37'si – özel ve üçüncü parti faktörlerinde ortalamanın altında şikayet davranışı sergileyen tüketicilerdir. Öfkeli (irates) – örneklemin % 21'i – sadece arkadaşlarına/akrabalarına şikayet etme faktöründe ortalamanın üzerindedir. Aktivistler (activists) – örneklemin % 28'i – her üç boyutta da ortalamanın üzerinde şikayet tutumu gerçekleştiren tüketicilerdir [4].

Tüketici davranışlarının bölümlendirilmesi için kümeleme metotları yaygın olarak kullanılmıştır [9-10]. Pazar bölümlendirmesi, tüketiciler genellikle psikografik, demografik ve elde ettikleri yararlar [11] ya da davranışsal değişkenler [12-13] temeline dayanmaktadır. İkincil olarak, çok sayıda araştırma tüketici tercihleri ya da tercih verilerinden pazar yapısı elde etmeyi hedeflemiştir. Marka değiştirme verisi, sadık olan ve hiçbir ürüne sadık olmayan tüketicilerin bölümlendirilmesinde geniş olarak kullanılmıştır [14-15]. Diğerleri, satın alma sıklıklarını ya da dağınık panel verilerini, pazar yapısını belirlemek için kullanmıştır [16-17]. Üçüncü ve son olarak, birçok araştırma pazar yapısı analizleri ile pazar bölümlendirmesi metotlarının kombinasyonu kullanılmıştır. Wedel ve Steenkamp, bulanık pazar yapılarını (fuzzy market structure) ve bulanık fayda segmentlerini (fuzzy benefit segments) tahmin eden genelleştirilmiş bulanık küme konumunda regresyon yaklaşımı (generalised fuzzy clusterwise regression approach) geliştirmiştir [18].

Diğer bir yaklaşımda ise, kümeleme analizi, diskriminant analizi gibi tekniklerle tek basamaklı analizler (örneğin ilk basamakta verileri kümelemek, ikinci basamakta verileri yorumlamak) kullanılmasının yetersizliği bir çok çalışma ile ortaya


konmuştur [21]. Grover ve Srivinassan, marka seçim olasılıklarının hem pazar yapısını hem de pazar bölümlerini tanımladığını göstermiştir [15]. Shugan, pazar yapısını, tüketici segmentasyonunu ve fiyat duyarlılığını ortak bir çerçeve altına toplamıştır [19]. Kamakura ve Russel gözlemlenen satın alma verilerinden marka ve satın alma faydalarını, tercihler bazında küçük segmentlere ayırmıştır [20].

Sözü geçen tekniklerin lineer bazlı olması sebebiyle, birtakım sıkıntılar daha doğurması, yapay sinir ağlarının kullanımını gündeme getirmiştir. Birçok geleneksel veri analizi aracının, yapay sinir ağlarında bir karşılığı vardır. Yapay sinir ağlarında yer alan gizli katmanlar ve lineer olmayan fonksiyonlar, bu aracı, diğer araçlardan üstün kılmıştır [21].



3 YAPAY SINİR AĞLARI

Biyolojik sinir ağının temel inşa bloğu olan basit bir sinir hücresi nöron olarak adlandırılır. Şekil 3-1’de şematik diyagramı gösterilen tipik sinir hücresi üç ana bölümden oluşmaktadır: Soma olarak adlandırılan hücre gövdesi, akson ve dendritler. Dendritler dendritik ağaç biçimindedir, nöron gövdesi civarında uzun çalılar görünümündedirler. Dendritler üzerinden girişler alınır, soma tarafından girişler işlenir. Nörondaki sinyalleri taşıyan uzun bir sinirsel bağlantı halindeki akson ise, işlenen girişleri çıkışa aktarır. Akson dendrit bağlantısı ise sinaps olarak adlandırılır. Sinaps nöronlar arasında elektrokimyasal bağlantıyı sağlamaktadır.



Şekil 3-1 Basit Bir Sinir Hücresi

Yapay sinir ağları kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır. Bu çalışmaların ortaya çıkardığı bulgular, her bir nöronun komşu nöronlardan bazı bilgiler aldığı ve bu bilgilerin biyolojik nöron dinamiğinin öngördüğü biçimde bir çıktıya dönüştürüldüğü şeklinde idi. Bugün yapay sinir ağları olarak isimlendirilen alan, birçok nöronun belirli biçimlerde bir araya getirilip bir işlevin gerçekleştirilmesi üzerindeki yapısal olduğu kadar matematiksel ve felsefi

sorunlara yanıt arayan bir bilim dalı olmuştur [25]. Yapay sinir ağının düğümleri ve bağlantıları, çok değişik biçimlerde bir araya getirilebilir. Ağlar, bu düğüm ve bağlantı mimarilerine göre değişik isimler alırlar [22].

Günümüzde birçok bilim alanında yapay sinir ağı, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur.

Doğrusal Olmama

Yapay sinir ağlarının temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen yapay sinir ağı da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile yapay sinir ağı, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

Öğrenme

Yapay sinir ağının arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. Yapay sinir ağının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle yapay sinir ağı, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

Genelleme

Yapay sinir ağı, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir yapay sinir ağı, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş yapay sinir ağı modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

Uyarlanabilirlik

Yapay sinir ağı, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen yapay sinir ağı, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir.

Hata Toleransı

Yapay sinir ağı, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir yapay sinir ağının bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

Donanım ve Hız

Yapay sinir ağı, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, yapay sinir ağının hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

Analiz ve Tasarım Kolaylığı

Yapay sinir ağının temel işlem elemanı olan hücrenin yapısı ve modeli bütün yapay sinir ağı yapılarında yaklaşık aynıdır. Dolayısıyla, yapay sinir ağının farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan yapay sinir ağları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin yapay sinir ağı ile çözümünde önemli bir kolaylık getirecektir. [23]

Kümeleme için kullanılan tüm tekniklerde, kümeleme üyeliği atamakta problem yaşanmaktadır. Kümeye atama, verinin özelliklerine ve en fazla kümenin görece dağılımına (relative cluster dispersion) bağlıdır. Görece küme dağılımı, Chen ve arkadaşları tarafından, bütün küme üyeleri ile küme merkezleri arasındaki mesafe olarak tanımlanmıştır. Milligan, yaptığı bir çalışmada, düşük seviyede data dağılımlarında, herhangi bir kümeleme metodunun, doğru kümelemeleri verdiğini göstermiştir [24].

Beyindeki gerçek sinir hücrelerinin ağsal yapılarının modellenmesinin amaçlanması ile ortaya çıkan yapay sinir ağlarının uygulama alanları bilgisayar bilimi ve mühendislik üzerinde yoğunlaşmıştır. Ancak yapay sinir ağları özellikle sağladıkları yüksek hız nedeni ile son yıllarda bilgisayar bilimlerinin yanı sıra mühendislik, ekonomi, psikoloji gibi birçok farklı alanda kullanılan bir yöntem olarak karşımıza

çıkılmaktadır. Yapay sinir ağlarının istatistik alanında kullanımları üç ana konu üzerinde yoğunlaşır. Bunlar regresyon analizi, zaman serisi tahminleri ve sınıflama olarak ortaya konulabilir. Bu yüzden de yapay sinir ağları regresyon, diskriminant analizi, lojistik regresyon ya da tahmin yaklaşımlarının kullanıldığı tüm problemlere rahatlıkla uygulanabilir. [25]

Gately'ye göre yapay sinir ağları, örnekleri sınıflandırmak ya da geçmiş deneyimlere dayalı tahminlerde bulunup, kararlar vermek için kullanılan ve insan beynini taklit eden bir yazılım programıdır. İnsan beyni beş duyusundan aldığı verilerle hareket ederken, yapay sinir ağları veri gruplarındaki girdileri kullanır.

Biyolojik bir sinir hücresi, kaba bir hesaplama becerisine sahip tek bir hücreden oluşur. Bir ya da daha çok girdi tarafından uyarılır ve diğer sinir hücrelerine iletmek üzere bir çıktı yaratır. Oluşan çıktı, her bir girdinin kuvvetine ve girdilerin söz konusu hücre ile olan bağlantılarının yapısına bağlıdır. Girdiler ve çıktılar arası yapı oldukça karmaşık olabilir. Tek bir sinir hücresi, girdilerin ağırlıklı toplamı olarak modellendiği gibi karmaşık diferansiyel denklemler topluluğu olarak da modellenenebilir. Hücreler arası bağlantılar ise bilginin aktığı katmanlarla düzenlenirler. Hücreler arası bağlantıların kuvveti yani ağırlıklar yapay sinir ağının amacına göre değişiklik gösterir. Zaten, mimarisi bir başka deyişle yapısı aynı olan iki yapay sinir ağı birbirinden ayıran en temel özellik söz konusu bu ağırlıklardır. Yapay sinir ağlarında da tıpkı beyinde olduğu gibi tek bir hücrenin davranışı basit olsa da hücrelerden oluşan bir sistemin davranışı oldukça karmaşık olabilir.


Bulanık verilere dayalı çıkarımlar yapılması gerektiğinde, veriler matematiksel anlamda kaotik olduğunda ya da doğrusal olmadıklarında diğer yöntemlere kıyasla, yapay sinir ağları daha iyi sonuçlar verirler. Genel yaklaşım; geleneksel modelleme yöntemleri veya istatistiksel yöntemlerle çözülebilen problemlerin yapay sinir ağları ile daha etkin çözülebileceğidir. Sharda'nın yapay sinir ağlarının uygulamaları ile ilgili yapmış olduğu bir çalışma; yapay sinir ağlarının geleneksel istatistik tekniklerine kıyasla %71 oranında (42 çalışmanın 30'u) daha başarılı olduklarını ortaya koymuştur.

Sinir ağları geleneksel bilgisayar uygulamalarından birçok yerde ayrılır. Sinir ağları geleneksel anlamda "programlanmazlar". Tanınacak durum veya nesnelerle ilgili nitel tanımlamalar ya da benzer nesneleri birbirinden ayırmak için mantıksal kriterler

içermezler. Bunun yerine, gerçek durumu yansıtan tekrarlı birçok örneğin kendilerine sunulması yoluyla veriler arasındaki ilişkileri "keşfederler". Diğer bir deyişle, yapay sinir ağları adaptasyon yolu ile öğrenirler [25].

3.1 Yapay Sinir Ağlarının Temel Yapısı

Yapay sinir ağlarının birçok çeşidi olsa da genel yapı Şekil 3. 2'de gösterildiği gibidir. Bir ya da genellikle daha çok girdi söz konusudur. Bunlar girdi sinir hücreleri olarak adlandırılırlar ve sadece hipotetik hücrelerdir. Yani herhangi bir işlem söz konusu değildir, bu yüzden de varsayılan girdilere eşit değerde çıktılar üretirler. Ağın sonuçlarını ise bir ya da daha çok sayıdaki (genellikle az sayıda) çıktılar sağlar. Hipotetik girdilerin aksine çıktılar gerçektirler. Girdiler ve çıktılar birbirlerine bir "kara kutu" aracılığı ile bağlıdır. Zaten yapay sinir ağlarının modelini de bu kara kutunun yapısı belirler. Ancak bu gösterim genel olsa da tek değildir. Bazı modeller bu aracıyı ortadan kaldırıp doğrudan girdileri çıktılara bağladığı gibi, bazıları da araya birden çok sayıda aracı katman koyabilirler [25]. Ara katmanları olmayan, sadece giriş ve çıkış katmanları olan ağlar, karmaşık işlevleri hesaplama yeteneğinden yoksundur. Bu nedenle, karmaşık hesaplamalar için oluşturulan ağlarda en az bir ara katman olmalıdır [22].




Şekil 3-2 Yapay Sinir Ağlarının Temel Yapısı

Genel gösterimi yukarıdaki gibi olan yapay sinir ağları, birbirlerine yönlü ve ağırlıklandırılmış bağlantılar ile bağlı belirli sayıdaki işlem birimlerinden (sinir

hücreleri) oluşurlar. Girdi sinyalleri hücrenin bağlantılarından alınır, bu sinyallere ağırlıklar atanır ve toplanır. Sonuç "transfer fonksiyonu" olarak adlandırılan bir fonksiyona tabi tutulur.

Ancak yapay sinir ağlarında tekil hücreler çok basit kurallara göre hareket ederken, toplu davranışın oldukça karmaşık olduğu unutulmamalıdır.

Yapay sinir ağlarının gösterimi, düğümlerin hücreleri, bağlantıların da hücreler arası ilişkileri gösterdiği ağırlıklı yönlü çizgelerle ortaya konulabilir. İki katmanlı ileri-beslemeli ağlara bir örnek Şekil 3.3'te verilmiştir. Burada 3 girdi sinir hücresi, 4 gizli sinir hücresi ve 3 tane de çıktı sinir hücresi bulunmaktadır [25].



Şekil 3-3 Örnek Bir Yapay Sinir Ağı

Şekil 3.3'te verilen örnek yapay sinir ağı üç düzeyli olarak nitelendirilir. Düzey, diğer düzeylerdeki hücrelerle bağlantılı olan ancak kendi arasında bağlantılı olmayan hücreler topluluğu olarak tanımlanabilir.

Sonuç olarak yapay sinir ağı modelinin;

- Hücre değerlerinin bağlantılar aracılığı ile hücreler arasında geçebildiğini;

- Her bir bağlantının bir ağırlığı olduğunu ve ağıdaki hücre değerlerinin bu ağırlıklar ile çarpılarak iletilildiğini;

- Her bir hücrenin çıktı değerini elde etmek için girdisine bir hareket fonksiyonu uyguladığını

varsayan bir model olduğu söylenebilir [25].

3.2 Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında öğrenme süreci sayısal eğitim verilerine dayanarak ağırlık ve hata terimlerinin, yani bilinmeyenlerin değerlerinin belirlenmesi işlemidir.

Sinir ağları zaman içinde öğrenebildikleri için adaptif sistemlerdir. Başka bir deyişle, sinir ağları, problem çözmedeki performanslarını geçmiş deneyimlerine dayanarak geliştirebilme özelliğine sahiptirler. Yapay sinir ağlarında bu olay "öğrenme" olarak adlandırılır. Öğrenme algoritmaları istenen çıktıları elde edebilmek için bağlantıların ağırlıklarının belirlenmesi işlemidir.

Yapay sinir ağlarının öğrenme süreci ödül ve ceza mekanizması olarak düşünülebilir. Sistem, bir veriye doğru bir şekilde yanıt verdiğinde ağırlıklar güçlendirilir. Böylece gelecekte de benzer girdilere benzer çıktılar üretmesi sağlanmış olur. Ters şekilde, istenmeyen çıktılar ürettiğinde de ağırlıklar zayıflatılır. Böylece, gelecekte benzer girdilere farklı yanıtlar vermesi gerektiği öğretilir. Bu şekilde, istenen tür davranışlar için sistem teşvik edilirken, istenmeyenler için cezalandırılmış olur.

Yapay sinir ağı öğrendikten sonra daha önce verilmeyen girişler verilip, sinir ağı çıkışıyla gerçek çıkışı yaklaşımı incelenir. Eğer yeni verilen örneklerle de doğru yaklaşıyorsa sinir ağı işi öğrenmiş demektir. Sinir ağına verilen örnek sayısı optimum değerden fazla ise sinir ağı işi öğrenmemiş ezberlemiştir. Genelde eldeki örneklerin yüzde sekseni ağa verilip ağ eğitilir, daha sonra geri kalan yüzde yirmilik kısım verilip ağın davranışı incelenir diğer bir deyişle ağ böylece test edilir.

Masson ve Wang'a göre eğitim sürecinin amacı, istenen yapay sinir ağı yapısını elde etmek için ağırlıkların belirli değerler almasını sağlamaktır. Diğer bir deyişle, eğitim; ağırlıklar uzayında yapılan bir aramadır.

Bir sinir ağı temelde üç değişik türde öğrenebilir. Gözetimli, gözetimsiz ve karma öğrenme olarak adlandırılan bu öğrenme türleri ilerleyen bölümlerde anlatılmıştır [25].

3.2.1 Gözetimli Öğrenme

Yapay sinir ağına örnek oluşturmak için birçok veri toplanır. Daha sonra bu gruptan "eğitim grubu" olarak adlandırılan bir alt küme seçilir ve söz konusu bu kümedeki örnekler ağına verilir. Her bir örnek grubu için ağına ürettiği çıktı, üretmesi istenilen çıktılarla kıyaslanır ve doğru çıktılara ulaşabilmek için ağırlıklar güncellenir. Bu güncelleme işlemi ağına çıktılarındaki hatayı azaltmaya yöneliktir. Ağına ağırlıklarının güncellenmesini de içerecek şekilde eğitim örneklerinin ağıdan bir geçişi devir (epoch) olarak adlandırılır. Eğitim devirleri etkin bir sonuca ulaşana dek sürdürülür.

