İKTİSADÎ ARAŞTIRMALAR VAKFI
TEZ ÖDÜLLENDİRMESİ YARIŞMASI 2022

Zeynep KORKMAZ

YAPAY SİNİR AĞLARI YAKLAŞIMI İLE TEDARİKÇİ PORTFÖY ANALİZİ

Tez Danışmanı
Prof. Dr. Halim KAZAN

İstanbul Üniversitesi Sosyal Bilimler Enstitüsü'nce kabul edilmiş Yüksek Lisans Tezi "İktisadî Araştırmalar Vakfı Tez Ödüllendirmesi Yarışması'nın" 2022 yılı değerlendirmesinde ödüle layık görülmüş ve İktisadî Araştırmalar Vakfı İktisadi İşletmesi'nce yayınlanmıştır.

İstanbul - 2023

ISBN: 978-605-9310-74-1

Bu kitabın yayın hakları
İktisadî Araştırmalar Vakfı İktisadi İşletmesi'ne aittir.

**YAPAY SİNİR AĞLARI YAKLAŞIMI İLE
TEDARİKÇİ PORTFÖY ANALİZİ**

Zeynep KORKMAZ

İktisadî Araştırmalar Vakfı
İktisadi İşletmesi Yayınları
Yayın No: 89
Sertifika: 18066

İstanbul, Mart 2023

Kapak Tasarım ve Mizanpaj
Abdullah KIZILKAYA

Baskı:
Bizim Dijital Matbaa San. ve Tic. A.Ş.
Yenimahalle - Ankara
Sertifika No: 41356

İKTİSADÎ ARAŞTIRMALAR VAKFI
İktisadi İşletmesi
19 Mayıs Cad. No: 3 Golden Plaza Kat: 8 34360 Şişli / İSTANBUL
Tel: (0212) 233 21 07 (pbx) Fax: (0212) 233 21 96
e-mail: info@iav.org.tr www.iav.org.tr
TELG: FOUNDATION ISTANBUL

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME (İKTİSAT) ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI YAKLAŞIMI İLE TEDARİKÇİ PORTFÖY ANALİZİ

Zeynep KORKMAZ
2501210357

TEZ DANIŞMANI
Prof. Dr. Halim KAZAN

İSTANBUL – 2022

ÖZ

YAPAY SİNİR AĞLARI YAKLAŞIMI İLE TEDARİKÇİ PORTFÖY ANALİZİ

ZEYNEP KORKMAZ

Tedarikçi seçme, değerlendirme ve tedarikçi ilişkilerinde uygulanacak stratejilere karar verme süreci, işletmelerin rekabet gücünü belirlemede önemli bir rol oynamaktadır. Tedarik zinciri süreçlerinin etkin ve verimli bir şekilde yönetilmesi bakımından işletmelerin dış kaynak kullanımı stratejisine yönelmesi, satın alma fonksiyonunu ve tedarikçi ilişkileri yönetimini hayati bir duruma getirmektedir. İşletmeler tüm tedarik portföyünü tek bir strateji ile yönetemeyeceğinden, envanter gruplarına göre özelleştirilmiş farklı tedarikçiler için en uygun stratejilerin kullanılacağı bir tedarikçi segmentasyonu uygulaması gerekmektedir.

Bu araştırmada, tekstil sektöründe faaliyet gösteren bir işletmenin ERP sisteminden elde edilen detaylı stok envanter verileri kullanılarak işletmenin satın alma kalemleri Kraljic'in portföy modeline göre segmentlere ayrılmış ve bulundukları portföy grubuna göre stratejiler atanmıştır. Bu amaca ulaşmak için, denetimsiz bir makine öğrenmesi yöntemi olan k-ortalamalar yöntemi ile envanterde bulunan ürünler gruplara ayrılmıştır. Sonrasında denetimli bir makine öğrenmesi yöntemi olan yapay sinir ağlarından faydalanılarak ürün grupları tahmin edilmiştir. Analizler sonucunda, işletmenin girdilerinin Kraljic'in karar matrisine uygun bir şekilde kümelere ayrıldığı ve yapay sinir ağının farklı portföy sınıflarını başarılı bir şekilde tahmin ettiği görülmüştür. Elde edilen sonuçlara göre, tüm girdiler için Kraljic'in portföy modelinde yer alan stratejiler atanmıştır. Böylece alıcı işletmenin, satın aldığı ürünler bazında iş birliği yapacağı tedarikçileri seçmesi ve bu tedarikçilere yönelik izleyeceği politikaların belirlenmesi hususunda bir karar destek sistemi oluşturulmuştur.

Anahtar Kelimeler: Tedarikçi İlişkileri Yönetimi, Tedarikçi Segmentasyonu, Satın Alma Portföy Modeli, Kraljic Matrisi, Yapay Sinir Ağları

ABSTRACT

SUPPLIER PORTFOLIO ANALYSIS WITH ARTIFICIAL NEURAL NETWORKS APPROACH

ZEYNEP KORKMAZ

The process of choosing and evaluating suppliers and deciding on the strategies to be applied in supplier relations plays an important role in determining the competitiveness of businesses. In terms of effective and efficient management of supply chain processes, companies' orientation to outsourcing strategy makes purchasing function and supplier relationship management vital. Since businesses cannot manage their entire supply portfolio with a single strategy, it is necessary to apply a supplier segmentation in which the most appropriate strategies will be used for different suppliers customized according to inventory groups.

In this research, using the detailed stock inventory data obtained from the ERP system of a business operating in the textile industry, the purchasing items of the business are segmented according to Kraljic's portfolio model and strategies are assigned according to their portfolio group. In order to achieve this goal, the products in the inventory were divided into groups with the k-means method, which is an unsupervised machine learning method. Afterwards, product groups were estimated by using artificial neural networks, which is a supervised machine learning method. As a result of the analysis, it was seen that the inputs of the enterprise were clustered in accordance with Kraljic's decision matrix and the artificial neural network successfully predicted different portfolio classes. According to the results obtained, strategies in Kraljic's portfolio model were assigned for all inputs. Thus, a decision support system has been established for the buyer company to select the suppliers with which it will cooperate on the basis of the

products it purchases and to determine the policies to be followed for these suppliers.

Keywords: Supplier Relationship Management, Supplier Segmentation, Purchasing Portfolio Model, Kraljic Matrix, Artificial Neural Networks

ÖNSÖZ

Asistanlığını yapmaktan mutluluk duyduğum; bana her zaman güvenen ve desteğini esirgemeyen, değerli tez danışmanım Prof. Dr. Halim Kazan hocama;

Değerli görüşleriyle tezime yaptıkları katkılardan ötürü Prof. Dr. Selahattin Karabınar, Doç. Dr. Bülent Demir ve Dr. Serdar Semih Coşkun hocalarıma;

Vaka çalışmasını gerçekleştirdiğimiz Akın Raşel San. Tic. A.Ş. ailesine ve şahsında Sn. Arzu Berber'e;

Bugünlere gelmemde en büyük emeğe sahip olan ve her zaman arkamda duran anneme ve babama teşekkürlerimi sunarım.

ZEYNEP KORKMAZ
İSTANBUL, 2022

İÇİNDEKİLER

ÖZ..... **iii**
ABSTRACT..... **v**
ÖNSÖZ..... **vii**
TABLOLAR LİSTESİ..... **xi**
GRAFİKLER LİSTESİ..... **xii**
ŞEKİLLER LİSTESİ..... **xiii**
KISALTMALAR LİSTESİ..... **xiv**
GİRİŞ..... **1**

BİRİNCİ BÖLÜM

TEDARİK YÖNETİMİ

1.1. Tedarik Zinciri Yönetimi..... 5
1.2. Tedarik Zincirinde Koordinasyon ve Entegrasyon..... 7
1.3. Tedarik Zinciri Süreç Yönetimi..... 10
1.4. Dış Kaynak Kullanma Stratejileri..... 12
1.5. Tedarikçi İlişkileri Yönetimi..... 14
1.6. Tedarikçi Portföy Yönetimi..... 16
1.7. Tedarikçi Değerlendirme..... 22

İKİNCİ BÖLÜM

TEDARİKÇİ DEĞERLENDİRME YÖNTEMLERİ

2.1. K-Ortalamalar Kümeleme Analizi..... 25
2.2. Yapay Sinir Ağları..... 28
2.3. Biyolojik Sinir Hücresinden Yapay Sinir Ağlarına..... 29
2.4. Aktivasyon Fonksiyonları..... 31
2.5. Ağ Mimarileri..... 31
2.5.1. Tek Katmanlı Algılayıcılar (Perceptron)..... 32
2.5.2. Çok Katmanlı Algılayıcılar..... 34
2.5.2.1. İleri Beslemeli Ağlar..... 35
2.5.2.2. Geri Beslemeli Ağlar..... 35

2.6. Yapay Sinir Ağlarının Eğitilmesi..... 36
2.6.1. Gözetimli (Supervised) Öğrenme..... 37
2.6.2. Gözetimsiz (Unsupervised) Öğrenme..... 37
2.6.3. Takviyeli (Reinforcement) Öğrenme..... 37
2.7. Eğitim Algoritmaları..... 38
2.7.1. Geri Yayılım (Backpropagation) Algoritması..... 39
2.8. Eğitimde Dikkat Edilecek Hususlar..... 43
2.8.1. Ağırlıkların Belirlenmesi..... 44
2.8.2. Ağırlıkların Güncellenme Sıklığı..... 44
2.8.3. Ağ Boyutu..... 45
2.8.4. Ağın Performansı..... 45

ÜÇÜNCÜ BÖLÜM

UYGULAMA

3.1. Araştırmanın Problemi..... 49
3.2. Araştırmanın Amacı ve Önemi..... 50
3.3. Araştırmanın Kapsamı..... 51
3.4. Araştırmanın Yöntemi..... 52
3.4.1. Veri Ön İşleme..... 54
3.4.1.1. Verinin Dönüştürülmesi..... 54
3.4.1.2. Verinin Bölünmesi..... 55
3.4.2. Model Geliştirme..... 55
3.4.3. Model Uygulama..... 58
3.5. Bulgular ve Yorum..... 61
3.5.1. Tanımlayıcı İstatistikler..... 62
3.5.2. K-Ortalamalar Kümeleme Analizi Sonuçları..... 64
3.5.3. Ürün Sınıflarının Yapay Sinir Ağları İle Tahmin Edilmesi..... 67
3.6. Bulguların Geçerliği ve Güvenirliği..... 71
SONUÇ..... **73**
KAYNAKÇA..... **75**
EKLER..... **88**

TABLOLAR LİSTESİ

Tablo 1.1. Literatür taraması..... 23
Tablo 2.1. Aktivasyon fonksiyonlarının gösterimi..... 31
Tablo 2.2. XOR problemi..... 33
Tablo 3.1. YSA'da kullanılan parametreler..... 57
Tablo 3.2. Karışıklık matrisi..... 60
Tablo 3.3. Verideki değişkenler ve tanımları..... 71
Tablo 3.4. Tanımlayıcı istatistikler..... 62
Tablo 3.5. K-ortalamalar yöntemine ait ANOVA tablosu..... 65
Tablo 3.6. Küme başına düşen ürün sayısı..... 66
Tablo 3.7. YSA modeline ait değerlendirme sonuçları..... 67
Tablo 3.8. YSA modeline ait karışıklık matrisi..... 68
Tablo 3.9. Portföydeki tedarikçiler ve ürün sınıfları için uygun stratejiler atanması..... 70

GRAFİKLER LİSTESİ

Grafik 3.1. Tedarikçi başına ürün dağılımı..... 63
Grafik 3.2. İşletmenin satın alma hacmi içerisinde tedarikçilerin payı..... 64
Grafik 3.3. Ürünlerin k-ortalamalar yöntemi ile kategorilere ayrılması..... 65
Grafik 3.4. Satın alma kalemlerinin ürün gruplarına göre dağılımı..... 66

ŞEKİLLER LİSTESİ

Şekil 1.1. Entegre tedarik zinciri..... 10
Şekil 1.2. Dış kaynak kullanımı süreci..... 12
Şekil 1.3. Uygun stratejilerle birlikte Kraljic (1983) matrisi..... 18
Şekil 1.4. Satın almanın stratejik etkileri..... 21
Şekil 2.1. K-ortalamalar yöntemine ait akış şeması..... 27
Şekil 2.2. Biyolojik sinir hücresi..... 28
Şekil 2.3. Bir yapay sinir hücresi modeli..... 30
Şekil 2.4. Doğrusal olarak ayrılabilen ve ayrılamayan veri..... 33
Şekil 2.5. Çok katmanlı bir YSA..... 34
Şekil 2.6. Çok katmanlı bir YSA'da akış yönlerinin gösterimi..... 36
Şekil 2.7. Gradyan azalma algoritmasının gösterimi..... 40
Şekil 2.8. Geri yayılım ile eğitim..... 41
Şekil 2.9. Çok katmanlı bir YSA'nın yapısı..... 41
Şekil 2.10. Örnek bir polinom eğrisi..... 46
Şekil 2.11. Örnek başına hatanın zaman içindeki değişimi..... 47
Şekil 3.1. Araştırmanın akış şeması..... 53
Şekil 3.2. Verinin eğitim ve test kümelerine bölünmesi..... 55
Şekil 3.3. K-katlamalı çapraz doğrulama..... 59

KISALTMALAR LİSTESİ

ERP : Kurumsal Kaynak Planlama

GSYH : Gayrı Safi Yurtiçi Hasıla

İBYSA : İleri Beslemeli Yapay Sinir Ağları

SİG : Anlamlılık Değeri

YSA : Yapay Sinir Ağları

GİRİŞ

Tedarik zinciri yönetimi, bir ürün veya hizmetin hammaddenin temin edilmesinden başlayarak nihai müşteriye teslim edilinceye dek bilgi, deneyim, malzeme ve fon akışlarının yönetildiği dinamik bir süreçler topluluğudur. Tedarik zinciri sürecini ortaya çıkaran temel sebep ise, pazarda rekabet avantajı yakalamak amacıyla işletmelerin ana faaliyetlerinin dışında bulunan operasyonları diğer işletmelere devretmesi ve stratejik öneme sahip operasyonlara kaynak ayırarak dış kaynak kullanımı stratejisini benimsemeleridir. Dış kaynak kullanımı stratejisi ile birlikte küresel boyutta riskler daha da artmıştır. Öyle ki bu rekabet ortamında işletmeler, yalnızca bireysel varlıklar olarak değil tedarik zincirleri olarak rekabet ederek modern işletme yönetiminin en önemli paradigma değişimlerinden birini meydana getirmiştir (Lambert ve Cooper, 2000). Fakat dış kaynak kullanımı, bazı stratejik avantajların yanında birtakım riskleri de beraberinde getirmektedir.

Öngörülmesi zor bir şekilde düşük bir sıklıkta meydana gelen ve gerçekleştiğinde önemli derecede kesintiye sebep olan olaylar, tedarik zinciri süreçleri için önemli bir risk oluşturur. Örneğin, 2019 yılında Çin'in Wuhan kentinde ortaya çıkan Covid-19 salgını küresel çapta tedarik kesintilerinin yaşanmasına sebep olmuştur. Fortune Global 500 listesinde yer alan şirketlerin iki yüzden fazlasının Wuhan'da bulunması, dünya ekonomisinin Çin'e olan bağımlılığı, salgın sürecinde birçok havalimanı ve limanın askıya alınmasının yol açtığı kesintiler, bütün sektörlerde fiyatların dalgalanmasına ve arz riskinin yükselmesine sebep olmuştur. Birçok işletme, üretim ve dağıtım faaliyetlerini gerçekleştirememiş ve kapanma kararı almıştır. Örneğin Toyota, Covid-19 vakalarının hızlı artış gösterdiği Güneydoğu Asya ülkelerinden yedek parça tedarik edemediği için Japonya'da bulunan on dört tesisinde geçici olarak üretime ara vermiştir (TRT Haber, 2021). Çin'de yeniden uygulamaya konulan katı karantina tedbirleriyle birlikte, kara yollarındaki yük taşıma hacmi düşmüştür. Ürün lojistiğini yapacak araçların

bulunmaması nedeniyle çok sayıda gemi yüklerini indiremeden limanda beklemek zorunda kalmıştır (AA, 2022).

DHL (2022)'in Tedarik Zinciri Riskleri raporuna göre, küresel çapta arz riskini artıran tek unsur salgın koşulları değildir. Son yıllarda, salgın ile birlikte yıkıcı hava olayları ve bazı bölgelerde devam etmekte olan çatışmalar da arz kesintilerine neden olmuştur. 2021 yılında ABD ve Kanada'da ortaya çıkan rekor sıcak hava dalgası ve Avrupa'da görülen sel felaketi sanayi bölgelerine zarar vermiştir. Bunun yanında, 2022 yılında Rusya ve Ukrayna arasında başlayan çatışma ise enerji fiyatlarının artmasına, hava ve deniz yolu rotalarının değişmesine ve etkilenen bölgelerdeki sanayi faaliyetlerinin durmasına yol açmıştır. Örneğin Slovakya'da bulunan Volkswagen Bratislava fabrikası, Ukrayna'dan parça tedarik edemediği için üretimi askıya almıştır (TRT Haber, 2022).

Tüm bu yaşanan gelişmelerle birlikte küreselleşmenin pazarda yol açtığı arz riskini artırması ve müşteri ihtiyaçlarının farklılaşması tedarik zinciri yönetiminin etkinliğinin önemini artırmıştır. Tedarik zinciri yönetiminin başarılı bir şekilde gerçekleştirilmesi için, dış kaynak kullanımı stratejisinin benimsendiği durumlarda, satın alma fonksiyonun etkin bir şekilde yönetilmesi gerekir. Bu etkin yönetimin sağlanması adına işletmeler, tedarikçi ilişkileri yönetimi kavramına eğilmişlerdir. Tedarikçi ilişkileri yönetimi, bir işletmenin tedarikçileriyle ilişkilerini ne yönde geliştirdiği ve sürdürdüğüne ilişkin yürütülen bir iş sürecidir. Satın alma stratejisi, tedarikçi seçimi ve tedarikçi geliştirme gibi birden fazla boyuttan meydana gelen tedarikçi ilişkileri yönetimi süreci, dış kaynak kullanımından doğacak gizli maliyetleri azaltarak riskleri ve belirsizliği minimuma indirgemeyi hedeflemektedir. Tedarikçi seçme ve değerlendirme sürecinde ise en yaygın kullanılan yöntemlerden birisi portföy modelleridir. Bu modellerin temelini oluşturan Kraljic'in satın alma portföy modeli ise, işletmenin satın aldığı ürünleri kategorize ederek ve her bir kategorinin stratejik sonuçlarını hesaba katarak bir karar matrisi oluşturur. Böylece portföy modeli yaklaşımı ile satın alma süreci optimize edilir.

Bu çalışmanın amacı, bir işletmenin tedarikçilerini satın aldığı ürünler üzerinden değerlendirerek gruplara ayırmak ve her bir sınıf ürün için ya-

nıt stratejileri atayan bir karar destek sistemi geliştirmektir. Bu modeli, literatürdeki benzer çalışmalardan ayıran bir özellik, karar verme sürecinde ürünlerin kategorize edilmesi, tedarikçilerin uygun bir şekilde seçilmesi ve stratejilerin atanması aşamalarında yapay zeka tekniklerinin uygulanmasıdır. Böylelikle envanterdeki ürünler, finansal etki ve arz riski değişkenleri üzerinden k-ortalamalar kümeleme analizi ile gruplandırılmış ve yapay sinir ağları ile ürün grupları tahmin edilerek Kraljic matrisinde yer alan uygun stratejiler atanmıştır. Modelde makine öğrenmesi yaklaşımlarının kullanılması, Kraljic matrisinin otonom bir şekilde kullanılmasını sağlayarak odak işletmenin satın alma yöneticileri için bir karar destek sisteminin kurulmasını sağlamıştır.

Geliştirilen tedarikçi ilişkileri yönetimi modelinin, işletmenin portföyüne yeni bir ürün girdiğinde o ürünün hangi tedarikçiden satın alması gerektiği ve ilgili tedarikçi ile ilişki kurarken nasıl bir politika uygulaması gerektiği yönünde çözüm önereceği düşünülmektedir. Bu araştırmada geliştirilen model, Akın Raşel San. Tic. A.Ş'nin detaylı stok envanter raporu verisi üzerinde uygulanmıştır. Modelin pratikte ürettiği fayda işletme ile paylaşılmıştır.

Bu araştırma üç bölümden oluşmaktadır. Birinci bölümde, tedarik zinciri yönetimi kavramı açıklanmış ve özelinde tedarikçi ilişkileri yönetimi ile tedarikçi portföy yönetimi kavramları ele alınmıştır. Araştırmanın teorisini oluşturan Kraljic'in portföy yaklaşımı detaylı bir şekilde açıklanmıştır.

İkinci bölümde, Kraljic'in portföy modeline uygulanan makine öğrenmesi yaklaşımlarından k-ortalamalar kümeleme analizi ile yapay sinir ağları yöntemleri açıklanmıştır.

Üçüncü bölümde ise uygulama yer almaktadır. Öncelikle araştırmanın problemine, amacına ve önemine, araştırmanın vaka çalışması olarak yürütüldüğü işletme ve tekstil sektörü hakkındaki bilgilere ve araştırmanın modeline yer verilmiştir. Sonrasında modelin tüm aşamaları açıklanmış ve uygulama sonucunda elde edilen bulgular anlatılmıştır. Bulguların sonucunda, işletmenin tedarikçileri için uygulanacak stratejiler açıklanmıştır.

BİRİNCİ BÖLÜM
TEDARİK YÖNETİMİ

1.1. Tedarik Zinciri Yönetimi

Tedarik zincirleri, işletmeler arasındaki malzeme, nakit ve bilgi akışlarından meydana gelen dinamik bir sistemdir (Mentzer ve diğerleri, 2001). Küresel ekonomi bir insan vücuduna benzetilirse, tedarik zincirlerinin de birbirleri arasında kan alışverişinde bulunan organlardan ve kanın taşındığı damarlardan meydana gelen bir ağ olduğu söylenebilir. Bu yönüyle tedarik zincirleri küresel düzeyde en önemli ekonomik aktivitelerden meydana gelir.

Mentzer ve diğerleri (2001)'ne göre bir tedarik zincirinden söz edilebilmesi için en az üç işletmenin birbiriyle entegre olması ve bu entegrasyonda aşağı ve yukarı yönlü ürün, hizmet, para ve bilgi akışı yaşanması gerekir. Bir odak firma, bir tedarikçi ve bir müşteriden oluşan ağlara direkt tedarik zincirleri denir. Ağdaki işletme sayısı arttırıldığında ise genişletilmiş tedarik zincirleri elde edilir. Genişletilmiş tedarik zincirlerinde tedarikçilerin tedarikçileri ve müşterilerin müşterileri de yer alır. Bu ağa üçüncü parti lojistik servis sağlayıcılarını ve finans kurumları da eklendiğinde ise nihai tedarik zinciri elde edilmiş olur. Bu ise tedarik zincirinin en karmaşık versiyonudur.

Tedarik zincirindeki malzeme akışları lojistik faaliyetlerden oluşur. Doğal kaynaklardan hammadde elde edildikten sonra tedarik zincirinde aşağı yönde, yani arz yönünde, ilerler ve önce yarı mamule sonra da bitmiş ürüne dönüşür. Böylece bitmiş ürün nihai müşteriye ulaştırılır. Ürün tüketildikten sonra atığın geri dönüştürülmesi de tedarik zinciri kapsamında işlenin konulardan biridir (Condeixa ve diğerleri, 2020). Tedarik zincirindeki para akışları ise yukarı yönlü, yani müşteriden tedarikçiye doğru gerçekleşir. Bu ise genellikle bankalar arası para transferi şeklinde gerçekleşir. Bilgi akışları ise tedarik zincirinde hem aşağı yönlü hem de yukarı yönlü olarak

gerçekleşir. Bilgi akışına karşılık gelen kavram bilgi paylaşımıdır (Zhou ve Benton, 2007). Paylaşılan bilgi türleri arasında müşteri satış verileri, stok planları, kapasite, pazar bilgisi gibi bilgiler bulunabilir.

Tedarik zinciri daha çok bir sisteme benzetilirken tedarik zincirini yönetmek hem bir yönetim felsefesi hem de bir operasyon süreç yönetimidir. Bir felsefe olarak tedarik zinciri yönetimi "birimiz hepimiz, hepimiz birimiz için" mantığına dayalıdır. Bir işletme pazarda tek başına rekabet etmektense bir tedarik zincirine üye olarak rekabetin yıkıcı etkilerinden kendisini kurtarabilir. Çünkü bu şekilde rekabet bireysel işletmelerin değil, tedarik zincirinin problemi olacaktır (Christopher, 2016). Ayrıca, bir tedarik zinciri altında işletmeler birleştiğinde bir sinerji ortaya çıkar ve bu da rekabet avantajı sağlar. Bu sinerji, tedarik zincirinin ürettiği toplam değerin, işletmelerin ayrı ayrı ürettikleri değerler toplamından daha fazla olmasıyla açıklanır. Bu bağlamda tedarik zinciri yönetimi, hem bireysel olarak işletmelerin hem de bütünsel olarak tedarik zincirinin performansını geliştirmek için geleneksel işletme fonksiyonlarının sistematik ve stratejik olarak koordine edilmesidir (Mentzer ve diğerleri, 2001).

Tedarik zinciri yönetimi düşüncesinin ortaya çıkmasında etkili olan üç temel unsur dış kaynak kullanımı, rekabet ve belirsizliklerdir (Mentzer ve diğerleri, 2001). Hem endüstriyel hem de tüketici pazarlarında rekabet genellikle kalite, maliyet ve zaman boyutları üzerinden gerçekleşmektedir. Buna göre müşterilerine ihtiyaç duydukları ürün ve hizmetleri daha düşük bir maliyetle sunabilen işletmeler rekabette öne çıkmaktadır. Üretimde etkinliği arttırmak ve böylece maliyet avantajı sağlayabilmek için işletmeler 90'lı yıllardan itibaren dış kaynak kullanma stratejisini benimsemeye başlamıştır. Buna göre işletmeler yalnızca rakipleri tarafından taklit edilmesi güç olan ve ana değer kaynağını teşkil eden temel yetenekleri üzerinde odaklanmakta ve değer zincirinde birincil derecede önemli olmayan diğer faaliyetleri ise tedarikçilerine yüklemektedir. Bu strateji, işletmelerde satın alma fonksiyonunun önemini arttırmış ve onu stratejik bir öneme kavuşturmuştur. Öte yandan, 2000'li yıllardan itibaren Çin'in dünya piyasalarında üretim üstünlüğünü ele geçirmesiyle birlikte dış kaynak kullanma stratejisi yerelden globale kaymıştır. Ancak uzayan lojistik koridorları belirsizlikleri arttırmış ve pek çok tedarik zinciri riskini de beraberinde getirmiştir. Bu

risklerin başında da üretimde kullanılan hammadde ve yarı mamullerin arzında kesinti yaşanması olasılığı gelmektedir. Dolayısıyla, tedarik zinciri yöneticilerinin rekabette öne çıkabilmek için baş etmek zorunda kaldıkları ikinci unsur risk faktörüdür. Arz kesintileri üretimde aksamalara ve sonuç olarak müşteri beklentilerini karşılayamamaya sebep olmaktadır (Van Weele, 2001).