Veri grubunun bir alt kümesi ile ağına eğitilmesinin nedeni geri kalan örneklerin ağına öğrenme etkinliğinin testi için kullanılmasıdır. Zira sadece eğitilen bir yapay sinir ağına doğrudan uygulamaya konması doğru değildir. Bundan önce yapay sinir ağına test edilmeli ve eğitim sürecinde ulaşılan başarıya test aşamasında da ulaşıp ulaşamadığı gözlemlenmelidir. Genellikle eğitim aşamasında çok küçük hata değerlerine ulaşmak mümkündür ancak önemli olan test aşamasında da bu değerlerin aynısı elde edilmese de onlara yaklaşabilmektir [25].

3.2.1.1 Algılayıcılar (Perceptions)


Algılayıcı, 1958 yılında Rosenblatt tarafından ortaya konan ve gözetimli öğrenmeyi kullanan ilk yapay sinir ağına adıdır. Ancak biyolojik modelleri temel almış olan ve öğrenme yeteneği bulunan algılayıcının önemli bir zayıf noktası bulunuyordu. Bu da sınıflamayı gerektiren önemli bir bölüm görevi yerine getirmek için öğrenmeyi gerçekleştiremiyor oluşuydu. Söz konusu sınıflama problemleri çıktı düzeyinde doğrusal ayrılabilir olmayanlardı.

Algılayıcıların bu önemli yetersizlikleri yapay sinir ağları çalışmalarının uzun bir süre durgunluk dönemine girmesine neden olmuştur. Daha sonra 1986 yılında Rumelhart, Hinton ve Williams tarafından yapılan araştırmaların yayınlanması ve

doğrusal ayrılabilirlikle kısıtlı olmayan çok katmanlı ileri beslemeli ağların ortaya konması ile yapay sinir ağları tekrar önem kazanmıştır [25].

3.2.1.2 İleri Beslemeli Ağlar

Yapay sinir ağların bir türü olan ileri-beslemeli ağlar iki veya daha çok katmandan oluşan işlem birimleri hiyerarşileridir. İlk katman sinir ağına bilgilerin verildiği girdi hücrelerinden oluşur ve bu hücreler, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücrelere iletir. Son katman ise çıktıların alındığı katmandır. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Şekil 3.4'te üç katmana sahip bir ileri beslemeli yapay sinir ağının gösterimi yer almaktadır.



Şekil 3-4. İleri Beslemeli Üç Katmanlı Yapay Sinir Ağı


Uygulamada sadece bir gizli düzeye sahip yapay sinir ağlarının sınırlı sayıda veriden oluşan fonksiyonları ve sürekli fonksiyonları öğrenebildiği görülmüştür, ikinci bir gizli düzeye gereksinim sadece genellikle sürekli ancak bazı noktalarda bu sürekliliği bozan durumlar varsa ortaya çıkabilir. Ancak yine de gerçek hayatta karşılaşılan problemlerin çoğunluğunun tek gizli düzeye çözümlenebileceği ve birden fazla gizli düzey kullanmanın öğrenmeyi yavaşlatacağı unutulmamalıdır.

Doğrusal olarak ayrılabilen fonksiyonlar için algılayıcılar uygunken gerçek hayatta karşılaşılan birçok problemin temel özelliği olan doğrusal olarak ayrılamama özelliğine sahip olanlar için ileri beslemeli yapay sinir ağları kullanılabilir.

Yapay sinir ağları için birçok yapı ve öğrenme algoritması ortaya konmuştur. İçlerinde en sık kullanılanı geri yayılmalı (back-propagation) öğrenme algoritmasını kullanan ileri beslemeli yapay sinir ağlarıdır. Çok katmanlı ileri beslemeli yapay sinir ağları iki ya da daha çok düzeyde organize olmuş sinir hücrelerinden oluşurlar. En az birer hücreye sahip girdi ve çıktı düzeylerinin yanı sıra bu iki düzeyin arasında genellikle bir, bazen daha çok gizli düzey bulunur, "İleri beslemeli" terimi bilginin sadece tek yönlü aktığının bir göstergesidir. Her bir düzeyin girdileri bir önceki düzeyin çıktılarıdır ve ürettikleri çıktılar da bir sonraki düzey için girdi görevini üstlenirler. Ağdaki her bir sinir hücresinin çıktısı, söz konusu hücrenin girdilerinin bir fonksiyonudur [25].

3.2.1.3 Geri Beslemeli Ağlar

Geri beslemeli yapay sinir ağında, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Şekil 3.5'te iki katmanlı ve çıkışlarından giriş katmanına geri beslemeli bir yapay sinir ağı yapısı görülmektedir.



Şekil 3-5 Geri Beslemeli İki Katmanlı Yapay Sinir Ağı

Geri yayılmalı öğrenme algoritması; daha önceden hiç kullanılmamış bir verinin girdi katmanından ağa verilmesinden sonra doğru tahminin yapılması yani doğru

çıkıya ulaşılması için ağırlıklarının eğitilmesidir. Bu eğitimin yapılabilmesi için de mutlaka her bir girdi için istenen çıktının da ağırlıklandırılması gereklidir. En küçüklenmek istenen hata çok basit olarak ulaşmak istenen çıktı değeri ile öğrenme süreci boyunca hesaplanan, diğer bir deyişle gerçekleşen çıktı arasındaki değerdir. Geri yayımlı algoritmada ileri ve geri olmak üzere iki temel adım vardır. İleri adım sırasında bilinen veriler girdi katmanından ağırlıklandırılır. Her bir değişken için bir adet girdi hücresi vardır. Daha sonra gizli katmandaki her bir hücre için girdi hücreleri ile ilgili ağırlıkların çarpımının toplamından oluşan bir değişken hesaplanır [25].

Öğrenme Parametrelerinin Belirlenmesi

Gerçek hayatta karşılaşılan problemlerin çoğunluğunun tek gizli düzeye çözümlenebileceği belirtilmişti. Bu yüzden eğer üzerinde çalışılan yapay sinir ağı öğrenmesi beklenen fonksiyonu yeterince iyi öğrenemiyorsa, problem sinir ağının modelinde değil, çok büyük olasılıkla yetersiz eğitim ya da yetersiz sayıda gizli sinir hücresinin kullanılmasındadır. Zira yapay sinir ağının tasarımında, kullanılan gizli sinir hücresi sayısının da çok büyük rolü vardır. Bu konuda ise gerçekçi bir tahminde bulunmak oldukça zordur. Az kullanmak yetersiz öğrenmeye yol açtığı gibi, çok sayıda gizli sinir hücresi kullanmak da öğrenme aşamasında iyi sonuçlar verse de test aşamasında etkin bir öğrenmenin gerçekleşmemesine, yani sinir ağının eğitim verilerini sadece ezberlemesi, ancak öğrenmemesine neden olur. Zaten geri yayımlı öğrenme algoritmasının eleştirilen en önemli özelliği eğitim seti üzerinde doğru ağırlıklara ulaşana dek çok zaman geçmesi, bir diğer deyişle devir sayısının fazla olması iken bir diğer eleştiri noktası ise yapay sinir ağının iyi bir performans sergilemesinin büyük ölçüde doğru sayıda gizli sinir hücresi seçimine bağlı olmasıdır.

Uygun gizli sinir hücresi sayısının bulunması için kullanılan kurallardan biri "geometrik piramit kuralı" olarak adlandırılır. Söz konusu kural, pratikte kullanılan birçok yapay sinir ağındaki sinir hücrelerinin piramit şeklini oluşturduğu yani girdilerden çıktılara doğru azalma gözlemlendiği varsayımına dayanır. Eğer kullanılan girdi sinir hücresi sayısının " n " ve çıktı sinir hücresi sayısının da " m " tane olduğu biliniyorsa, geometrik piramit kuralı uyarınca, gizli sinir hücresi sayısı;

$$\sqrt{m * n}$$

(3.1)

formülü ile bulunabilir. Ancak bu formülün ideal sayının bulunması için kabaca bir rakam ortaya koyduğu unutulmamalıdır.

Gizli düzeyde kullanılması gereken sinir hücresinin sayısının belirlenmesi için önerilen diğer bir yol da girdi seviyesindeki hücrelerin %75'i kadar gizli sinir hücresi kullanmaktır. Gruca ve Klenz ise en etkin öğrenmeyi sağlayacak gizli sinir hücresi sayısının bulunması için "n" girdi hücresi sayısı ve "m" çıktı hücresi sayısı olmak üzere; $(2n+m)^{1/2}$ ile $(2n+1)$ arası bir değer önermektedirler. Hardgrave ve diğ. ile Venkatachalam ve Sohl'a göre ise uygun gizli sinir hücre sayısı girdi hücrelerinin yarısı ile iki katından bir fazlası arası bir değerdir.

Kullanılacak gizli sinir hücresi sayısının ideal değerini bulmak için en iyi yol biraz yorucu ve zaman alıcı olsa da çok küçük sayıda (örneğin iki) gizli sinir hücresi ile başlayıp arttırarak ve her seferinde belirlenen performans kriteri uyarınca yapay sinir ağının etkinliğini hesaplayarak ideal sayıyı belirlemektir. Bu süreç, denenen her gizli sinir hücresi sayısı için söz konusu yapay sinir ağının eğitilmesini ve test edilmesini gerektireceğinden uzun fakat oldukça sağlıklı bir yoldur.

Yukarıda tanımlı süreç boyunca dikkat edilmesi gereken en önemli şey, yapay sinir ağının veri grubunu ezberlemeyip öğrenmesini sağlamaktır. Bunun için de eğitim sürecindeki optimum iterasyon sayısını da belirlemek gerekir. Zira belirli bir noktadan sonra eğitim sürecindeki hata oranı azalmaya devam etse de genel veri grubunda performans düşme eğilimine girecek yani hata oranı yükselmeye başlayacaktır. Eğitim verisi, monoton şekilde azalıp bir yerde asimptota yaklaşırken, diğer veri grubu olan test veri grubunda hata başlangıçta azalsa da eğitmeye devam etmekle hata beklenenin tersine artış göstermektedir.

Eğitim sürecinde kullanılan gizli sinir hücresi sayısı ve eğitim sürecinin uzunluğunun yanı sıra dikkat edilmesi gereken bir üçüncü nokta da başlangıçta rassal olarak değer atanan ağırlıklardır. Rassal olarak atanmaları nedeniyle belirli sayıdaki gizli sinir hücresi ile sadece bir kez yapılan eğitim sürecinin etkinliği tartışmaya açıktır. Bu yüzden, ortalama bir deneme rakamı belirlenmeli ve her bir gizli sinir hücresi için yapay sinir ağı daha önceden belirlenen o rakam kadar tekrar tekrar çalıştırılmalıdır.

Böylece rassallıktan kaynaklanan yanımlarda büyük ölçüde ortadan kaldırılmış olur. Ancak, tekrarlı öğrenme yapılırsa bile söz konusu gizli sinir hücresi sayısı için en iyi öğrenme etkinliğine ulaşıp ulaşılmadığının hiçbir zaman tam olarak bilinemeyeceği unutulmamalıdır.

Tüm bu parametrelerin belirlenmesinin yanı sıra eğitim sürecinin kesilmesi gereken nokta olan hata tolerans düzeyinin de belirlenmesi gereklidir. Zira, ağırlıkların belirlenmesi sürecinde çıktı hücrelerinin değerlerinin istenen değerlerinden sapma yüzdesi de eğitim sürecinin önemli bir parametresidir. Bu parametre belirlenirken yapay sinir ağları dahil hiçbir tekniğin % 100 bir doğrulukla tahmin ya da sınıflama yapamayacağı dikkate alınmalı; incelenen problemin türüne göre uygun bir hata toleransı yüzdesi belirlenmelidir.

Söz konusu bu değerlerin belirlenmesi süreci boyunca geçmiş verilerden yararlanılabilir. Diğer bir deyişle, geçmişte benzer problemlerde kullanılan parametre değerlerinden yaklaşık değerler elde etmek için yararlanılabilir ancak uygun bir yapay sinir ağı mimarisi ve parametre değerleri için belirli sayıda bir deneme-yanılma yapılması gerekliliği göz ardı edilmemelidir [25].

3.2.2 Gözetimsiz Öğrenme

Bir diğer öğrenme türü ise gözetimsiz (unsupervised) öğrenmedir. Tıpkı gözetimli öğrenmede olduğu gibi yapay sinir ağına bir dizi girdi verilir ancak istenen çıktılar kıyaslama yapmak üzere elde değildir. Ağı öğrenme süreci, eğitim grubunun özelliklerini ağı keşfetmesi ve bu özellikleri kullanarak girdileri farklı özelliklerine göre gruplandırması üzerine kuruludur.

Yapay sinir ağlarının çoğunluğu gözetimli öğrenme yaklaşımını benimsese de bir kısım yapay sinir ağı uygulamaları gözetimsiz öğrenme başlığı altında toplanmalıdır. Gözetimsiz öğrenmeyi gözetimli öğrenmeden ayıran en belirgin fark, gözetimsiz öğrenmede ulaşılmak istenen çıktının elde veri olarak bulunmaması, yani önceden bilinmemesidir. Bu tarz yaklaşımda istenen, yapay sinir ağının eldeki verilerin yapısını keşfetmesidir [25].

3.2.2.1 Özörgütlemeli Haritalar


Özörgütlemeli haritalar, gözetimsiz öğrenme metodudur ve sadece girdilere ihtiyaç duyar. Ağ, girdiler arasındaki ilişkiyi kendisi bulmalı ve bir koda dönüştürerek çıktı üretmelidir. En sık kullanılan özörgütlemeli haritalar, Kohonen'e aittir. Kohonen özörgütlemeli haritalar, standart ileri beslemeli yapay sinir ağlarından sonra en çok kullanılan yapay sinir ağı metodudur.

Bu harita ya da ağın yapısı, biyolojik haritalardaki ağ yapısının, dış uyarıcıların topolojilerini yansıtması ve bu topolojileri temsil etmesi üzerine kurulmuştur. Lineer olmayan haritalamalar yapabilir, bir çok veri noktasını içerecek uzayda merkezlenmiş nöronlar ile girdi verisini, çok boyutlu uzaya yayabilir. Kohonen haritaları herhangi bir boyutta olabilir; en sık kullanılanı iki boyutlu (kuadratik) olanıdır [26]. Ancak ilk düzey girdi normalizasyonu gerektirdiğinden bazen üç düzeyli olarak da tanımlanabilir. N adet girdisi olan ağda m çıktı olduğu varsayılırsa Kohonen ağı çok basit olarak ağırlıklı toplamdan oluşan ve çıktının aşağıdaki gibi hesaplandığı bir ağ olarak ortaya konulabilir.

$$\sum_{i=1}^{n-1} x_i w_i \quad (3.2)$$

Kohonen ağında, giriş katmanına ek olarak, birbiriyle topolojik olarak ilişkili sinirlerden oluşan tek bir çıkış katmanı vardır. Her bir giriş, çıkış katmanındaki her bir sinire bağlıdır. Şekil 3-6'da bu yapı görülmektedir. Çıktı düzeyi, her bir çıktı hücresinin ağırlık vektörü ile girdiler arasındaki Öklid uzaklığını hesaplar. En yakın (en az mesafede) olan çıktı hücresi, "1" değerini alarak kazanan ilan edilir. Diğer tüm hücreler "0" değerini alırlar. Özörgütlemeli haritalar türündeki yapay sinir ağlarında da tipik olarak girdi ve çıktı düzeyleri olmak üzere 2 düzey vardır.

Ağ, rastsal ağırlıklarla çalışmaya başlar. Herhangi bir giriş uygulandığında, giriş vektörüne Öklid uzaklığı en az olan sinir seçilir ve bu sinire gelen bağlantı giriş ağırlıkları giriş vektörüne yaklaşacak şekilde yenilenir. Bu kazanan sinirle birlikte, onun topolojik komşuluğunda bulunan belli sayıda sinire gelen ağırlıklar da benzeri şekilde değiştirilir. Kazanan sinirin ne büyüklükte bir komşuluktaki diğer sinirleri etkileyeceği zaman içinde değişkenlik gösterir [22].



Şekil 3-6. İki Boyutlu Kohonen Ağı

Gözetimli öğrenmede, sinir hücreleri, kendilerine ait bağlantıların ağırlıklarını eğitim sürecindeki hata oranını küçükleme hedefi doğrultusunda değişime uğratar. Kohonen ağlarında ise, hücreler öğrenme ayrıcalığı için birbiri ile rekabet ederler. Veri grubunun ağı beslendiği her bir seferde sadece bir (bazı durumlarda komşuları da olabilir) hücre ağırlıklarını değiştirme hakkına sahip olur. Kohonen ağları çok basit bir temele otursa da sağladığı hız ve kolaylık açısından pratikte çok kullanılırlar [25].