Tedarik zincirlerinde rekabetin diğer boyutunu kalite ve zaman faktörleri oluşturmaktadır. Üretilen ürünler tüketiciye ne kadar makul bir maliyetle sunulursa sunulsun, eğer kalite standartları yeterli değilse bu müşteride tatminsizliğe neden olmaktadır. Bunun yanında günümüzde rekabet avantajı yaratan en önemli unsurların başında hız gelmektedir. Müşteriler siparişlerini kendilerine vaat edilen zamanda alamazlarsa memnuniyetsizlik yaşamaktadırlar. Bu da firmaların müşteri kaybetmesine yol açmaktadır. Firmalar tedarik zinciri felsefesinin sağladığı faydalardan yararlanarak müşterilerine daha kısa teslim süreleri vaat edebilmekte ve bu vaatlerini güvenilir bir şekilde yerine getirmektedirler. Bunu sağlayan en önemli güç ise tedarik zincirinin iyi koordine olmasıdır (Benton, 2018). Bir sonraki bölümde tedarik zincirinin koordinasyonu konusu işlenecektir.

1.2. Tedarik Zincirinde Koordinasyon ve Entegrasyon

Bir tedarik zinciri genellikle lojistik, satına alma, envanter yönetimi, üretim planlama gibi farklı işletme fonksiyonlarından ve bu fonksiyonlar üzerinden farklı işletmeleri birbirlerine bağlayan çapraz fonksiyon takımlarından oluşur. Dolayısıyla tedarik zinciri yönetiminde hem işletmeler arası hem de işletme içinde fonksiyonlar arası koordinasyon sağlanır. Böylelikle daha yüksek müşteri memnuniyeti, daha fazla değer ve daha düşük maliyetlerle beraber daha güçlü bir rekabet avantajı elde edilir (Van Weele, 2001).

Tedarik zincirinde koordinasyon kavramı, genellikle iş birliği, eşgüdüm, entegrasyon gibi kavramların yerine kullanılmaktadır. Tedarik zincirinde entegrasyon bir bütünün parçası olma, iş birliği, beraber çalışma ve eşgüdüm ortak hareket etme anlamına gelmektedir (Arshinder ve diğerleri, 2008). Tedarik zinciri koordinasyonunun kabul görmüş bir tanımı bulunmamakla beraber bu üç unsurun bileşimi olduğu söylenebilir. Koordinasyon eksik olduğunda bu düşük bir performansla kendini gösterir. Yanlış talep

tahminleri, düşük kapasite kullanımı, envanter fazlası, geri dönüşler, müşteri odağından sapmalar ve düşük müşteri memnuniyeti, tedarik zincirinde koordinasyon eksikliğinin sonuçları arasındadır (Arshinder ve diğerleri, 2008).

Tedarik zincirinde koordinasyon mekanizmaları arasında sözleşmeler, bilgi entegrasyonu ve ortak karar alma bulunmaktadır (Arshinder ve diğerleri, 2008). Tedarik zincirlerinin performansını azaltan en önemli faktör, paydaşlar arasındaki çıkar çatışmalarıdır. Paydaşların tedarik zincirindeki diğer partnerlerine duydukları güven ve bağlılık, çıkar çatışmalarının tedarik zinciri performansına olan olumsuz etkisini azaltır (Mentzer ve diğerleri, 2001). Ortak karar alma, tedarik zincirindeki çıkar çatışmalarını azaltan bir mekanizmadır. Sözleşmelerse tedarik zincirinde işletmeler arası koordinasyonu sağlar. Fiyat, kalite, miktar, yer ve zaman gibi parametreleri açıklığa kavuşturarak alışverişte belirsizliği azaltır ve işletmeler arasındaki uzun vadeli ilişkilerin temelini oluşturur.

Prajogo ve Olhager (2012), tedarik zinciri entegrasyonunu lojistik entegrasyon ve bilgi entegrasyonu olarak ikiye ayırır. Lojistik entegrasyon malzeme akışının kusursuz bir şekilde gerçekleşmesi anlamına gelir. Şekil 1.1'de lojistik entegrasyonun aşamaları görülmektedir. Entegrasyonun olmadığı temel düzeyde işletme içi fonksiyonlar ayrı birer birim olarak hareket eder ve her biri kendi performansını maksimize etmeye çalışır. Hatta diğer iş birimlerini rakip olarak görür. Tedarik zincirinde entegrasyon düzeyi arttıkça rekabet yerini iş birliğine bırakır. Entegrasyon önce işletme içinde gerçekleşir. Daha sonra da işletmeler arası entegrasyon sağlanır. Böylelikle odak firma, tedarikçiler ve müşteriler bir bütünün parçaları gibi davranırlar (Stevens, 1989).

Üreticiler özellikle ekonomik büyümenin yavaş olduğu makroekonomik ortamlarda yalın üretim prensiplerini benimseyerek stoksuz çalışmak isterler (Christopher, 2016). Böylelikle stok maliyetlerini azaltmayı amaçlarlar. İşletmelerin yalın üretim ve tam zamanında üretim uygulamalarını başarabilmelerinin anahtarı lojistik entegrasyondur (Prajogo ve Olhager, 2012). Lojistik entegrasyonun zayıf olduğu durumlarda ise kamçı etkisi ortaya çıkar. Kamçı etkisi, tüketici talebinde oluşan herhangi bir dalgalanmanın

tedarik zincirinde yukarıya doğru çıktıkça daha büyük bir varyansla dalgalanmasıdır (Metters, 1997). Kamçı etkisi üreticiler ve tedarikçiler için gereksiz stok maliyetlerine yol açmakta ve verimsizliğe neden olmaktadır.

Lojistik entegrasyonun başarılı bir şekilde uygulanabilmesi için bilgi entegrasyonu bir ön koşuldur (Benton, 2018). Malzeme akışına paralel olarak bilgi akışı destekleyici mahiyette çalışır. Bilgi entegrasyonun hem sosyal hem de teknik yönü vardır. Bilgi akışının sağlanabilmesi için öncelikle işletmelerin bilgi teknolojileriyle birbirlerine bağlanmaları gerekir. Kurumsal Kaynak Planlaması (ERP), otomasyon sistemleri, web portalları bu teknolojilere örnek olarak verilebilir. Ancak bilgi entegrasyonunun tam olarak gerçekleşebilmesi için bunlar yeterli değildir. Tedarik zincirindeki yöneticilerin aynı zamanda ortaklarına güvenmeleri gerekmektedir. Bu güvenin oluşması ise ancak uzun vadeli ilişkilerle mümkün olabilmektedir. Dolayısıyla görüldüğü gibi, bilgi paylaşımı entegrasyonun sosyal boyutunu oluşturmaktadır (Prajogo ve Olhager, 2012).

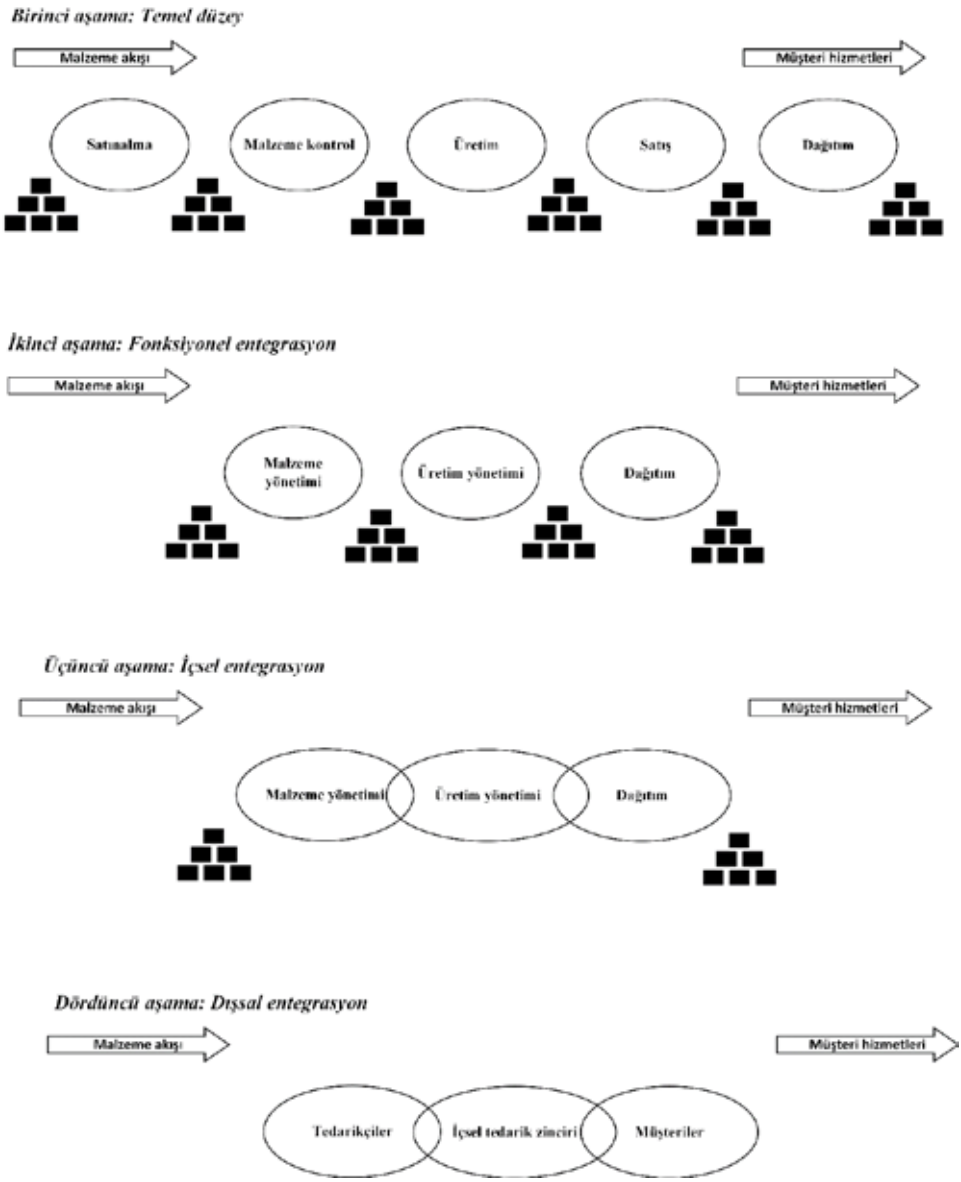

Şekil 1.1: Entegre tedarik zinciri (Stevens, 1989)

1.3. Tedarik Zinciri Süreç Yönetimi

Dış kaynak kullanımı, stratejik ve finansal değerlendirme ile başlar, bir uzman tedarikçi seçimiyle beraber satın alma modelinin hayata geçirilmesi ve tedarikçi ilişki yönetimi ile devam eder. Benton (2018)'a göre, stratejik

değerlendirme ve finansal değerlendirme aşamaları "iş durumunun değerlendirilmesi" kapsamına girerken; tedarikçi ortaklığının kurulması, satın alma modeline geçilmesi ve ilişki yönetimi aşamaları "uygulama ve yönetim" kapsamına girmektedir. İş durumunun değerlendirilmesi ve yönetilmesi aşamalarının sonucunda dış kaynak modelinin uygulanması ve yönetilmesi süreci, bazı avantaj ve dezavantajları, iş birliği yapılacak tedarikçilerin seçimini ve tedarik sürekliliğinin nasıl sağlanacağı gibi soruları gündeme getirir (Bozarth ve Handfield, 2008).

Küresel Tedarik Zinciri Forumu, tedarik zinciri yönetiminde sekiz süreç tanımlamaktadır (Croxton ve diğerleri, 2001).

- *Müşteri ilişkileri yönetim süreci*: Bu süreç, işletmenin rekabet stratejisi için en uygun müşteri grubunun belirlenmesi işlemlerinden oluşmaktadır. Bu süreçte kritik müşteriler için standart ürün ve hizmet anlaşmaları belirlenir.
- *Müşteri hizmetleri yönetim süreci*: Bu süreç, imzalanan ürün ve hizmet anlaşmalarının yürürlükte kaldığı sürece yerine getirilen işlemlerden oluşur. Bu süreçte müşterilere teslim süreleriyle ilgili ya da sipariş edilen ürünlerin bulunabilirliğiyle ilgili gerçek zamanlı bilgi paylaşılır.
- *Talep yönetim süreci*: Bu süreç, müşteri talebiyle tedarik zincirinin arz kapasitesinin birbiriyle eşleştirildiği aşamadır. Başka bir deyişle, talep yönetimi sürecinde arzın talebi karşılaması sağlanır. Bu amacı gerçekleştirebilmek için satış noktasındaki veriler çok önemsenir. Talep tahminlerine dayalı olarak üretim planları hazırlanır.
- *Sipariş karşılama süreci*: Müşteri sipariş doluluk oranları tedarik zinciri performansının en önemli göstergelerinden birisidir. Yüksek bir sipariş karşılama oranıyla çalışabilmek için işletmenin üretim, dağıtım ve taşımacılık operasyonlarının uyumlu çalışması gerekir.
- *Üretim akışı yönetim süreci:* Geleneksel stoka üretim yaklaşımında üreticiler, belirli bir çizelge dâhilinde bitmiş ürün depolarlar ve bunu piyasaya sunarlar. Tedarik zinciri anlayışında ise siparişe göre üretim yapılır. Küçük partiler halinde tam zamanında ürün üretilir. Böylece envanter fazlasının önüne geçilmiş olur.

- *Ürün geliştirme ve ticarileştirme süreci:* Bu süreçte hem tedarikçiler hem de müşteriler ürün geliştirme süreçlerine dâhil edilerek yeni ürünün piyasaya sürülme döngüsü kısaltılır ve talebe ilişkin riskler azaltılmış olur. Ürün yaşam döngülerinin kısalması, bu sürecin rekabette işletmelerin ayakta kalabilmesi adına önemini arttırmıştır.
- *Tedarikçi ilişkileri yönetim süreci*: Bu süreçte, işletmenin stratejik amaçlarıyla en çok uyum sağlayan kritik tedarikçi grubu belirlenerek bu tedarikçilerle uzun vadeli ilişkiler geliştirilir. Amaçlanan durum, kazan-kazan ilişkisidir. Tedarikçi ilişkileri yönetimi süreci ise en temelde dış kaynak kullanımı stratejisine dayanır. Sonraki bölümlerde bir işletmenin tedarikçilere gereksinim duyma sebepleri ve tedarik yönetimi ilişkileri ele alınacaktır.

1.4. Dış Kaynak Kullanma Stratejileri

İşletmelerin uzun vadede varlıklarını idame ettirme çabaları, küreselleşme ile birlikte ülkeler arasındaki sınırların silikleşmesi ve pazarda meydana gelen hızlı değişimler, işletmeleri kalite ve maliyet avantajı ile beraber rekabet gücünü artırmaya yönelik stratejiler kullanmaya zorlamaktadır. İşletmelerin ana faaliyetleri dışındaki faaliyetlerini tedarikçilerden sağlaması da bu amaca hizmet etmektedir (Van Weele, 2001).

Bir işletme "üret veya satın al" problemine "satın al" yönünde karar verirse, bu kararın bir sonraki adımı kiminle ortaklık kurulacağı olacaktır. Buna bağlı olarak işletme, bir tedarikçi seçimi yapmalıdır. Bu satın alma stratejisine ise, dış kaynak kullanımı adı verilmektedir. Dış kaynak kullanımı, "üret veya satın al" kararının sonucunda işletmelerin, kendilerine rekabet avantajı sağlayacak faaliyetlere odaklanmak amacıyla kendi uzmanlık alanı dışında kalan faaliyetleri tedarikçilere devretmesidir (Dalay ve diğerleri, 2002). Farklı bir deyişle, organizasyon içinden sağlanan faaliyetlerin organizasyon dışından satın alınması işlemidir (Lacity ve Hirschheim, 1993).

Şekil 1.2: Dış kaynak kullanımı süreci (Benton, 2018).

Dış kaynak kullanımı, stratejik ve finansal değerlendirme ile başlar, bir uzman tedarikçi seçimiyle beraber satın alma modelinin hayata geçirilmesi ve tedarikçi ilişki yönetimi ile devam eder. Benton (2018)'a göre, stratejik değerlendirme ve finansal değerlendirme aşamaları "iş durumunun değerlendirilmesi" kapsamına girerken; tedarikçi ortaklığının kurulması, satın alma modeline geçilmesi ve ilişki yönetimi aşamaları "uygulama ve yönetim" kapsamına girmektedir. İş durumunun değerlendirilmesi ve yönetilmesi aşamalarının sonucunda dış kaynak modelinin uygulanması ve yönetilmesi süreci, bazı avantaj ve dezavantajları, iş birliği yapılacak tedarikçilerin seçimini ve tedarik sürekliliğinin nasıl sağlanacağı gibi soruları gündeme getirir (Bozarth ve Handfield, 2008).

Dış kaynak kullanımına yönelik bazı stratejik faydalar aşağıdaki gibidir (Benton, 2018):

- Doğrudan işletme maliyetlerinin azalmasına ve sabit maliyetlerin değişken maliyetlere dönüştürülmesine yardımcı olur.
- Şirket odağını ana faaliyetlere yönelterek kurumun kendi yetkinliklerine odaklanmasını sağlar.
- Dış olanaklarını genişleterek yeni pazarlara yayılımını arttırır.
- Dış kaynaklardan yeni teknolojiler ve yetenekler temin ederek işletmenin verimliliğini ve kalitesini arttırır.

Buna karşın dış kaynak kullanımı bazı riskleri ve gizli maliyetleri de bünyesinde barındırır (Bozarth ve Handfield, 2008):

- Tedarikçi, ürünü yeterli kalite standartlarında üretme kabiliyetine sahip olmayabilir. Dış kaynaktan temin edilen ürün veya hizmetin kalitesini doğru bir şekilde değerlendirmek alıcı firma için iç kaynaktan beslenmekten daha zor olacaktır (Benton, 2018).
- Tedarikçi firma ile alıcı firma arasında koordinasyon ve kontrol sorunları yaşanabilir.
- Dış kaynak kullanan işletmeler, zaman içinde sahip oldukları teknolojik ve temel yeteneklerini kaybedebilirler.

- Tedarik zinciri ortaklarının yasal yükümlülüklerini yerine getirmemesi veya sözleşme hükümlerine uymaması riski ortaya çıkabilir.

Dış kaynak kullanımı faydalarının gerçekleşmesi ile tedarik zinciri ortakları ve alıcı firmanın karşılıklı çıkarlarının korunması için bir sözleşme ile birlikte bir adanmışlık duygusunun da olması gerekmektedir (Benton, 2018).

Yukarıda bahsedilen riskler ve gizli maliyetler, işletmeleri tedarik zinciri ortaklıklarını daha iyi tanımaya ve önem düzeyi yüksek tedarikçiler ile uzun vadeli ilişkiler kurmaya teşvik etmektedir. Bu durum, tedarikçi ilişkileri yönetimi kavramının gelişmesini sağlamıştır.

1.5. Tedarikçi İlişkileri Yönetimi

Tedarik zinciri yönetiminin başarılı bir şekilde gerçekleştirilmesi için, satın alma ile dış kaynak kullanım maliyetlerinin, toplam üretim maliyetlerinin büyük bir bölümünü üstlendiği durumlarda, satın alma fonksiyonunun dikkatli bir şekilde planlanması gerekir. Bu nedenle işletmeler, yüksek sayıda tedarikçi ile ortaklık kurmayı göze alamamaktadırlar. Çünkü daha az tedarikçi demek, işletme için kilit öneme sahip tedarikçilerle daha iyi ilişkiler geliştirmek demektir (Turban ve diğerleri, 2005). Buna bağlı olarak, rekabet ortamı içinde daha iyi performansa sahip olan tedarikçiler seçilmeli ve değerlendirilmelidir (Weber ve diğerleri, 1991). Bu duruma yanıt olarak işletmeler, tedarikçi ilişkileri yönetimi sistemine daha fazla eğilmişlerdir.

Tedarikçi ilişkileri yönetimi, bir işletmenin rekabetçi bir şekilde yeni bir ürün geliştirebilmesi ve verimli bir şekilde üretebilmesi için stratejik önem arz eden tedarikçilerle iş birliği yapılmasını amaçlayan bir sistemdir (Park ve diğerleri, 2010). Yenilikçi ürünler geliştirmek ve bunları başarılı bir şekilde pazara sunmak için gerekli uzmanlığı sağlayabilecek kilit tedarikçilerle daha yakın ilişkiler geliştirmek, tedarik risklerinden doğacak zararı minimize etme ve maliyet verimliliğini sağlama avantajı ile kalitenin devamlılığı ihtiyacının bir sonucu olarak ortaya çıkan kritik bir iş sürecidir (Lambert ve Schwieterman, 2012).

Trent (2005), bu iş sürecinin aşağıda verilen dört davranışsal tedarik yönetimi ilişkisi ile yürütülebileceğini ifade etmektedir:

1. *Ters etkili ilişkiler,* tedarikçi firma ve müşteri firma arasında 'kaybet-kaybet' ilişkisinin olduğu durumu ifade eder. Tarafların karşılıklı olarak birbirlerinin çıkarlarına karşı çalıştıkları ilişki durumudur. Bu durum, kısa ve uzun vadede yeni bir değer yaratmakta başarısızlıkla sonuçlanacaktır. Bu nedenle ters etkili ilişkiler tavsiye edilmemektedir (Benton, 2018).

2. *Rekabetçi ilişkilerde,* tedarikçi firma ve müşteri firma arasında 'kazan-kaybet', ilişkisinin olduğu durumları ifade eder. Kazan-kaybet durumu, iki veya daha fazla tarafın sabit bir toplam değer üzerinde rekabet etmesi ve kazananın pastanın tamamını veya daha büyük payı alması anlamına gelir. Sıfır toplamlı veya sabit toplamlı oyun olarak da bilinir (Monczka ve diğerleri, 2015). Bu ilişkide hem tedarikçiler hem de alıcılar çıkarlarını maksimize etmek isterler.

3. *İşbirlikçi ilişkiler,* bütünleştirici ve 'kazan-kazan' ilişkileri olarak da bilinir. Bu ilişkide her iki taraf da yakın bağlara sahiptir ve verilerin açık paylaşımı üzerinde çalışır. Taraflar, ihtiyaçlarını ve isteklerini beraber karşılamaya yönelik teklifler yaparak pastadaki payın adil bir şekilde bölüşümünü belirlemek üzerine müzakere yapar. Bu ilişkiler, uzun süredir birbirleri ile çalışan tedarikçiler veya alıcılar arasında olmaktadır Trent (2005).

4. *Birlikte çalışma ilişkileri,* iş birlikçi ilişkiler gibi bir 'kazan-kazan' durumunu ifade eder. Yaratıcı ilişkiler olarak da bilinir ve bir organizasyonun başarısı için önemli olan mal ve hizmetleri sağlayan küçük bir tedarikçi grubunu içerir. Birlikte çalışma ilişkilerini, iş birlikçi ilişkiden ayıran, satın alma firmasının birincil yani kilit tedarikçileriyle kurduğu ilişki türü olmasıdır. Bu ilişkinin temel özelliği, pazarda performans göstermenin yeni ve yenilikçi yollarını belirlemek için tedarikçi ve alıcının bir takım gibi karşılıklı olarak çalışmaya istekli olmalarıdır. Bu nedenle, iş birlikçi ilişkiler, taraflar arasında mümkün olan en gelişmiş ilişkileri temsil eder Trent (2005).

1.6. Tedarikçi Portföy Yönetimi

İşletmeler, maliyetlerini düşürürken yüksek kaliteyi korumak amacıyla güçlü stratejiler geliştirerek ve yenilikçi yöntemler uygulayarak tedarik zinciri süreçlerini iyileştirmek durumundadır. Aşağıdaki sorular, işletme için doğru tedarikçi stratejileri geliştirmede faydalı olabilir (Van Weele, 2001):

- İşletmenin hâlihazırdaki satın alma stratejileri uzun vadedeki ihtiyaçlarını karşılamakta mıdır?
- Tedarikçiler ile alıcı işletme arasındaki güç dengesi nasıldır? Alıcı işletmenin tedarik pazarında tek bir tedarikçiye bağımlı olduğu veya baskın konumda olduğu ürünler nelerdir?
- Tedarik edilen ürünlerin ne kadarı uzun veya kısa vadeli sözleşmeler yoluyla karşılanmaktadır?
- Yakın gelecekte tedarik edilen ürünlerin sağlanmasında yaşanabilecek olası zorluklar veya kesintiler alıcı işletmenin karlılık hedeflerini ne yönde etkileyebilir?
- Tedarikçiler ile alıcı işletme arasında iş birliği hususunda fırsatlar mevcut mudur?

Bu sorulardan hareketle stratejik tedarikçi ilişkileri yönetimi süreci, tedarikçilerle ilişkilerin nasıl geliştirileceği ve yönetileceğine yönelik yanıtlar sağlar. Bu bağlamda, tedarik zinciri süreçlerini iyileştirmede ve tedarikçi stratejileri geliştirmede bazı satın alma portfolyolarından faydalanılmıştır. Tedarikçi yönetiminde portföy yaklaşımından faydalanmak, tedarikçilerin bir firmanın başarısında artan rolü nedeniyle önemlidir (Wagner ve Johnson, 2004). Bir tedarikçi portföy modeli, ürünlerin sınıflandırılması, ürünlerin teslimi için tedarikçi ilişkilerinin analiz edilmesi ve gerekli stratejilerin eyleme geçirilmesi olmak üzere üç adımda gerçekleştirilir (Olsen ve Ellram, 1997). Bunun yanında, işletmelerin satın alma kalemlerine yaptığı harcalamaların tedarikçi sınıflandırma başına analizi yapıldığında 20-80 kuralını gösterecektir. Pareto kuralı gereği, tedarikçilerin veya ürünlerin %20'si satın alma miktarının %80'ine tekabül edecektir (Van Weele, 2001). Pareto

kuralının gerçekleşmesinin ardından, satın alma portföy modeli kullanılarak tedarik kalemleri analiz edilir.

Fiocca (1982) ve Kraljic (1983) tarafından geliştirilen modeller, literatürde kullanılan portföy analizi yaklaşımlarına örnektir. Fiocca (1982), müşteri hesaplarını yönetmek için bir portföy yaklaşımı önerir. Bu yaklaşımda hesaplar, stratejik önemine ve hesabı yönetmenin zorluğuna göre sınıflandırılmaktadır. Bu sınıflandırmaya dayalı olarak, yüksek stratejik öneme sahip hesaplar, müşterinin ve alıcı-tedarikçi ilişkisinin gücü boyutları kullanılarak ikinci bir portföyde daha analiz edilmektedir. Fiocca (1982) tarafından önerilen model, Yorke ve Droussiotis (1994) tarafından yayınlanan bir vaka çalışmasında değiştirilmiş bir biçimde kullanılmıştır.

Kraljic (1983) ise bir ürün portföyü modeli geliştirmiştir. Kraljic'in modeli, bir firmanın satın alma kalemlerinin karlılık üzerindeki etkisi ve arz riski olmak üzere iki boyut temelinde oluşur. Satın alma kalemlerinin karlılık üzerindeki etkisi, matris üzerinde finansal riski temsil etmektedir. İşletmenin satın aldığı ürünlerin işletmenin karlılığı üzerindeki etkisi ve katma değerini göstermektedir. Arz riski ise, ürünün tedarik edilme riskini ifade etmektedir. Bir ürünün alternatif tedarikçi sayısı az olduğunda arz riskinin yüksek olduğu kabul edilmektedir. Bu boyutlardan hareketle satın alma kalemleri ise kaldıraç etkili, stratejik, düzenli ve darboğaz ürünler olmak üzere dört kategoride sınıflandırılır. Bu değişkenlerden hareketle, ortaya iki boyutlu ve dört bölmeli bir matris çıkar. Şekil 1.2'de Kraljic (1983)'e ait satın alma portföyü yer almaktadır. Bununla birlikte, Kraljic (1983) tarafından her bir portföy sınıfı için belirlenen stratejiler açıklanmıştır.