Özörgütlemeli haritalar, girdi veri uzayının yoğunluk fonksiyonunun olasılığının lineer olmayan izdüşümünü, daha az sayıda boyuta indirger. Bu boyutların her biri, farklı bir ağırlık vektörü tarafından temsil edilir. Bu izdüşüm, benzer modelleri, komşuluk birimleri şeklinde haritalandırır. [27]

Kohonen ağı sınıflama problemleri için kullanılır. Özörgütlemeli haritalarda sinir ağı mimarisi tamamen kümeleme probleminin yapısına bağlıdır. Çıktı hücre sayısı, veri grubunun küme sayısına eşittir. Girdi hücre sayısı ise, verilerin boyut sayısına eşittir. Çıktı hücrelerinin değerlerinin yukarıda verilen formül uyarınca belirlenmesinden sonra, en yüksek değerde uyarılmış olan hücre kazanan hücre olarak belirlenir ve ağıdaki bağlantıların ağırlıkları bu doğrultuda güncelleştirilir. Bir noktadan sonra sistem dengeye ulaşır; yani öyle ki belirli bir eğitim sürecinden sonra ağırlık vektöründe belirgin bir değişim gözlenmemeye başlanır. Bu aşamaya gelindiğinde eğitim tamamlanmış demektir ve artık en fazla uyarılan çıktının bulunması ile yapılan sınıflandırma işi, herhangi bir veri seti için gerçekleştirilebilir.

Özörgütlemeli haritalar için öğrenme algoritması aşağıdaki gibi özetlenebilir [25].

Giriş sinir matrisi $Giriş_x$ ve $Giriş_y$ ile gösterilsin. Buradan sinirlerin girişlerinin toplam sayısı,

$$I = Giriş_x * Giriş_y \quad (3.3)$$

olur. Burada bu katmandaki sinirlerin sayısı için $i=0$ 'den $I-1$ 'e kadar seçilir. Örneğin, giriş sinirlerinin sayısı için x_0 den x_{I-1} 'e kadarına x_j diye adlandırılсын.

Yarışmacı katman matrisi $Çıkış_x$ ve $Çıkış_y$ ile gösterilsin. Anlatımı basitleştirmek için kare harita seçilirse, $Çıkış_x = Çıkış_y$ olur. Bu durumda yarışmacı sinirlerin toplam sayısı;

$$J = Çıkış_x * Çıkış_y \quad (3.4)$$

olur. Bu katmandaki sinirlerin sayısı için $j=0$ dan $J-1$ 'e kadar seçilir.

Adım 1. N adet girdiden m adet çıktıya olan bağlantıların başlangıç ağırlık değerlerini rassal ve küçük değerler olarak ata. Öğrenme oranı katsayısı α_0 , (genellikle 0,2 ile 0,5 arasında), toplam işlem sayısı T (genellikle 10,000) seçilir.

Adım 2. Yeni girdiyi ağa tanıt.

Adım 3. Tüm hücreler için uzaklığı hesap et.

$$d_i = \sum_{j=0}^{m-1} (x_i(t) - w_{ij}(t))^2 \quad (3.5)$$

Burada $x_i(t)$, t zamanında i. hücrenin girdi değeri, $w_{ij}(t)$ de t zamanındaki i girdi hücresinden j çıktı hücresine olan bağlantının ağırlık değeridir.

Adım 4. En küçük uzaklığa sahip çıktı hücresini (j^*) belirle.

Adım 5. j^* hücresinin ve komşu hücrelerinin ağırlık değerlerini güncelle.

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t)(x_i(t)w_{ij}(t)) \quad (3.6)$$

$$\Delta w_{ij} = \begin{cases} \alpha_1(x_i - w_{ij}(\text{eski})) & \text{eğğed, ise} \\ 0 & \end{cases} \quad (3.7)$$


Burada η yine öğrenme oranıdır.

Adım 6. Ağırlık değerleri sabitlenmediyse adım 2'ye dönerek tekrar et.

Özörgütlemeli haritalarla kümeleme analizinin paylaştığı ortak problem, herhangi bir çözüm için uygun istatistiksel testin belirlenmemiş olmasıdır. Chen ve arkadaşları (1995) tarafından yapılan bir çalışmaya göre, kümeleme analizi ve özörgütlemeli haritalar birlikte kullanıldığında, elde edilen sonuçların kalitesi artmaktadır. Düşük düzeyde veri dağılımı olduğunda, özörgütlemeli haritaların küme oluşturma etkinliği, tek bağlantılı ve k komşuluğu (Kst neighbourhood) hariç diğer tekniklerin etkinlikleri ile karşılaştırılabilir düzeydeyken; veri dağılımının düzeyi arttıkça, özörgütlemeli yapay sinir ağlarının verdiği sonuçlar, diğer tekniklerin verdiği sonuçlardan daha anlamlı olmaktadır. 2 sınıflı kümelemede, özörgütlemeli yapay sinir ağı tüm veri dağılımı düzeylerinde mükemmel sonucu veren tek metottur [24].

Özörgütlemeli Harita Örneği

Bu örnekte sınıflandırma için aşağıdaki şekilde gösterilen bir özörgütlemeli harita ağı ele alınmıştır. J_1 ve J_2 diye adlandırılan 2 kümeli 4 vektör # 1: (1,1,0,0); # 2: (0,0,0,1); # 3: (1,0,0,0); # 4: (0,0,1,1) verilsin. Örneklenecek küme sayısı en çok 2 olduğundan $J=2$ 'dir.



Şekil 3-7. Özörgütlemeli Harita Ağı Örneği

İlk öğrenme oranını $\alpha(0) = 0,6$, seçilmiştir. Bu durumda bir sonraki değer, $\alpha(t-1) = 0,5 \alpha(t)$ olacaktır. Ağırlıklar aşağıda verildiği gibi rasgele seçilmiştir.

$$\begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \\ w_{31} & w_{32} \\ w_{41} & w_{42} \end{bmatrix} = \begin{bmatrix} 0,2 & 0,8 \\ 0,6 & 0,4 \\ 0,5 & 0,7 \\ 0,9 & 0,3 \end{bmatrix} \quad (3.8)$$

Özörgütlemeli Haritanın Eğitim Aşaması

Adım 1: Eğitime başlanır.

Adım 2: Birinci vektör, (1,1,0,0) için Adım 3-5 uygulanır.

Adım 3: Bu adımda mesafe aşağıdaki gibi hesaplanır.

$$J_1 = \sqrt{((0,2-1)^2 + (0,6-1)^2 + (0,5-0)^2 + (0,9-0)^2)} = 1,36$$

$$J_2 = \sqrt{(0,8-1)^2 + (0,4-1)^2 + (0,7-0)^2 + (0,3-0)^2} = 0,98 \leftarrow \text{en az}$$

Adım 4: Giriş vektörü çıkış düğüm değerine yakın olduğundan J_2 kazanan sinir olacaktır. Dolayısıyla J' 'ye ait ağırlıklar güncellenecektir.

Adım 5: Kazanan düğümün ağırlıklarını güncellenir.

$$w_{ij}(\text{yeni}) = w_{ij}(\text{eski}) + \Delta w_{ij}(\text{yeni})$$

$$w_{12}(\text{yeni}) = w_{12}(\text{eski}) + 0,6[x_1 - w_{12}(\text{yeni})]$$

$$w_{12}(\text{yeni}) = 0,4 w_{12}(\text{eski}) + 0,6 x_1$$

$$w_{12}(\text{yeni}) = (0,4 \times 0,8) + 0,6 x_1,$$

bulunur. $i = 1$ den 4' kadar (1,1,0,0) uygulanır. Bu durumda $w_{12} = 0,92$ olur. Aynı şekilde J_2 'ye bağlı geriye kalan w_{22} , w_{32} ve w_{42} güncellenirse ağırlık matrisi bulunur.

J_1	J_2
0,2	0,92
0,6	0,76
0,5	0,28
0,9	0,12
↑	↑
Uyarlanmamış	Uyarlanmış

Adım 2: İkinci vektör için (0,0,0,1), Adım 3-5 tekrarlanır.

$$\text{Adım 3: } J_1 = \sqrt{((0,2-0)^2 + (0,6-0)^2 + (0,5-0)^2 + (0,9-1)^2)} = 0,66 \leftarrow \text{en az}$$

$$J_2 = \sqrt{((0,92-0)^2 + (0,76-0)^2 + (0,28-0)^2 + (0,12-1)^2)} = 2,2768$$

Adım 4: Giriş vektörü düğüm 1'e yakın olduğundan kazanan J_1 'dir.

Adım 5: J_1 'e bağlı olan ağırlık matrisinin ilk kolonunu güncellenir.

$$\begin{bmatrix} 0,08 & 0,92 \\ 0,24 & 0,76 \\ 0,20 & 0,28 \\ 0,96 & 0,12 \end{bmatrix}$$

↑
Uyarlanmış

Adım 2: Üçüncü vektör (1,0,0,0,) için Adım 3-5 tekrarlanır.

Adım 3: $J_1 = \sqrt{((0,08-1)^2 + (0,24-0)^2 + (0,2-0)^2 + (0,96-0)^2)} = 1,8656$

$J_2 = \sqrt{((0,92-1)^2 + (0,76-0)^2 + (0,28-0)^2 + (0,12-0)^2)} = 0,6768 \leftarrow \text{en az}$

Adım 4: Giriş vektörü düğüm 2'nin çıkışına yakın olduğundan kazanan J_2 kazanandır.

Adım 5: J_2 'e bağlı olan ağırlık matrisinin ikinci kolonu güncellenir.

$$\begin{bmatrix} 0,08 & 0,968 \\ 0,24 & 0,304 \\ 0,20 & 0,112 \\ 0,96 & 0,048 \end{bmatrix}$$

↑
Uyarlanmış

Adım 2: Dördüncü vektör için Adım 3-5 tekrarlanır.

Adım 3: $J_1 = \sqrt{((0,08-0)2 + (0,24-0)2 + (0,2-1)2 + (0,96-1)2)} = 0,7056 \leftarrow \text{en az}$

$J_2 = \sqrt{((0,968-0)2 + (0,304-0)2 + (0,112-1)2 + (0,048-1)2)} = 2,724$

Adım 4: Kazanan J_1 'dir.

Adım 5: Ağırlık matrisinin ilk kolonu güncellenir.

$$\begin{bmatrix} 0,032 & 0,968 \\ 0,0964 & 0,304 \\ 0,680 & 0,112 \\ 0,984 & 0,048 \end{bmatrix}$$

↑

Uyarlanmış

Adım 6: Öğrenme katsayısı azaltılır. $\alpha=0,5$ ($0,6$)= $0,3$, ağırlık güncelleme yapılır ve ikinci turdaki ağırlık matrisi bulunur.

$$w_{ij}(\text{yeni}) = w_{ij}(\text{eski}) + 0,3[x_i - w_{ij}(\text{eski})]$$

$$w_{ij}(\text{yeni}) = 0,7 w_{ij}(\text{eski}) + 0,3 x_i$$

$$\begin{bmatrix} 0,016 & 0,980 \\ 0,047 & 0,360 \\ 0,630 & 0,055 \\ 0,999 & 0,024 \end{bmatrix}$$

Öğrenme oranının 0,6'dan 0,01'e düşmesi için yapılan ayarlamaları 100 işlem sonunda aşağıdaki sonuçları verir.

İşlem 0: Ağırlık matrisi:

$$\begin{bmatrix} 0,2 & 0,8 \\ 0,6 & 0,4 \\ 0,5 & 0,7 \\ 0,9 & 0,3 \end{bmatrix}$$

İşlem 1: Ağırlık matrisi:

$$\begin{bmatrix} 0,032 & 0,970 \\ 0,096 & 0,300 \\ 0,680 & 0,110 \\ 0,980 & 0,048 \end{bmatrix}$$

İşlem 2: Ağırlık matrisi:

$$\begin{bmatrix} 0,0053 & 0,9900 \\ -0,1700 & 0,3000 \\ 0,7000 & 0,200 \\ 1,0000 & 0,0086 \end{bmatrix}$$

İşlem 10: Ağırlık matrisi:

$$\begin{bmatrix} 1,5 \text{ e } -7 & 1,0000 \\ 4,6 \text{ e } -7 & 0,3700 \\ 0,6300 & 5,4 \text{ e } -7 \\ 1,0000 & 2,3 \text{ e } -7 \end{bmatrix}$$

İşlem 50: Ağırlık matrisi:

$$\begin{bmatrix} 1,9 \text{ e } -9 & 1,0000 \\ 5,7 \text{ e } -15 & 0,4700 \\ 0,5300 & 6,6 \text{ e } -15 \\ 1,0000 & 2,8 \text{ e } -15 \end{bmatrix}$$

İşlem 100: Ağırlık matrisi:

$$\begin{bmatrix} 6,7 \text{ e } -17 & 1,0000 \\ 2,0 \text{ e } -16 & 0,4900 \\ 0,5100 & 2,3 \text{ e } -16 \\ 1,0000 & 1,0 \text{ e } -16 \end{bmatrix}$$

Bütün bu ağırlık matrisleri sonuçta aşağıdaki matris olur.

$$w = \begin{bmatrix} 0,0 & 1,0 \\ 0,0 & 0,5 \\ 0,5 & 0,0 \\ 1,0 & 0,0 \end{bmatrix}$$

Burada ilk kolon birinci kümedeki iki vektörün ortalamasını, ikinci kolon ikinci kümedeki iki vektörün averajını göstermektedir. Bu aşamada, çağırma işlemine geçilir.

Özörgütlemeli Haritanın Çağırma Aşaması

Bu aşama, ele alınan yapay sinir ağının hangi vektörünün hangi kümeye dahil olduğunun sınındığı aşamadır. Toplam sinir sayısı aşağıda gösterilmiştir.

$$J = w^T x x^T \quad (3.9)$$

$$J = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \\ w_{31} & w_{32} \\ w_{41} & w_{42} \end{bmatrix} \quad x \begin{bmatrix} x_1 & x_2 & x_3 & x_4 \end{bmatrix}$$

$$\begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = \begin{bmatrix} 0,0 & 0,0 & 0,5 & 1,0 \\ 1,0 & 0,5 & 0,0 & 0,0 \end{bmatrix} \quad x \quad \begin{bmatrix} 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 \end{bmatrix} \quad \leftarrow \begin{array}{l} \text{Vektör \#1} \\ \text{Vektör \#2} \\ \text{Vektör \#3} \\ \text{Vektör \#4} \end{array}$$

Çağırma aşamasında Vektör # 1 ile Vektör # 3 bir kümeyi oluştururken Vektör # 2 ve Vektör # 4'ün diğer kümeyi oluşturduğu görülür.

$$\text{Vektör \# 1 : } \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 1,5 \end{bmatrix} \quad \leftarrow \text{Küme \# 1}$$

$$\text{Vektör \# 2 : } \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \leftarrow \text{Küme \# 2}$$

$$\text{Vektör \# 3 : } \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad \leftarrow \text{Küme \# 1}$$

$$\text{Vektör \# 4 : } \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \leftarrow \text{Küme \# 2}$$

Burada açıkça Vektör # 1 ile Vektör # 3 bir bibiriyle; Vektör # 2 ve Vektör # 4 de bir biriyle aynı olduğu görülmektedir [22].

Eğitim sürecinde, ağırlıkların güncelleştirilmesi için iki farklı yöntem kullanılabilir. Toplamli yöntem olarak adlandırılan ilk yöntemde; girdi vektörünün belirli bir oranı ağırlık vektörüne eklenir ve toplam birim uzunluğa bölerek tekrar normalize edilir.

Böylece ağırlık vektörü az bir şekilde veri grubunun doğrultusunda itilmiş olur. X'in ağa verilen girdi vektörü ve w^t 'nin t zamanında kazanan hücre olarak belirlenen hücrenin ağırlık vektörü aşağıdaki gibi basit bir şekilde hesaplanabilir. Formüldeki η , öğrenme hızı olarak adlandırılır.

$$w^{t+1} = \frac{w^t + \eta x}{\|w^t + \eta x\|} \quad (3.10)$$

Yukarıdaki yönteme alternatif olabilecek bir diğer ağırlık güncelleme yöntemi de çıkarımlı yöntemdir. Widrof-Hoff öğrenmesi olarak da adlandırılan bu yöntemde ağırlık vektörünün veri vektörü doğrultusunda yönlendirilmesinin bir yolunun da aralarındaki hata farkının bulunması olduğuna inanılır. Bu farkın belirli bir oranı ağırlık vektörüne eklenirse, ağırlık vektörü veri vektörü doğrultusunda yönlendirilmiş olur. Yukarıdaki formülde kullanılan notasyonlar kullanılacak olursa yöntem aşağıdaki algoritmayı temel alır.

$$e_i = x - w^i \quad (3.11)$$

$$w^{t+1} = w^t + \eta e \quad (3.12)$$

Buradaki η , öğrenme oranı mutlaka 1'den küçük hatta en fazla 0.4 civarında olmalıdır. Genelde en iyi çözümleme yavaş öğrenme oranı ile ulaşılır.