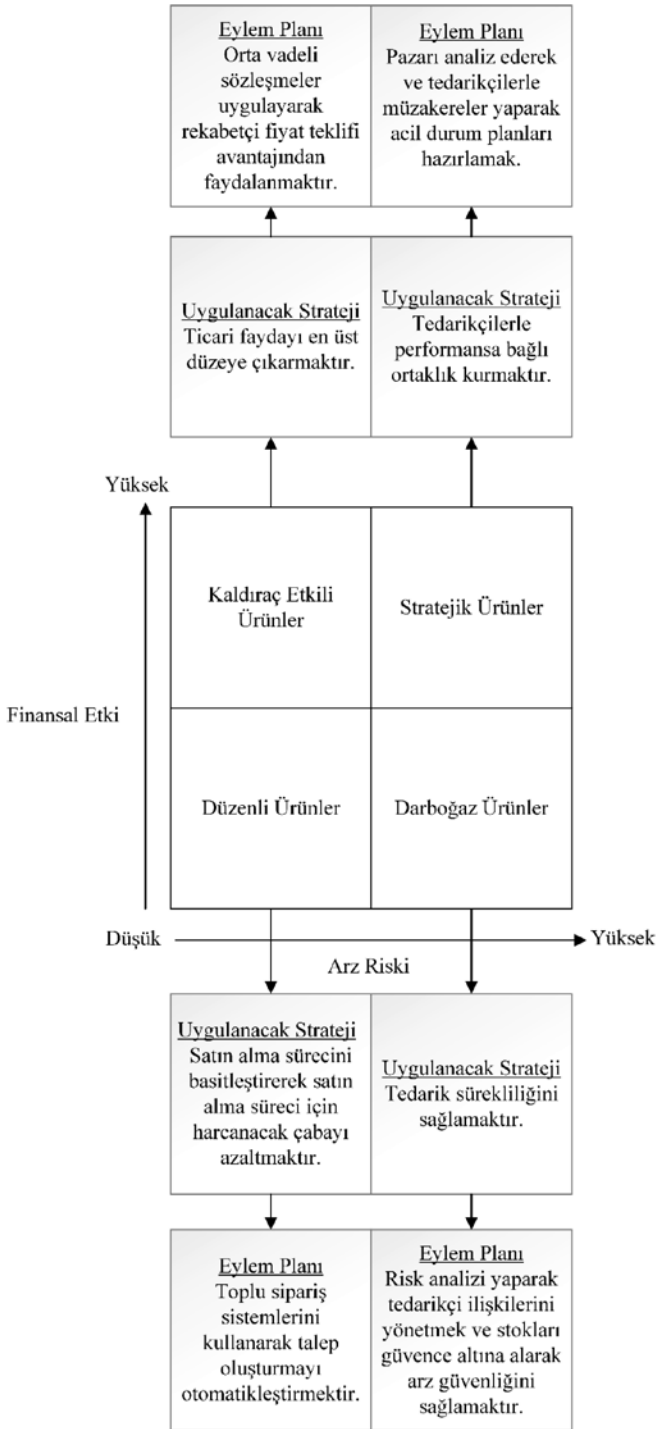

Şekil 1.3: Uygun stratejilerle birlikte Kraljic (1983) matrisi.

Kaldıraç etkili ürünler: Bu ürünler, düşük tedarik riski ile birlikte nihai ürünün maliyetinin kısmen büyük bir payını temsil eder. Kaldıraç etkili ürünlerde, pazarda birçok alternatif tedarikçi ve ürün kolayca bulunur. Birçok tedarikçisi olduğu için bu ürünler güvenli kabul edilir. Bunun yanında, büyük miktarlarda satın alınan ürünlerdir. Dolayısıyla fiyattaki küçük bir değişikliğin toplam maliyetler ve dolayısıyla karlılık üzerinde büyük bir etkisi olacağı için, kaldıraç etkili ürünlerde güç dengesi alıcıdan yanadır. Uygulanacak strateji aşağıdaki gibidir (Caniels ve Gelderman, 2005):

- Satın alma gücünden yararlanma: Bu stratejide alıcı işletme, rekabetçi fiyat teklifi avantajını kullanır. Tedarikçiler ve ürünler ikame edilebildiği için uzun vadeli tedarik sözleşmelerine ihtiyaç yoktur.

Stratejik ürünler: Bu ürünler yüksek teknoloji içeren, hem kârlılık üzerinde büyük bir etkiye hem de yüksek arz riskine sahip olan ürünleri temsil eder. Stratejik ürünlerde, pazarda bulunan tedarikçilerin sayısı fazla değildir, pazarda ürün bulmak ve ürünleri diğer alternatiflerle değiştirmek oldukça zordur. Güç dengesinin ortada olması istenir. Uygulanacak stratejiler aşağıdaki gibidir (Caniels ve Gelderman, 2005):

- Stratejik ortaklıkları sürdürmek: Tedarik riskini dengelemek için işletme, tedarikçileriyle karşılıklı güven ve bağlılık yoluyla yakın iş birliği kurarak arz riskini en aza indirme eğilimindedir. Tedarikçilerle yakın iş birliği, ürün kalitesinin artmasına, teslimatta güvenilirliğine, ödemede kolaylığa ve maliyetlerin düşmesine yardımcı olacaktır. Bu durum, alıcılar ve tedarikçiler arasında dengeli bir güç olarak adlandırılabilir.

- Kilitli ortaklıkları kabul etmek: Bu strateji, genellikle alıcı işletme, tedarikçileriyle negatif yönlü bir ilişkiye maruz kaldığında ve sözleşmeyi feshedemediğinde gerçekleşir. Kilitli konum, tedarikçinin belirli bir tekel gücüne sahip olması nedeniyle ortaya çıkar. Bu durumda güç dengesi tedarikçiden yanadır.

- Ortaklıkları sonlandırmak: Bu strateji, tedarikçi ilişkisi onarılamaz hale geldiğinde uygulanır. Alıcı işletme, alternatif tedarikçiler bularak

tedarikçilere olan bağımlılıklarını azaltmaya çalışır. Bu durumda güç dengesi hala tedarikçiye bağlıdır.

Düzenli (kritik olmayan) ürünler: Bu ürünler, düşük maliyetle birlikte düşük arz riski barındıran ürünleri temsil ederler. Düzenli ürünlerin alternatif tedarikçileri çoktur, pazarda kolayca bulunur ve bu ürünler gerektiğinde ikameleri ile kolaylıkla değiştirilebilir. Bu durumda düzenli ürünlerin piyasasının oldukça serbest olması ve alternatiflerini bulmanın kolay olması nedeniyle az sayıda probleme yol açarlar. Ayrıca satın alma departmanının harcadığı zamanın %80'ini ve satın alma devir hızının %20'sinden daha azını oluştururlar (Caniels ve Gelderman, 2005). Sarf malzemeler bu sınıfa örnek verilebilir. Güç dengesi ortadadır. Uygulanacak strateji aşağıdaki gibidir:

- Toplu sipariş sistemlerini kullanmak: Düzenli ürünlerin satın alma süreci, lojistik ve yönetimin karmaşıklığını azaltmayı amaçlayan bir satın alma stratejisi gerektirir. Sözleşme sürecinde rutin tedarikçiler ile iş birliği yapmak bir çözüm olarak görülmektedir.

Darboğaz ürünler: Bu ürünler, düşük finansal değere ve yüksek arz riskine sahip olan ürünleri temsil ederler. Darboğaz ürünlerde, pazardaki tedarikçi sayısı fazla değildir ve pazarda bu ürünleri elde etmek oldukça zordur. Tekelci bir piyasanın varlığından söz edilebilir, bu nedenle bu ürünler hassas konumdadır. Bu durumda alıcı işletmede üretimin aksaması riski ortaya çıkar. Güç dengesi tedarikçiden yanadır. Uygulanacak stratejiler aşağıdaki gibidir (Caniels ve Gelderman, 2005):

- Bağımlılığı kabul ederek olumsuz sonuçları azaltmak: Bu stratejinin ana odağı, gerektiğinde ek maliyetleri kabul ederek alıcı-tedarikçi ilişkisini sürdürmeye devam etmektir. İşletmenin risk analizi yaparak en önemli darboğaz ürünlerini belirlemesi gerekir.

- Bağımlılığı ve riski azaltarak alternatif çözümler bulmak: Bu strateji, tedarikçilere olan bağımlılığı azaltmaya yöneliktir. Bunu başarmanın yolu, ürün özelliklerini genişletmek, yeni tedarikçiler bulmak veya hâlihazırda kullanılan ürünü ikame ürünlerle değiştirmektir.

- Tedarik kalemlerinin sınıflandırılmasının yanı sıra Kraljic, portföy

yaklaşımının genel fikrinin "arz kırılganlığını en aza indirmek ve potansiyel satın alma gücünden en iyi şekilde yararlanmak" olduğunu belirtmiştir. Bu nedenle Kraljic'in portfolyo yaklaşımında alıcı-tedarikçi ilişkisi arasında bulunan güç ve bağımlılık önemli bir rol oynamaktadır (Dubois ve Pedersen, 2002). Alıcı ve tedarikçi işletme arasındaki stratejik etkilerin incelendiği matris, fırsatları veya kırılganlık alanlarını belirlemeye ve tedarik risklerini değerlendirmeye yardımcı olmaktadır. Burada amaç, işletmenin satın alma gücünü tedarikçilerinin güçlü yönlerine karşı görmesini sağlamaktır (Kraljic, 1983).

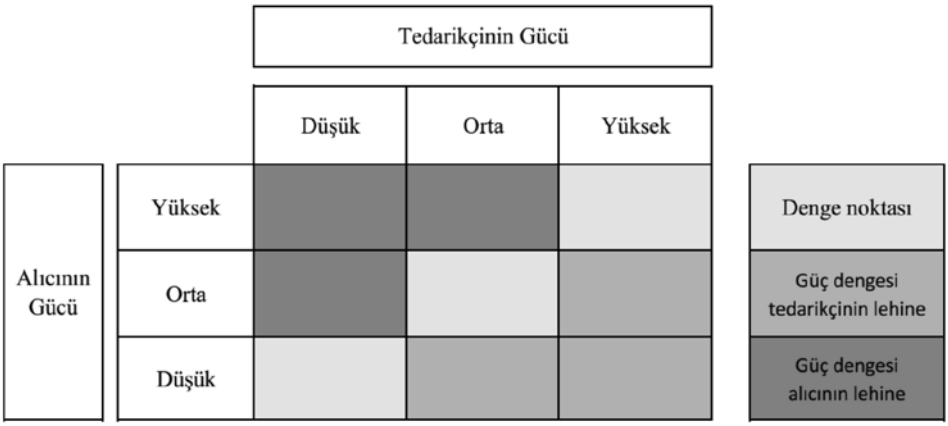

Şekil 1.4: Satın almanın stratejik etkileri Kraljic (1983).

Kraljic (1983)'e göre, alıcı işletmenin baskın bir rolü oynadığı ve tedarikçilerin gücünün orta veya düşük olarak nitelendirildiği ürün türlerinde, makul derecede agresif bir strateji benimsenmelidir. Tedarik riski az olduğundan, işletmenin düşük fiyat ve uygun sözleşmeler yoluyla kâr avantajı elde etme şansı daha yüksektir. Fakat, tedarikçi ilişkilerini tehlikeye atacak veya tedarik kesintilerinin yaşandığı zamanlarda düşük fiyatlarda ısrar ederek tedarikçilerini kaybetmesine yol açacak şekilde satın alma avantajını kullanmamaya özen göstermelidir.

Tedarikçilerin alıcı işletmeye göre güçlü olduğu ürünlerde ise, işletme yeni potansiyel tedarikçiler veya ürünler için olası alternatifler aramalıdır. Bunun yanında riski ve faydası düşük olan tedarik kalemleri için pasif kalmanın maliyetli olacağı da hesaba katılmalıdır. Öte yandan, saldırgan bir

tavır da tedarikçi ilişkilerine zarar verebilir. Bu durumda, işletme denge politikası izlemelidir. İşletme çoğu zaman, kendisini farklı ürünler ve tedarikçilerle ilgili olarak, farklı rollerde bulacaktır (Kraljic, 1983).

1.7. Tedarikçi Değerlendirme

Performans değerlendirmesi, bir işletmenin belirli hedefleri yansıtan belirli bir kriteri ne ölçüde karşıladığını ölçmektir (Coşkun ve diğerleri, 2022). Tedarik zinciri yaklaşımında performans değerlendirmesi alıcının tedarikçi işletmeleri analiz etmesidir. Tedarikçilerin geçmişteki performanslarını ve gelecekteki potansiyellerini analiz etmek, mevcut sözleşmeleri periyodik olarak değiştirme ihtiyacını azalttığından önem arz etmektedir.

Tedarikçi değerlendirme sürecinin amacı, pazarda mevcut olan en iyi tedarikçileri seçmek veya var olan tedarikçilerle sözleşmelerin devam edip etmeyeceğine karar vermektir. Tedarikçi seçimi ve değerlendirmesi stratejik ve uzun vadeli bir karardır. Tedarikçilerle uzun vadeli bir ilişki, alıcı için büyük fayda sağlar. Gelecek planlarında istikrar, yüksek ürün kalitesi, güvenilir teslim süreleri ve indirimler gibi avantajlar sunar.

Web of Science Core Collection veri tabanında “Kraljic Matrix” anahtar kelimesiyle yapılan tarama neticesinde, son beş yılda yönetim bilimleri alanında sekiz adet araştırma makalesi yayınlandığı görülmüştür. Bu makalelere ilişkin özet bilgiler aşağıdaki tabloda görüldüğü gibidir.

Amaç	Yöntem	Sonuç	Uygulama alanı	Referans
Tedarikçi sınıflaması için geniş ve kapsamlı bir model geliştirme	AHP; Gantt diyagramı	Çevirim süresi bağlamında kritik tedarikçilerin belirlenmesi	Sokak lambası üreten bir İtalyan KOBİ şirketi	(Bianchini vd., 2019)
Tedarikçi sınıflama	DEMATEL; ANP; VIKOR	Kriterler arası etkileşimin modellenmesi	AVM inşaatı projesi	(Ghanbarizadeh vd., 2019)
Kraljic matrisine dayalı objektif ve nicel bir karar analizi	Çok nitelikli değer fonksiyonu	Fayda-maliyet görüşüne dayalı karar verme	10 milyon dolarlık Satın alma portföyü olan bir işletme	(Montgomery vd., 2018)
Bitmiş ürünün sürdürülebilirliğini sağlama	Kavramsal modelleme	Yeşil tedarikçi performans değerlendirme sistemi	Kimya endüstrisinde bir vaka çalışması	(Garzon vd., 2019)
Üretim çevrim süresini azaltıcı bayi stratejilerinin belirlenmesi	Vaka çalışması; içerik analizi, nitel analiz	Rasyonelleşti-rilmiş tedarikçi tabanı	Siparişe göre üretim yapan bir Hint firması	(Seth ve Rastogi, 2019)
Kaynaklamada pazarlık stillerinin belirlenmesinde Satın alma portföy analizinin rolü	Vaka çalışması; deneysel test	Rekabetçi, İşbirlikçi, Uyumlaştırıcı pazarlık stratejileri	Satın alma yöneticilerine yönelik anket çalışması	(Kang vd., 2018)
Optimal proje satın alma portföyü	Belirsizlik altında karar verme	Ortaklıklardan yapılan kaynaklama en düşük riske maruz	İnşaat projeleri	(Dixit, 2022)
Kaldıraç etkili ürünlerin satış fiyatlarının değerlendirilmesi	Veri Zarflama Analizi	Tedarikçi seçme ve değerlendirmede inovatif bir yaklaşım	İtalyan mekanik üreticisi firma	(Visani ve Boccali, 2020)

Tablo 1.1: Literatür taraması.

Bianchini ve diğerleri (2019), tedarikçi sınıflaması için esnek ve geniş bir model önermiştir. Model, çevirim sürelerini kısaltmak amacıyla kritik tedarikçiler üzerinde uygulanmıştır. Ghanbarizadeh ve diğerleri (2019), farklı sektörlerden 190 üreticiye anket uygulamış ve üreticilerin 4. sanayi devrimine hazır olup olmadıklarını araştırmıştır. Montgomery ve diğerleri (2018), Kraljic portföy matrisinin kavramsal bir model olduğundan bahsetmiş ve nicel bir ölçüm aracı olmamasının bir zayıflık olduğundan bahsetmiştir. Böylelikle tedarikçileri ve ürünleri sınıflamak için objektif ve nicel bir karar destek sistemi önermiştir. Garzon ve diğerleri (2019), tedarikçi seçiminin sürdürülebilirlik açısından önemini vurgulamıştır. Böylelikle yeşil tedarik zinciri yönetimi bağlamında bir tedarikçi performans yönetim sistemi geliştirmiştir. Seth ve Rastogi (2019), tedarikçi rasyonelleştirmesi üzerinde durmuş ve bayi yönetiminde çevirim sürelerini azaltabilmek için uygulanması gereken stratejileri belirlemiştir. Kang ve diğerleri (2018), dış kaynak kullanımında müzakere stratejileri üzerinden tedarikçi portföyünün yönetimine odaklanmıştır. Dixit (2022), inşaat projelerinde geçerli olan bir çerçeve ve ürün türleri, alıcı-satıcı ilişkileri, fiyatlama rejimi gibi birbirleriyle ilişkili 64 unsur belirlemiştir. Visani ve Boccali (2020), kaldıraç etkili ürünlerde satın alma fiyatlarını değerlendirmek için veri zarflama analizine dayalı bir karar destek modeli önermiştir.

İKİNCİ BÖLÜM

TEDARİKÇİ DEĞERLENDİRME YÖNTEMLERİ

Tedarikçi değerlendirmesinde çok çeşitli yöntemler kullanılmakla birlikte bu tez çalışmasında teknikler veri madenciliği yöntemleriyle sınırlandırılmıştır. Veri madenciliğinde kullanılan yöntemler, tanımlayıcı modeller ve tahmin edici modeller olmak üzere iki başlık altında toplanmaktadır (Kantardzic, 2011). Tanımlayıcı modeller, araştırmacının karar vermesini kolaylaştırmak için verideki örüntülerin açığa çıkarılması amacıyla denetimsiz öğrenme işlevini yerine getirir (Jain ve Srivastava, 2013). Tahminleyici modeller ise geçmişteki verilerden hareketle, değişkenlerin gelecekteki değerlerini tahmin etmek amacıyla denetimli öğrenme modellerini kullanır (Jothi ve diğerleri, 2015). Bu bölümde, tanımlayıcı yöntemlerden kümeleme analizi ve tahminleyici yöntemlerden yapay sinir ağları anlatılacaktır.

2.1. K-Ortalamalar Kümeleme Analizi

Kümeleme, örnekler arasındaki uygun bir yakınlık veya benzerlik kavramına dayalı olarak N sayıda örneği farklı kümeler halinde gruplandırma süreci olarak tanımlanabilir (Erdoğmuş ve diğerleri, 2016). Farklı bir ifadeyle kümeleme analizi, bir dizi gözlem değerini küme içi benzerliklerin yüksek, kümeler arası benzerliğin ise düşük olduğu homojen gruplara ayırmayı amaçlayan bir veri madenciliği yöntemidir (Tzortzis ve Likas, 2014). Kümeleme, önceden tanımlanmış sınıf etiketli eğitim örneklerine dayanmadığı için, bir gözetimsiz öğrenme türü olarak makine öğrenimi ve istatistiksel örüntü tanıma alanlarında kullanılmaktadır (Stork ve diğerleri, 2001).

Kümeleme analizi, örneklerin kümelere ayrılma yöntemine göre hiyerarşik ve hiyerarşik olmayan yöntemler olmak üzere iki farklı yaklaşımda incelenir (Atbaş, 2008).

- Hiyerarşik kümeleme, benzer gözlemlerin adım adım parçadan bütüne bir araya getirilmesi veya bütünden parçaya doğru ayrıştırılması-

dır. Bu prensibe göre, birleştirici ve bölücü olmak üzere iki temel hiyerarşik kümeleme analizi tekniği bulunmaktadır. Tümevarım olarak da adlandırılan birleştirici yaklaşım, başlangıçta birbirinden bağımsız olan tüm örneklerin benzerliklerine göre adım adım yeni bir küme oluşturmasıdır. Tümdengelim olarak bilinen bölücü yaklaşım ise, tüm örneklerin bir arada bulunduğu bir kümenin adım adım tek bir kümeye ayrılmasıdır (Akpınar, 2014).

- Hiyerarşik olmayan kümeleme, hiyerarşik yaklaşımın aksine örnekleri bir ağaç diyagramı formunda kümelere bölmek yerine, n sayıda örnek değeri k sayıda kümeye ayırmaktadır (Özdamar, 2004). Bu yaklaşım içinde en çok kullanılan yöntemlerden birisi k-ortalamalar (k-means) yöntemidir (Çalış ve Baynal, 2016).

İlk olarak Lloyd (1982) tarafından kullanılan k-ortalamalar terimi, daha sonra MacQueen (1967) tarafından geliştirilmiştir. K-ortalamalar algoritması, denetimsiz öğrenme literatüründe yer alan ve gözlem değerlerinin benzerliklerini göz önünde bulundurarak bu gözlem gruplarını bölmeyi amaçlayan çok değişkenli bir istatistik yöntemidir. Farklı bir ifadeyle k-ortalamalar yönteminin amacı, bir veride bulunan örnekleri, araştırmacı tarafından belirlenen sayıca kümelere ayırmaktır (Alpar, 2013). K, pozitif bir tam sayı olan küme sayısını temsil etmektedir. Gözlemlerin hangi kümeye ait olduğunu bulmak bir optimizasyon problemidir. Sabit bir k küme sayısı belirlendiğinde, gözlem değerleri ve karşılık gelen küme merkezleri arasındaki Öklid uzaklığının karelerinin toplamı en aza indirilir (Bandyopadhyay ve diğerleri, 2020).

$p1,...,p_n$, R^d'de tanımlanan n sayıdaki bir verinin gözlem değerlerini temsil etmektedir. R^d'de küme ağırlık merkezlerini temsil eden K noktaları $\{m_j\}$ $(j=1,2,...,k)$ bulunmaktadır. p_i ve m_j arasındaki Öklid uzaklığı $d(p_i, m_j)$ şeklinde verildiğinde aşağıdaki denklemde gösterildiği gibi ortalama karesel hata minimize edilir (Arthur and Vassilvitskii, 2007).

$$\frac{1}{n}\sum_{i=1}^{n}[\min_{f} d^2(p_i, m_j)]$$

Buna göre k-ortalamalar algoritması, veri setinin belirlenen k adet küme

sayısına bölünmesi ile başlar. Veri setindeki tüm birimler kendisine en yakın Öklid uzaklığında bulunan kümeye atanır. Yapılan her atamadan sonra kümelerin merkezi yeniden hesaplanır ve gözlem değerlerinin farklı bir kümeye taşınıp taşınmayacağına karar verilir. Bu adımlar veride bulunan tüm gözlem değerleri bir kümeye atanıncaya kadar devam eder. Gözlem değerleri bir kümeye yerleştirildikten sonra yeniden küme ortalamalarının hesaplanmasının nedeni, söz konusu birimleri daha yakın kümelere atayarak kümeler arasındaki farklılığın en büyük, küme içi farklılığın ise en küçük olmasını sağlamaktır (Çalış ve Baynal, 2016). Bu sürecin sonunda k adet kümeye ayrılmış bir verinin kümeler arası ortalama karesel hata değerinin minimum olması beklenir. Aşağıda k-ortalamalar yöntemine ait akış şeması verilmektedir:

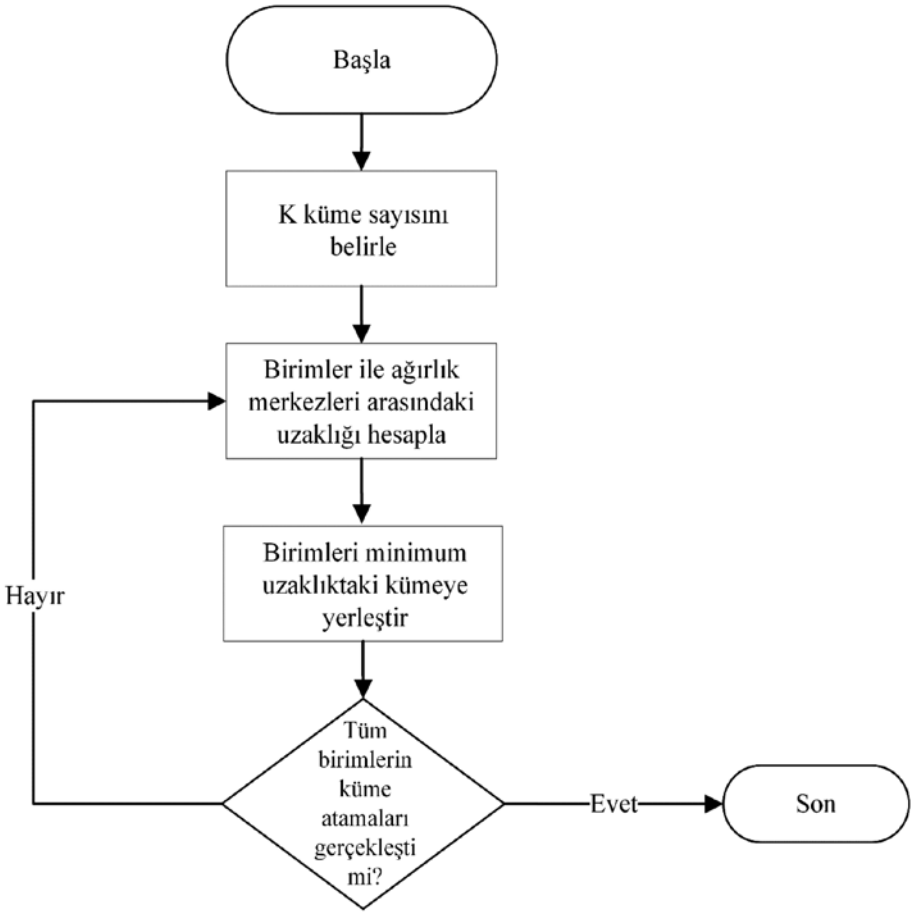

Şekil 2.1: K-ortalamalar yöntemine ait akış şeması (Bustamam ve diğerleri, 2017).

2.2. Yapay Sinir Ağları

Biyolojik bir öğrenme makinesi olarak tanımlanan beynin anlama yeteneği, mevcut bilgisayarlardan fazla olsa da bilgisayarlar sayısal işlemleri gerçekleştirmede daha hızlıdır. Yapay sinir ağları (YSA), beynin bilgiyi işlerken sahip olduğu güç ve hızdan ilham alır (Haykin, 2010).

Beyin temel olarak, birbirine bağlı olan milyarca nörondan oluşur. Biyolojik bir sinir hücresi, soma adı verilen bir nöronal hücre gövdesinden ve onları birbirine bağlayan akson ve dentrit adında giriş ve çıkış kanallarından oluşur (Haykin, 1994). Her nöron, dentritlerdeki diğer nöronlardan elektro-kimyasal girdiler alır. Bu elektrik girdilerinin toplamı nöronu aktive etmek için yeterince güçlü ise akson boyunca bir elektro-kimyasal sinyal iletir. Sonrasında bu sinyaller, birbirine bağlı olan diğer nöronlara iletilir (Zou ve diğerleri, 2008). Beynimiz, birbirine bağlı bu elektro-kimyasalları ileten nöronlardan oluşur. Böylelikle, çok sayıda basit işlem biriminden, son derece karmaşık görevleri yerine getirmeyi başarır. Bilim insanları biyolojik sinir hücrelerinin çalışma prensibinden ilham alarak YSA'ları geliştirmişlerdir (Grossberg, 1988).

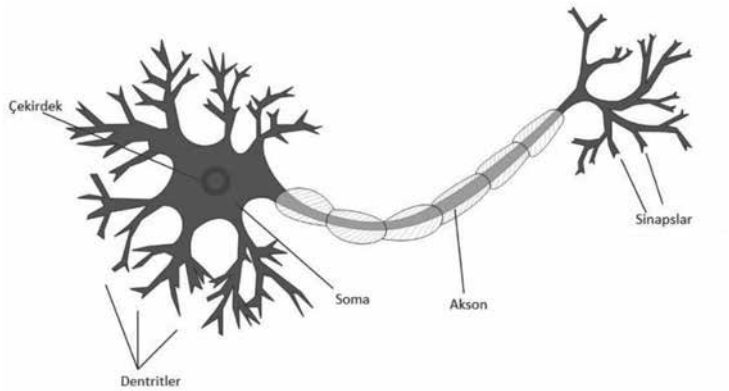

Şekil 2.2: Biyolojik sinir hücresi (Miller ve Forte, 2017).

YSA ile ilgili çalışmalar yıllar öncesine dayanır (Widrow ve Lehr, 1990). 1940'lı yılların başında McCulloch ve Pitts (1943) psikolojik teoriler ve nöro-fizyolojik araştırmalardan yola çıkarak ilk defa sinir ağlarının temellerini attılar. Aynı zaman diliminde psikologlar "öğrenme" ile ilgili yeni modeller geliştiriyorlardı. Bununla ilgili olarak Hebb (1949) YSA eğitim algoritmalarının başlangıcı olarak kabul edilen bir eğitim modeli önerdi. Hebb'e

(1949) göre iki nöron aynı anda ateşlenirse aralarında bir bağlantı geliştirilebilirdi. 1950'lerde ve 1960'larda araştırmacılar ilk YSA'yı oluşturmak için bu öngörüyü birleştirdiler. Farley ve Clarck (1954) rastgele ağlarda uyaranlar ile tepki ilişkilerini anlamak için modeller oluşturdu. Bu teorilerin diğer ayrıntıları, Rosenblatt (1958), Widrow ve Hoff (1960), Caianiello (1961), Steinbuch (1961), Minsky ve Papert (1969) tarafından gerçekleştirildi. Rosenblatt ilk YSA'yı oluşturmuş ve buna algılayıcı (perceptron) adını vermiştir. Widrow ve Hoff (1960), ağırlığın kurala göre ayarlanmasından önceki değeri inceleyen bir öğrenme prosedürü geliştirdi. Buna göre, bir algılayıcının hata değeri olabileceği düşünülürse, hata ağ üzerinde dağıtılabilir veya diğer algılayıcıların ağırlık değerleri ayarlanabilirdi. Minsky ve Papert (1969) ise tek katmanlı bir algılayıcının XOR problemini çözemediğini gördü ve iki katmanlı ileri beslemeli bir YSA önerdi. Seksenli yıllar ise YSA için bir dönüm noktası oldu (Akpınar, 2014). Hopfield (1982) yaklaşımı çift yönlü çizgiler kullanarak daha kullanışlı makineler yarattı. Rumelhart ve diğerleri (1986) ise çok katmanlı algılayıcılarda geri yayılım ağlarını geliştirdi.

Günümüzde ise YSA, el yazısı (Ciresan ve diğerleri, 2011), yüz (Kwolek, 2005), konuşma (Sukittanon ve diğerleri, 2004), nesne (Huang ve LeCun, 2006) tanıma ve algılama, doğal dil işleme (Goldberg, 2017) ve robotik gibi çok çeşitli alanlarda çalışmalar yapılmaktadır.

2.3. Biyolojik Sinir Hücresinden Yapay Sinir Ağlarına

YSA, tüm birimleriyle özerk fakat; tamamen birbirine bağlı ve senkronize olarak çalışan bağımsız bir hesaplama öğesi kümesidir (Bilbao ve Bilbao, 2017). Bir nöron, bir sinir ağının çalışması için temel olan bir bilgi işlem birimidir. Tek bir nöronun basit bir matematiksel modeli 1943'te McCulloch ve Pitts tarafından bir konferansta tanıtılmış ve şekil 2.2.'de gösterilen formu almıştır (Bishop, 2006). Haykin (2010)'e göre, bir sinir hücresinin üç temel unsuru tanımlanmıştır:

- Her biri kendi ağırlık değeri ile temsil edilen ve sinaps olarak ifade edilen bağlantılar: k nöronuna bağlı sinaps m girişindeki x_m sinyali, ağın ağırlığı olan w_{km} ile çarpılır. w_{kj} ağırlığında bulunan alt indislerin nasıl yazıldığını bilmek önemlidir. w_{km}'deki ilk alt indis söz konusu

nöronu temsil ederken ikinci alt indis, ağırlığın ifade ettiği sinapsın giriş ucunu belirtir. İnsan beynindeki bir sinaps ağırlığının aksine, yapay bir nöronun ağırlığı pozitif veya negatif değerler içeren bir aralıkta tanımlanabilir.

- Girdi sinyallerini toplamak için nöronun kuvvetlerine göre ağırlıklandırılmış bir toplam fonksiyonu: Burada yapılan işlemler toplanarak bir birleştirici vazifesi görür.
- Çıktının aralığını sınırlandırmak için kullanılan bir aktivasyon fonksiyonu: Çıktı değerlerinin belirlenen aralıkta sınırlanması için bir aktivasyon fonksiyonu kullanılır. Çıktı değeri sıklıkla [0,1] veya [-1,1] aralığında tanımlanır.

Şekil 2.2.'de gösterilen modelde $x_1, x_2,...,x_m$ giriş değerlerini; $w_{k1}, w_{k2},\ldots,$ w_{km} k nöronunun ağırlıklarını; b_k yanlılık (bias) değerini; v_k girdi değerlerinin toplam fonksiyonu çıktısını; φ aktivasyon fonksiyonunu ve y_k ise ağın çıktısını temsil eder. Harici olarak b_k ile gösterilen yanlılık değeri, kalıcı olarak +1'e ayarlanmış olan ekstra bir girdi değerinden gelen bir ağırlık değeri kabul edilebilir (Bishop, 2006). Bu bilgiler doğrultusuna denklemler aşağıdaki gibi tanımlanır:

$$net = u_k = \sum_{j=1}^{m} w_{km}.x_m$$

$$f(net) = y_k = \varphi\,(u_k + b_k)$$

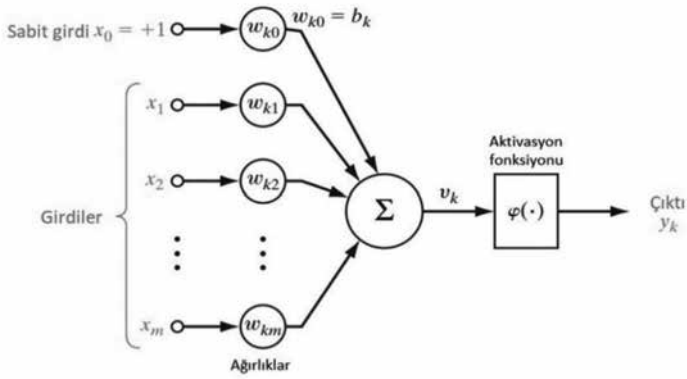

Şekil 2.3: Bir yapay sinir hücresi modeli (Haykin, 2010).

2.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, bir nöronun ateşlenip ateşlenmeyeceğine karar vermek için kullanılan girdi ve yanlılık değerlerinin ağırlıklı toplamını hesaplamak için kullanılır. Aktivasyon fonksiyonlarına literatürde sıklıkla transfer fonksiyonu da denir (Munakata, 2008). Bir sinir ağından beklenen çıktı doğrusaldır ve bu doğrusal girdileri, doğrusal olmayan çıktılara dönüştürmek için, doğrusal olmayan aktivasyon fonksiyonları gereklidir (Nwankpa ve diğerleri, 2018). Tablo 2.1'de literatürde sıklıkla kullanılan bazı aktivasyon fonksiyonlarına ait bilgiler yer almaktadır:

No	Aktivasyon Fonksiyonu	Grafik	Denklem	Fonksiyon Aralığı
1	Doğrusal (Lineer) Fonksiyon	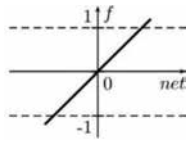	$f(x) = x$	(-∞,∞)
2	Adım Fonksiyonu	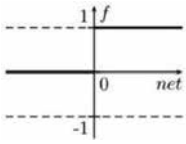	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	{0,1}
3	Sigmoid Fonksiyonu	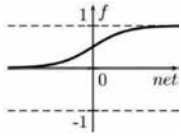	$f(x) = \frac{1}{1 + e\text{-}x}$	[0,1]
4	Hiperbolik Tanjant Fonksiyonu	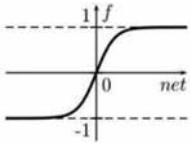	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	[-1,1]

Tablo 2.1: Aktivasyon fonksiyonlarının gösterimi (Öztürk, 2011).

2.5. Ağ Mimarileri

Karmaşık bir sistem olan insan beynini modellemek için sistemin veya ağın nasıl oluştuğunu anlamak gerekir. Sinir ağı mimarisi, ağın yapısının tasarlanmasını ifade eder. Bir ağ tasarlamak için, nöron sayısını ifade eden ağın boyutuna ve yapısına karar verilmelidir. Buna göre YSA'lar "ileri beslemeli", "geri beslemeli" veya "yinelemeli" biçimde tasarlanabilir (Merlo ve diğerleri, 2003). Aynı şekilde bir grup nöron tek katmanlı bir ağ oluştura-

bilir veya tek katmanlı bir ağ çok katmanlı bir sinir ağına evrilebilir (Song, 1992). Kullanılacak sinir ağı, problemin yapısına göre değişiklik gösterir ve probleme hangi ağ yapısının uygun olduğu karar verici tarafından belirlenir (Karaatlı ve diğerleri, 2012).

Rosenblatt'ın 1958 yılında, "perceptron" adını verdiği ve öğrenme kabiliyetine sahip ilk YSA yaklaşımından günümüze, sinir ağları hiyerarşik bir yapıda olmuştur (Elmas, 2016). Buna göre YSA, birden fazla katman halinde organize edilen bir dizi nörondan meydana gelir (Cichocki ve Unbehaven, 1993). Söz konusu hiyerarşik yapıya göre sinir ağının her i. katmanında n_i sayısı kadar nöron vardır ve bu nöronlara girişler önceki katman nöronlarından bağlanır. Giriş katmanı uyarma sinyalleri ile beslenir. Her bir nörona ağırlık eklenir ve ağırlıklar eğitim setine göre uyarlanarak güncellenir. Bu sayede YSA, ağırlıklarını ayarlayarak bir yanıt üretmeyi öğrenir (Ayyagari, 2011).

2.5.1. Tek Katmanlı Algılayıcılar (Perceptron)

En basit sinir ağına algılayıcı (perceptron) adı verildiği Bölüm 2.2.'de ifade edilmişti. Algılayıcı, Şekil 2.2.'de görüldüğü üzere tek bir giriş ve bir çıktı katmanı içerir (Aggarwal, 2018).

Rosenblatt, McCulloch - Pitts modelinden farklı olarak biyolojik ağlar arasında oluşan bağlantının rassal olarak oluştuğuna inanıyordu. Rassal olarak birbirine bağlanan bu ağların özelliklerini karakterize etmek için istatistiksel bir ayrılabilirlik teorisi ve bir öğrenme kuralı geliştirdi. "Perceptron yakınsama teorisi" olarak bilinen bu teori, ağın eğitilmesi durumunda doğru ağırlık değerlerine yaklaşacağını ispatladı. Buna göre öğrenme, basit ve otomatikti (Freeman ve Skapura, 1991). Ne yazık ki algılayıcının yetenekleri sınırlıydı. Minsky ve Papert (1969), perceptronun belirli temel işlevleri yerine getiremediğini gösterdiler. Minsky ve Papert (1969)'e göre, algılayıcı ancak doğrusal olarak ayrılabilen örüntüleri ayırt edebiliyordu. Fakat birçok sınıflandırma problemi doğrusal olarak ayrılabilir sınıflara sahip olmadığından bu durum algılayıcının uygulanabilirliğine ciddi bir kısıtlama getiriyordu ve perceptron basit bir XOR problemine dahi çözüm üretemiyordu.

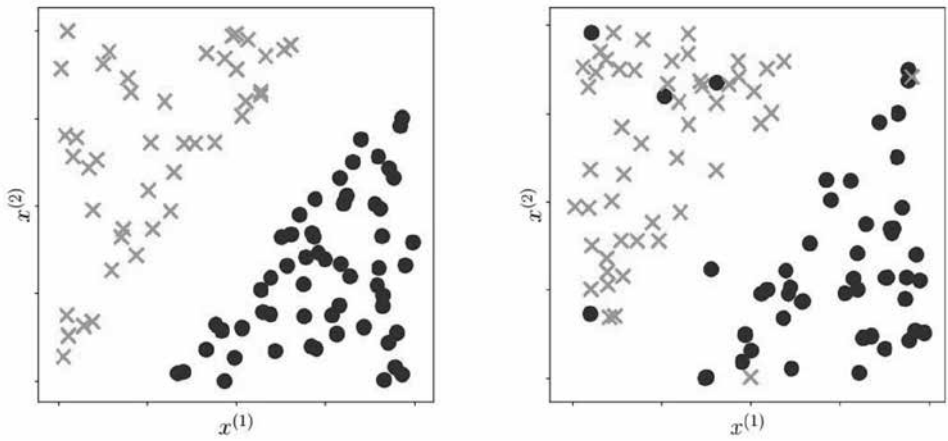

Şekil 2.4: Doğrusal olarak ayrılabilen ve ayrılamayan veri (Deisenroth ve diğerleri, 2020).

Tek katmanlı algılayıcı, doğrusal olarak ayrılamayan bir problem olan XOR problemini çözmekte başarısızdır. XOR probleminin çözümü için çok katmanlı sinir ağları kullanılmalıdır (Nitta, 2003).

$Girdi_1$	$Girdi_2$	*Çıktı*
0	0	0
0	1	1
1	0	1
1	1	0

Tablo 2.2: XOR problemi.

Minsky ve Papert'in önerdiği algılayıcı bir eşik değeri şartı içeriyordu. Ağdaki hesaplanan net girdi değeri eşik değerinin üzerindeyse 1; eşik değerinin altındaysa 0 değerini veriyordu (Freeman ve Skapura, 1991):

$$f(net) = \begin{cases} net \geq \theta \longrightarrow 1 \\ net < \theta \longrightarrow 0 \end{cases}$$

Algılayıcının bir eşik değeri şartına bağlı olması gözlenen değerlerin doğrusal olarak ayrılabilmesine olanak tanımaktadır. Çıktı değeri ile beklenen değer farklı ise ağırlık değerleri güncellenir. Eğitim setinde sonuçlar doğru bulunana kadar bu hesaplamalara devam edilir. Bu şekilde algılayıcının ağdaki sınıfları ayıran doğruyu bulmaya çalışması sağlanır.

2.5.2. Çok Katmanlı Algılayıcılar

Doğrusal olmayan problemlerin çözümünde tek katmanlı ağların başarısız olması, çok katmanlı ağların geliştirilmesine yol açmıştır. Çok katmanlı bir ağ, çevreden edinilen bilginin alındığı bir girdi katmanı, girdi ve çıktı katmanları arasında bulunan bir veya birden fazla gizli katman ve bir çıktı katmanından meydana gelir (Arı ve Berberler, 2017).

Haykin (2010)'e göre, aşağıdaki maddeler çok katmanlı bir sinir ağının temel özelliklerini içermektedir:

- Ağdaki her nöron, türevlenebilir bir doğrusal olmayan aktivasyon fonksiyonu içerir.
- Ağ, giriş ve çıkış katmanlarından farklı olarak bir veya daha fazla gizli katman bulundurur.
- Ağ, büyüklüğü ağırlık değerleri tarafından belirlenen ve nöronları birbirine bağlayan çok sayıda bağlantıdan oluşur.

Şekil 2.5'te çok katmanlı bir YSA'ya ait bileşenler gösterilmektedir.

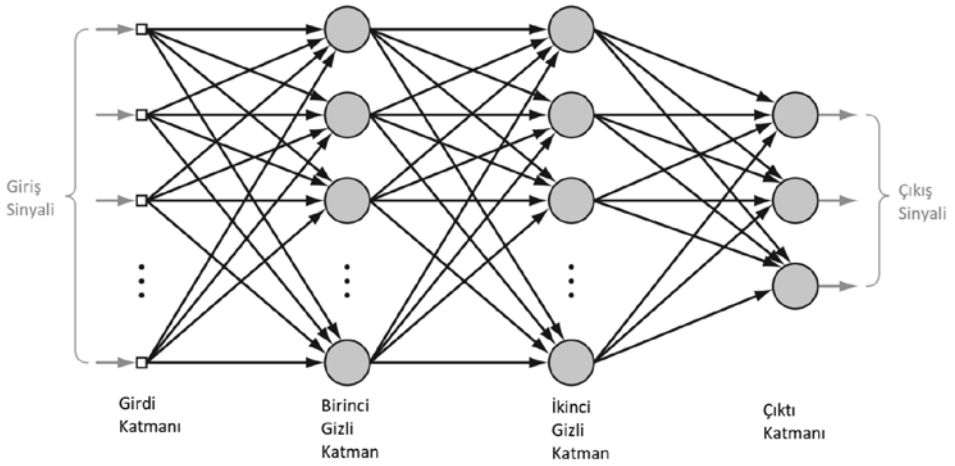

Şekil 2.5: Çok katmanlı bir YSA (Haykin, 2010).

Çok katmanlı ağlar ise, ağın yapısına göre ileri beslemeli ve geri beslemeli ağlar olarak isimlendirilirler. Buna göre eğitim iki aşamada ilerler (Haykin, 1994):

1. İleri beslemenin yapıldığı aşamada, ağın ağırlıkları sabitlenir ve girdiler çıktı katmanına ulaşana kadar, ağda önceki katmandan bir sonraki katmana doğru yayılır. Bu nedenle, değişiklikler ağdaki nöronların çıktıları ile sınırlıdır.
2. Geri beslemenin yapıldığı aşamada, ağın verdiği çıktı ile istenen yanıt karşılaştırılarak bir hata değeri üretilir. Ortaya çıkan hata değeri üzerinden tekrar katmandan katmana bir ilerleme gerçekleşir, ancak bu aşamada yayılma geri yönde yapılır. Geri yayılımda, ağın ağırlıklarına ayarlamalar yapılır.

2.5.2.1. İleri Beslemeli Ağlar

İleri beslemeli yapay sinir ağları (İBYSA), nöronların katmanlar halinde gruplandığı ve yalnızca ileri bağlantıların bulunduğu en popüler YSA mimarilerinden biridir (Mendes ve diğerleri, 2002). İleri beslemeli bir ağın amacı, bir f fonksiyonuna yaklaşmaktır (Goodfellow ve diğerleri, 2016). Örneğin, bir sınıflandırıcı için $y = f(x)$, bir x girdisini bir y kategorisi ile eşleştirir. İBYSA, bir $y = f(x;\theta)$, eşleşmesini tanımlar ve en iyi fonksiyon yakınsamasıyla sonuçlanan θ parametrelerinin değerini öğrenir. Bu modele ileri beslemeli denir. Çünkü bilgi x'den değerlendirilmekte olan fonksiyon üzerinden, f'i tanımlamak için yapılan hesaplamalara ve son olarak y çıkışına kadar gelir. Modelin çıktılarının bir geri bildirim içermez (Goodfellow ve diğerleri, 2016). Eğitimde delta öğrenme kuralı ya da en küçük ortalama kareler yöntemi gibi işlevlerin kullanılmasının dışında perceptron öğrenme kuralına benzer. Türevlenebilir bir aktivasyon fonksiyonu kullanıldığı için, gradyan azalma algoritmasının uygulanabileceği bir hata minimizasyonu yöntemi gerçekleştirilebilir (Elmas, 2016).

2.5.2.2. Geri Beslemeli Ağlar

Geri yayılımlı ağların temel amacı, önceki katmanlarda bulunan düğümlerin çıktısının, sonraki katmanlarda yol açtığı hata değerlerini kullanarak bir hata tahmini sağlayacak doğru ağırlık değerlerini öğrenmektir. Gizli katmandaki bir düğümün hata tahmini, sonrasında bulunan düğümlerin hata tahminlerinin ve ağırlıklarının bir fonksiyonu olarak hesaplanır. Bu, daha sonra düğümdeki ağırlıklara göre bir hata gradyanı hesaplamak ve bu düğümün ağırlıklarını güncellemek için kullanılır. Bu aşamada, gizli katman

düğümlerindeki hataların, çıktının bir eğitim etiketiyle karşılaştırılmasıyla doğrudan hesaplanmasından ziyade, geriye doğru yayılarak tahmin edilmesi şeklinde hesaplanmaktadır. Bu sürecin tamamı, ağdaki tüm düğümlerin ağırlıklarını güncellemek için geriye doğru yayılır (Aggarwal, 2015). Şekil 2.6'da bir ağ üzerinde yapılan hesaplamaların ileri yayılması ve hata sinyallerinin geri yayılması aşamaları gösterilmektedir.

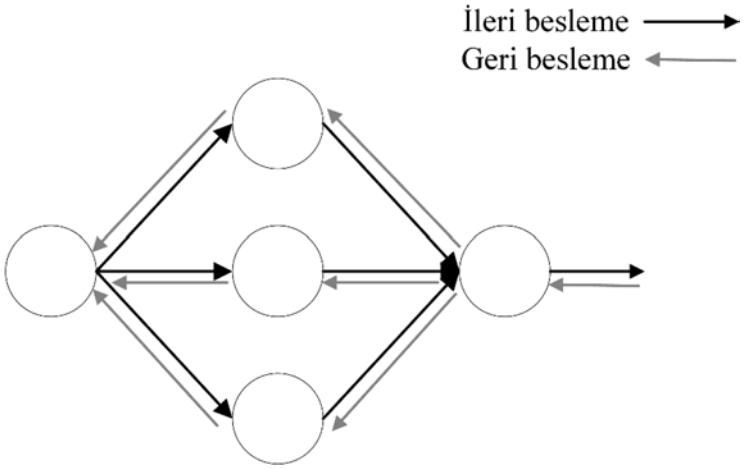

Şekil 2.6: Çok katmanlı bir YSA'da akış yönlerinin gösterimi (Haykin, 2010).

2.6. Yapay Sinir Ağlarının Eğitilmesi

YSA, öğrenme yeteneğine sahiptir ve ağırlık ile yanlılık değerinin uyarlanabilir bir şekilde değiştiği interaktif bir öğrenme süreciyle performansını arttırır. Sinir ağının belirli bir girdi setinden doğru çıktıları verebilmesi için, yapması gereken hesaplamaları kendini eğiterek öğrenir (Bilbao ve Bilbao, 2017). Benzer şekilde Çakar (1997), öğrenme sürecini ağın kendisine verilen girdilerin tutarlı cevaplar üretebilmesi için kendi üzerinde değişiklikler yapması olarak tanımlamaktadır. Böylece ağlarda yapılan ayarlamalar, çevreden gelen verilerden tahminleme, çıkarım ve sınıflama yapılmasına olanak tanır.

Öğrenme türü, parametre değişikliklerinin gerçekleşme şekline göre belirlenir. Öğrenme paradigması sinir ağının çalıştığı çevreyi ifade eder ve gözetimli öğrenme, gözetimsiz öğrenme ile takviyeli öğrenme olmak üzere üç temel paradigmaya sahip olduğu ifade edilir (Şekerli, 2019).

2.6.1. Denetimli (Supervised) Öğrenme

Denetimli bir sinir ağı "öğretmenle öğrenme" kavramı ile açıklanabilir (Tettamanzi ve Tomassini, 2001). Bununla birlikte sinir ağı başlangıçta çevreyi bilmez, ancak daha sonra bir eğitim süreci ile öğrenme yeteneği elde eder. Gözetimli öğrenmenin amacı, sinir ağına "öğretmeni" taklit etmeyi öğretmektir. Öğrenme süreci, eğitim verilerini sinir ağına vermekle başlar. Öğretmen tarafından her girdi vektörüne karşılık gelen bir yanıt üretilir. Sinir ağı başlangıçta mimarisine bağlı olarak bir çıktı üretir ve her bir geri beslemeden gelen hata sinyaline göre kendisini ayarlayarak çevre hakkındaki bilgiyi öğrenmeye başlar. Hata değeri, öğretmen tarafından belirlenen hedeflenen yanıt ile sinir ağı tarafından verilen yanıt arasındaki bir karşılaştırmanın sonucundan üretilir (Tettamanzi ve Tomassini, 2001). Bu hata düzeltme işlemi bir tür öğrenme kuralı ile yapılır. Eğitim sırasında aşırı öğrenme meydana gelebilir ve sinir ağının genelleme yeteneğine zarar verebilir (Lawrence ve Giles, 2000). Genelleme gücünün kaybı, sinir ağının tahmin kabiliyeti üzerinde olumsuz bir etkiye sahiptir. Aşırı öğrenmeyi önlemek için, belirli bir durdurma kriteri karşılandığında sinir ağının eğitimi durdurulur (Hu, 2002).

2.6.2. Denetimsiz (Unsupervised) Öğrenme

Denetlenen bir sinir ağının aksine, denetimsiz bir sinir ağı bir "öğretmen olmadan öğrenme" kavramı ile tanımlanabilir (Schmidhuber, 2019). Bu tip sinir ağları bir eğitmenin varlığını gerektirmez. Bu nedenle ağ bir yanıt üretmez. Denetimsiz öğrenme, "kendi kendine organize" bir şekilde gerçekleşir (Tettamanzi ve Tomassini, 2001). Eğitim süreci boyunca, sinir ağı çevreden girdileri alır ve bu gelen örüntüleri kategorilere ayırmayı öğrenir. Daha sonra ağa yeni bir girdi verildiğinde, sinir ağı bu yeni girdiyi bir çıktı ile ilgili bir grupta sınıflandırır. Karşılık gelen bir sınıf bulunmazsa, yeni girdi vektörü için farklı bir sınıf oluşturur. İstatistiksel olarak ifade edilecek olursa, denetimsiz bir sinir ağı kümeleme analizine benzer şekilde çalışır (Hu, 2002).