3.2.3 Karma (Reinforcement) Öğrenme

Gözetimli ve gözetimsiz öğrenme kadar sıklıkla kullanılmasa da söz edilmesi gereken üçüncü bir tür öğrenme karma bir öğrenme türü olan karma öğrenmedir. Karma öğrenme kesin çıktılar ağı karşılaştırma için verilemediği için gözetimsiz ama, ağı ürettiği çıktılar iyi ya da kötü olarak nitelendirip bu da yapay sinir ağına belirtilebildiği için gözetimli öğrenme olarak nitelendirilebilir. Bazı kaynaklarda bu tür öğrenme doğru yanıtın ne olduğu belirtilmese de yanıtın doğru olup olmadığı belirtildiği yani bir tür denetim uygulandığı için gözetimli öğrenme başlığı altında ele alınmaktadır [25].

3.3 Yapay Sinir Ağı'nın Tahmin Modelleri İçin Kullanımı

Gelecek değerlerin tahmini oldukça genel bir problemdir. Ekonomistler, meteorologlar ve daha birçok meslek sahibi geleceğe yönelik bazı değerleri tahmin etmekten sorumludurlar. Yapay sinir ağları, bu konuda şu ana kadar uygulanan diğer tahmin yöntemlerine göre oldukça yeni olmasına rağmen etkin olarak kullanılabilirliğinin temelde iki nedeninden bahsedilebilir:

- i. Yapay sinir ağları öylesine çok yönlüdürler ki ilgilenen kişiyi birçok model arasından herhangi birim seçmek zorunda bırakmazlar. AR, MA, ARIMA ve daha birçok tahmin modeli arasından veri grubunu en iyi tahmin edeni bulmak zorunluluğu yerine yapay sinir ağına veri grubu beslenir, ve genellikle oldukça iyi sonuçlar veren kendi modelini bulması ve sonuçları ortaya koyması beklenir.
- ii. Yapay sinir ağları ile kaotik birçok bileşen diğer modellere göre daha iyi bir şekilde irdelenebilir.

Yapay sinir ağlarının ekonometrik modellere göre daha avantajlı bir konumda olmasının en temel nedeni eldeki veri grubu ile ilgili herhangi bir varsayıma gerek duymadan karmaşık ve doğrusal olmayan ilişkileri modelleyebilmeleridir. Çok katmanlı yapay sinir ağları sadece girdi değişkenlerinde değil parametrelerde de doğrusal olmama özelliğine sahip parametrik regresyon modelleri olarak düşünülebilirler.

Yapay sinir ağı ile tahminde karşılaşılan en önemli tehlike fazlasıyla uyumdur (overfitting). Birçok ağı, çok sayıda bağımsız parametreye sahip olduğundan eğitim veri grubunu oldukça iyi tahmin etse de genelde kötü performans sergileyen yapay sinir ağı ile karşılaşma mümkündür. Ancak bu tehlikenin de, diğer tüm yöntemlerde de gerekli olan, dikkatli bir test süreci ile rahatlıkla aşılabileceği unutulmamalıdır.

Bir yapay sinir ağına eğitilmesi ve kullanımı süreci bir dizi adımdan oluşur. Bu adımlar şöyle özetlenebilir:

- i. Üzerinde çalışılacak konunun belirlenmesi: Tahmini yapılacak konunun ve kapsamın belirlenmesi bir sonraki adımda gerekli olacak veri toplanmasının etkinliği açısından önemlidir.
- ii. İlgili veri grubunun toplanması ve kullanıma hazır hale getirilmesi: Konunun kapsamı göz önünde bulundurularak konu ile ilgili değişkenler belirlenmeli ve bu değişkenlerle ilgili veriler toplanmalıdır. Daha sonra ise söz konusu veri grubunun yapay sinir ağına kullanıma hazır hale getirilmesi gereklidir. Sinir ağına beslenecek verilerin normalize edilmesi gereklidir. Genellikle verileri $[0 \ 1]$ aralığı yerine $[0.1 \ 0.9]$ aralığına gelecek şekilde normalize etmek yapay sinir ağlarında sık ve etkin kullanılan bir yöntemdir.
- iii. Veri grubunun ikiye bölünmesi: Yapay sinir ağına eğittikten sonra sergileyeceği performansı görmek için test etmek şarttır. Bu yüzden de veri grubu eğitim ve test veri grubu olmak üzere ikiye bölünmelidir.
- iv. Uygun yapay sinir ağı mimarisinin seçilmesi: Yapay sinir ağlarında kullanılacak gizli düzey sayısı, gizli sinir hücresi sayısı, momentum sabiti ya da öğrenme hızı değerleri gibi belirlenmesi gereken parametreler vardır ki bunlar bütün olarak söz konusu yapay sinir ağına mimarisinin temelini oluştururlar ve eğitim aşamasına geçmeden önce mutlaka belirlenmiş olmaları gereklidir.

- v. Uygun öğrenme (eğitme) algoritmasının seçilmesi: Literatürde incelenilen problemin tipine göre değişim gösteren algoritmalarından hangisinin kullanılacağı belirlenmelidir.
- vi. Yapay sinir ağının eğitilmesi: Eğitim veri grubu kullanılarak bu aşama tamamlanmalı ve benzer veri grupları söz konusu ağa verildiğinde iyi tahminler gerçekleştirecek şekilde sinir hücreleri arasındaki bağlantıların ağırlıklarının belirlenmesi sağlanmalıdır. Yapay sinir ağları yardımı ile çözümlenen problemlerin %85'inde geri-yayılmalı öğrenme algoritması ve sadece bir gizli düzey kullanılmıştır.
- vii. Yapay sinir ağının test edilmesi: Eğitilmiş olan ağın, gerçekten etkin tahminler yapıp yapmadığı önceden ayrılmış olan test veri grubu ile ölçülmelidir.
- viii. Yapay sinir ağın kullanılması: Yeni veri grupları ya da mevcut verilerin ağa beslenmesi sonucu tahminlerin gerçekleştirilmesi.

Herhangi bir tahmin problemi için bir yapay sinir ağının eğitildiğini varsayalım. Söz konusu ağın performansının mutlaka test verileri ile test edilmesi şarttır. Test verileri içindeki bilinen noktalar kullanılarak yapay sinir ağı çalıştırılır ve tahminleri gerçekleştirmesi istenir. Daha sonra yapılan her bir tahmin için gerçekleşen tahmin değerleri ile eldeki asıl değerler karşılaştırılır. Bu aşamada bir tahmin tekniğinin etkinliğini ölçmek için üzerinde uzlaşma sağlanan tek bir performans ölçütü yoktur. Ancak yine de birçok yapay sinir ağının hataların karesinin ortalamasını (MSE) kullandığı söylenebilir. MSE, hedef değerler ile gerçekleşen değerler arasındaki farkın karesinin alınması, eldeki veri grubu için toplamın alınması ve daha sonra elde kaç veri varsa bu sayıya bölünerek ortalamanın bulunmasını gerektirir:

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2 \quad (3.13)$$

Bu hata terimi en çok kullanılan olsa da benzer şekilde RMSE yani hataların karelerinin ortalamasının karekökü de çok kullanılan diğer bir performans ölçütüdür.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2} \quad (3.14)$$

RMSE, terimini kullanırken dikkat edilmesi gereken nokta, kullanılan veri grubunun ölçüm birimi büyüklüğüdür. Öyle ki, eğer tahmin edilen seri milyonlar düzeyindeyse 5 değerindeki bir RMSE küçük, ancak 10'lu sayılarla ifade edilmişse büyük olarak nitelendirilmelidir. Bu yüzden inch ile milimetre ölçüm birimleri kullanan iki ayrı yapay sinir ağının performansı karşılaştırılırken sorun çıkabilir. Bu problemi ortadan kaldırmak için birimsiz bir değere sahip olmak yararlıdır. Hata terimlerinin karesinin toplamı ile hedeflenen değerlerin karesinin toplamının birbirlerine olan oranının bulunması ile de göreceli RMSE değeri elde edilir ve birimsiz olduğu için iki yapay sinir ağının performans karşılaştırmasında rahatlıkla kullanılabilir.

$$RELRMSE = \sqrt{\frac{\sum_{i=0}^{n-1} (t_i - o_i)^2}{\sum_{i=0}^{n-1} t_i^2}} \quad (3.15)$$

Bu performans ölçüm teriminde pay değerlerinden birinin 0 olması sonuçta yanıltıcı bir terime neden olabilir ki bu problem de aşağıdaki gibi küçük bir işlem eklemesiyle ortadan kaldırılabilir.

$$RELRMSE = \sqrt{\frac{\sum_{i=0}^{n-1} (t_i - o_i)^2}{\sum_{i=0}^{n-1} (t_i - \bar{t})^2}} \quad (3.16)$$

Daha az kullanılan birimsiz bir performans ölçüm terimi de her bir hata teriminin hedef değere bölünüp, toplamın alınmasından önce mutlak değerlerinin bulunması ile hesaplanabilir.

$$MRE = \frac{1}{n} \sum_{i=0}^{n-1} \left| \frac{t_i - o_i}{t_i} \right| \quad (3.17)$$

Yapay sinir ağırları ile eğitim sürecinden sonraki test aşamasında eğitim süreci sonunda elde edilen hata terimine yakın bir hata elde edilemiyorsa bunun başlıca nedeni eğitim sürecinde kullanılan örneklerin sayıca ya da nitelik açısından yetersiz bilgi içeriyor olması ya da yapay sinir ağının ağırlıklarının yeterince iyi belirlenememiştir. Her iki durumda da eğitim süreci gerekli düzeltmeler yapılarak tekrarlanmalı ve bu aşama sonucu elde edilen değere yakın bir test değeri elde edilmesi sağlanmalıdır.

Yapay sinir ağırları, tez çalışmasında, tahmin sürecinin yanı sıra kümeleme analizi için de kullanılmıştır. Bu nedenle, bir sonraki bölümde yapay sinir ağırları ile kümeleme analizi çalışması üzerinde durulacaktır [25].

3.4 Yapay Sinir Ağının Kümeleme Analizi İçin Kullanımı

Kümeleme analizi büyük ve karmaşık veri setim aynı grubun elemanları benzer özellikleri paylaşacak şekilde az sayıda veri gruplarına indirger. Kümeleme analizi, her bir küme ya da grubun belirli özelliklere göre homojen olması yani grup içindeki elemanların birbirine benzeyecek şekilde ve her bir küme, bir diğerinden yine aynı özelliklere göre farklı olacak şekilde gruplandırılmasıdır. Kümeleme analizinde iki temel kavram vardır: uzaklık ve benzerlik. Uzaklık iki elemanın birbirinden ne kadar ayrı olduğunu ortaya koyarken benzerlik de yakınlığın göstergesidir. Bu analiz tekniğinde elemanların birbirine olan yakınlıkları tüm değişkenlerin birbirine olan uzaklıklarının karesi olarak ifade edilebilecek Öklid uzaklığının karesine göre hesaplanır.

Kümeleme analizinde en sık kullanılan beş algoritma: basit bağlantı (single linkage), tam bağlantı (complete linkage), ortalama bağlantı (average linkage), merkezilik yöntemi (centroid method) ve Ward yöntemi (Ward's method). Bu algoritmalar arasındaki temel farklılık kümeler arası uzaklığı hesaplamak için kullandıkları matematiksel süreçlerdedir. Her birinin sistematik bazı eğilimleri (veya hataları) vardır. Merkezilik yöntemi; örneğin; düzensiz şekillerde kümeler yaratan bir hataya sahiptir: bunu yanı sıra sadece belirli aralıktaki ya da kesirli verileri kullanabilir. Birçok alanda kullanılabilen kümeleme analiz çalışmaları için yapay sinir ağırları

oldukça yeni, bir o kadar da robust ve kusursuz bir yaklaşım olarak karşımıza çıkar. Robust olarak nitelendirilmelerinin en temel nedeni yapay sinir ağına girdi olarak sunulan veri eksik ya da yanlışlıklar barındırsa bile ağın anlamlı çözümler üretecek şekilde öğrenebilme yeteneğinin olmasıdır. Kümeleme analizi için kullanılan yapay sinir ağları da gözetimsiz öğrenme kapsamındadır. Zira önceden eğitim için ağa verilebilecek bir veri seti yoktur. Ancak ağdan elde edilen verileri en uygun şekilde gruplandırması beklenir. Özörgütlemeli haritalar olarak da adlandırılan bu yapay sinir ağı türü özellikle veri grubu oldukça dağınıksa (high dispersion) yani gruplandırılması güçse, diğer kümeleme analiz tekniklerine göre daha iyi sonuçlar verir. Veri grubunun dağınıklığı azaldıkça etkinliği diğer kümeleme analiz tekniklerine yaklaşır ancak hiçbir zaman onların aşağısına düşmez.

Bu tezdeki yapay sinir ağları ile ilgili kısımlarda MATLAB 6.5 kullanılmıştır. MATLAB, sadece yapay sinir ağları üzerine odaklanan bir program değil; optimizasyon, istatistik ve temel matematik ile ilgili birçok uygulamayı da içeren bir paket programdır. Yapay sinir ağları ile ilgili olan kısmı, "Toolboxes" bölümü içindedir ve yapay sinir ağlarının tasarımı, eğitimi ve simülasyonu üzerine kuruludur.

3.5 Yapay Sinir Ağlarının Pazarlama Uygulamaları

Faktörler arası yüksek derecede ilişki olduğunda, veri gürültülü ya da tam olmadığında, yapay sinir ağları, istatistiksel tekniklerin ikamesi ya da tamamlayıcısı olabilir. Aşağıda, yapay sinir ağlarının pazarlama yönetiminde kullanılabileceği bazı alanlar yer almaktadır:

Satış Tahminleri

Yöneticiler, genellikle hammadde satın alımında, işgücü yönetiminde, üretim planlama sürecinde kararlar almak için satışları tahmin etme ihtiyacı duyarlar. Çok sayıda satış kanalının talebini tatmin etmenin yanı sıra, etkin stok yönetimi için satış tahminleri şarttır. Tahminler, bölgesel dağıtım planlarının ve dağıtım aralıklarının temelini oluşturur. Ticari alan büyüklüğü, rekabet, ürünler arasındaki satış ve fiyat farklılıkları, nüfus dağılımı ve diğer demografik özelliklere ait veri tabanlarını kullanarak, istatistiksel metotlar yardımıyla perakendeciler, satış tahminleri yapmaktadır.

En sık kullanılan geleneksel metot, çok deęişkenli regresyon analizidir (multiple regression analysis). Çok deęişkenli regresyon analizinin uygulanması için ařağıdaki yer aldığı gibi deęişkenler arası istatistiksel ilişkilerin bilinmesini gerektirir[28]:

- Ürünün pazar talebi
- Tüketicilerin gelirleri
- Nüfus
- Ürünün fiyatı
- İkamelelerinin fiyatı
- Tamamlayıcı ürünlerin fiyatı

Normal şartlar altında, satış tahmini yapacak kişinin, her bir dağıtım kanalının kesin formülünü bilmesi güçtür. Bu da regresyon analizinde güçlük yaratan faktörlerden bir tanesidir. Genellikle, pazar arařtırmacıları, verinin yapısını basitleřtirmek için doğrusal varsayımlarda bulunur; ancak doğrusal modeller dönüşüm noktalarının (turning points) belirlenmesinde son derecede başarısızdır. Pazarlama yöneticileri, sürekli satış ve fiyat verileriyle ilgilendiğinden, dönüşüm noktalarının olmaması mümkün deęildir. Hatta bazı durumlarda veri kaotik yapı dahi gösterebilir. Çok deęişkenli regresyon analizi, bir anda sadece bir bağımlı deęişken ele alabilir. Birden fazla faktör yorumlanmak istendiğinde eksik kalmaktadır. Ayrıca, veri eksikliği söz konusu olduğunda, yapay sinir ağı, boşlukları model oluşturarak giderebilir. Regresyon analizinde bir veri eksikliği olduğunda ise, ya ilgili deęişken, tüm gözlemlerden atılır ya da gözlem yapılamaz.

Diğer yandan, girdi düzeyindeki sinir hücreleri sayısının bağımsız deęişken sayısına eşit olduğu ve çıktı düzeyindeki sinir hücreleri sayısının bağımlı deęişken sayısına eşit olduğu bir yapay sinir ağı, bu problemleri çözebilir. Gizli katman sayısı ve her bir gizli katmanda yer alacak sinir hücresi sayısı, rassal olarak seçilir. En az bir adet ara katmana sahip yapay sinir ağı, önceden varsayım yapılmasına ihtiyaç duymadan deęişkenler arasındaki ilişkileri ortaya çıkarabilir.