2.6.3. Takviyeli (Reinforcement) Öğrenme

İnsanlar, somut bir eğitim verisi yoluyla öğrenmezler. İnsanlarda öğrenme, kararların alındığı sürekli bir deneyim odaklı süreçtir ve çevreden alınan ödül ya da ceza, gelecekte alınacak kararlarda öğrenme sürecine reh-

berlik etmek için kullanılır (Skinner, 1938). Davranışçı öğrenme kuramına göre organizmanın davranışını; çevreden ortama gelen bir ödül (olumlu pekiştirme) veya istenmeyen bir durumun ortamdan çekilmesi (olumsuz pekiştirme) takip ederse, organizma o davranışı öğrenme eğilimine girer. Böylece pekiştireç beklentisiyle aynı davranışı tekrar etmeye başlar. Ancak ilerleyen adımlarda organizma pekiştireç alamazsa davranış söner. Edimsel koşullanma olarak da bilinen bu kuram, insan ve hayvanlardaki psikomotor davranışların çoğunu açıklamaktadır (Cüceloğlu, 2000). Başka bir deyişle zeki varlıklarda öğrenme, ödül güdümlü deneme yanılma yöntemidir. Ayrıca, insan zekâsı ve içgüdüsünün çoğu, milyonlarca yıl boyunca evrim olarak adlandırılan başka bir çevre odaklı süreçle evrimleşen genetikte kodlanmıştır. Bu nedenle, biyolojik zekanın neredeyse tamamı, çevre ile etkileşimli bir deneme yanılma sürecinden kaynaklanmaktadır ve bu nedenle tüm biyolojik zekâ bu gerçeğe atfedilebilir. Yapay zekanın amacı da biyolojik zekayı simüle etmek olduğundan, son derece karmaşık öğrenme algoritmalarının tasarımını basitleştirmede biyolojik başarılardan ilham almak doğaldır. Bir sistemin, ödüllendirici sonuçlar elde etmek için karmaşık bir ortamla etkileşime girmeyi öğrendiği, ödül odaklı deneme yanılma sürecine, makine öğrenimi terminolojisinde takviyeli veya pekiştirici öğrenme denir. Takviyeli öğrenmede, deneme yanılma süreci, zaman içinde beklenen ödülleri en üst düzeye çıkarma ihtiyacı tarafından yönlendirilir. Takviyeli öğrenme, oyun oynama algoritmaları (Silver ve diğerleri, 2016), kendi kendini süren arabalar (Shalev-Shwartz ve diğerleri, 2016) ve hatta çevre ile etkileşime giren akıllı robotlar (Lin, 1993) gibi akıllı araçlar oluşturma arayışının bir kapısı olarak görülmektedir. Farklı bir deyişle takviyeli öğrenme, yapay zekanın genel formlarına geçiş için bir kapıdır (Aggarwal, 2018).

2.7. Eğitim Algoritmaları

YSA'nın eğitiminde kullanılan klasik öğrenme algoritmalarının çoğunun temelini daha önceki bölümlerde de bahsedilmiş olan Hebb, Hopfield, Delta ve Kohonen kuralları oluşturur. *Hebb kuralında*, matematiksel olarak aynı işaretli iki aktif nörondan biri bir başka nöronun çıktısını oluşturuyorsa nöronlar arasındaki ağırlık güçlendirilir. *Hopfield kuralı*, Hebb kuralı ile benzer olarak nöronlar arasındaki giriş ve çıkışların her ikisi de aktif veya pasifse aralarındaki ağırlık değerlerini öğrenme oranı kadar artırır veya

azaltır. *Delta kuralı*, bir nöronun verdiği çıktı değer ile hedef çıktı değer arasındaki farkı azaltma prensibiyle ortalama kare hatasını minimize ederek ağırlık değerlerini değiştirir (Akpınar, 2014). *Kohonen öğrenme kuralı ise*, doğadan ilham alınarak geliştirilen bir yöntemdir. Kohenen'e göre nöronlar öğrenmek için yarışırlar. Buna göre en yüksek çıktı değerine sahip olan nöron kazanacak ve ağırlıkları güncellenecektir (Elmas, 2016). Sinir ağlarının eğitimi için başka algoritmalar da olmasına rağmen, bu çalışmada çok katmanlı ileri beslemeli sinir ağları için en yaygın olarak kullanılan türeve dayalı yöntemler anlatılacaktır.

2.7.1. Geri Yayılım (Backpropagation) Algoritması

İlk çalışmaları Werbos (1974) ve Parker (1982) tarafından yapılan geri yayılım algoritması, Rumelhart ve diğerlerine (1986) kadar iyi bilinen bir yöntem değildi. Geri yayılım, ağın çıktıları ile istenen çıktı arasındaki farka dayalı olarak hataların hesaplandığı gözetimli bir öğrenme sürecidir (Öztürk, 2011). Geri yayılım öğrenimi, ağ ağırlıklarını hata işlevinin en hızlı şekilde azaldığı yönde günceller. Bu işleme, en dik iniş arama veya gradyan azalma yöntemi de denir (Arora, 2004). Gradyan vektörü veya en dik iniş yöntemi, kısıtsız optimizasyon problemleri için en basit, en eski ve en iyi bilinen nümerik yöntemdir (Cinemre, 2011). Cauchy tarafından 1847'de geliştirilen yöntemin felsefesi, $f(x)$ maliyet fonksiyonunun mevcut iterasyonda yerel olarak en hızlı şekilde azaldığı vektör yönünü bulmaktır (Taha, 2010). Gradyan azalma, birinci dereceden bir optimizasyon yöntemidir ve bir fonksiyonun minimum noktasını bulmak için belirlenen bir noktadan gradyanın negatif yönünde belirlenen bir oranda adımlar atılır. Başka bir deyişle, bir vadiye ulaşana kadar yokuş aşağı amaç fonksiyonunun yarattığı yüzeyin eğim yönü takip edilir (Ruder, 2017).

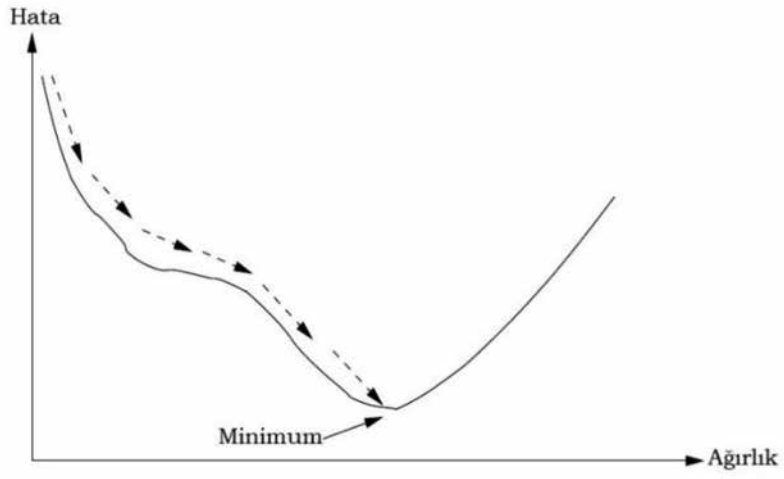

Şekil 2.7: Gradyan azalma algoritmasının gösterimi (Engelbrecht, 2007).

Geri yayılım algoritmasının temel adımları aşağıdaki gibi verilmiştir (Hu, 2002):

Adım 1: Ağa bir giriş vektörü verilir ve çıktı değerleri hesaplanır.

Adım 2: Hesaplanan çıktı değerleri hedef değerlerle karşılaştırılır ve farkı hesaplanır.

Adım 3: Hatayı azaltmak için her bir ağırlığın hangi yönde değiştirileceği belirlenir. Bu, her bir ağırlığa göre hata değerinin türevini alarak elde edilebilir.

Adım 4: Her bir ağırlığa uygulanacak güncellemenin büyüklüğü belirlenir.

Adım 5: Ayarlamalar ağırlıklara uygulanarak hata en aza indirilir.

Adım 6: Eğitim setindeki tüm vektörlerin hatası kabul edilebilir bir seviyeye düşene veya belirli bir durma kriteri karşılanıncaya kadar önceki tüm adımlar tüm eğitim setinde tekrarlanır.

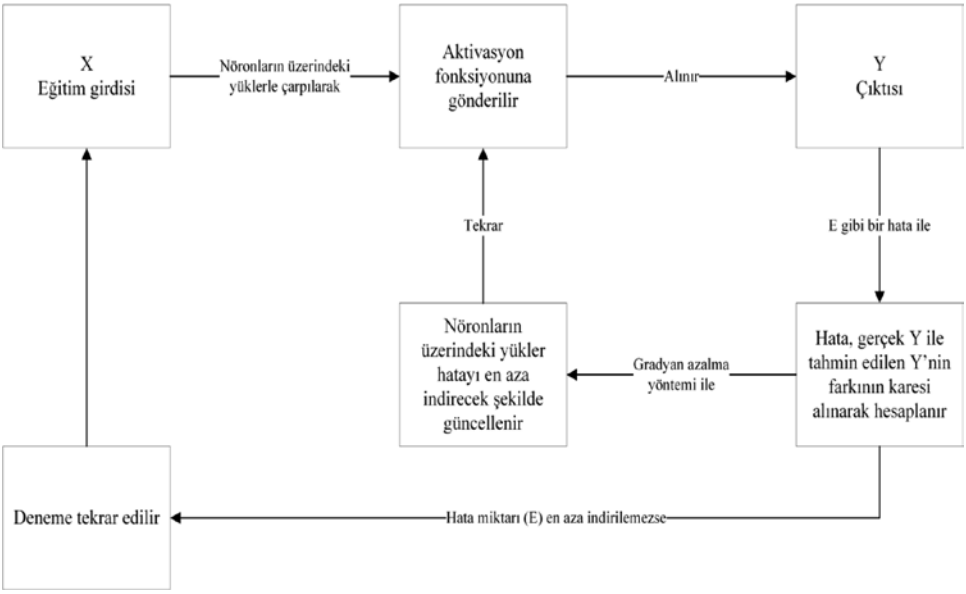

Şekil 2.8: Geri yayılım ile eğitim (Detienne ve diğerleri, 2003'ten esinlenilerek hazırlanmıştır).

Bir nöronun ağırlık değişimi, o nörondan gelen ağırlığın hata üzerindeki etkisiyle orantılıdır. Hata, ağdaki nöronun konumuna bağlıdır. Çıktı katmanındaki bir çıkış nöronu ve gizli katmandaki gizli bir nöron için hata değerleri farklı şekilde hesaplanır. Skansi (2018)'ye göre, aşağıdaki denklemlerde geri yayılım algoritmasının matematiksel formülleri çok katmanlı bir ağ yapısı üzerinden gösterilmiştir. h gizli katmanı, y_h nöronların ağırlıklarını, z_o aktivasyon fonksiyonundan geçirilerek elde edilen nöron değerini ve y_o da çıktı değerlerini gösterir. Denklemlerin olabildiğince açık gösterilebilmesi için her katmanda yalnız bir nöron varmış gibi iki indis kullanılmıştır.

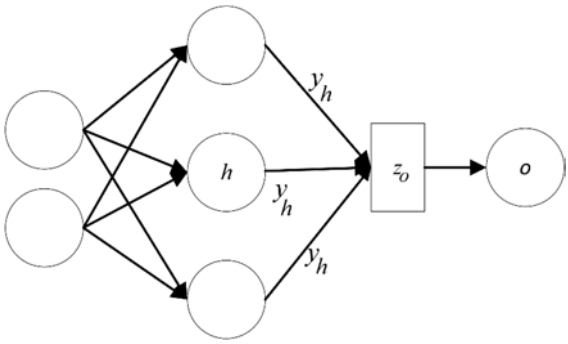

Şekil 2.9: Çok katmanlı bir YSA'nın yapısı.

Verilen bir ağ mimarisi, ağdaki ağırlıklar tarafından bir hata veya amaç fonksiyonu oluşturularak başlar (Qian, 1999). En küçük kareler yöntemi fonksiyonu aşağıdaki gibi oluşturulur (Skansi, 2018):

$$E = \frac{1}{2} \sum_{o \in \text{çıktı}} (t_o - y_o)^2$$

Yukarıdaki gösterimde sırasıyla y_o, eğitim kümesine ait o'nuncı gözlem değerine karşılık gelen girdi nöronunun tahmin değerini, t_o ise o'nuncı gözlem değerine karşılık gelen girdi nöronunun gerçek değerini verir. Hata fonksiyonu, doğrusal olmayan bir fonksiyondur ve minimum değere ulaşmak için her bir ağırlığın kısmi türevi alınmalıdır (Cura, 2004). Buna bağlı olarak geri yayılım değerlerini hesaplarken yapılması gereken ilk işlem denklemde verilen çıktı ile hedef değer arasındaki farkı bir hata türevine dönüştürmektir:

$$\frac{\partial E}{\partial_{y_o}} = -(t_0 - y_o)$$

y_o ile ilgili hata türevi, z_o ile ilgili bir hata türevine dönüştürülmelidir. Bunun için türevin zincir kuralı kullanılmalıdır. Zincir kuralının kullanılmasının sebebi, gizli katmanındaki çıktı değerlerinin bilinmemesidir. Bundan dolayı en küçük kareler yöntemi gizli katmanda kullanılamaz (Alpaydın, 2004):

$$\frac{\partial E}{\partial z_o} = \sum_o \frac{\partial_{y_o}}{\partial_{z_o}} . \frac{\partial E}{\partial_{y_o}} = y_o(1 - y_o) \frac{\partial E}{\partial_{y_o}}$$

y_h'ye göre hata türevi:

$$\frac{\partial E}{\partial y_h} = \sum_o \frac{\partial_{z_o}}{\partial_{y_h}} . \frac{\partial E}{\partial_{z_o}} = \sum_o w_{h_o} . \frac{\partial E}{\partial_{z_o}} = \sum_o w_{h_o} . \frac{\partial E}{\partial z_o}$$

$\frac{\partial E}{\partial_{y_o}}$ ile $\frac{\partial E}{\partial y_h}$ arasında yapılan adımlar, geri yayılımın kalbidir (Skansi, 2018). $\frac{\partial_{z_o}}{\partial_{y_h}} = w_{h_o}$ ağırlığını verecektir. Bu şekilde zincir kuralı kullanılarak hata geriye yayılmıştır. $\frac{\partial E}{\partial_{z_o}}$ değeri bilindiği için ağırlıklar ile ilgili hata türevleri aşağıdaki gibi hesaplanır:

$$\frac{\partial E}{\partial w_{h_o}} = \frac{\partial z_o}{\partial w_{h_o}} \cdot \frac{\partial E}{\partial_{z_o}} = y_i \frac{\partial E}{\partial z_j}$$

Son olarak ağırlıkları güncellemek için "genel ağırlık güncelleme kuralı" ile ağırlıklar ayarlanır:

$$w_i^{yeni} = w_i^{eski} + (-1)\eta \frac{\partial E}{w_i^{eski}}$$

η öğrenme oranını temsil eder. -1 çarpanı, *E* hata değerinin aza indirildiğine emin olmak için buradadır. Aksi takdirde, ilgili formül algoritmayı gradyan yönüne doğru götürecektir ki bu fonksiyonun çukur noktasına değil, tepe noktasına gittiğini gösterir. Bu eşitliğin indislerden arındırılmış hali ise aşağıdaki gibidir (Skansi, 2018):

$$w_{yeni} = w_{eski} - \eta \nabla E$$

Öğrenme oranı olan η, pozitif yönlü küçük bir sayıdır. η, yakınsamayı garanti etmek ve uygun öğrenme verimliliğini sağlamak için belirli bir aralıktan seçilmelidir. Yeterince düşük bir öğrenme oranı, hata fonksiyonunu en aza indiren ağırlık değerlerini bulacaktır (Rumelhart ve diğerleri, 1986). Öğrenme oranı çok yüksek ayarlanırsa, ağın hata fonksiyonu iyileşmeye devam etmeden hızlı bir şekilde değişecektir. Öte yandan öğrenme oranı çok küçük olduğunda, bir sinir ağının eğitimi daha fazla zaman alacaktır veya hata yüzeyinde yerel minimuma kolayca takılacaktır. İdeal bir öğrenme oranı, öğrenmeyi hızlandıracak ve gradyan aramasının hata fonksiyonunda global minimumu bulmasına izin verecek olan oran olmalıdır (Hu, 2002). Arama rastgele bir başlangıç noktasından başlar ve yeni çözüm noktasında en dik iniş yönü tekrar hesaplanır. Hata fonksiyonu yüzeyinde minimum değere ulaşılıncaya kadar algoritma tüm iterasyonlarda tekrar edilir (Arora, 2004).

2.8. Eğitimde Dikkat Edilecek Hususlar

Çok katmanlı bir sinir ağının eğitilmesinde ağın performansını etkileyecek konularda karşılaşılan sorunlar ile ilgili aşağıdaki soruların cevaplanması çalışılacaktır:

- Ağırlıklar nasıl başlatılır ve ağırlık değerlerinin güncellenmesi nasıl gerçekleşir?
- İleri beslemeli bir ağ oluşturmak için kaç gizli katman olmalı ve her bir gizli katmanda kaç nöron kullanılmalıdır?
- Ağın başarılı bir şekilde öğrendiği nasıl anlaşılır?

2.8.1. Ağırlıkların Belirlenmesi

Eğitim genellikle rastgele seçilen başlangıç ağırlık değerleri ile başlar. Tipik olarak, seçilen ağırlıklar -1.0 ve 1.0 veya -0.5 ila 0.5 arasında olacak şekilde küçük değerlerdir. Çünkü daha büyük ağırlık büyüklükleri, katman düğümlerinin çıkışını doygunluğa çekebilir. Bu durum daha büyük miktarlarda eğitim süresi gerektirebilir. Bununla birlikte zayıf başlatılmış ağırlıklar da daha yavaş bir eğitime yol açabilir veya daha hızlı bir eğitime ihtiyaç duyan bir ağın, yerel minimuma takılma riskini artırarak iyi bir performans elde etmesini engelleyebilir (Bengio, 2012).

2.8.2. Ağırlıkların Güncellenme Sıklığı

Mehrotra ve diğerlerine (1996) göre, yapılan ağ güncellemeleri için genel olarak iki farklı yaklaşım olduğu söylenebilir:

1. *Örnek başına (patern based) öğrenme*: Bu öğrenme kuralında ağırlıklar her örnek sunumundan sonra değiştirilir. Öncelikle ağa ilk örnek gösterilir ve ardından ağın verdiği çıktı ile hedef çıktı arasındaki fark hesaplanarak hata değeri dağıtılır. Bu kural ikinci örneğin de hatasının dağıtılmasıyla devam eder. Tüm örneklerin ağa sunularak ve ağırlıkların güncellenmesiyle sona erer (Öztemel, 2003).

2. *Tüm örnek seti verildiğinde (epoch based)*: Burada ise ağırlıklar ancak tüm örnekler ağa verildiğinde güncellenir. Bir devir (epoch) tüm eğitim setinin sunumundan oluşur. Farklı eğitim örnekleri tarafından önerilen ağırlık değişiklikleri, her dönemin sonunda meydana gelecek tek bir değişiklik olacak şekilde bir araya getirilir (Öztemel, 2003).

Her iki yöntem de eğitime makul derecede düşük bir hata elde edilene kadar veya eğitim için ayrılan maksimum yineleme sayısına ulaşana kadar devam edilir.

2.8.3. Ağ Boyutu

Çok katmanlı bir sinir ağında gizli katman ve katmanlarda bulunan nöron sayısı hakkında söylenmesi gereken ilk şey, bunun problemin türüne göre değişeceği ve uygun sayıyı karar vericinin belirleyeceğidir (Öztemel, 2003). Çoğu problemin çözümü için üç katmanlı bir sinir ağı yeterlidir. Gizli katman sayısının da ikiden fazla olmasının eğitim süresini ve aşırı uyum riskini arttıracağı söylenebilir (Hu, 2002). Bununla beraber eğitimde geri yayılım algoritması kullanılıyorsa, gizli katmanlarda bulunan nöron ve ağırlık sayısının artırılmasının global minimumun bulunmasını kolaylaştırdığı gösterilmiştir (Lawrence ve diğerleri, 1998). Ayrıca, ağa verilecek girdi sayısının girdi katmanında bulunan düğüm sayısını ve hiyerarşik olarak çıktı katmanında bulunan çıktıların düğüm sayısını etkileyeceği unutulmamalıdır (Akpınar, 2014).

2.8.4. Ağın Performansı

Makine öğreniminin ana odağı model performansıdır ve yukarıda incelenen yaklaşımlar her ne kadar bir sinir ağının performansında önemli bir yer tutsalar da uyumun iyiliği incelenmeden bu yaklaşımlar teorik olarak eksik kalacaklardır (Liu ve diğerleri, 2008). Bir algoritmanın performansındaki küçük ancak önemli değişimleri güvenle tanımlayamadan modelin tahminleme gücünü geliştirmek ne yazık ki mümkün değildir. Model performansının doğru tahmin edilmesi, modeller arasında seçim yapmak çok önemlidir (Moss ve diğerleri, 2018). Model performansına etki eden faktörlerden birisi eğitimin ne kadar süreceğidir.

Eğitim yinelemelerinin (epoch) sayısını belirlemek, eğitimin ne zaman durdurulması gerektiğini sormak demektir. Kaastra ve Boyd'a (1996) göre, bu soruyu cevaplamaya yardımcı olacak iki yaklaşım vardır:

1. Hata yakınsaması ile durma.

2. Eğitim- test kesintileri ile durma.

İlk yaklaşımı benimseyen bir araştırmacı eğitimi ancak hata yakınsama durumuna ulaşana kadar devam ettirmelidir. İkinci yaklaşım, araştırmacının eğitim sırasında bir dizi eğitim-test kesintisi yapmasını gerektirir (Mendel-

sohn, 1993). Ağın eğitimi, önceden tanımlanmış sayıda yinelemenin ardından kesilir ve ağ, test kümesindeki genelleme yeteneğine göre değerlendirilir. Değerlendirme tatmin edici değilse eğitim süreci her kesintiden sonra devam eder ve değerlendirme kriteri karşılanırsa durdurulur. Fakat belirtilen her iki yaklaşım da bir yakınsama durumu garanti edemez. Bu, eğitim sırasında değerlendirmeye bağlı olmanın, ağın aşırı uyum nedeniyle genelleme yeteneğinde bir azalmaya neden olabileceği anlamına gelir.

Makine öğrenmesi algoritmalarında performansın düşük olmasının en büyük iki nedeni ise yetersiz uyum (underfitting) ve aşırı uyumdur (overfitting).

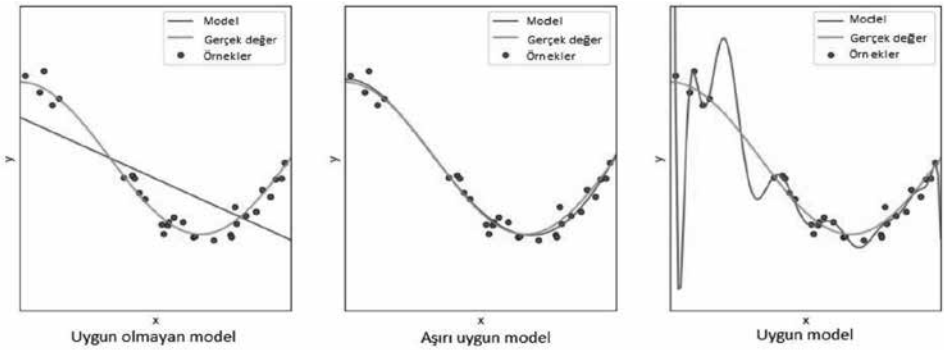

Şekil 2.10: Örnek bir polinom eğrisi (Scikit-learn, 2022).

Bu iki etken ağın genelleme yeteneğine zarar verir. Genelleme, bir sinir ağının eğitim sırasında model tarafından görülmeyen spesifik örnekler verildiğinde, ağın kavramları ne kadar iyi öğrendiğidir (Brownlee, 2016). Genelleme, eğitim tamamlandıktan sonra ağın gerçek problem üzerinde ne kadar iyi performans gösterdiğinin bir ölçüsüdür. Yani sinir ağının yeni verilere tepki verme yeteneğidir. Genelleme yeteneği, eğitilen bir ağın daha önce hiç görmediği verilerle aynı sınıftan verileri sınıflandırabileceği anlamına gelir ve eğitim seti dışındaki yeni veriler üzerinde ağın performansı değerlendirilerek test edilir. Genelleme yeteneği en çok, verideki örneklerinin sayısı ve örneklerin problemi ne kadar iyi temsil ettikleri, problemin karmaşıklığı ve ağ boyutu olmak üzere üç parametreden etkilenir (Hush ve Horne, 1993). Genelleme ise, aşırı uyum ile bozulur ve bu da tahminlerde önemli bir sapmaya yol açar (Karystinos ve Pados, 2000). Aşırı uyum, ite-

rasyon veya parametre sayısının çok fazla olduğu durumlarda öğrenmeyi sürdürerek modelin ezberlemeye başlamasıdır (Alpaydın, 2004). Bu noktada ağ iyileşiyor gibi görünse de eğitim setindeki hata, eğitim sırasında bir noktaya kadar azalmaktadır. Sonrasında tekrar kötüleşmeye başlar, yani daha önce görülmeyen örneklerde hata artar.

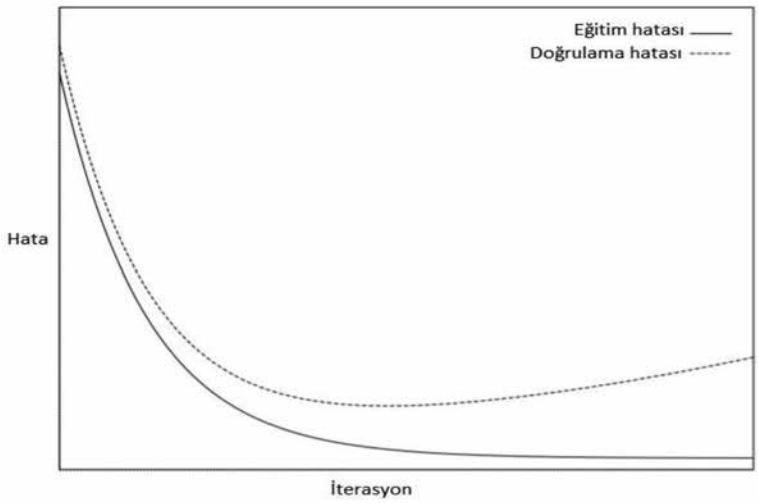

Şekil 2.11: Örnek başına hatanın zaman içindeki değişimi (Prechelt, 1998).

Prechelt (1998)'e göre, temel olarak aşırı uygunluğu engellemenin iki yolu vardır:

- Ağ boyutunu azaltmak: Parametre sayısını azaltmaya yönelik teknikler kullanılır.
- Erken durdurma: Bir sinir ağının denetimli eğitimi sırasında aşırı uyumun ne zaman başladığını tespit etmek için çapraz doğrulama (cross validation) uygulanır ve daha sonra aşırı uyumu önlemek için eğitim yakınsamadan önce durdurulur.

Yukarıda yer alan öneriler kullanılarak YSA'nın tahmin başarısının artırılması amaçlanır.

ÜÇÜNCÜ BÖLÜM

UYGULAMA

Bu bölümde uygulamaya yer verilmiştir. Araştırmanın problemi, amacı, önemi, kapsamı ve metodolojisi açıklanmış ve bulgular detaylı bir şekilde tartışılmıştır.