Yapay sinir ağıları, yeni bir girdi oluştuğunda, ağırlıklarını tekrar belirleyerek değişen çevreye ayak uydurabilir. Regresyon metodunda ise, böyle bir durumda tüm süreç baştan ele alınmalıdır.

Yapay sinir ağlarında her bir sinir hücresi, ayrı bir lineer kombinasyondur. Bu nedenle, kompleks ilişkileri belirlemede başarılıdır [29].

Araştırmacılar, tahmin etmede yapay sinir ağlarının performansını test etmişlerdir. De Groot ve Wurtz yapay sinir ağlarını standart lineer olmayan modellerle karşılaştırmış ve veri lineer olmayan özellikler içerdiğinde yapay sinir ağlarının en iyi yöntem olduğu sonucuna varmışlardır [30]. Hruscha, yapay sinir ağı ile market tepkisinin ekonometrik modelini karşılaştırmıştır ve çalışmanın sonuçlarına göre, yapay sinir ağı daha iyi model uyumu sağlamaktadır [31]. White, geri beslemeli metot (back-propagation method) ile stokastik yaklaşım prosedürleri (stochastic approximation procedures) arasındaki benzerlikleri ortaya çıkarmıştır [32].

Hedef Pazarlama

Pazar araştırmacılarının karşılaştığı problemlerden bir tanesi, benzer objeleri sınıflandırmaktır. Örneğin, ürününü test etmek isteyen bir firma, “benzer” şehirleri seçmek konusunda sıkıntı yaşayabilir. “Benzer” şehirler, nüfus ya da ortalama gelir değişkenlerine göre sınıflandırılabilir. Pazar araştırmacılarının karşılaştıkları bir diğer problem ise, hedef pazarın seçilmesidir [28].

Hedef pazarlama, bir ya da birkaç pazar bölümünü hedeflemek ya da her bir bölüm için ürün ve pazarlama programı geliştirmek için pazarı gruplama stratejisidir. Bu strateji ile şirketler, doğru kişiler için çabalarını harcamış olacaklardır.

Hedef pazarlamanın ilk basamağı, pazar bölümlendirmesidir. Çalışmanın ilk aşamalarında pazar bölümlendirmesinin temelinde yatan değişkenler açıklanmıştır.

Hedeflenen pazar bölümü, farklı ürünler ve firmalar pazardan pazara değişmektedir. Pazar bölümlendirmesinde kullanılan geleneksel metot kümeleme analizidir. Diğer yandan yapay sinir ağları da bu süreç için kullanılabilir. [28]

Kümeleme analizinin detayları çalışmanın önceki bölümlerinde anlatılmıştı. Birçok kümeleme analizi metodu sezgisel yaklaşıma sahiptir; farklı metotlar farklı sonuçlar verebilmektedir. Hiyerarşik kümeleme metodunda, araştırmacılar, bir benzerlik

ölçüsü seçmek zorundadırlar. Bu metot, örneklem büyüklüğü fazla olduğunda uygun bir yöntem değildir.

Kümeleme için, yapay sinir ağları metodu da kullanılabilir. 2 seviyeli basit bir ağ ile ya da özörgütlemeli haritalar ile gruplama yapılabilir. Tüketicinin demografik, sosyoekonomik, coğrafik ve ürünle ilgili özellikleri bir sinyal oluşturur. Hedeflenen pazar bölümü sayısı üç olsun. Üç bölüm, ağda üç çıktı sinir hücresi ile temsil edilir. Girdi hücresinden her bir çıktı hücresine doğru sinyaller teker teker geçer. Bu süreçte ağ, her bir çıktı hücresinin çıktısını oluşturur. En yüksek değerde çıktıya sahip çıktı hücresi, kazanmış olur ve ilgili girdiye sahip tüketiciler “kazanan” hücrenin (segment) üyesi olurlar [28].

Özörgütlemeli haritalar, rekabete dayalı öğrenme kavramını geliştirmişlerdir. Bu metotta, en yakın ağırlık vektörüne sahip bölüme, yapay sinir ağının sinyal vermesi sağlanır. Bunun için tek koşul, mesafenin önceden belirlenmiş limitler arasında kalıyor olmasıdır. Aksi takdirde, yeni bir segment oluşturulur.

Pazarlama alanına uygulanabilecek daha sınırsız alan mevcuttur.

4 UYGULAMA

İlaç sektöründeki en önemli kavramlardan bir tanesi pazar bölümlendirmesidir. Bunun nedeni, firmaların yoğun rekabet içinde, yasalarla belirlenmiş kaynak kullanımı ve tanıtım olanakları ile satış ve pazarlama aktiviteleri yürütebilmeleri, sektörde farklı özelliklere sahip çok sayıda doktor olması; buna karşılık belirli sayıda satış temsilcileri bulundurabilmeleridir. Dolayısıyla, hangi doktor segmentine hangi bilimsel hizmetlerin sunulması, hangi tanıtım faaliyetleriyle ulaşılması gerektiği, ilaç sektöründe önemli bir konu olarak karşımıza çıkmaktadır.

Klafatis ve Cheston, Amerika'da ilaç sektöründe ilaç pazarında bölümlendirmesi çalışmalarını incelemiştir. Bu araştırmaya göre, ilaç firmalarının %72'si pazar bölümlendirmesi yapmaktadır [33]. 1997 yılından günümüze kadar, bu oranın arttığı düşünülürse, pazar bölümlendirmesinde etkinliğin, ilaç firmaları açısından ne kadar önemli olduğu anlaşılır.

Hollanda'da 290 firmayla yapılan bir anket çalışması sonucunda anketi yanıtlayan 160 firmanın (% 70,1) veritabanlı pazarlama aktivitelerinde segmentasyon kullandıkları ortaya konmuştur. Segmentasyon uygulayan firmaların % 90'ı, segmentasyonu hedef belirlemek amacıyla kullanmaktadır. Anketi yanıtlayan az sayıda firma, segmentasyonu, tüketicilerin davranışlarını değiştirmek için kullandıklarını ifade etmişlerdir. Anketi yanıtlayan firmaların yaklaşık % 27'si, her pazar bölümü için tahmin modelleri oluşturmak için segmentasyon kullanmaktadır. Birçok firma, farklı tepkiler gösteren tüketicileri gruplamak için segmentasyon kuralları aramaktadır. Yine, birçok firma, satın alma miktarları homojen olan tüketici gruplarını bir segment içinde toplamaktadır. Segmentasyonun amacı, firmaların sadece % 42,8'inde karı ayırtmaktır. Kredibilite düzeylerini ayırtmak, az firmanın segmentasyon yaparken hedeflediği bir durumdur [34].

Uygulama, bir ilaç firmasına ait bir ürün üzerine yapılmıştır. İlaç firmalarının pazarlama aktiviteleri, temel olarak tıbbi satış mümessillerinin, ürünü reçeteleyecek doktorları ziyaret etmesi ve doktorlara ürünü tanıtması şeklinde gerçekleşmektedir.

Tıbbi satış mümessillerinin tüm doktorlara ulaşması ve ürünlerini tanıtmaları, doktor sayısı karşılığında mümessil sayısının yetersizliği nedeniyle mümkün olmamaktadır. Diğer yandan, firma, tüm illerde mümessil bulunduramadığı için, bazı doktorlara erişim kısıtlı olmaktadır. Bu noktadan yola çıkarak, sadece belirli miktarda doktoru hedeflemek gerekliliği ortaya çıkmaktadır. Doktor hedeflemesinde kullanılabilecek bir takım kriterler vardır. Çalışmada kullanılan kriterler aşağıda listelenmiştir:

- Ulusal Fikir Lideri: Üniversite ya da eğitim veren devlet hastanesinde görev yapan, profesör/doçent, tercihen yurt dışı çalışma deneyimi olan, bilimsel yayınları takip eden, Türkiye bazında tanınan ve saygı gören hekim
- Bölgesel Fikir Lideri: Üniversite ya da eğitim veren devlet hastanesinde görev yapan, profesör/doçent, tercihen yurt dışı çalışma deneyimi olan, bilimsel yayınları takip eden, bulunduğu bölgede tanınan ve saygı gören hekim
- Yüksek reçeteleme potansiyeli: İlgili sendromla ilgili reçete yazma potansiyeli çok olan (ilgili sendrom hastası görme potansiyeli yüksek) hekim.
- İlacın Etkin Olduğu Sendroma İlgili: Klinikte ilgili sendromun uzmanı olarak kabul gören, danışılan, teşhis ve tedavi protokolü takip edilen hekim
- Kurum Kararını Etkime: Klinik şefi, başhekim, poliklinik şefi, başasistan gibi pozisyonlarda görev yapan ünitenin teşhis ve tedavi protokollerini belirleyen hekim.
- Çalıştığı Kurum: “Üniversite Hastanesi”, “Devlet Hastanesi”, “Özel Hastane”, “Muayenehane” alternatif kurumlardır.
- Unvanı: “Profesör”, “Doçent”, “Yardımcı Doçent”, “Uzman” alternatif unvanlardır.

Bu çalışmada, diğer yandan yapay sinir ağları için Matlab programı kullanılmış; çıkan bölümler birbiriyle karşılaştırılmıştır.

Ancak bu yönlendirmeye destek verip vermediğini araştırmak için 650 adet veri için öncelikle hiyerarşik kümeleme yapılarak küme sayısı belirlemek hedeflenmiştir.

Müşteriler arası heterojenliği göstermesi için, araştırmacılar iki ya da daha fazla metodun birleştirilmesini ortaya koymuş, bu metotlar arasındaki düşük korelasyon katsayısının, birleştirilmiş modelin etkinliğini artırdığını önermiştir [35].

Literatürde önerilen ve Punj ve Steward tarafından 1983 yılında yapılan ve 2002 yılında Kuo ve diğerleri tarafından da kullanılan bir yöntem olan, önce hiyerarşik kümeleme Wards'ın metodu ile küme sayısını ortaya çıkarmak, ardından hiyerarşik olmayan k-ortalamları ile kümelemeyi gerçekleştirmek, bu çalışmada da yapılmıştır [36]. Aynı yöntem, Ziberna ve Zabkar tarafından da yapılmış ve Ward's yöntemi kullanılarak yapılan hiyerarşik küme sonuçları ile k-ortalamları yöntemi kullanılarak yapılan hiyerarşik olmayan küme sonuçları birbirleriyle karşılaştırıldığında, sonuçların % 81.5'inin her iki yöntemle de aynı kümede olduğunu göstermişlerdir [37].

4.1 Veri Toplama

Değişkenler belirlenirken, firma yetkilileri ile görüşülmüştür. Firma için en önemli kriterler, ulusal fikir lideri olmak, bölgesel fikir lideri olmak, kurum kararını etkiliyor olmak, reçeteleme potansiyeli yüksek olmak ve incelenen sendroma ilgisi olmaktır. Doktorları bölümlere ayırmak için, doktora ait satış, incelenen ürünün ya da rakibin reçetelenmesi, gördüğü sendroma ait hasta sayısı, doktorun ilaçtan memnuniyet derecesi gibi değişkenler de kullanılabilir; ancak bu tip datalara erişme imkanı bulunmamasından dolayı, bu tip değişkenler çalışma dışında bırakılmıştır.

Değişkenlere ait bilgiler, mümessillere uygulanan bir anket yoluyla alınmıştır. Çalışmanın başında, ankette incelenen sendromla ilgili 1541 adet doktor vardı. Asistanlar, yukarıda belirtilen önemli beş kriteri sağlamadığı için çalışma dışı bırakılmıştır. Çalışmada 650 adet doktor incelenmiştir.

Tüm değişkenler, 0-1 değişkenlerden oluşmaktadır.

4.2 Kümeleme Analizi

Kümeleme Analizinin adımları aşağıdaki şekilde anlatılmıştır:

Problemi formüle etmek:

Değişkenler, firma yetkilileri ile görüşmeler doğrultusunda belirlenmiştir.

Mesafe ya da benzerlik ölçüsü seçimi;

En sık kullanılan yöntem obje çiftleri arasındaki mesafe bakımından benzerliğin ölçülmesidir. Birbirleriyle arasındaki mesafe az olan objeler birbirlerine daha benzerken, birbirinden uzak olanlar daha ayrıdır. İki obje arasındaki mesafeyi hesaplamamanın bir çok yolu vardır. En fazla kullanılan yakınlık ölçüsü “Öklid mesafesi” ya da onun karesidir. Bu çalışmada da hiyerarşik kümelemede “öklid mesafesi” kullanılmıştır.

Değişkenler, 0-1 değişkenleri olduğu için standartlaştırmaya ihtiyaç duyulmamıştır.

Bir kümeleme prosedürü seçimi ;

Literatürde de değinildiği gibi, öncelikle hiyerarşik kümeleme ile küme sayısını belirlenmiş; ardından hiyerarşik olmayan kümeleme analizi ile kümeler ortaya konmuştur.

Kümelerin sayısına karar verme

Hiyerarşik kümeleme analizi ile sınıf sayısı belirlenebildiği gibi, konu hakkında bilgili kişilerden de yönlendirici bilgi alınabilir. Firma tarafından, dört adet kümeye yönlendirilmiş; ancak hiyerarşik kümeleme analizinin sonuçları da irdelenmiştir.

4.2.1 Kümeleme Analizi Sonuçları

Tablo 4-1’de, küme sayısını belirlemek üzere yapılan hiyerarşik kümeleme analizi sonucunda çıkan aglomerasyon şedülünün son basamakları görülmektedir.

Tablo 4-1. Aglomerasyon Şedülü

Agglomeration Schedule

Stage	Cluster Combined		Coefficients	Stage Cluster First Appears		Next Stage
	Cluster 1	Cluster 2		Cluster 1	Cluster 2	
625	81	359	2.000	329	213	632
626	146	159	2.000	0	0	631
627	1	10	2.010	597	617	630
628	5	32	2.066	591	618	638
629	230	332	2.167	622	0	643
630	1	121	2.241	627	571	641
631	21	146	2.333	615	626	645
632	53	81	2.333	573	625	644
633	12	22	2.333	593	416	635
634	39	103	2.400	608	0	642
635	12	77	2.457	633	588	637
636	11	165	2.660	616	577	640
637	12	41	2.727	635	0	639
638	5	6	2.733	628	624	641
639	2	12	2.742	621	637	646
640	11	126	2.785	636	619	642
641	1	5	2.913	630	638	644
642	11	39	3.206	640	634	645
643	4	230	3.341	623	629	647
644	1	53	3.529	641	632	648
645	11	21	3.700	642	631	646
646	2	11	3.897	639	645	647
647	2	4	4.022	646	643	648
648	1	2	5.155	644	647	649
649	1	17	5.336	648	620	0

Agglomerasyon şedülünde katsayı değerinin büyük bir miktarda sıçrayış gösterdiği noktanın altında kalan satır sayısının bir fazlası küme sayısını vermektedir. Buna göre, Tablo 4-1'den görüldüğü gibi üç kümeye ayırmak uygun olacaktır. Hiyerarşik olmayan kümeleme metodundan k-ortalamları metoduna 3 sınıf çıktı olarak girildiğinde elde edilen sonuçlar aşağıda gösterilmektedir:

Quick Cluster

Iteration History ^a

Iteration	Change in Cluster Centers		
	1	2	3
1	1.221	1.416	1.148
2	.334	.287	.598
3	4.E-02	1.E-01	.142
4	5.E-03	1.E-02	4.E-02
5	.000	.000	.000

a. Convergence achieved due to no or small distance change. The maximum distance by which any center has changed is .000. The current iteration is 5. The minimum distance between initial centers is 2.828.

Beşinci iterasyonun sonucunda, küme merkezleri arasında bir değişiklik meydana gelmemeye başladığı için, bu noktada analiz durmuştur.

Number of Cases in each Cluster

Cluster	1	397.000
	2	156.000
	3	97.000
valid		650.000
Missing		.000

Her bir kümeye düşen veri sayısı gösterilmektedir. Birinci kümeye 397, ikinci kümeye 156, üçüncü kümeye 97 adet doktor düşmüştür.

Tablo 4-2. Üç Kümeli k-ortalamları Analizi Sonucu

	S1(%)	S2(%)	S3(%)
UFL	17	67	17
BFL	18	50	32
İlgi	70	25	5
Reçete	90	6	4
KKE	26	42	33
Prof	0	100	0
Doç	4	3	93
Yrd Doç	15	69	15
Uzm	97	3	0
Üniv	17	58	25
Dev	91	3	7
Özel	58	26	18
Muay	67	20	13

Kümeleri Yorumlama ve Profilleme

Sonuçlardan görülebildiği gibi verileri üç sınıfa bölmek anlamlı sınıflar çıkarmamaktadır. Belirlenen üçüncü sınıfta sadece doçentlerin ağırlığı vardır ki; bu pazar bölümü, diğer pazar bölümlerine göre farklı bir hizmet sunmayı gerektirecek bir özellik değildir. Zira, firma yetkilileri tarafından önerilen sınıf sayısı da dördtür. Küme sayısını, hiyerarşik olmayan kümeleme metotlarından k-ortalamları metoduna dört olarak giriş yapıldığında elde edilen sonuçlar aşağıdaki gibidir:

Iteration History ^a

Iteration	Change in Cluster Centers			
	1	2	3	4
1	1.154	.402	1.377	1.295
2	.383	.101	.195	.229
3	.153	9.E-03	6.E-02	1.E-02
4	4.E-02	4.E-03	.000	1.E-02
5	.000	.000	.000	.000

a. Convergence achieved due to no or small distance change. The maximum distance by which any center has changed is .000. The current iteration is 5. The minimum distance between initial centers is 2.449.

Yine beş iterasyon sonucunda analiz durmuştur.

Number of Cases in each Cluster

Cluster	1	53.000
	2	392.000
	3	105.000
	4	100.000
Valid		650.000
Missing		.000

Her bir kümeye düşen veri sayısını gösterilmektedir. Birinci kümeye 53, ikinci kümeye 392, üçüncü kümeye 105, dördüncü kümeye 100 adet doktor düşmüştür.

Değişkenlerin, hangi sınıflara düştüklerine ait oran (%) aşağıdaki tabloda özetlenmiştir:

Tablo 4-3. Dört Kümeli k-ortalamları Analizi Sonucu

	S1(%)	S2(%)	S3(%)	S4(%)
UFL	8	0	38	54
BFL	18	15	47	20
İlgi	1	69	20	9
Reçete	3	91	3	3
KKE	43	17	20	20
Prof	7	0	0	93
Doç	36	0	64	0
Yrd Doç	21	6	73	0
Uzm	1	96	3	0
Üniv	0	16	47	37
Dev	10	90	0	0
Özel	25	50	12	13
Muay	16	65	1	18

- Segment1: Kurum Kararını Etkileyen Doktorlar(% 43) ağırlıklıdır.
- Segment2: Yoğunlukla Devlet Hastanelerinde Çalışan (%90) reçeteleme potansiyeli yüksek (% 91) ve sendromla ilgili (% 69) uzman(% 96) doktorlar yer almaktadır.
- Segment3: Yoğunlukla üniversite hastanelerinde çalışan (%47), doçent (% 64) ve yardımcı doçent (% 73) bölgesel fikir lideri (% 47) doktorlar yer almaktadır.
- Segment4: Ulusal fikir lideri (54) profesör (% 93) doktorlar yer almaktadır.

4.2.2 Geçerlilik Testi

Geçerlilik testi diskriminant analizi kullanılarak yapılmıştır.

Diskriminant analizinin bir amacı, bir grubu en iyi tarif eden değişkenler kümesini belirlemektir. Diğer bir amacı ise sınıflama yapmaktır. Kümeleme analizi, istatistiksel anlamda, birbirlerinden farklılıklar gösteren tüketici grupları yaratır. Gruplara daha sonradan katılacakların, hangi kıstaslara göre sınıflandırılacağını söylemez. Diskriminant analizi birinci amacından yola çıkarak, kümeleme analizinin,

bireyleri nasıl kümelediğini öğrenir ve her bir grup için formül çıkarır. Gruplara katılacak bireyler, bu formüller aracılığıyla, kolaylıkla sınıflandırılabilir. Diğer amacı doğrultusunda ise, kümeleme analizinde kullanılan verilerin bir kısmı diskriminant analizi yapılır ve her iki metodun elde ettiği sonuçlar karşılaştırılır. Uygulamada, 650 adet veri diskriminant analizine sokulmuş ve çapraz geçerlilik testi uygulanmıştır. Diskriminant analizinin sonuçları ve açıklamaları aşağıdaki verilmiştir:

Discriminant Analysis 1

Box's Test of Equality of Covariance Matrices

Log Determinants

Cluster Number of Case	Rank	Log Determinant
1	11	.a
2	9	.a
3	8	.a
4	8	.a
Pooled within-groups	12	-36.918

The ranks and natural logarithms of determinants printed are those of the group covariance matrices.

a. Singular

Test Results ^a

Tests null hypothesis of equal population covariance matrices.

a. No test can be performed with fewer than two nonsingular group covariance matrices.

Grupların kovaryans matrislerinin eşitliği test edilmektedir. Fakat bu test, verilerin 0-1 değişken değerlerinden oluşmasından dolayı anlamlı sonuç vermemiştir.

Variables Failing Tolerance Test ^a

	within-G roups Variance	Tolerance	Minimum Tolerance
V9	2.66E-02	.000	.000

All variables passing the tolerance criteria are entered simultaneously.

a. Minimum tolerance level is .001.

Değişkenlerin, diskriminant fonksiyonundaki diğer değişkenlerle olan korelasyonlarını inceleyen bir testtir. Eğer, değişkenin korelasyonu yüksek olursa, tolerans değeri düşük olmakta ve diskriminant fonksiyonuna katılmamaktadır. Bu teste göre dokuzuncu değişkeni (uzman değişkeni), tolerans testinden geçememiş ve diskriminant fonksiyonuna katılmamıştır.

Summary of Canonical Discriminant Functions

Eigenvalues

Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
1	19.639 ^a	76.4	76.4	.975
2	5.254 ^a	20.4	96.8	.917
3	.822 ^a	3.2	100.0	.672

a. First 3 canonical discriminant functions were used in the analysis.

Özdeğerler, gruplar arası kareler toplamı ile grup içi kareler toplamı oranıdır. Özdeğeri en yüksek olan fonksiyon, grup ortalamalarını en ayrı yapan fonksiyondur. En düşük özdeğer sahip fonksiyon, datanın dağılımını en az açıklayan fonksiyondur.

Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1 through 3	.004	3500.0	36	.000
2 through 3	.088	1559.5	22	.000
3	.549	384.460	10	.000

Wilks'in Lambdası, gruplar arası farklılıklarla açıklanmayan diskriminant skorlarındaki toplam varyansın oranını gösterir. 0 ile 1 arası değer alır. Anlamlılık düzeyi sıfıra yakınsa grup ortalamaları birbirinden farklıdır.

**Standardized Canonical
Discriminant Function Coefficients**

	Function		
	1	2	3
V1	-.075	.013	-.009
V2	.034	.119	.033
V3	-.002	-.041	-.079
V4	-.226	-.360	.034
V5	-.012	.243	.329
V6	1.097	-.329	.210
V7	.902	.952	.571
V8	.781	.895	.404
V10	.179	.342	-1.031
V11	-.236	.045	-.241
V12	.082	.080	-.169
V13	.071	-.014	.051

Değişkenlerin birimleri farklı olduğunda, standart olmayan katsayıları kullanmak, değişkenlerin diskriminant fonksiyonuna katkılarını etkileyecektir. Bu nedenle, değişkenlerin göreceli etkilerini görebilmek için standartlaştırılmış diskriminant fonksiyonu katsayıları kullanılabilir. Bu çalışmada, değişkenlerin değerleri 0 ile 1 olduğu için, standartlaştırmaya ihtiyaç duyulmamıştır.

Structure Matrix

	Function		
	1	2	3
V6	.719*	-.631	.038
V9 ^a	-.564*	-.542	-.312
V7	.052	.409*	.249
V4	-.216	-.255*	-.033
V8	.024	.230*	-.060
V2	.036	.104*	-.007
V10	.241	.252	-.868*
V11	-.227	-.195	.447*
V5	.035	.072	.313*
V13	.000	-.055	.236*
V12	.021	-.025	.216*
V3	-.020	.005	-.123*
V1	.043	.017	-.050*

Pooled within-groups correlations between discriminating variables and standardized canonical discriminant functions
Variables ordered by absolute size of correlation within function.

- *. Largest absolute correlation between each variable and any discriminant function
- a. This variable not used in the analysis.

Değişkenlerle diskriminant fonksiyonları arasındaki korelasyonları verir. Bu tablo yardımıyla değişkenlerin fonksiyonlara katkı değerleri ölçülebilir. Örneğin, V6 ve V9 değişkenleri, birinci fonksiyona en fazla katkıyı sağlamaktadır.

Canonical Discriminant Function Coefficients

	Function		
	1	2	3
V1	-.548	.096	-.067
V2	.139	.486	.134
V3	-.005	-.115	-.222
V4	-.689	-1.094	.103
V5	-.054	1.071	1.454
V6	10.703	-3.204	2.049
V7	3.685	3.889	2.330
V8	3.382	3.875	1.752
V10	.661	1.258	-3.798
V11	-.728	.140	-.744
V12	.317	.309	-.654
V13	.183	-.037	.132
(Constant)	-2.009	-.257	.835

Unstandardized coefficients

Standartlaştırılmamış diskriminant fonksiyonu katsayılarını vermektedir.

Functions at Group Centroids

Cluster Number of Case	Function		
	1	2	3
1	2.010	2.695	2.810
2	-3.075	-.941	-.057
3	1.706	4.451	-1.009
4	9.198	-2.412	-.204

Unstandardized canonical discriminant functions evaluated at group means

Classification Statistics

Classification Function Coefficients

	Cluster Number of Case			
	1	2	3	4
V1	-5.812	-3.181	-5.218	-10.040
V2	4.222	1.362	4.521	2.336
V3	3.886	4.969	4.533	5.107
V4	1.977	9.159	-.129	2.302
V5	5.532	-2.253	1.876	-4.708
V6	46.604	-2.044	29.896	133.724
V7	42.342	2.783	39.153	41.946
V8	35.917	-.394	35.002	35.160
V10	40.553	43.506	57.064	50.327
V11	39.997	45.319	43.306	36.293
V12	45.275	44.413	48.218	47.943
V13	7.741	6.564	7.116	8.847
(Constant)	-41.937	-28.756	-47.237	-93.224

Fisher's linear discriminant functions

Veri grupları için sınıflandırma fonksiyonunun katsayılarını vermektedir. Sütunlarda kümeler, satırlarda değişkenler yer almaktadır. Yeni bir veri geldiğinde her bir değişken değerini, ilgili katsayısı ile çarpıp sabit değerlerle toplama işlemi her bir küme için gerçekleştirilir. Yeni veri, en yüksek değere sahip olan kümeye ait olacaktır.

Classification Results ^{b,c}

		Cluster Number of Case	Predicted Group Membership				Total
			1	2	3	4	
Original	Count	1	42	3	0	8	53
		2	3	389	0	0	392
		3	0	13	92	0	105
		4	0	0	0	100	100
	%	1	79.2	5.7	.0	15.1	100.0
		2	.8	99.2	.0	.0	100.0
		3	.0	12.4	87.6	.0	100.0
		4	.0	.0	.0	100.0	100.0
Cross-validated ^a	Count	1	42	3	0	8	53
		2	3	389	0	0	392
		3	0	13	92	0	105
		4	0	0	0	100	100
	%	1	79.2	5.7	.0	15.1	100.0
		2	.8	99.2	.0	.0	100.0
		3	.0	12.4	87.6	.0	100.0
		4	.0	.0	.0	100.0	100.0

a. Cross validation is done only for those cases in the analysis. In cross validation, each case is classified by the functions derived from all cases other than that case.

b. 95.8% of original grouped cases correctly classified.

c. 95.8% of cross-validated grouped cases correctly classified.

Gerçek küme üyelikleri ile diskriminant fonksiyonlarına göre elde edilmiş tahmin sonuçlarının karşılaştırıldığı tablodur. Orijinal satırında bütün veriler sınıflandırma fonksiyonlarında yerine konularak gruplara atanmaktadır. Diyagonalde gözükten değerler doğru sınıflandırılmış veri sayılarını göstermektedir. Örneğin, hiyerarşik kümeleme ile birinci gruba atılmış 42 adet verinin, diskriminant analizi ile yine birinci gruba ait olduğu tahmin edilmektedir. 3 adet veri, hiyerarşik kümeleme ile birinci gruba atılmışken, diskriminant analizi ile ikinci grupta yer almıştır. Toplamda verilerin % 95,8'i, her iki yaklaşımla da aynı grupta yer almıştır.

Çapraz geçerlilik satırında, bir örneğin dışındaki kalan bütün verilerle diskriminant fonksiyonu tahmin edilmekte ve dışarıda kalan örnek diskriminanttan elde edilen sınıflandırma fonksiyonuyla bir gruba atanmaktadır. Yine diyagonaldeki değerler, doğru sınıflandırılmış veri sayılarını göstermektedir.

Elde edilen veriler, başka bir geçerlilik testine daha tutulmuştur. Burada izlenen yol şu şekildedir: 650 adet verinin % 70'i ile k-ortalamları yöntemi ile kümeleme yapılmış; bu kümelerin orta değerleri (centroid) kullanılarak, geriye kalan % 30'luk kısım için k-ortalamları yöntemi ile kümeleme yapılmıştır. Verinin % 30'u ile elde edilen bölümler ile tüm verinin k-ortalamları yöntemi ile kümelenmesiyle elde edilen bölümler çapraz tablolama ile karşılaştırılmıştır.

650 adet veriye ilişkin analizin sonuçları aşağıdaki gibidir:

Quick Cluster

Iteration History ^a

Iteration	Change in Cluster Centers			
	1	2	3	4
1	1.154	.402	1.377	1.295
2	.383	.101	.195	.229
3	.153	9.E-03	6.E-02	1.E-02
4	4.E-02	4.E-03	.000	1.E-02
5	.000	.000	.000	.000

a. Convergence achieved due to no or small distance change. The maximum distance by which any center has changed is .000. The current iteration is 5. The minimum distance between initial centers is 2.449.

Küme merkezlerindeki değişimi göstermektedir. Değişim yeterince küçüldüğünde, kümeleme iterasyonu durdurulur.

Final Cluster Centers

	Cluster			
	1	2	3	4
V1	0	0	0	0
V2	0	0	0	0
V3	0	0	0	0
V4	0	1	0	0
V5	0	0	0	0
V6	0	0	0	1
V7	1	0	1	0
V8	0	0	0	0
V9	0	1	0	0
V10	0	0	1	1
V11	1	1	0	0
V12	0	0	0	0
V13	0	0	0	0

Kümeleme analizi sonucunda elde edilen sonuç küme merkezlerini vermektedir.

Number of Cases in each Cluster

Cluster	1	53.000
	2	392.000
	3	105.000
	4	100.000
Valid		650.000
Missing		.000

Her bir gruba düşen veri miktarına düşen veri miktarını göstermektedir.

Aşağıda verilerin % 70'i ile yapılan k-ortalamları kümeleme analizi sonuçları yer almaktadır:

Quick Cluster

Iteration History ^a

Iteration	Change in Cluster Centers			
	1	2	3	4
1	1.037	.894	1.348	1.131
2	.414	7.E-02	.214	.236
3	.221	7.E-03	8.E-02	.000
4	.167	6.E-03	.000	8.E-02
5	9.E-02	.000	.000	5.E-02
6	.000	.000	.000	.000

- a. Convergence achieved due to no or small distance change. The maximum distance by which any center has changed is .000. The current iteration is 6. The minimum distance between initial centers is 2.449.

Final Cluster Centers

	Cluster			
	1	2	3	4
V1	0	0	0	0
V2	0	0	0	0
V3	0	0	0	0
V4	0	1	0	0
V5	0	0	0	0
V6	0	0	0	1
V7	1	0	0	0
V8	0	0	0	0
V9	0	1	0	0
V10	0	0	1	1
V11	1	1	0	0
V12	0	0	0	0
V13	0	0	0	0

Kümeleme analizi sonucunda elde edilen bu sonuç küme merkezleri saklanmış ve verinin geriye kalan % 30'luk kısmının k-ortalamları ile kümelenmesinde kullanılmıştır.

Number of Cases in each Cluster

Cluster	1	38.000
	2	275.000
	3	77.000
	4	65.000
Valid		455.000
Missing		.000

Crosstabs

Case Processing Summary

	Cases					
	Valid		Missing		Total	
	N	Percent	N	Percent	N	Percent
Cluster Number of Case * Cluster Number of Case	455	100.0%	0	.0%	455	100.0%

Cluster Number of Case * Cluster Number of Case Crosstabulation

			Cluster Number of Case				Total
			1	2	3	4	
Cluster Number of Case	1	Count	37				37
		% within Cluster Number of Case	100.0%				100.0%
	2	Count		275			275
		% within Cluster Number of Case		100.0%			100.0%
3	Count				77		77
	% within Cluster Number of Case				100.0%		100.0%
4	Count		1			65	66
	% within Cluster Number of Case		1.5%			98.5%	100.0%
Total		Count	38	275	77	65	455
		% within Cluster Number of Case	8.4%	60.4%	16.9%	14.3%	100.0%

650 adet verinin grup üyelikleri ile 455 adet (ilk % 70) verinin grup üyeliklerinin karşılaştırılmasıdır. Sadece 1 adet veri farklı gruplanmıştır.