3.1. Araştırmanın Problemi

Küreselleşme ile pazardaki rekabetin artması, işletmeleri yönetim yaklaşımlarını değiştirmeye zorlamaktadır. Bu doğrultuda işletmeler, ürettikleri ürün veya hizmetleri daha etkin ve verimli bir şekilde üretmek maksadıyla temel yeteneklerine odaklanırlar (Özutku, 2002). Böylece temel yetenekleri dışında kalan faaliyetleri dış kaynaklara aktararak tedarikçilere yaptırır. Dış kaynak kullanım stratejisi, işletmelerin en iyi yaptıkları faaliyetlere odaklanarak ve tedarikçinin yeteneklerinden faydalanarak iç kaynaklardaki getirilerini en üst düzeye çıkarmalarına olanak tanır (Rezaei ve Ortt, 2013). Gittikçe büyüyen dış kaynak kullanma eğilimi, bir işletmenin satın alma sürecinin başarısında oldukça önemli bir rol oynamaktadır. Öyle ki tedarikçilerin bir işletmenin maliyetlerini düşürme ve karlılığını yükseltmesinde doğrudan etkisi vardır. Bu nedenle işletmeler gelirlerinin önemli bir yüzdesini tedarik için harcamak zorundadır (Goffin ve diğerleri, 1997). İşletmelerin birçoğunda dış kaynak kullanım maliyeti, toplam maliyetin büyük bir payını oluşturur. Çoğu durumda toplam maliyet içindeki dış kaynak maliyeti %70'e kadar çıkabilmektedir (Spekman ve diğerleri, 1994). Tedarik maliyetlerinin bu denli yüksek olması işletmeleri tedarik zinciri süreçlerini optimize etmeye yönlendirmektedir. Satın alma maliyetlerinde yapılacak %1 oranındaki bir azalış, satışlarda %10'a varan bir artışa neden olabilir (Sandelands, 1994). Bu nedenle tedarikçi yönetimi, işletmelerin hayatta kalmaları için elzemdir. Bu bağlamdan hareketle tedarikçi seçme ve değerlendirme sürecinin amacı, işletme için optimal faydayı sağlayacak tedarikçileri belirlemektir (Yangınlar, 2018). Bu süreç kapsamında, odak

işletmenin portföyünde bulunan tedarikçiler periyodik olarak seçme ve değerlendirme işlemine tabi tutulur. Sürecin sonunda tedarikçilerle sözleşme feshi veya uzun vadeli ortaklık kurma konusunda bir karar verilerek satın alma riski minimuma indirilir.

Bu araştırmada, tedarikçi seçme ve değerlendirme probleminin çözümü için portföy yaklaşımı kullanılmıştır. Tedarikçi portföy yaklaşımı, "herkese uyan tek bir beden" stratejisini kullanmak yerine (Krause, 1997), alıcı-tedarikçi ilişkisini yönetmek için daha stratejik bir yaklaşım sunmaktadır. Bu bağlamdan hareketle, satın alma sürecini iyileştirmek için ürün grupları arasındaki benzerliklere göre bir tedarikçi segmentasyonu yapılarak tedarikçi gruplarına göre özelleştirilmiş satın alma stratejileri oluşturulur.

Açıklanan hedeflere ulaşmak için, "odak firma tedarikçi ilişkilerini nasıl yönetmelidir?" sorusuna cevap aranacaktır. Ana soruya bir yanıt üretmek için ise bazı alt problem cümleleri aşağıdaki gibi ifade edilmiştir:

P1: Yeni bir tedarikçinin hangi segmentte yer alacağına nasıl karar verilir?

P2: Tedarikçi değerlendirme otonom strateji ataması nasıl gerçekleştirilir?

3.2. Araştırmanın Amacı ve Önemi

Bu araştırmanın amacı, Kraljic'in kavramsal portföy yönetimi yaklaşımına dayanarak vaka çalışmasındaki işletme için tedarikçi ilişkileri yönetiminde otonom bir karar destek sistemi modeli geliştirmektir. Farklı bir ifadeyle, söz konusu karar destek sistemi modeli, odak firmanın tedarikçilerini satın aldığı ürünler üzerinden segmentlere ayırarak her bir segment için Kraljic'in karar matrisinde yer alan yanıt stratejilerini atamaktadır.

Geliştirilen modelin bir tedarikçiyle iş birliğini genişletme veya sona erdirme konusundaki karar verme sürecini basitleştireceği düşünülmektedir. Böylelikle kullanılan kavramsal model, gerçek bir dünya probleminin çözümüyle doğrulanacaktır. Segmentasyon işleminde temel kriter, maliyet ve arz riskidir.

3.3. Araştırmanın Kapsamı

Bu çalışma, Tekirdağ bölgesinde faaliyet gösteren Akın Raşel San. Tic. A.Ş. isimli bir tekstil firmasında bir vaka çalışması olarak yürütülmüştür. Odak firma, 300 çalışana ve aylık 1000 tonluk bir üretim kapasitesine sahip olup; ihracat yapan işletmeler için dokuma kumaşların örme ve boyama işlemlerini yapmaktadır.

Eski çağlardan bu yana varlığını devam ettiren ve sanayi devrimi ile beraber seri üretime geçen tekstil sektörü, doğada bulunan elyafın işlenerek ipliğe, kumaşa ve hazır konfeksiyon ürününe dönüştürüldüğü bir iş koludur (Uyanık ve Çelikel, 2019). Tekstil sektörünün Gayri Safi Yurtiçi Hasıla (GSYH) ve ihracat kalemleri içindeki payı, ürettiği katma değer ve yarattığı istihdamla Türkiye'nin lokomotif sektörünü oluşturmaktadır (Uyanık ve Çelikel, 2019). Dolayısıyla tekstil sektörünün ülkenin ihracat verileri üzerinde doğrudan etkili olduğunu söylenebilir. Bu doğrultuda, Sanayi ve Teknoloji Bakanlığı Kalkınma Ajansları Genel Müdürlüğünün (2021) yayınladığı rapora göre, tekstil sektöründe Covid-19 salgını öncesi üretim kapasitesi %83.4 iken salgının şiddetlendiği dönemde %48.6 oranına düştüğü gözlenmiştir. Buna bağlı olarak rapora göre, salgın döneminde tekstil sektöründeki işletmeleri en çok zorlayan darboğazlardan birinin hammadde ve tekstil kimyasalları gibi bileşenlerin tedarik kesintileri olduğu saptanmıştır. Gerek salgının dünyada en çok etkilediği sektörlerden biri olması gerek salgın öncesinde de devam eden sorunlar, sektördeki daralmayı perçinlemiştir. Hammadde tedarikinde yaşanan kesintiler, makinelerde dışa bağımlılık yaşanması, kaynakların kullanımının verimsiz oluşu, Endüstri 4.0 sürecinde geç kalınması gibi sebepler tekstil sektörü için birtakım stratejilerin oluşturulmasını gerekli kılmıştır (Sanayi ve Teknoloji Bakanlığı Kalkınma Ajansları Genel Müdürlüğü, 2021).

Bu araştırma, adı geçen raporda önerilen stratejilerden "dijitalleşme alt yapısının desteklenmesi" maddesi üzerinde durarak tekstil sektöründe faaliyet gösteren bir işletmenin tedarik zinciri süreçleri için bir yapay zeka çözümü sunmaktadır. Bu doğrultuda araştırmada, odak firmanın ERP sisteminden elde edilen detaylı stok envanter raporları kullanılmıştır. Odak firmanın envanter kalemleri boyalar, tekstil kimyasalları ve sarf malzemeleri başlıkları altında üç sınıf girdi çeşidinden oluşmaktadır. ERP sisteminden

elde edilen veriler envanterde satın alınan ürünlerin tedarikçi bilgilerini, ürün çeşidini, birim fiyatlarını, stok ve sarf miktarlarını içermektedir. Odak firmadan elde edilen ham veriler kullanılarak Kraljic'in portfolyo modelinde bulunan finansal etki ve arz riski değişkenleri keşfedilerek veri nihai kullanıma hazır hale getirilmiştir.

3.4. Araştırmanın Yöntemi

Tedarik portföy yönetiminde önemli bir yere sahip olan Kraljic matrisi, tedarikçilerin yer alacağı segmentleri ve segmentlerin kriterlerini kavramsal olarak tanımlamakta ancak matematiksel bir teknik önermemektedir. Bu çalışma, Kraljic matrisini matematiksel bir zemine oturtarak pratik uygulamalarda kullanılır hale getirmiştir.

Araştırma metodolojisinde kullanılan makine öğrenmesi yaklaşımlarında karma bir yöntem uygulanması benimsenmiştir. Uygulamada, vaka çalışmasındaki işletmenin bilgi sisteminde bulunan detaylı stok envanter verileri kullanılmıştır. Satın alma portföy modeli geliştirmek için öncelikle k-ortalamalar kümeleme analizi yöntemi uygulanmıştır. Kümeleme analizi yapılmasının amacı, işletmenin envanter kalemlerinin sınıf etiketlerini belirleyerek yapay sinir ağlarının tahmin etmesi beklenen gerçek sınıf verilerini oluşturmaktır. YSA, tahmin ettiği değerler ile kümeleme analizinden elde edilen gerçek sınıf değerlerini kıyaslayarak üretilen hata değerini minimuma indirecek şekilde ağırlık değerlerini güncelleyecektir. Böylelikle araştırmanın metodolojisinde, denetimsiz öğrenme modelinden denetimli öğrenme modeline geçiş yapılmıştır. Yapılan kümeleme analizinin ışığında, yapay sinir ağları kullanılarak Kraljic matrisinde anlatılan farklı satın alma sınıflarına dayalı bir tedarikçi değerlendirme modeli geliştirilmesi amaçlanmıştır.

Bu araştırmada kurgulanan yapay sinir ağı, stokastik gradyan azalma algoritması ile eğitilmiş ve bir sınıflandırma problemi üzerinde çalıştırılmıştır. Şekil 3.1'de bu araştırma boyunca izlenen adımların akış şeması yer almaktadır. Bu şemada da görüldüğü üzere araştırmanın akışı üç aşamadan ve on bir adımdan oluşmaktadır. Bu aşamalar; veri ön işleme, tedarikçi segmentasyonunun gerçekleştirildiği ve YSA'nın kurgulandığı model geliştirme ve YSA'ndan elde edilen sonuçların değerlendirilerek stratejilerin atandığı model uygulama aşamalarıdır. İlerleyen bölümlerde bu aşamalarda hangi adımların olduğu ve bu adımlarda hangi işlemlerin yapıldığı anlatılmaktadır.

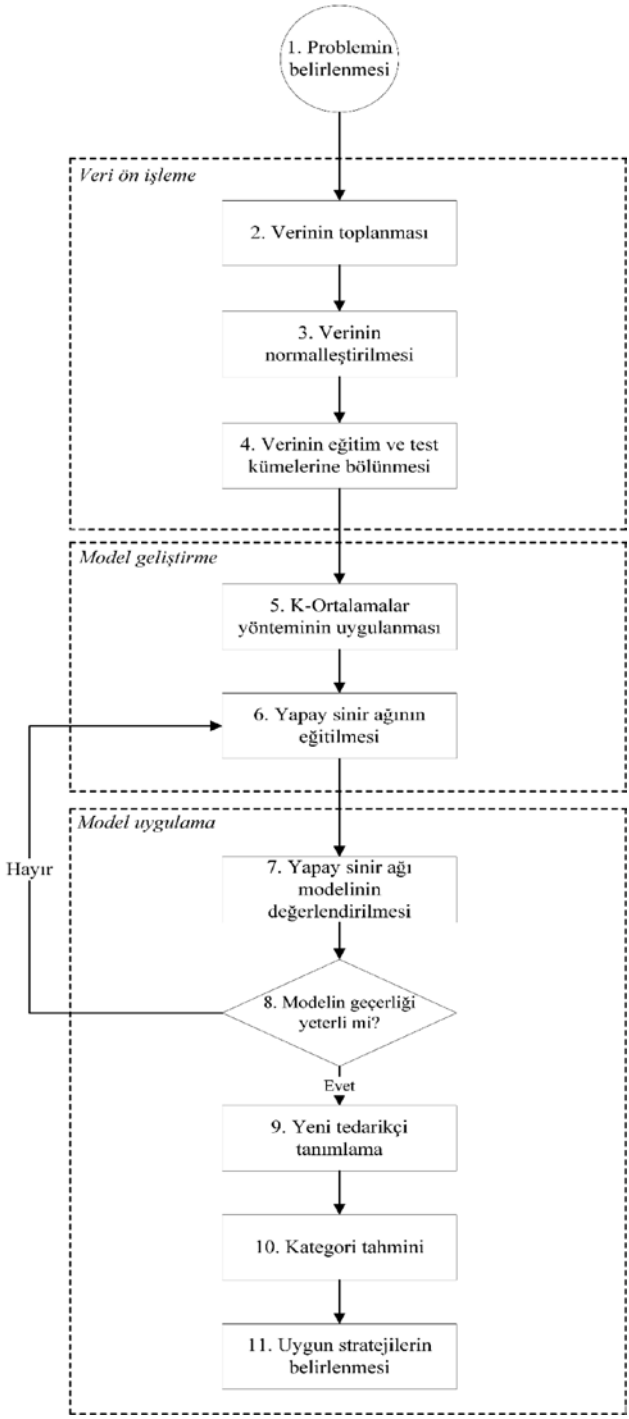

Şekil 3.1: Araştırmanın akış şeması.

3.4.1. Veri Ön İşleme

Veri ön işleme, toplanan verilerin analize hazır hale getirilmesi için yapılan işlemleri içeren bir süreçtir (Akpınar, 2014). Bu süreç, verilerin dağınıklığına ve büyüklüğüne bağlı olarak oldukça uzun bir zaman alabilmektedir. Veri hazırlama süreci, sinir ağının öğrenimi ile ilgili olarak araştırmacıların, verilerin nasıl temsil edileceği, hangi kavramların öğrenileceği ve veri analizi sonuçlarının nasıl sunulacağı konusunda karar almalarına olanak sağlayarak verilerin gerçek dünyada kullanılmasını çok daha kolay hale getirir. Veri ön işlemede yapılan işlemlerin başarısı, sonraki analizlerin geçerlik ve güvenirliği üzerinde önemli etkilere sahiptir. Başarısızlık ise özünde ölçümlere karışan hata miktarının çokluğu anlamına gelmektedir. Ölçme sonuçlarına karışacak tesadüfi hatalar sonuçların güvenirliğini, sistematik hatalar ise doğrudan sonuçların geçerliğini düşürebilmektedir.

Veri ön işleme aşaması, verilerin toplanmasından sonra başlar ve kullanılacak verilerin seçilmesi, bağımsız değişkenlerin belirlenmesi, verinin temizlenmesi, standartlaştırılması ve veri setinin bölünmesi aşamaları ile devam eder. Ön sürece ait hazırlığın tamamlanmasının ardından analiz ve öğrenim başlar.

3.4.1.1. Verinin Dönüştürülmesi

Verilerin analize hazırlanması adımında verilerin dönüştürülmesi işlemi gerçekleştirilmiştir. Veri dönüştürme, verinin kullanılan yöntemlerle daha uyumlu olması ve daha sağlıklı çıktıların alınabilmesi için, belirlenen bir fonksiyona göre farklı bir ölçeğe dönüştürülmesi demektir (Akpınar, 2014). Bu işlemlerden birisi de verinin standardize edilmesidir.

Verilerin standardize edilmesi, veri setindeki değişkenlerin aynı ölçeğe indirgenmesi işlemidir. Veri dönüştürmenin ana amacı, herhangi bir öğrenme algoritmasını besleyebilecek yüksek kalitede veri üretmektir (Aksu ve diğerleri, 2019). Böylelikle yapay sinir ağındaki yanlılığın en aza inmesi beklenir.

Bu araştırmada en çok kullanılan standartlaştırma yöntemlerinden biri olan z skoruna dönüştürme yöntemi kullanılmış olup aşağıdaki gibi formü-

lize edilmiştir. Z skoru ile standartlaştırma süreci, her bir örnek değerinin ortalama ile farkının alınıp standart sapmaya bölünmesidir.

$$z = \frac{x - \mu}{\sigma}$$

3.4.1.2. Verinin Bölünmesi

Veri setinin standartlaştırılması ve analize hazır hale getirilmesi, ölçümlere karışabilecek tesadüfi hatalardan arınmayı sağlamaktadır. Bu ise kurulan modelin güvenirliğini sağlamayı amaçlamaktadır. Bir sonraki aşamada ise modelin geçerliğinin test edilmesi gelmektedir. Kurulan model tahmin yapma amacı güttüğünden geçerlik testi de modelin yeni karşılaşılan durumlar için yordama yapabilme gücünün ölçülmesine dayanmalıdır.

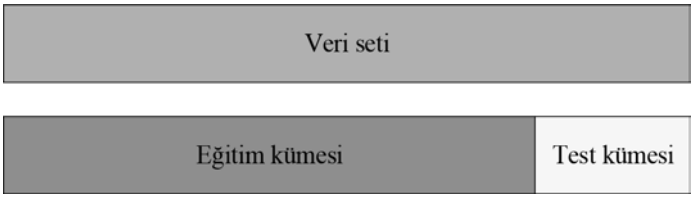

Şekil 3.2: Veri setinin eğitim ve test kümelerine bölünmesi.

Modelin yordama geçerliğini test edebilmek için ise şekil 3.2'de görüldüğü gibi veri seti eğitim kümesi ve test kümesi olacak şekilde iki kümeye bölünür. Bölme işleminde literatürde kabul gören sabit bir oran bulunmamaktadır. Ancak eğitim kümesi/test kümesi oranının pratikte 0.80/0.20 gibi; 0.75/0.25 gibi; ya da 0.66/0.33 gibi uygulandığı söylenebilir. Veri setinin eğitim ve test kümelerine bölünmesi işleminden sonra modelin eğitilmesi aşamasına geçilir.

3.4.2. Model Geliştirme

Özellikle firmaların çok sayıda tedarikçisi olduğunda, tüm ilişkileri tek tek yönetmek zordur. Bu nedenle tedarikçi ilişkileri yönetiminde firmalar farklı tedarikçi grupları için işletmeler arasında stratejiler geliştirirler (Wagner ve Johnson, 2004). Tedarikçi segmentasyonu, tedarikçi seçimi ve tedarikçi ilişkileri yönetimi arasında bir adım olarak, benzerliklerine göre farklı tedarikçi grupları üretir (Rezaei ve Ortt, 2013). Buna göre, işletmeler alıcı ve satıcının amaçlarını kolaylaştıracak şekilde ve maliyet-fayda dengesi-

ni korumak amacıyla, benzer birtakım özelliklere göre periyodik olarak alt gruplar halinde inceleme ve gruplandırma işlemine tabi tutulur (Mitchell ve Wilson, 1998).

Bu araştırmada, benzer özellik gösteren tedarikçileri bir araya getirme ve farklı özellik gösteren tedarikçilerin ayrıştırılması işlemi kümeleme algoritmalarından k-ortalamalar yöntemi ile gerçekleştirilmiştir. Kraljic matrisinin finansal risk ve arz riski boyutlarından oluştuğu göz önüne alınarak envanter kalemleri, dört farklı gruba ayrılmıştır. Böylelikle Kraljic matrisinde yer alan dört sınıf ürün grubunun kümeleri belirlenmiştir. Bir sonraki aşamada yapay sinir ağı modeli, ürün sınıflarını tahmin etmek üzere eğitilmiştir.

Bir modelin eğitilmesi, verilen bir bağımsız değişken değerine göre bağımlı değişkenin alacağı değeri tahmin eden fonksiyonu belirlemek anlamına gelmektedir. Örneğin, $y = \beta_0 + \beta_1 x + \varepsilon$ gibi bir basit doğrusal regresyon probleminde tahminci olarak en küçük kareler doğrusunun kullanıldığını düşünelim. $i = 1, ..., n$ olmak üzere yeni karşılaşılan x_i durumlara karşı $\hat{y}_i$ tahminlerini yapabilmek için tahmin doğrusunun dikey koordinat eksenini kestiği β_0 noktası ile doğrunun eğim bilgisini veren β_1 katsayısının ε hata terimini minimize edecek şekilde optimize edilmesi gerekmektedir. Modelin eğitilmesi aşamasında analitik veya nümerik yaklaşımlarla bu parametreler belirlenir. Böylece gelecekte yeni durumlarla karşılaşıldığında regresyon denklemi yeni tahminler üretir.

Görüldüğü gibi eğitim kavramı aslında model parametrelerinin toplam hata değeri olan $\sum_i \varepsilon_i$'yi en küçükleyecek şekilde optimizasyonu anlamına gelmektedir. Bu durum diğer makine öğrenmesi algoritmalarında olduğu gibi yapay sinir ağında da geçerlidir. Ancak bu sefer optimize edilen parametreler beta değerleri değil, ağırlık değerleri, kullanılan eğitim algoritmasının hiper parametre değerleri, her bir katmandaki gizli nöron sayısı gibi parametrelerdir.

Bu araştırmada da ağın eğitilmesi için türev tabanlı yöntemlerden gradyan azalma algoritması kullanılmıştır. Gradyan azalma algoritması, amaç fonksiyonunun birinci dereceden türevini alarak eğim yönünde hata değerini düşürmeye çalışır. Bu çalışmada eğitim sürecinde, ağa veriler gözlem

başına verildiği için stokastik gradyan azalma yöntemi kullanılmıştır. Gradyan azalma algoritmasına ait hiper parametre değerlerinden öğrenme oranı 0.1 ve durdurma koşulu olarak maksimum iterasyon sayısı 200 olarak belirlenmiştir.

Ağ mimarisinde girdi katmanı, gizli katman ve çıktı katmanından oluşmak üzere çok katmanlı bir sinir ağı yapısı kullanılmıştır. Girdi katmanı ve çıktı katmanı ele alınan problemin yapısına bağlıdır. Girdi katmanında bulunan nöron sayısı seçilen verilerdeki bağımsız değişken sayısına göre ayarlanırken çıktı katmanındaki nöron sayısı verilerdeki sınıf sayısına göre belirlenmiştir. Gizli katmanda bulunan nöron sayıları ise seçilen problemler için literatürde tavsiye edilen değerler kullanılmıştır. Bunun yanında, aktivasyon fonksiyonları içinden sigmoid fonksiyonu uygulanmıştır. Tüm ağırlıklar için alt ve üst değer sınırı [-1, 1] olarak belirlenmiştir. Başlangıç ağırlıkları rassal olarak bu aralıkta seçilmiştir. Kullanılan veri setinin özellikleri ve oluşturulan YSA mimarisi aşağıda verildiği gibidir:

Parametreler	Değerler
Öznitelik	3
Sınıf	4
Eğitim Verisi	147
Test Verisi	49
Girdi Katmanı	3
Gizli Katman	9
Çıktı Katmanı	4
Öğrenme Oranı	0.1
Aktivasyon Fonksiyonu	Sigmoid Fonksiyonu
Durma Koşulu	200

Tablo 3.1: YSA'da kullanılan parametreler.

Peki, optimize edilen parametre değerleri modelin geçerliğine ikna olabilmemiz için yeter şartı sağlar mı? Şüphesiz makine öğrenmesi algoritmalarının amaçları matematiksel olarak estetik özelliklere sahip eserler ortaya koymak değil, gerçek dünyada olan biteni mümkün olduğunca doğru bir şekilde modelleyebilmektir. Bu sebeple model parametrelerinde optimum değerlere yakınsamış olmak analiz sürecinin bittiği anlamına gelmemek-

tedir. Bir sonraki aşamada modelin başarısı değerlendirilmeli ve geçerliği hakkında yargıya varılmalıdır.

3.4.3. Model Uygulama

Makine öğrenmesinde model değerlendirme, geliştirilen modelin amaçlandığı gibi çalışıp çalışmadığının sorgulanması ve pratik uygulamalarda kullanılabilirliği hakkında karar verilmesi anlamına gelmektedir. İyi bir model, ölçmeyi amaçladığı değişkeni yüksek bir doğruluk değeriyle (accuracy) ölçebilen modeldir. Öyleyse doğruluk değeri, modelin yordama yani tahmin geçerliğinin bir ölçütü olacaktır.

Şekil 3.2'de görüldüğü üzere veri seti eğitim kümesi ve test kümesi diye iki alt kümeye bölünmüştü. Eğitim kümesi ile model eğitildikten sonra $j = 1, ..., m$ olmak üzere test kümesinin öznitelik değerleri olan x_j kullanılarak $\hat{y}_j$ gibi bir tahmin kümesi elde edilir. Daha sonra, bu tahmin değerleriyle test kümesindeki y_j değerleri karşılaştırılarak tahminlerin doğruluğu araştırılır. Eğer eğitilen model bir sınıflama problemini çözüyorsa, doğruluk değeri (accuracy) $doğru\ tahmin\ değerleri\ /\ j$ şeklinde hesaplanır. Bu oran, modelin yordama geçerliğinin bir göstergesidir.

Şekil 3.2'de görüldüğü gibi, model eğitilirken veri setinin eğitim ve test kümelerine bölünerek test kümesinin eğitimde kullanılmamasının temel sebebi, model değerlendirmede oluşabilecek yanlılığın önüne geçmektir. Veri setinin bölünmediğini ve model değerlendirmede kullanılacak test verilerinin, modelin eğitiminde kullanılan verilerden rastgele seçildiğini düşünelim. Tahminci, bu veri noktalarını eğitim aşamasında gördüğü için olması gerekenden daha yüksek bir doğruluk değeri elde edebilir. Bu ise, performans ölçümüne karışan bir sistematik hatadır. Model değerlendirmeye karışabilecek pozitif yönlü bir sistematik hata, gelecekte karşılaşılacak olan yeni durumlar karşısında modelin beklenen performansı gösterememesi gibi bir duruma yol açabilir. Bu sebeple model değerlendirmede kullanılan test verileri, eğitimde kullanılmamış olan veri örneklerinden oluşmalıdır (Bengio ve Grandvalet, 2004).

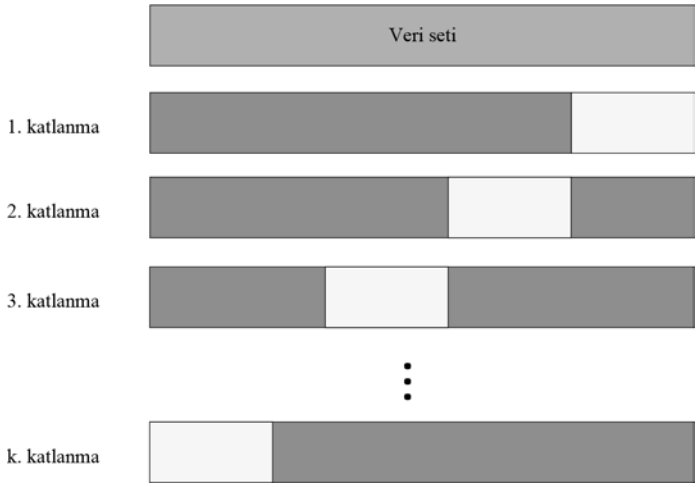

Şekil 3.3: K-katlamalı çapraz doğrulama.

Model değerlendirmede karşılaşılan diğer bir handikap ise örneklemin yeterince büyük olmamasıdır. Eğitim kümesi veri setinden rastgele seçildiği için örneklem yeterince büyük olmadığında doğruluk değerine karışan tesadüfi hatanın miktarı da artacaktır. Bu durum ise ölçümlerin güvenirliğini azaltır. Doğruluk değerini tesadüfi hatalardan arınık bir şekilde hesaplayabilmek için k-katlamalı çapraz doğrulama (k-fold cross validation) yöntemi geliştirilmiştir. Bu yöntem, Şekil 3.3'te görüldüğü gibi veri setinin eğitim ve test kümelerine bölünme işinin k defa yapılması ve her katmanda doğruluk değerlerinin tekrar hesaplanması şeklinde uygulanmaktadır (Zaim ve diğerleri, 2021). Böylelikle, elde edilen k adet doğruluk değerinin ortalaması alınarak doğruluk değerinin beklenen değeri ve standart hatası hesaplanır. Algoritma kıyaslamalarında bu beklenen değerler üzerinden karşılaştırma yapmak tercih edilmelidir (Dietterich, 1998). Veri seti genişledikçe bu standart hata değeri küçülür ve doğruluk değeri olasılık dağılımının parametresine yakınsar.

Bu bilgilere bağlı olarak bu araştırmada, elde edilen sonuçların güvenirliğini artırmak amacıyla, çapraz doğrulama için k değeri 10 olarak belirlenmiştir. Buna göre on parçaya bölünen veri setinin dokuz parçası eğitim için bir parçası da test için kullanılır ve bu süreç her katlamada farklı bir test seti kullanılarak on kere gerçekleştirilir.

Çapraz doğrulama sonucunda elde edilen sonuçların performans değerlendirmelerinin objektif bir şekilde yapılabilmesi için karışıklık matrisi hesaplanmıştır. Karışıklık matrisi, algoritmanın sınıflandırma performansını değerlendirmeye yardımcı olmak için kullanılır (Tripathy ve diğerleri, 2016).

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Tablo 3.2: Karışıklık matrisi.

Karışıklık matrisindeki sınıfların etiketlerini karşılaştırmak için, "Doğru Pozitif (DP)", "Yanlış Pozitif (YP)", "Doğru Negatif (DN)", "Yanlış Negatif (YN)" terimleri kullanılmaktadır (Alan, 2020):

- Doğru Pozitif (DP), pozitif olarak sınıflandırılıp ve gerçekte pozitif olan gözlemleri;
- Yanlış Negatif (YN), gerçekte pozitif olup sınıflandırıcı tarafından negatif tahmin edilen gözlemleri;
- Doğru Negatif (DN), gerçekte negatif olup sınıflandırıcının negatif olarak tahmin ettiği gözlemleri;
- Yanlış Pozitif (YP) ise gerçekte negatif olup sınıflandırıcının pozitif tahmin ettiği gözlemleri temsil eder.

Karışıklık matrisinden elde edilen değerlere dayalı olarak, herhangi bir sınıflandırıcının performansını değerlendirmek için "doğruluk", "kesinlik", "duyarlılık", "F-ölçütü" gibi diğer parametre değerleri hesaplanır.

Doğruluk değeri, sınıflandırma sürecinin en yaygın ölçüsüdür. Daha önce de belirtildiği gibi doğru sınıflandırılmış örnek sayısının toplam örnek sayısına oranı olarak hesaplanır. Fakat doğruluk değeri bir modelin başarı-

sını ölçmek için yeterli değildir. Modelde negatif örneklerin pozitif olarak tahmin edilmesinden ve pozitif örneklerin negatif olarak tahmin edilmesinden kaynaklanan hatanın da ölçülmesi gerekmektedir.

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN}$$

Kesinlik değeri, sınıflandırıcının pozitif olarak doğru olarak etiketlenen örnek sayısının, pozitif olarak sınıflandırılan toplam örnek sayısına oranıdır. Farklı bir ifadeyle, sınıflandırıcının bir sınıf için yaptığı ölçümlerde ne kadar hassas olduğunun yanıtıdır. Kesinlik değeri bire yaklaştıkça sınıflandırıcının tahmin ettiği negatif örnek oranı azalmaktadır (Alan, 2020).

$$Kesinlik = \frac{DP}{DP + YP}$$

Duyarlılık değeri, pozitif olarak tahmin edilen toplam örnek sayısının, gerçekte pozitif ve negatif olan toplam örneklere oranıdır. Bir sınıflandırıcının duyarlılığı, gerçek pozitif değerlerin oranını, farklı bir deyişle bir örneğin gerçekte var olma durumunu gösterir. Duyarlılık değeri bire yaklaştıkça yanlış negatif örnek sayısı o kadar azalır (Alan, 2020).

$$Duyarlılık = \frac{DP}{DP + YN}$$

F- ölçütü, kesinlik ve duyarlılık değerinin harmonik ortalamasıdır. Sistemi, nihai sonuç üzerinde daha fazla etkiye sahip olan kesinlik veya duyarlılık yönünde optimize etmek gerekir.

$$F - ölçütü = 2 * \frac{Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik}$$

Geliştirilen modelin geçerliği ispat edildikten sonra model pratikte hazır hale gelmiş olacaktır. Tedarikçi değerlendirme uygulaması için önerilen hibrit yaklaşım çok sayıda tedarikçinin ve envanter kaleminin bulunduğu işletmelerde kullanılabilir.

3.5. Bulgular ve Yorum

Bu bölümde, tedarikçi değerlendirme probleminin vaka çalışmasındaki işletme üzerinde uygulanması neticesinde elde edilen sonuçlara yer verilecektir. Bu sonuçlar ve yapılan yorumlar, modelin değerlendirme aşaması-

nı kapsamaktadır. Analizlerin yapımında IBM SPSS 21 paket programı ve Python programlama dilinde bulunan Scikit-Learn (Pedregosa ve diğerleri, 2011) makine öğrenmesi kütüphanesi kullanılmıştır.

Kümeleme analizinden elde edilen sonuçların ardından detaylı stok envanter verisi üzerinde, yapay sinir ağının k-katlamalı çapraz doğrulama yöntemi ile on kere çalıştırılması neticesinde elde edilen karışıklık matrisi sonuçları verilecektir.

3.5.1. Tanımlayıcı İstatistikler

Vaka çalışmasındaki işletmenin ERP sisteminden alınan detaylı stok envanter verisi incelenmiş ve tanımlayıcı istatistik değerlerinin elde edileceği değişkenler ile Kraljic matrisinde yer alan finansal etki ile arz riskini ölçecek toplam 8 değişken olduğu tespit edilmiştir. Tablo 3.3'te veride bulunan değişkenlerin bilgileri yer almaktadır:

Değişkenler	Değişken Tanımları
Tedarikçi Adı	İşletmenin satın alma kalemlerini tedarik ettiği firmaları göstermektedir.
Ürün Adı	İşletmenin satın alma kalemlerinin isimlerini göstermektedir.
Ürün Çeşidi	İşletmenin satın aldığı ürünleri boya, hizmet ve sarf malzemesi olarak sınıflandırmaktadır.
Ürün Sayısı	Her bir tedarikçiden kaç adet ürün satın alındığını göstermektedir.
Tedarikçi Ağırlığı	Tedarikçi başına satın alınan ürün sayısının toplam ürün sayısına oranını göstermektedir.
Sarf Miktarı	Ürünün aylık kullanım miktarını göstermektedir.
Dönem Sonu Stok	Ürünün kullanımından sonra kalan stok miktarını göstermektedir.
Birim Fiyat	Ürünün birim fiyatını göstermektedir.

Tablo 3.3: Verideki değişkenler ve tanımları.

Tablo 3.3'te bulunan gözlenen değişkenlerden hareketle aşağıda oluşturulan endeksler yardımıyla finansal etki ve arz riskini ölçecek gizil değişkenler elde edilmiştir. Finansal etki değişkeni, toplam stok miktarının birim fiyat ile çarpımı sonucu elde hesaplanmaktadır.

Finansal Etki = Birim fiyat x (Sarf Miktarı + Dönem Sonu Stok)

Arz riski ise, işletmenin satın alma hacmi içinde her bir tedarikçinin payı hesaplanarak elde edilmiştir.

$$Arz\ Riski = \frac{Tedarikçi\ başına\ satın\ alınan\ ürün\ sayısı}{\sum Envanterde\ bulunan\ ürün\ sayısı}$$

Verinin normal dağılmasını sağlamak için finansal etki değişkenine logaritma dönüşümü uygulanmış ve her iki değişken de standardize edilmiştir. Tablo 3.4'te envanter verisinde bulunan ürünlere ve değişkenlere ait tanımlayıcı istatistik ölçüleri gösterilmektedir:

Değişkenler	Örneklem	Minimum	Maksimum	Ortalama	Standart Sapma	Asimetri	Basıklık
Arz Riski	195	1	25	12,58974	7,790154	0,086	-1,305
Finansal Etki	195	1,422	6,18	3,49681	0,75314	0,207	0,832

Tablo 3.4: Tanımlayıcı istatistikler.

Vaka çalışmasındaki işletmenin envanterinde toplamda 195 girdi bulunmaktadır. Her iki değişkene ait asimetri ve basıklık ölçüleri incelendiğinde ise verinin normal dağıldığı görülmektedir. Bununla birlikte tedarikçi başına düşen ürün ve tedarikçi başına satın alma hacmi grafiği incelendiğinde dağılımın Pareto kuralını sağladığı görülmüştür. Grafik 3.1: Tedarikçi başına ürün dağılımı.

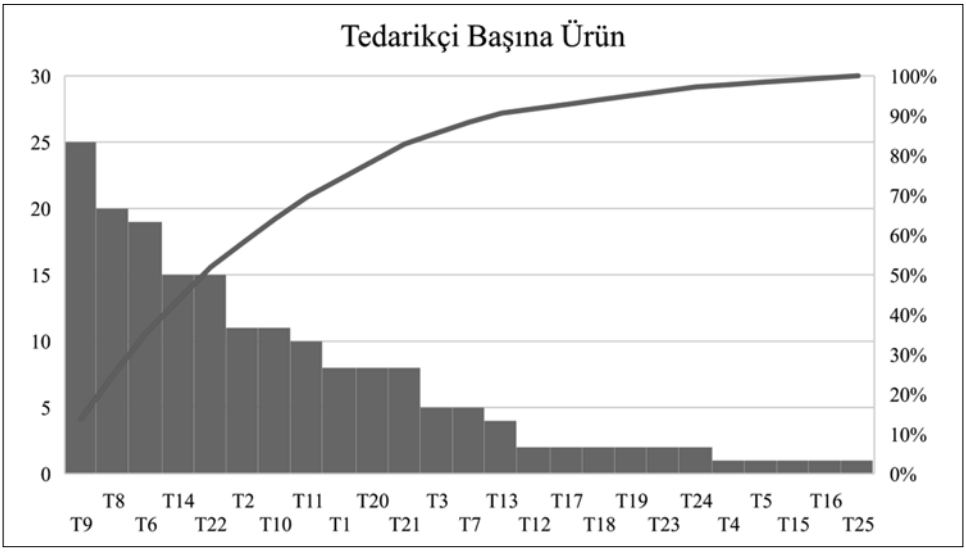

Grafik 3.1: Tedarikçi başına ürün dağılımı.

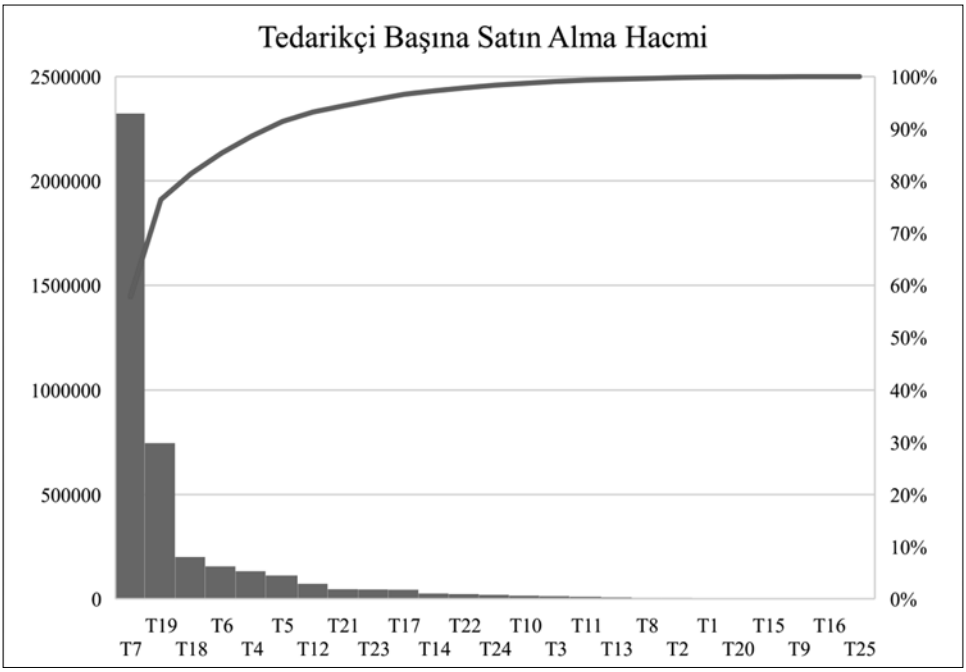

Grafik 3.2: İşletmenin satın alma hacmi içerisinde tedarikçilerin payı.

Pareto kuralının gerçekleşmesiyle birlikte veri, kümeleme analizine hazır hale getirilerek satın alma portföy modeli uygulanmıştır.

3.5.2. K-Ortalamalar Kümeleme Analizi Sonuçları

Araştırmada, Pareto kuralı sağlandıktan ve böylelikle vaka analizindeki işletmenin stratejik ürünlerinin ve tedarikçilerinin tespit edilmesinde ilk adım atıldıktan sonra Kraljic (1983)'in portfolyo yaklaşımı uygulanır. Kraljic matrisi, tedarikçiyi seçme ve sonrasında ürün bazında ilişkinin yönetilmesi adına kavramsal bir model sunmaktadır. K-ortalamalar kümeleme analizinin yapılmasının amacı, finansal etki ve arz riski değişkenlerini kullanarak işletmenin satın alma kalemlerini Kraljic matrisinde bulunan segmentlere ayırmaktır. Analiz öncesinde kullanılan değişkenler z skoru hesaplanarak standardize edilmiştir. Küme sayısı, Kraljic matrisinde bulunan ürün kategorileri gereğince dört olarak belirlenmiştir. Uzaklık ölçüsü olarak ise Öklid uzaklığı kullanılmıştır. Algoritma 13 iterasyonda yakınsama göstermiştir. Tablo 3.5'te k-ortalamalar yöntemine ait sonuç tablosu görülmektedir:

	Küme		Hata			
	Ortalama Kare	SD	Ortalama Kare	SD	F	Sig.
Arz Riski	49,564	3	0,237	191	208,949	,000
Finansal Etki	43,46	3	0,333	191	130,48	,000

Tablo 3.5: K-ortalamalar yöntemine ait ANOVA tablosu.

Sonuçlar incelendiğinde her iki değişkenin de anlamlı bir şekilde kümelere ayrıldığı görülmektedir. Bununla birlikte, F değerlerine bakıldığında arz riskinin (F=208,949) kümelere ayırmada daha etkili olduğu görülmektedir.

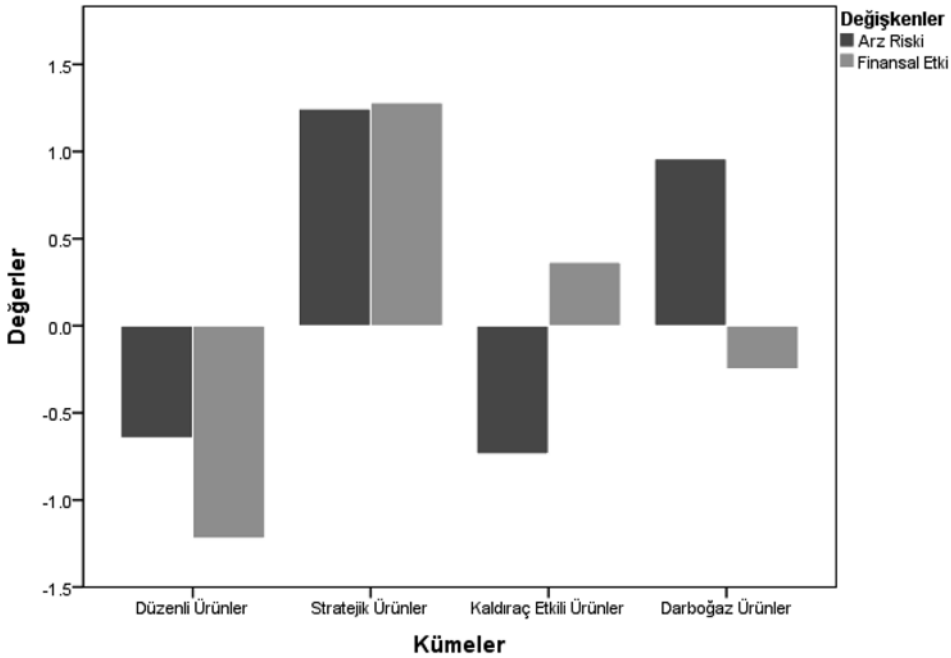

Grafik 3.3: Ürünlerin k-ortalamalar yöntemi ile kategorilere ayrılması.

Grafik 3.3 incelendiğinde, vaka çalışmasındaki işletmenin girdilerinin Kraljic'in portfolyo yaklaşımına uygun şekilde kümelere ayrıldığı görülmektedir.

1. *kümede,* hem finansal etkinin hem de arz riskinin ortalamanın altında kalarak her iki değişkenin de etkisinin düşük olduğu ve düzenli ürünleri gösterdiği görülmektedir.

2. *kümede,* hem finansal etkinin hem de arz riskinin ortalamanın üzerinde kalarak her iki değişkenin de etkisinin yüksek olduğu ve stratejik ürünleri gösterdiği görülmektedir.
3. *kümede,* finansal etki değişkeninin yüksek iken arz riskinin düşük olduğu ve kaldıraç etkili ürünleri gösterdiği görülmektedir.
4. *kümede,* finansal etkinin düşük iken arz riskinin etkisinin oldukça yüksek olduğu ve darboğaz ürünleri gösterdiği görülmektedir.

Bununla birlikte Tablo 3.6 ve Grafik 3.4 incelendiğinde her bir kümenin içinde bulunan tedarik sayıları görülmektedir.

Kümeler	Küme Başına Düşen Örnek Sayısı
1	45
2	31
3	73
4	46
Örneklem	195

Tablo 3.6: Küme başına düşen girdi sayısı.

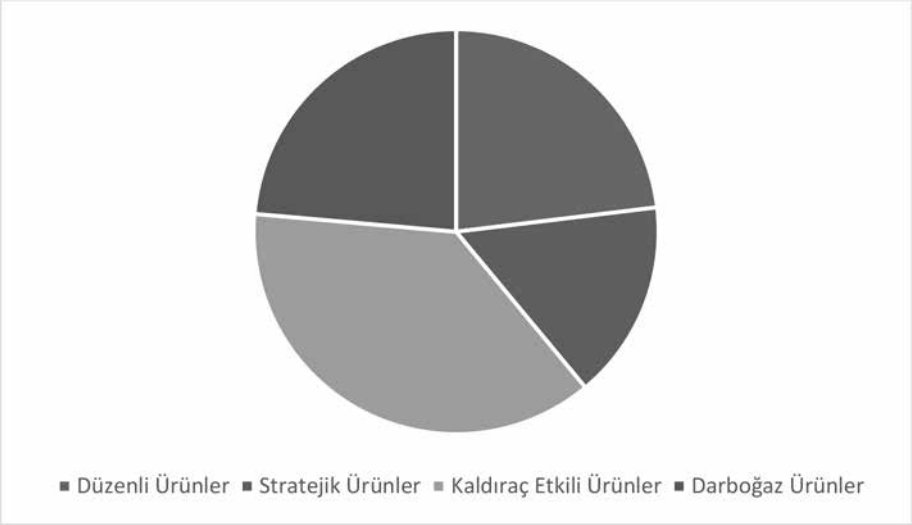

Grafik 3.4: Satın alma kalemlerinin ürün gruplarına göre dağılımı.

Tablo 3.6 ve Grafik 3.4 birlikte incelendiğinde, vaka çalışmasındaki işletmenin portföyünün en yüksek payını, %37 gibi oranla kaldıraç etkili ürünlerin oluşturduğu saptanmıştır. Bu oranı, %24 ile darboğaz ürünler, %23 ile düzenli ürünler ve %16 ile stratejik ürünler takip etmiştir.

3.5.3. Ürün Sınıflarının Yapay Sinir Ağları ile Tahmin Edilmesi

K-ortalamalar kümeleme analizi ile veride bulunan her bir ürünün bulundukları küme bilgisi elde edildikten sonra denetimli öğrenme yaklaşımına geçiş yapılarak yapay sinir ağı modeli uygulanmıştır. Model, Tablo 3.1'de gösterildiği gibi finansal etki, arz riski ve ürün kategorisi olmak üzere üç adet öznitelikten ve k-ortalamalar yönteminden elde edilen ürün sınıfı olmak üzere bir adet bağımlı değişkenden oluşmaktadır.

Yapay sinir ağı ile sınıflandırma analizini gerçekleştirirken veri setinin %75'i eğitim verisi ve %25'i test verisi olmak üzere rassal bir şekilde iki parçaya bölünmüştür. Bununla birlikte, k değeri 10 olacak şekilde, k katlamalı çapraz doğrulama metodu kullanılarak modelin güvenirliğinin de artırılması amaçlanmıştır. Yapay sinir ağından elde edilen sonuçlar, her bir küme için sınıflandırma problemi değerlendirme kriterleri ve karmaşıklık matrisine göre göre Tablo 3.7 ve Tablo 3.8'deki gibi raporlanmıştır.

Kümeler	Kesinlik	Duyarlılık	F1-Ölçütü	Küme Başına Test Verisine Düşen Örnek Sayısı
1	%92	%100	%96	11
2	%88	%100	%93	7
3	%100	%100	%100	18
4	%100	%85	%92	13
Doğruluk			%96	49
Aritmetik Ortalama	%95	%96	%95	49
Ağırlıklı Ortalama	%96	%96	%96	49

Tablo 3.7: YSA modeline ait değerlendirme sonuçları.

Kümeler		Tahmin Değeri			
		1. Küme	**2. Küme**	**3. Küme**	**4. Küme**
Gerçek Değer	**1. Küme**	11	0	0	0
	2. Küme	0	7	0	0
	3. Küme	0	0	18	0
	4. Küme	1	1	0	11

Tablo 3.8: YSA modeline ait karmaşıklık matrisi.

Modelin genel başarısı incelendiğinde, modelin %96 doğruluk değeri ürettiği ve bundan hareketle tahmin başarısının yüksek olduğu görülmektedir. Bununla beraber, küme başına test verisine düşen örnek sayısının, toplam örnek sayısına göre ağırlığı baz alınarak kesinlik, duyarlılık ve F-1 ölçütü kriterlerinin ağırlıklı ortalamaları hesaplanmıştır. Modelin başarısında doğruluk değerini, tüm kriterlerin ağırlıklı ortalama değerini %96 ile tahmin ederek desteklemektedir. Modelin toplam hatası ise, %4 olarak hesaplanmıştır.

1. *kümede,* düzenli ürün kategorisinde yer alan ürünlerin %92'si gerçekten düzenli ürün olarak tahmin edilmiştir. Düzenli ürün olarak tahmin edilmesi istenen ürünlerin %100'ü düzenli ürün olarak tahmin edilmiştir. Bu durumda modelin doğru olarak tahmin etme etkililiğinin maksimum olduğu ifade edilmektedir. Tablo 3.8'deki karmaşıklık matrisi incelendiğinde ise test kümesinde yer alan 11 düzenli ürünün tamamının doğru kümede tahmin edildiği görülmektedir.

2. *kümede,* stratejik ürün kategorisinde yer alan ürünlerin %88'i gerçekten stratejik ürün olarak tahmin edilmiştir. Stratejik ürün olarak tahmin edilmesi istenen ürünlerin %100'ü stratejik ürün olarak tahmin edilmiştir. Bu durumda modelin doğru olarak tahmin etme etkililiğinin maksimum olduğu ifade edilmektedir. Tablo 3.8'deki karmaşıklık matrisi incelendiğinde ise test kümesinde yer alan 7 stratejik ürünün tamamının doğru kümede tahmin edildiği görülmektedir.

3. *kümede,* kaldıraç etkili ürün kategorisinde yer alan ürünlerin %100'ü gerçekten kaldıraç etkili ürün olarak tahmin edilmiştir. Kaldıraç etkili ürün olarak tahmin edilmesi istenen ürünlerin %100'ü kaldıraç etkili ürün olarak tahmin edilmiştir. Bu durumda modelin doğru olarak tahmin etme etkililiğinin maksimum olduğu ifade edilmektedir. Tablo 3.8'deki karmaşıklık matrisi incelendiğinde ise test kümesinde yer alan 18 kaldıraç etkili ürünün tamamının doğru kümede tahmin edildiği görülmektedir.

4. *kümede,* darboğaz ürün kategorisinde yer alan ürünlerin %100'ü gerçekten darboğaz ürün olarak tahmin edilmiştir. Darboğaz ürün olarak tahmin edilmesi istenen ürünlerin ise %85'i darboğaz ürün olarak tahmin edilmiştir. Bu durumda modelin doğru olarak tahmin etme etkililiğinin diğer kümelere göre düşük olduğu saptanmıştır. Tablo 3.8'deki karmaşıklık matrisi incelendiğinde ise test kümesinde yer alan 13 darboğaz üründen birinin düzenli ürün, birinin ise stratejik ürün olarak yanlış tahminde bulunduğu görülmektedir.

Yapay sinir ağı modelinden sınıflandırma sonuçlarından hareketle tüm girdi sınıfları için Kraljic matrisinde yer alan stratejiler Tablo 3.9'daki gibi oluşturulmuştur.

Segment	Ürün Grubu	Tedarikçiler	Önerilen Strateji
1	Düzenli Ürünler	T1, T2, T3, T4, T5, T6, T7, T10, T11, T14, T19, T21, T22, T25, T26	**1.** Zaman tasarrufu sağlamak amacıyla merkezi satın alma yolu izlenmelidir.
			2. Düşük tutarda çok sayıda tedarikçiden ikame edilebilecek ürünler olduğu için, emniyet stoku azaltılarak stok maliyetleri azaltılmalıdır.
			3. Boya ve kimyasal kategorisindeki ürünlerin satın alma sürecinde sipariş süresi orta vadeli planlanmalıdır.
			4. Portföyde yer alan sarf malzemeleri kategorisindeki ürünlerin satın alma sürecinde e-ticaret çözümlerinden faydalanılmalıdır.
2	Stratejik Ürünler	T6, T7, T8, T14	**1.** Tedarikçilerle uzun vadede güçlü ilişkiler kurulması amaçlanmalıdır.
			2. Tedarikçilerle iş birliği yapılmalı, gerektiği takdirde tedarikçinin performansını artırmasına yardımcı olunmalıdır.
			3. Ürünlerin ve tedarikçilerin ikame edilmesi zor olduğu için emniyet stoku artırılmalı ve acil eylem planları yapılmalıdır.
3	Kaldıraç Etkili Ürünler	T1, T2, T9, T10, T11, T12, T13, T14, T15, T16, T17, T18, T19, T20, T21, T22, T23, T24, T26	**1.** Satın alma planlaması orta vadeli olarak yapılmalıdır.
			2. Güç dengesi alıcıdan yana olduğu için kar amacı ön planda tutulmalıdır.
			3. Ürünlerin ve tedarikçilerin ikame edilmesi kolay olduğu için düzenli olarak piyasa araştırması yapılmalıdır.
4	Darboğaz Ürünler	T6, T7, T8, T14, T22	**1.** Tedarikçilerle uzun vadeli ilişkiler geliştirilmelidir.
			2. Yüksek miktarlarda sipariş verilmelidir.
			3. Tedarikçilerin ikamesi zor olduğu için emniyet stoku artırılmalıdır.
			4. Pazarda alternatif tedarikçiler araştırılmalıdır.