Quick Cluster

Initial Cluster Centers

	Cluster			
	1	2	3	4
V1	0	0	0	0
V2	0	0	0	0
V3	0	0	0	0
V4	0	1	0	0
V5	0	0	0	0
V6	0	0	0	1
V7	1	0	0	0
V8	0	0	0	0
V9	0	1	0	0
V10	0	0	1	1
V11	1	1	0	0
V12	0	0	0	0
V13	0	0	0	0

Input from FILE Subcommand

Başlangıç küme merkezleri, 455 adet veriyle elde edilen sonuç küme merkezleri ile aynı alınmıştır.

Iteration History ^a

Iteration	Change in Cluster Centers			
	1	2	3	4
1	.345	9.E-02	.300	.214
2	.103	.000	.000	4.E-02
3	.000	.000	.000	.000

- a. Convergence achieved due to no or small distance change. The maximum distance by which any center has changed is .000. The current iteration is 3. The minimum distance between initial centers is 1.211.

Final Cluster Centers

	Cluster			
	1	2	3	4
v1	0	0	0	0
v2	0	0	0	0
v3	0	0	0	0
v4	0	1	0	0
v5	0	0	0	0
v6	0	0	0	1
v7	1	0	1	0
v8	0	0	0	0
v9	0	1	0	0
v10	0	0	1	1
v11	1	1	0	0
v12	0	0	0	0
v13	0	0	0	0

Number of Cases in each Cluster

Cluster	1	16.000
	2	117.000
	3	28.000
	4	34.000
Valid		195.000
Missing		.000

Crosstabs

Cluster Number of Case * Cluster Number of Case Crosstabulation

			Cluster Number of Case				Total
			1	2	3	4	
Cluster Number of Case	1	Count	16				16
		% within Cluster Number of Case	100.0%				100.0%
	2	Count		117			117
		% within Cluster Number of Case		100.0%			100.0%
	3	Count			28		28
		% within Cluster Number of Case			100.0%		100.0%
	4	Count				34	34
		% within Cluster Number of Case				100.0%	100.0%
Total		Count	16	117	28	34	195
		% within Cluster Number of Case	8.2%	60.0%	14.4%	17.4%	100.0%

Verilerin tamamını kullanarak yapılan sınıflandırma ile, 455 adet veriden elde edilen küme merkezleri kullanılarak, geriye kalan 195 adet verinin sınıflandırılması arasında tam bir uyum gözlenmektedir.

Yukarıda değinilmiş her iki geçerlilik testi sonucuna dayanarak, kümeleme analizi ile elde edilmiş grup üyeliklerinin geçerliliği kanıtlanmıştır.

4.3 Yapay Sinir Ağları

Genellikle yapay sinir ağının kalitesi hızı, sistemi eğitmek için kullanılan ağın topolojisine (gizli katman ve gizli düğüm sayısı) yüksek oranda bağlıdır. Yapay sinir ağlarında, optimum bir ağ söz konusu değildir. Tatmin edici sonuç veren bir ağın kurulması için, farklı ağ topolojilerinin kullanılması gerekebilir [38].

4.3.1 Sonuçları

Matlab 6.5 programı sonuçları aşağıdaki gibidir:

Hiyerarşik kümelemenin sonucunda önerilen üç adet küme matlab programı ile de analiz edilmiştir. Sonuçlar Tablo 4.4'te yer aldığı gibidir:

Tablo 4-4. Üç Sınıfa Göre Matlab Sonucu

	S1(%)	S2(%)	S3(%)
UFL	11	72	17
BFL	16	66	18
İlgi	1	30	68
Reçete	3	7	90
KKE	44	37	19
Prof	23	77	0
Doç	34	61	4
Yrd Doç	19	69	12
Uzm	1	3	96
Üniv	0	83	17
Dev	10	0	90
Özel	50	0	50
Muay	22	13	65

- Segment1: Kurum kararını etkileyen (% 44) ve özel hastanede çalışan (% 50) doktorlar ağırlıklıdır.

- Segment2: Yoğunlukla üniversite hastanelerinde çalışan (% 83), profesör (% 77), doçent (% 61) ya da yardımcı doçent (% 69), ulusal fikir lideri (% 72) ya da bölgesel fikir lideri (% 66) doktorlar yer almaktadır.
- Segment3: Yoğunlukla devlet hastanelerinde çalışan (% 90), uzman (% 96) sendroma ilgili (% 68) ve reçeteleme potansiyeli yüksek (% 90) doktorlar yer almaktadır.

Özörgütlemeli haritalar ile ortaya konan üç kümeli pazar bölümlendirmesi, k-ortalamları kümeleme analizi ile ortaya konan pazar bölümlendirmesinden, daha anlamlı çıkmıştır.

Dört sınıf için Matlab programı ile özörgütlemeli haritaların çıktısı ise Tablo 4-5'te gösterilmiştir:

Tablo 4-5. Dört Sınıfa Göre Matlab Sonucu

	S1(%)	S2(%)	S3(%)	S4(%)
UFL	6	11	17	67
BFL	14	6	34	46
İlgi	64	6	13	17
Reçete	26	65	3	6
KKE	21	9	47	23
Prof	0	0	0	100
Doç	3	6	88	3
Yrd Doç	8	8	0	85
Uzm	35	62	3	0
Üniv	0	17	31	52
Dev	38	54	3	5
Özel	14	43	18	25
Muay	68	1	9	22

- Segment1: Yoğunlukla muayenehanelerde çalışan (% 68), sendroma ilgisi olan doktorlar ağırlıklıdır.
- Segment2: Yoğunlukla devlet (% 54) ve özel (% 43) hastanelerinde çalışan, reçeteleme potansiyeli yüksek (% 65) uzman ağırlıklı (% 62) doktorlar yer almaktadır.
- Segment3: Yoğunlukla doçent (% 88) kurum kararını etkileyen (% 47) doktorlar yer almaktadır.

- Segment4: Yoğunlukla üniversite hastanelerinde çalışan (% 52), yardımcı doçent (85) ya da profesör (% 100), ulusal (% 67) ya da bölgesel fikir lideri (% 46) doktorlar yer almaktadır.

4.3.2 Geçerlilik Testi

Özörgütlemeli haritalar ile elde edilen sonuçların geçerliliğini test etmek için, 1-520 arası veriler öğrenme datası (training data); 521-650 arası veriler simülasyon datası (simulation data) olarak alınmıştır. Matlab programı, öğrenme datası girdi olarak alınarak ağ çalıştırılmış; ardından simülasyon datası tanıtılarak ağ simüle edilmiştir.

Simülasyon verisi olan 130 adet doktor için elde edilen segment numaraları, aşağıdaki tabloda görülmektedir. “Tüm Veriler” isimli sütunlarda, bütün veriler kullanılarak elde edilen segment numaraları, “Geçerlilik Verileri” isimli sütunda ise, 520 adet doktor verisinden elde edilen segment numaraları verilmiştir.

Tablo 4-6. Geçerlilik Testi Sonucu Segment Numaralarının Karşılaştırılması

Tüm Veriler	Geçerlilik Verileri	Tüm Veriler	Geçerlilik Verileri	Tüm Veriler	Geçerlilik Verileri	Tüm Veriler	Geçerlilik Verileri	Tüm Veriler	Geçerlilik Verileri	Tüm Veriler	Geçerlilik Verileri	Tüm Veriler	Geçerlilik Verileri
1	1	1	2	1	2	2	1	3	4	3	4	4	3
1	1	1	2	1	2	2	1	3	4	3	4	4	3
1	1	1	2	1	2	2	1	3	4	3	4	4	3
1	1	1	2	1	2	2	1	3	4	3	4	4	3
1	1	1	2	1	2	2	1	3	4	3	4	4	3
1	1	1	2	1	2	2	2	3	4	3	4	4	3
1	1	1	2	1	2	2	2	3	4	3	4	4	3
1	1	1	2	1	2	2	2	3	4	3	4	4	3
1	1	1	2	1	2	2	2	3	4	4	3	4	3
1	1	1	2	1	2	2	2	3	4	4	3	4	3
1	2	1	2	1	2	2	2	3	4	4	3		
1	2	1	2	1	2	2	2	3	4	4	3		
1	2	1	2	1	2	2	2	3	4	4	3		
1	2	1	2	1	2	2	2	3	4	4	3		
1	2	1	2	1	2	2	2	3	4	4	3		
1	2	1	2	2	1	2	2	3	4	4	3		
1	2	1	2	2	1	2	2	3	4	4	3		
1	2	1	2	2	1	3		3	4	4	3		

130 adet segment değerinden 21 (% 16) adet segment numarası birbirinden farklıdır. Tablodan görülebileceği gibi, dört segmentten iki tanesi birbiriyle % 100 örtüşürken, toplamda verinin % 84'ü uyum göstermektedir. Bu da, elde edilen sonuçların güvenilirliğini göstermektedir.

4.4 Sonuçların Yorumlanması

Jasna Soldic-Aleksic tarafından Yugoslavya'daki en ünlü şeker markaları tercihi üzerinde gerçek verilerle kümeleme metodu ve özörgütlemeli haritalar yöntemleri kullanılarak yapılan bir çalışmaya göre, özörgütlemeli haritalar, kümeleme süreci için çok iyi bir alternatiftir. Ancak; tek başına kullanmak ve geleneksel kümeleme metotlarının unutulması değil; her iki metodun da birlikte kullanılması halinde en iyi sonuçların alınacağı önerilmiştir. [39]

Tablo 4-7. Matlab ile SPSS Çıktılarının Karşılaştırılması

	Kümeleme Analizi	Yapay Sinir Ağları
S1	Kurum Kararını Etkileyen Doktorlar(% 42,5)	Yoğunlukla doçent (% 88) ve kurum kararını etkileyen (% 47) doktorlar
S2	Devlet hastanelerinde çalışan (% 90,5) reçeteleme potansiyeli yüksek (% 90,8) ve sendromla ilgili (% 69,4) doktorlar	Yoğunlukla muayenehaneleri olan (% 68) sendromla ilgili doktorlar (%64)
S3	Yoğunlukla üniversite hastanelerinde çalışan (%46,7), doçent (% 64) ve yardımcı doçent (% 72,9) Bölgesel Fikir Lideri (% 46,7) Doktorlar	Devlet (% 54) ya da özel (% 43) hastanelerinde çalışan reçeteleme potansiyeli yüksek (% 65) uzman doktorlar (% 62)
S4	Ulusal Fikir Lideri (53,8) Profesör (% 92,6) Doktorlar	Ulusal (% 67) ya da bölgesel (% 46) fikir lideri yoğunlukla üniversite hastanelerinde çalışan (% 52) profesör (% 100) ve yardımcı doçentler(% 85)

Yukarıdaki tablodan görülebileceği gibi, birinci segment, her iki kümeleme metodu için de kurum kararını etkileme değişkeni bakımından ortak çıkmıştır. Kümeleme analizi, ulusal fikir lideri doktorları bir segment, bölgesel fikir liderleri doktorlarını ayrı bir segment olarak oluşturmalarına rağmen, yapay sinir ağları ile bu iki kümeyi birleştirilmiş ve tek bir küme olarak analiz sonuçlanmıştır. Reçeteleme potansiyeli yüksek doktorlar ile sendromla ilgili doktorlar, yapay sinir ağları tarafından ayrı

kümeler olarak, kümeleme analizi tarafından tek bir küme olarak belirlenmiştir. Firma yetkilileri ile yapılan görüşmede, yapay sinir ağıları metodunun verdiği sonuçların daha kullanışlı olduğu ifade edilmiştir.

Pazar bölümlendikten sonra hedefleme basamağına geçilmektedir. Firma tarafından, aslında tüm pazar bölümleri hedeflenmektedir; ancak pazar bölümleri arasında, satış mümessili tarafından gerçekleştirilen ziyaret sayılarının farklılık göstermesi beklenmektedir. Örneğin “reçeteleme potansiyeli yüksek olan doktorlar” ve “sendromla ilgili doktorlar” segmentinde yer alan doktorlara diğer doktorlara oranla daha fazla ziyaret edilmesi gerekmektedir. Reçeteleme potansiyeli yüksek olan doktorların bilimsel toplantılara ve sosyal aktivitelere katılmasında destek verilir; diğer yandan sendromla ilgili doktorlara yine bilimsel toplantılara katılımında ve bilimsel yayınları takip etmelerinde destek verilmektedir. Belirtilen segmentler için eklenebilecek stratejiler olduğu gibi, diğer segmentler için de farklı stratejiler belirlenebilir.

5 SONUÇLAR

Günümüz koşulları altında, tüm tüketicilerinin ilgisini, tek bir pazarlama karması ile çekme stratejisinin başarılı olmama riski çok yüksektir; çünkü tüketici ihtiyaçlarını, tercihlerini ve satın alma yeteneklerini etkileyen birçok değişken söz konusudur. İlaç sektörü makro bazda incelendiğinde, diğer sektörlerle göre farklı dinamiklere sahip bir profil ortaya çıkmaktadır. Bu farklı profili yaratan en önemli neden ise sektörde serbest rekabetin bulunmamasıdır. Sektördeki rekabetin çerçevesi dört ana değişken tarafından çizilmektedir.

- Global ve yerel sağlık otoritelerinin regülasyonları
- Geri ödeme sistemlerinde bütçe kısıtlama uygulamaları
- Ürünler ile ilgili tanıtım faaliyetleri üzerindeki kısıtlamalar
- Patent ve fikri hakların korunması konularının yerel yasalarca farklı uygulanması

Serbest rekabeti engelleyen tüm bu koşullara ek olarak, ilaç geliştirilmesi için yapılan yüksek araştırma-geliştirme yatırımlarına rağmen son yıllarda geliştirilen moleküllerin yatırım geri dönüş oranının çok düşük kalması ilaç üreticilerinin farklı iş modelleri arayışına yönelmelerine sebep olmuştur. 2000li yıllarda Glaxo Wellcome & Smith Kline Becham birleşmesi, Pfizer'in Warner Lambert firmasını daha sonra da Pharmacia Upjohn firmasını satın alması bu yeni iş modellerine örnek olarak gösterilebilir.

İlaç sektöründe 4 farklı oyuncu bulunmaktadır. Bunlar, nihai tüketiciler (hasta), sağlık görevlileri (doktor, hemşire, eczacı vs.), ilaç üreticileri ve dağıtıcıları (orijinal ve/veya jenerik ürün üreticileri, ecza depoları vs.) ve sağlık otoriteleridir. (Sağlık Bakanlığı, hastane yöneticileri, tabip odaları vs.)

Serbest rekabetin sınırlandırıldığı bu karmaşık yapının içinde ayrıca yoğun rekabetin mevcut olması, yasalarla belirlenmiş kaynak kullanımı ve tanıtım olanakları ile yürütülen satış ve pazarlama aktivitelerinin en verimli şekilde gerçekleştirilmesini

gerektirmektedir. Bu noktada, ana hedef kitle olarak karşımıza çıkan hekimlere yapılan tanıtım faaliyetlerinin maksimum verimlilik içinde yürütülmesi sektörün uzun vadeli gelişimi açısından büyük önem arz etmektedir. Çok farklı karakteristiklere sahip olan hekimlere hizmet sunarken rekabet avantajını elde etmek için uygulanması gereken belki de en önemli strateji hedef kitle segmentasyonudur.

Sınırları çok katı bir şekilde çizilmiş olan pazar şartları altında yapılan satış ve pazarlama faaliyetleri, geniş hedef kitlelere penetrasyon sırasında yoğun rekabet içinde farklılaşmayı gerektirmektedir. Geniş hedef kitlelere yönelik olarak yapılacak standart satış ve pazarlama aktiviteleri rekabet avantajını minimuma indirmektedir. Bu sebeple, geniş hedef kitlelerin en iyi şekilde analiz edilerek segmente edilmesi ve ürün stratejilerinin bu segmentlere göre tespit edilerek rekabet avantajı elde edilmelidir.

İlaç sektöründe pazar bölümlendirmesi, aslen doktorların bölümlenmesidir. Doktorların bölümlenmesi önemlidir; çünkü farklı doktorların farklı ihtiyaç ve beklentileri olabilir. Mümkün ziyaret, sadece ilgili firma ürünün özelliklerinin doktora anlatılması demek değildir. Doktorlar ile mümessiller arasında sosyal ilişkiler söz konusu olabilir, ziyaret esnasında mümessil, son bilimsel çalışmaları doktora aktarabilir, doktor ile firma ortak çalışmalar ile klinik araştırmalar gerçekleştirebilir.

Bu çalışma dahilinde, tanıtımı yapılan ürünün belirlenmiş hedef kitlesinin segmentasyonu sırasında sayısız değişken tanımlamak mümkündür. (Uzmanlık, alt uzmanlık, odaklanılan hasta tipi, klinik tecrübe, unvan, çalışılan kurum tipi, coğrafi bölge, bilimsel yeniliklerin takibi, hasta potansiyeli, ilaç reçeteleme alışkanlıkları, yabancı dil bilgisi, bilgisayar kullanma becerisi, kişisel özellikler, cinsiyet, bilimsel toplantılarda konuşmacı olması, fikir lideri olarak uluslararası/ ulusal / bölgesel / klinik bazda kabul görme vs) Ancak, çalışma sonuçlarının en efektif şekilde değerlendirilebilmesi ve bu sonuçların uygulanabilirliğinin pratikte mümkün olması hedeflenerek, çalışma kapsamında incelenen tanımlı pazarda oluşturduğumuz segmentler değişkenlerin önem derecesi ve ulaşılabilirlik kriterleri baz alınarak aşağıdaki şekilde belirlenmiştir:

Unvan:	1- Prof.	2- Doç.	3- Yrd. Doç.	4- Uzman
Fikir Lideri:	1- Ulusal	2- Bölgesel		

Kurum Kararı:	1- Etkiler	2- Etkilemez		
Reçete Potansiyeli:	1- Var	2- Yok		
Kurum tipi:	1- Üniversite	2- Devlet	3- Özel	4- Muayenehane
Hastalığa ilgi:	1- Var	2- Yok		

Pazarı bölümlendirmek için farklı sınıflandırma yöntemlerin uygulanması ve farklı yöntemler sonucu farklı pazar bölümlerinin ortaya konulması muhtemeldir. Bu çalışma kapsamında da yapay sinir ağları ve kümeleme analizi yaklaşımları kullanılmış ve her iki yöntemle elde edilen sonuçlar karşılaştırılmıştır. Ortaya konması uygun olan küme sayısı için hem hiyerarşik kümeleme analizi yöntemine hem de firma yetkilisine danışılmıştır. Sonuçta dört adet pazar bölümünün uygun olacağına karar verilmiştir. Elde edilen sonuçlara göre, kurum kararını etkileyen doktorlar bir pazar bölümü, sendromla ilgili doktorlar başka bir pazar bölümü, reçeteleme potansiyeli yüksek doktorlar başka bir pazar bölümü ve ulusal ve bölgesel fikir liderleri başka bir pazar bölümü oluşturmaktadır.

Hangi yöntemin daha iyi sonuç verdiği, ortaya koydukları pazar bölümleri arasında uygulanabilecek strateji farklılığını ortaya koyması ile belirlenebilir. Çalışmanın teorik kısmında da değinildiği gibi, pazarı bölümlendirmenin temel amacı, bölümler arasında farklı stratejiler belirleyebilmek ve bu stratejiler sonucunda farklı tepkiler almaktır. Ortaya çıkan segmentasyon sonucunda, yapay sinir ağları yaklaşımının, kümeleme analizi yaklaşımından daha faydalı bir pazar bölümlendirmesi sağladığı görülmüştür. Aslında her iki teknikle de, kurum kararını etkileyen doktorlar bir pazar bölümü olarak karşımıza çıkmıştır. Kümeleme analizi, ulusal fikir liderleri ile bölgesel fikir liderlerini ayırmış; reçeteleme potansiyeli yüksek olan doktorlarla sendroma ilgisi olan doktorları bir sınıf altında birleştirmişken, yapay sinir ağları, ulusal fikir lideri ile bölgesel fikir liderlerini birleştirmiş, sendromla ilgili olan doktorlarla reçeteleme potansiyeli yüksek doktorları ayırmıştır. Sendroma ilgisi olan doktorlarla reçeteleme potansiyeli yüksek olan doktorların ayrılması, bu bölümlere uygulanabilecek farklı stratejilerin söz konusu olmasından dolayı daha anlamlı bir sonuç olarak kabul görmektedir. Yine aynı şekilde, bölgesel fikir liderleri ile ulusal fikir liderlerinin aynı sınıf altında toplanması, bu özelliklere sahip doktorlara benzer yaklaşımlarda bulunulabileceğinden daha anlamlı bir sonuç olarak kabul görmektedir.

Pazar bölümlendirmesinin ardından hedef kitleler tespit edilmelidir. Bu hedef kitlelerin özellik, beklenti ve ihtiyaçları değerlendirilerek farklı satış ve pazarlama aktiviteleri yürütülmeli ve böylece farklılaşarak rekabet avantajı sağlanarak yapılan yatırımın geri dönüşü optimize edilmelidir. Yapay sinir ağı yöntemi ile elde edilen sonuçlardan yola çıkarak, kurum kararını etkileyen doktorların, bölgesel bazdaki bilimsel toplantılara yoğun olarak davet edilmesi; sendromla ilgili doktorlara, ürünle ilgili daha fazla ziyaret edilmesi ve ürün tanıtımı yapılması, reçeteleme potansiyeli yüksek doktorlara daha fazla numune bırakılarak hastalarında kullanması ve ilacın etkisinin net bir biçimde görülmesi, ulusal ve bölgesel fikir liderlerinin de hem ulusal bazda hem de uluslararası bazda düzenlenen bilimsel toplantılara davet edilmesi gibi farklı bir takım stratejiler ortaya konabilir. Bu pazar bölümleri arasında, mümessilin doktora yapmayı planlayacağı ziyaret sayıları da farklılık gösterecektir. Örneğin, ulusal ya da bölgesel fikir liderleri, mümessillerin ziyaretine ek olarak, ilgili ürünün müdürü gibi şirket merkezinden bazı kişilerce daha ziyaret edilebilir. Bu tip doktorlar yoğun olarak ziyaret edilmesi gereken doktorlardır. Diğer yandan yoğun olarak ziyaret edilmesi gereken diğer bir pazar bölümünü ise, reçeteleme potansiyeli yüksek doktorlar oluşturmaktadır. Reçeteleme potansiyelleri yüksek olduğu için, bu doktorlar diğer rakip firmalar tarafından da yoğunlukla ziyaret edilecektir. Bu çalışma kapsamında, mümessilin ulaşamayacağı yerde ikamet eden doktorlar göz önünde bulundurulmamış; tüm doktorların ulaşılabilir olduğu varsayılmıştır. Doktorların mümessillerin çalışma alanlarına olan uzaklığı, bu varsayımı ortaya kaldırmak için, girdi değişkeni olarak kullanılabilir.

Pazar bölümleri arasında, yapılan ziyaretin içeriği de değişebilir. Sendromla ilgili doktorlarla, yoğun olarak ürünün etkin olduğu sendrom ve ürünün özellikleri ön planda tutulurken, fikir liderlerine yapılan ziyaret, daha fazla sosyal iletişimi gerektirebilir.

Pazar bölümlendirmesi ile ortaya konan doktorların, firma tarafından farklı talepleri olabileceği gibi, yine bu pazar bölümleri arasında, firmanın doktorlardan farklı beklentileri de söz konusu olabilir. Örneğin, kurum içi planlanabilecek eğitimlerde ya da belirli bir bölge içinde kurumlar arası planlanabilecek eğitimlerde, kurum kararını etkileyen doktorların konuk konuşmacı olması, sendromla ilgili doktorların klinik içi eğitim vermeleri ve firmanın birtakım araştırma projelerine destek vermeleri, reçeteleme potansiyeli yüksek doktorların, hastalarını sendromla ilgili çok

iyi sorgulamaları, bölgesel ve ulusal fikir liderlerinin, mümessil panellerine eğitmen olarak davet edilmesi ve kongre ve sempozyumlarda konuşmacı olmaları beklenebilir.

Pazar bölümlendirmesinin, ilaç firmaları tarafından zor olan tarafı, bu sürecin her bir ürünü için ayrı ayrı tasarlanması gerektiğidir, çünkü her ürün için, doktor bazında girdi verileri değişkendir. Örneğin, bir doktor, herhangi bir ürün için yüksek reçeteleme potansiyeline sahipken, aynı doktor başka bir ürün için bu potansiyele sahip olmayabilir. Diğer yandan, ürünlerin mümessiller tarafından çalışıldığı doktor uzmanlık grupları da farklıdır. Bir ürün için ürologlar hedeflenirken, diğer bir ürün için kardiyologlar hedeflenmektedir. Tüm bu nedenlerden dolayı, firma için doktor bazında pazar bölümlendirmesi yapmak mümkün olmamaktadır.

Bu çalışmanın ileriki bir aşaması olarak, doktorları bölümlendirmenin girdi verileri değişebilir. Firmalar için, mümessillerinin doktorların gözünde nasıl algılandığı önemli bir araştırma konusudur. Doktorun mümessilin ziyaretinden ne oranda bilimsel bir katkı beklediği, doktorun mümessilin giyimi ile ilgili ne düşündüğü, mümessilin promosyonel malzeme vermesinin önemi, doktorların ne tip promosyonel malzemeler istediği, mümessilin numune bırakmasının etkisi, birden fazla mümessilin aynı doktoru ziyaret etmesinin etkisi, mümessilin doktoru bilimsel ya da eğitici toplantılara ne sıklıkla davet etmesinin beklendiği, ne tip toplantılara davet etmenin daha çok tercih edildiği, mümessilin ürün bilgisine hakimiyeti, mümessil ziyaretinin ne sıklıkla gerçekleşmesinin daha uygun olacağı gibi konular, anket aracılığıyla doktorlara sorularak, doktorlar, mümessillerden bekledikleri hizmetler doğrultusunda da bölümlendirilebilir.

KAYNAKLAR

- [1] Kotler, Philip, 1994. Marketing Management, Prentice Hall, Inc, New Jersey
- [2] Morris, Michael H., Pitt, Leyland F. And Honeycutt, Earl D., 2001, Business to Business Marketing, pp.3, Sage Publications, USA
- [3] Kotler, Philip, Jain, Dipak and Maesincee, Suvit, 2002, Marketing Moves, HBR, USA
- [4] Wedel, Michel and Kamakura, Wagner, 2000, Market Segmentation Conceptual and Methodological Foundations, Kluwer Academic Publications, USA
- [5] Mentzer, John T., Myers, Matthew B., Cheung, Mee-Shew, 2004, Global Market Segmentation for Logistics Services, *Industrial Marketing Management*, **33**, 15-20
- [6] Freytag, Per Vagn, Clarke, AnnHojbjerg, 2001, Business to Business Market Segmentation, *Industrial Marketing Management*, **30**, 473-486
- [7] Sharma, Subsash, 1996, Applied Multivariate Techniques, John Wiley & Sons, Inc, Canada
- [8] Hruschka, Harald, Fettes, Werner and Probst, Markus, 2003, Market Segmentation by maximum likelihood clustering using choice elasticities, *European Journal of Operational Research*
- [9] Krieger, A.M., Gren, P.E., 1996, Modyfying Cluster-Based Segments to Enhance Aggrement With an Exogenous Response Variable, *Journal of Marketing Research*, **33(3)**, 351-363
- [10] Punji, G., Stewart, D.M., 1983, Cluster Analysis in Marketing Research: Review and Suggestions for Applications, *Journal of Marketing Research*, **20**, 134-148
- [11] Wedel, M., Steenkamp, J., 1991, A Clusterwisw Regression Method for Simultaneous Fuzzy Market Structuring and Benefit Segmentation, *Journal of Marketing Research*, **28**, 385-396
- [12] Elrod, T., Winer, R.S., 1982, An Empirical Evaluation of Aggregation Approaches for Developing Market Segments, *Journal of Marketing Research*, **32**, 1-16
- [13] Gren, P.E., Krieger, A.M., 1991, Segmenting Markets with Conjoint Analysis, *Journal of Marketing*, **55**, 20-31

- [14] Rao, V.R., Sabavalo, D.J., 1981, Inference of Hierarchical Choice Processes From Panel Data, *Journal of Consumer Research*, 8, 85-96
- [15] Grover, R., Srinivassan, V., 1987, Simultaneous Approach to Market Segmentation and Marketing Structuring, *Journal of Marketing Research*, 24, 139-153
- [16] Elrod, T., 1998, Choice Map: Inferring a Product-Market Map From Observed Choice Behaviour, *Marketing Science*, 7, 21-40
- [17] Elrod, T., Keane, M.P., 1995, A Factor Analytic Probit Model fro Representing the Market Structure in Panel Data, *Journal of Marketing Research*, 32, 1-16
- [18] Joh, Chang-Hyeon, Timmermans, Harry J.P. and Popkowski-Leszczyc, Peter T.L., 2003, Indentifying Purchase-history Sensitive Shopper Segments Using Scanner Panel Data and Sequence Alignment Methods, *Journal of Retailing and Consumer Services*, 10, 135-144
- [19] Shugan, S.M., 1987, Estimating Brand Positioning Maps Using Supermarket Scanning Data, *Journal of Marketing Research*, 24, 1-18
- [20] Kamakura, W.A., Russel, G.J., 1989, A Probablistic Choice Model for Market Segmentation and Elasticity Structure, *Journal of Marketing Research*, 26, 379-390
- [21] Natter, Martin, 1999, Conditional Market Segmentation by Neural Networks: a Monte-Carlo Study, *Journal of Retailing and Consumer Services*, 6, 237-248
- [22] Elmas, Çetin, ,2003, Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık San.ve Tic. A.Ş., Ankara
- [23] Efe, Önder, Kaynak, Okyay, 2000, Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul
- [24] Cehn, S.K., Mangiamli, P. ve West, D., 1995, The Comparative Ability of Self-organizing Neural Networks to Define Cluster Structure, *Omega*, 23, 271-279
- [25] Şahin, Şule Önsel, 2001, Yapay Sinir Ağları Yardımı ile Dinamik Bir Senaryo Analizi, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü
- [26] Kim, Jaesoo, Wei, Sherrie and Ruys, Hein, 2003, Segmenting the Market of West Australian Senior Tourists Using an Artificial Neural Network, *Tourism Management*, 24, 25-34
- [27] Vellido, A., Lisboa, P.J.G. and Meehan, K., 1999, Segmentation of the On-line Shopping Market Using Neural Networks, *Expert Systems with Applications*, 17, 303-314

- [28] Venugopal, V., Baets, W., 1994, Neural Networks and Their Applications in Marketing Management, *Journal of Systems Management*, 45-9, 16-21
- [29] Venugopal, V., Baets, W., 1994, Neural Networks and Statistical Techniques in Marketing Research, *Marketing Intelligence and Planning*, 12-7, 30-38
- [30] De Groot, C., Wurtz, 1991, Analysis of Univariate Time Series with Connectionist Nets: A Case Study of Two Classical Examples", *Neuro Computing*, 3, 172-192
- [31] Hruschka, H., 1993, Determining Market Response Functions by Neural Network Modelling: A Comparison with Econometric Techniques", *European Journal of Operations Research*, 66, 27-35
- [32] White, II., 1989, Neural Network Learning and Statistics, *AI Expert*, 4-12, 48-82
- [33] Kalafatis, Stavros P., Cheston, Vicki, 1997, Normative Models and Practical Applications of Segmentation in Business Markets, *Industrial Marketing Management*, 26, 519-530
- [34] Verhoef, Peter C, Spring, Penny N., Hoekstra, Janny C. And Leeflang, Peter S.H., 2002, The Commercial Use of Segmentation and Predictive Modeling Techniques for Database Marketing in the Netherlands
- [35] Suh, E. H., Noh, K.C. and Suh, C.K., 1999, Customer List Segmentation Using The Combined Response Model, *Expert Systems With Applications*, 17, 89-97
- [36] Kuo, R.J., Ho, L.M. and Hu, C.M., 2002, Cluster Analysis in Industrial Market Segmentation Through Artificial Neural Network, *Computers and Industrial Engineering*, 42, 391-399
- [37] Ziberna, Ales, Zabkar, Vesna, 2003, Application of End Users Market Segmentation Using Statistical Methods, *Developments in Applied Statistics*, 19
- [38] Zahavi, J. Levin, N., 1997, Applying Neural Computing to Target Marketing, *Journal of Direct Marketing*, 11, 5-22
- [39] Soldic-Aleksic, Jasna, , 2002, Data Driven Approach, to Market Visualisation and Segmentation: an Application on Yugoslav Market, Preceedings of the Conference Compstat 2002 Short Communications and Posters, Faculty of Economics, Department of Statistics and Mathematics, Belgrade University
- [40] Kiang, Melody Y., 2003, A Comparative Assessment of Classification Methods, *Decision Support Systems*, 35, 441-454
- [41] Hruschka, Harald, Natter, Martin, 1999, Comparing Performance of Feedforward Neural Nets and K-means for Cluster-based Market Segmentation, *European Journal of Operational Research*, 114, 346-353

ÖZGEÇMİŞ

1979 yılında İstanbul'da doğdu. 1997'de Fevziye Mektepleri Vakfı Özel Ayazağa Işık Lisesi, 2001 yılında ise İTÜ İşletme Fakültesi Endüstri Mühendisliği Bölümü'nden mezun oldu. Aynı yıl İTÜ Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı Endüstri Mühendisliği Programı'na girdi. 2002 Nisan ayından itibaren bir ilaç firmasında çalışmaktadır.