Tablo 3.9: Portföydeki tedarikçiler ve ürün sınıfları için uygun stratejilerin atanması.

3.6. Bulguların Geçerliği ve Güvenirliği

Bir araştırmada geliştirilen modelin kalitesi, gerçek hayatı ne kadar iyi temsil ettiğiyle ölçülür. Gerçek hayatın temsili ise, modelin amacı doğrultusunda çalışması ve pratik uygulamalarda kullanılabilirliği anlamına gelmektedir. Bu amaca hizmet gücüne ise modelin geçerliği adı verilmektedir. Farklı bir ifadeyle geçerlik, ölçülmek istenen bir kavramın doğru ölçülme derecesidir (Ercan ve Kan, 2004). İyi bir model, ölçmeyi amaçladığı bir kavramı yüksek bir doğruluk değeriyle ölçebilen modeldir. Örneğin, bir sınıflandırma veya tahmin modelinin gelecekte alınacak kararlara ilişkin doğruluk değeri yüksek çıkıyorsa, bu durum modelin geçerliğinin yüksek olduğu anlamına gelmektedir. Bu durumda doğruluk değeri, modelin yordama geçerliğinin bir ölçütü olacaktır.

Bir modelin geçerliğinin yüksek olmasının ölçütlerinden bir diğeri ise, ölçüm sonuçlarının sistematik hatalardan arınmış olmasıdır. Sistematik hata, ölçüm sonuçlarına yanlılık karıştırarak modelin ürettiği sonuçların geçerliğini düşürür. Bu araştırmada, Tablo 3.7'de elde edilen sonuçlara göre modelin doğruluk değeri %96 olarak oldukça yüksek bir değer olarak hesaplanmıştır. Bu durum, modelin yordama geçerliğinin yeterli olduğunu göstermektedir. Bunun yanı sıra araştırma, finansal etki değişkenini ürünlerin toplam maliyet içindeki payı üzerinden; arz riskini ise alıcının satın alma hacmi içerisinde tedarikçinin payı üzerinden hesaplanmıştır. Literatürde sıkça yer alan kalite, teslimat süresi gibi tedarikçi değerlendirme kriterleri modele dahil edilmemiştir. Bu durum modelin içerik geçerliğini düşürmektedir.

Modelin sistematik hatalardan arınmış olmasının yanında standart hatadan arınmış olması da oldukça önemlidir. Standart hata, ölçüme kuralsız bir şekilde karışan hata türüdür ve bu durum modelin güvenirliğini düşürür. Güvenirlik, bir ölçme aracının sabit koşullar altında tekrarlı ölçümler yapıldığında elde edilen ölçüm değerlerinin kararlılık düzeyidir (Ercan ve Kan, 2004). Bu tanımdan hareketle, model üzerinde yapılan tekrarlı ölçümlerin ürettiği sonuçların birbirine yakın sonuçlar olması beklenir. Bu çalışmada güvenirliğin ölçümü için, k katlamalı çapraz doğrulama metodu kullanılmıştır. K katsayısı 10 olarak belirlenmiş ve her defasında veri setinden ras-

sal olarak farklı bir test verisi seçilerek sınıflandırma ölçütleri on defa elde edilmiş ve bu değerlerin ortalaması sunulmuştur. Tablo 3.7'de elde edilen sonuçlar incelendiğinde modelin ürettiği sonuçların yüksek olduğu görülmektedir. Dolayısıyla modelin güvenirliğinin de yeterli düzeyde olduğu ifade edilebilir.

SONUÇ

Tedarikçi performans değerlendirmesi, işletmelerin rekabet gücünü belirlemede önemli bir rol oynamaktadır. İşletmelerin dış kaynak kullanımı stratejisine yönelmesi, tedarik zinciri süreçlerinin etkin ve verimli bir şekilde yönetilmesi bakımından satın alma fonksiyonunu ve tedarikçi ilişkileri yönetimini hayati bir duruma getirmiştir. İşletmeler, tüm tedarikçilerini ve satın alma kalemlerini tek bir strateji ile yönetemeyeceği için ürün çeşitlerine göre özelleştirilmiş bir satın alma stratejisi ile farklı tedarikçiler için en uygun stratejilerin kullanılacağı bir tedarikçi segmentasyonu uygulaması gerekmektedir. Bu araştırmada da tedarikçilerin segmentlere ayrılması ve sonrasında uygun tedarikçinin seçilerek ilişkinin yönetilmesi adına Kraljic'in portföy yaklaşımı kavramsal bir model olarak sunulmaktadır. Kraljic matrisi, işletmenin satın alma kalemleri üzerinden seçilen tedarikçinin finansal etkisi ve arz riski değişkenlerini kullanarak ürün gruplarının ve standart stratejilerin yer aldığı bir karar matrisi oluşturmaktadır. Bu tez çalışmasında, standart stratejilerin yer aldığı Kraljic'in portföy modeli bir karar destek sistemine çevrilmiştir.

Tedarikçi seçme ve değerlendirme probleminde kullanılan çeşitli yaklaşımlar olsa da günümüzde yapay zeka ve veri madenciliğinin gelişmesi, karar alma sürecini otomatize etmeyi kolaylaştırmaktadır. Denetimli ve denetimsiz makine öğrenmesi yaklaşımları da tedarikçi seçme ve değerlendirme problemi için etkin bir çözüm yöntemi sunmaktadır. Bu çalışmada, ürünlerin segmentlere ayrılmasında k-ortalamalar kümeleme analizi ve ürün sınıflarının tahmin edilerek bulundukları portföy grubuna göre stratejilerin atanmasında ise yapay sinir ağları kullanılmıştır. Önerilen model, bir vaka çalışması üzerinde uygulanmış ve ampirik olarak test edilmiştir. Model, veri ön işleme, model geliştirme ve model uygulama olmak üzere üç ana aşama ve on bir adımdan oluşmaktadır. Modelde kullanılan veriyi, tekstil sektöründe faaliyet gösteren bir işletmenin ERP sisteminden elde edilen detaylı stok envanter raporları oluşturmaktadır. Veri ön işleme aşamasında, veri analize hazır hale getirilmiş

ve veride yer alan gözlenen değişkenlerden Kraljic'in portföy modeline uygun gizil değişkenler keşfedilmiştir. Bununla birlikte, tedarikçi başına düşen ürün sayısı ve tedarikçi başına satın alma hacminin Pareto kuralını karşıladığı görülmüş ve verinin Kraljic'in portföy analizine hazır olduğu sonucuna varılmıştır. Model geliştirme aşamasında, hazırlanan veri SPSS paket programına aktarılmış ve k-ortalamalar kümeleme analizi uygulanarak ürünlerin sınıfları belirlenmiştir. Böylece keşifsel bir yöntemle Kraljic'in önerdiği teori keşfedilmiştir. Veri ön işleme aşamasında elde edilen ürün grupları, finansal etki ve arz riski değişkenleri bağımsız değişkenleri oluştururken, kümeleme analizi sonucu keşfedilen ürün kategorileri ise bağımlı değişkeni oluşturmaktadır. Böylelikle model, yapay sinir ağını eğitmek üzere eğitime hazır hale getirilmiştir. Sınıflandırma yapmak amacıyla kullanılan ileri beslemeli yapay sinir ağı modelinin eğitilmesinde stokastik gradyan azalma algoritması kullanılmıştır. Model uygulama aşamasında ise eğitimi tamamlanan yapay sinir ağı modelinin sınıflandırma başarısı tartışılmıştır. Karmaşıklık matrisi ve sınıflandırma ölçütleri incelendiğinde model performansının yüksek olduğu ile modelin geçerlik ve güvenirliğinin yeterli olduğu sonucuna ulaşılmıştır.

Modelin pratik uygulamalara katkısı, alıcı işletme yeni bir ürünü satın almak istediğinde geçmiş verilerden faydalanarak, portföyündeki tedarikçilerin hangisinden satın alacağı, ürünü hangi segmentte değerlendireceği ve bir ürünü satın alırken ilgili tedarikçiye ne yönde bir politika izleyeceğinin belirlenmesi hususunda bir karar destek sistemi sunmak olarak gösterilebilir. Böylelikle farklı ürün sınıflarına dayalı bir tedarikçi değerlendirme modeli geliştirilerek çok sayıda satın alma kalemini yönetmesi gereken büyük ölçekli üretim işletmelerinde belirsizliğin azaltılması sağlanmıştır. Bununla birlikte, Kraljic'in portfolyo yaklaşımının makine öğrenmesi algoritmalarıyla kullanıldığı çalışmaların sınırlı sayıda olduğu görülmüştür. Dolayısıyla bu araştırmanın sanayi uygulamalarında kullanılır hale getirilmesiyle birlikte literatüre önemli bir katkıda bulunacağı düşünülmektedir.

Araştırma, önemli katkılarının yanı sıra bazı sınırlılıklara da sahiptir. Literatürde tedarikçi seçme ve değerlendirme üzerine ürün kalitesi, teslimat süresi, inovasyon gibi çok sayıda kriter mevcuttur. Gelecekteki çalışmalarda araştırmaya yeni boyutlar eklenerek kapsamı genişletilebilir. Bu sayede, ölçülmesi hedeflenen kavramın içerik geçerliği artırılmış olacaktır.

KAYNAKÇA

AA, 2022 — Şanghay'daki Kovid-19 Kapanması Ekonominin Can Damarlarını Tıkıyor. 21 Mayıs 2022 tarihinde https://www.aa.com.tr/tr/dunya/sanghaydaki-kovid-19-kapanmasi-ekonominin-can-damarlarini-tikiyor/2569236 adresinden erişildi.

Aggarwal, C. C., 2015 — Data Mining: The Textbook. Springer.

Aggarwal, C. C., 2018 — Neural Networks and Deep Learning. Springer.

Akpınar, H., 2014 — Data: Veri Madenciliği Veri Analizi. Papatya Yayıncılık Eğitim.

Aksu, G., Güzeller, C. O., ve Eser, M. T., 2019 — "The Effect of The Normalization Method Used In Different Sample Sizes On The Success of Artificial Neural Network Model." International Journal of Assessment Tools In Education, 6(2), 170-192.

Alan, A. 2020 — Makine Öğrenmesi Sınıflandırma Yöntemlerinde Performans Metrikleri ile Test Tekniklerinin Farklı Veri Setleri Üzerinde Değerlendirilmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü.

Alpar, R., 2013 — Uygulamalı Çok Değişkenli İstatistik Yöntemler, Detay Yayıncılık.

Alpaydin, E., 2004 — Introduction To Machine Learning. MIT Press.

Arı, A., ve Berberler, M. E., 2017 — "Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı." Acta Infologica, 1(2), 55-73.

Arora, J. S., 2004 — Introduction To Optimum Design. Elsevier.

Arshinder, Kanda, A., ve Deshmukh, S. G., 2008 — "Supply Chain Coordination: Perspectives, Empirical Studies and Research Directions." International Journal of Production Economics. Elsevier.

Atbaş A.C., 2008 Kümeleme Analizinde Küme Sayısının Belirlenmesi Üzerine Bir Çalışma. Yüksek Lisans Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü.

Ayyagari, S. B., 2011 Artificial Neural Network Based Fault Location For Transmission Lines.

Bandyopadhyay, S., Thakur, S. S., ve Mandal, J. K., 2021 "Product Recommendation For E-Commerce Business By Applying Principal Component Analysis (PCA) and K-Means Clustering: Benefit For The Society." Innovations In Systems and Software Engineering, 17(1), 45-52.

Bengio, Y., 2012 "Practical Recommendations For Gradient-Based Training of Deep Architectures." In Neural Networks: Tricks of The Trade (Pp. 437-478). Springer, Berlin, Heidelberg.

Bengio, Y., ve Grandvalet, Y., 2004 "No Unbiased Estimator of The Variance of K-Fold Cross-Validation." Journal of Machine Learning Research, 5(Sep), 1089-1105.

Benton Jr, W. C., 2018 Satın Alma ve Tedarik Zincir Yönetimi.

Bianchini, A., Benci, A., Pellegrini, M., ve Rossi, J., 2019 "Supply chain redesign for lead-time reduction through Kraljic purchasing portfolio and AHP integration." Benchmarking: An International Journal.

Bilbao, I., ve Bilbao, J., 2017 "Overfitting Problem and The Over-Training In The Era of Data: Particularly For Artificial Neural Networks." Eighth International Conference On Intelligent Computing and Information Systems (ICICIS) (Pp. 173-177). IEEE.

Bishop, C. M., 2006 Pattern Recognition and Machine Learning. Springer.

Bozarth, C. C., Handfield, R. B., ve Weiss, H. J., 2008 Introduction To Operations and Supply Chain Management. Upper Saddle River, NJ: Pearson Prentice Hall.

Brownlee, J., 2016 "Supervised and Unsupervised Machine Learning Algorithms." Machine Learning Mastery, 16(03).

Bustamam, A., Tasman, H., Yuniarti, N., Frisca, ve Mursidah, I., 2017 "Application of K-Means Clustering Algorithm In Grouping The DNA Sequences of Hepatitis B Virus (HBV)." In AIP Conference Proceedings (Vol. 1862, No. 1, P. 030134). AIP Publishing LLC.

Caianiello, E. R., 1961 "Outline of A Theory of Thought-Processes and Thinking Machines." Journal of Theoretical Biology, 1(2), 204-235.

Caniels, M. C., ve Gelderman, C. J., 2005 "Purchasing Strategies In The Kraljic Matrix—A Power and Dependence Perspective." Journal of Purchasing and Supply Management, 11(2-3), 141-155.

Cauchy, A., 1847 "Méthode Générale Pour La Résolution Des Systemes D'équations Simultanées." Comp. Rend. Sci. Paris, 25(1847), 536-538.

Christopher, M., 2016 Logistics & Supply Chain Management. Pearson Uk.

Cichocki, A., ve Unbehauen, R., 1993 "Robust Estimation of Principal Components By Using Neural Network Learning Algorithms." Electronics Letters, 29(21), 1869-1870.

Cinemre, N., 2011 Yöneylem Araştırması. Evrim Yayınevi.

Ciresan, D. C., Meier, U., Gambardella, L. M., ve Schmidhuber, J., 2011 "Convolutional Neural Network Committees For Handwritten Character Classification." In 2011 International Conference On Document Analysis and Recognition (Pp. 1135-1139). IEEE.

Condeixa, L. D., Silva, P., Moah, D., Farias, B., & Leiras, A., 2020 "Evaluating Cost Impacts On Reverse Logistics Using An Economic Order Quantity (EOQ) Model With Environmental and Social Considerations." Central European Journal of Operations Research, 1-20.

Coşkun, S. S., Kumru, M., ve Kan, N. M., 2022 "An Integrated Framework For Sustainable Supplier Development Through Supplier Evaluation Based On Sustainability Indicators." Journal of Cleaner Production, 130287.

Croxton, K. L., Garcia-Dastugue, S. J., Lambert, D. M., ve Rogers, D. S., 2001 "The Supply Chain Management Processes." The International Journal of Logistics Management, 12(2), 13-36.

Cura, T., 2004 Karar verme Aracı Olarak Yapay Sinir Ağları ve Yapay Sinir Ağları ile Portföy Optimizasyonu. İstanbul Üniversitesi, Sosyal Bilimleri Enstitüsü, Yayımlanmamış Doktora Tezi, 2004.

Cüceloğlu, D., 2000 İnsan ve Davranışı. İstanbul: Remzi Kitabevi.

Çakar, T., 1997 İmalat Sistemlerinin Tasarlanması ve Öncelik Kurallarının Belirlenmesinde Yapay Sinir Ağlarının Kullanılması. Doktora Tezi, Fen Bilimleri Enstitüsü.

Çalış, A., ve Baynal, K., 2016 "Kümeleme Analizi ile Bankacılık Sektöründe Satış Stratejilerinin Belirlenmesi", Beykent Üniversitesi. Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 9(1), 13-41.

Dalay, İ., Coşkun, R., ve Altunışık, R., 2002 Stratejik Boyutuyla Modern Yönetim Yaklaşımları. İstanbul: Beta Basım Yayım Dağıtım AŞ.

Deisenroth, M. P., Faisal, A. A., ve Ong, C. S., 2020 Mathematics For Machine Learning. Cambridge University Press.

Detienne, K. B., Detienne, D. H., ve Joshi, S. A., 2003 "Neural Networks As Statistical Tools For Business Researchers." Organizational Research Methods, 6(2), 236-265.

DHL, 2022 Understanding The "New Normal" Supply Chain Risks In 2022 and Beyond. 20 Mayıs 2022 tarihinde https://www.dhl.com/global-en/delivered/globalization/supply-chain-risks-in-2022.html adresinden erişildi.

Dietterich, T. G., 1998 "Approximate Statistical Tests For Comparing Supervised Classification Learning Algorithms." Neural Computation, 10(7), 1895-1923.

Dixit, V., 2022 "Risk assessment of different sourcing contract scenarios in project procurement." International Journal of Construction Management, 22(8), 1537-1549.

Dubois, A., ve Pedersen, A. C., 2002 "Why Relationships Do Not Fit Into Purchasing Portfolio Models—A Comparison Between The Portfolio and Industrial Network Approaches." European Journal of Purchasing ve Supply Management, 8(1), 35-42.

Elmas, Ç., 2016 Yapay Zeka Uygulamaları: (Yapay Sinir Ağı, Bulanık Mantık, Sinirsel Bulanık Mantık, Genetik Algoritma). Seçkin Yayıncılık.

Engelbrecht, A. P., 2007 Computational Intelligence: An Introduction. John Wiley ve Sons.

Ercan ve Kan., 2004 "Ölçeklerde Güvenirlik ve Geçerlik." Uludağ Üniversitesi Tıp Fakültesi Dergisi, 30(3), 211-216.

Erdoğmuş, P., Çolak, B., ve Durdağ, Z., 2016 "K-Means Algoritması ile Otomatik Kümeleme." El-Cezeri Journal of Science and Engineering, 3(2).

Farley, B. W. A. C., ve Clark, W., 1954 "Simulation of Self-Organizing Systems By Digital Computer." Transactions of The IRE Professional Group On Information Theory, 4(4), 76-84.

Fiocca, R., 1982 "Account Portfolio Analysis For Strategy Development." Industrial Marketing Management, 11(1), 53-62.

Freeman, J. A., ve Skapura, D. M., 1991 Neural Networks: Algorithms, Applications, and Programming Techniques. Addison Wesley Longman Publishing Co., Inc.

Garzon, F. S., Enjolras, M., Camargo, M., ve Morel, L., 2019 "A Green Procurement Methodology Based On Kraljic Matrix For Suppliers Evaluation and Selection: A Case Study From The Chemical Sector." In Supply Chain Forum: An International Journal (Vol. 20, No. 3, pp. 185-201). Taylor & Francis.

Ghanbarizadeh, A., Heydari, J., Razmi, J., ve Bozorgi-Amiri, A., 2019 "A purchasing portfolio model for the commercial construction industry: a case study in a mega mall." Production Planning and Control, 30(15), 1283–1304.

Goffin, K., Szwejczewski, M., ve New, C., 1997 "Managing Suppliers: When Fewer Can Mean More". International Journal of Physical Distribution ve Logistics Management.

Goldberg, Y., 2017 "Neural Network Methods For Natural Language Processing." Synthesis Lectures On Human Language Technologies, 10(1), 1-309.

Goodfellow, I., Bengio, Y., Courville, A., ve Bengio, Y., 2016 Deep Learning. Cambridge: MIT Press.

Grossberg, S. E., 1988 Neural Networks and Natural Intelligence. The MIT Press.

Haykin, S., 1994 Neural Networks: A Comprehensive Foundation, Mac. Milan, New

Haykin, S., 2010 Neural Networks and Learning Machines, 3/E. Pearson Education India.

Hebb, D. O., 1949 The Organization of Behavior: A Neuropsychological Theory. J. Wiley; Chapman ve Hall.

Hopfield, J. J., 1982 "Neural Networks and Physical Systems With Emergent Collective Computational Abilities." Proceedings of the National Academy of Sciences, 79(8), 2554-2558.

Hu, C., 2002 Advanced Tourism Demand Forecasting: Artificial Neural Network and Box-Jenkins Modeling. Purdue University.

Huang, F. J., ve Lecun, Y., 2006 "Large-Scale Learning With Svm and Convolutional For Generic Object Categorization." IEEE Computer Society Conference On Computer Vision and Pattern Recognition (CVPR'06) (Vol. 1, Pp. 284-291). IEEE

Hush, D. R., ve Horne, B. G., 1993 "Progress In Supervised Neural Networks." IEEE Signal Processing Magazine, 10(1), 8-39.

Jain, N., ve Srivastava, V., 2013 "Data Mining Techniques: A Survey Paper." IJRET: International Journal of Research In Engineering and Technology, 2(11), 2319-1163.

Jothi, N., ve Husain, W., 2015 "Data Mining In Healthcare–A Review." Procedia Computer Science, 72, 306-313.

Kaastra, I., ve Boyd, M., 1996 "Designing A Neural Network For Forecasting Financial." Neurocomputing, 10, 215-236.

Kang, M., Hong, P., Bartnik, R., Park, Y., ve Ko, C., 2018 "Aligning Purchasing Portfolio Management with Sourcing Negotiation Styles." Management Decision, 56(11), 2341–2356.

Kantardzic, M., 2011 Data Mining: Concepts, Models, Methods, and Algorithms. John Wiley ve Sons.

Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., ve Tokgöz, G., 2012 "Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini." Uluslararası Yönetim İktisat ve İşletme Dergisi, 8(17), 87-100.

Karystinos, G. N., ve Pados, D. A., 2000 "On Overfitting, Generalization, and Randomly Expanded Training Sets." IEEE Transactions On Neural Networks, 11(5), 1050-1057.

Kraljic, P., 1983 "Purchasing Must Become Supply Management." Harvard Business Review, 61(5), 109-117.

Krause, D. R., 1997 "Supplier Development: Current Practices and Outcomes." International Journal of Purchasing and Materials Management, 12–19.

Kwolek, B., 2005 "Face Detection Using Convolutional Neural Networks and Gabor Filters." International Conference On Artificial Neural Networks (Pp. 551-556). Springer, Berlin, Heidelberg.

Lacity, M. C., ve Hirschheim, R. A., 1993 Information Systems Outsourcing; Myths, Metaphors, and Realities. John Wiley ve Sons, Inc..

Lambert, D. M., ve Cooper, M. C., 2000 "Issues In Supply Chain Management." Industrial Marketing Management, 29(1), 65–83.

Lambert, D. M., ve Schwieterman, M. A., 2012 "Supplier Relationship Management As A Macro Business Process." Supply Chain Management: An International Journal.

Lawrence, S., Giles, C. L., ve Tsoi, A. C., 1998 "What Size Neural Network Gives Optimal Generalization? Convergence Properties of Backpropagation."

Lawrence, S., ve Giles, C. L., 2000 "Overfitting and Neural Networks: Conjugate Gradient and Backpropagation." Proceedings of The IEEE-INNS-ENNS International Joint Conference On Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives For The New Millennium (Vol. 1, Pp. 114-119). IEEE.

Lin, L. J., 1993 Reinforcement Learning For Robots Using Neural Networks (No. CMU-CS-93-103). Carnegie-Mellon University Pittsburgh PA School of Computer Science.

Liu, Y., Starzyk, J. A., ve Zhu, Z., 2008 "Optimized Approximation Algorithm In Neural Networks Without Overfitting." IEEE Transactions On Neural Networks, 19(6), 983-995.

Lloyd, S., 1982 "Least Squares Quantization In PCM." IEEE Transactions On Information Theory, 28(2), 129-137.

Macqueen, J., 1967 "Some Methods For Classification and Analysis of Multivariate Observations." In Proceedings of The Fifth Berkeley Symposium On Mathematical Statistics and Probability (Vol. 1, No. 14, Pp. 281-297).

Mcculloch, W. S., ve Pitts, W., 1943 "A Logical Calculus of The Ideas Immanent In Nervous Activity." The Bulletin of Mathematical Biophysics, 5(4), 115-133.

Mehrotra, K., Mohan, C. K., ve Ranka, S., 1997 Elements of Artificial Neural Networks. MIT Press.

Mendelsohn, L., 1993 "Training Neural Networks." Technical Analysis of Stocks and Commodities, 11(11), 457-460.

Mendes, R., Cortez, P., Rocha, M., ve Neves, J., 2002 "Particle Swarms For Feedforward Neural Network Training." Proceedings of The 2002 International Joint Conference On Neural Networks. IJCNN'02 (Cat. No. 02CH37290) (Vol. 2, Pp. 1895-1899). IEEE.

Mentzer, J. T., Dewitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C. D., ve Zacharia, Z. G., 2001 "Defining Supply Chain Management." Journal of Business Logistics, 22(2), 1–25.

Merlo, E., Mcadam, I., ve De Mori, R., 2003 "Feed-Forward and Recurrent Neural Networks For Source Code Informal Information Analysis." Journal of Software Maintenance and Evolution: Research and Practice, 15(4), 205-244.

Metters, R., 1997 "Quantifying the Bullwhip Effect In Supply Chains." Journal of Operations Management, 15(2), 89-100.

Miller, J. D., ve Forte, R. M., 2017 Mastering Predictive Analytics With R. Packt Publishing Ltd.

Minsky, M., ve Papert, S., 1969 Perceptrons: An Essay In Computational Geometry. MIT Press.

Mitchell, V. W., ve Wilson, D. F., 1998 "Balancing Theory and Practice: A Reappraisal of Business-To-Business Segmentation." Industrial Marketing Management, 27(5), 429-445.

Monczka, R. M., Handfield, R. B., Giunipero, L. C., ve Patterson, J. L., 2015 Purchasing and Supply Chain Management. Cengage Learning.

Montgomery, R. T., Ogden, J. A., ve Boehmke, B. C., 2018 "A quantified Kraljic Portfolio Matrix: Using decision analysis for Strategic Purchasing." Journal of Purchasing and Supply Management, 24(3), 192–203.

Moss, H. B., Leslie, D. S., ve Rayson, P., 2018 "Using JK Fold Cross Validation To Reduce Variance When Tuning NLP Models"". Arxiv Preprint Arxiv:1806.07139.

Munakata, T., 2008 Fundamentals of the New Artificial Intelligence: Neural, Evolutionary, Fuzzy and More. Springer Science ve Business Media.

Nitta, T., 2003 "Solving The XOR Problem and The Detection of Symmetry Using A Single Complex-Valued Neuron." Neural Networks, 16(8), 1101-1105.

Nwankpa, C., Ijomah, W., Gachagan, A., ve Marshall, S., 2018 "Activation Functions: Comparison of Trends In Practice and Research For Deep Learning." Arxiv Preprint Arxiv:1811.03378.

Olsen, R. F., ve Ellram, L. M., 1997 "A Portfolio Approach To Supplier Relationships." Industrial Marketing Management, 26(2), 101-113.

Özdamar, K., 2004 Paket Programlar ile İstatistiksel Veri Analizi, Eskişehir: Kaan Kitabevi.

Öztürk, C., 2011 Yapay Sinir Ağlarının Yapay Arı Kolonisi Algoritması ile Eğitilmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Kayseri, Türkiye.

Özutku, H., 2002 "İnsan Kaynakları Yönetiminde Yeni Eğilimler." Verimlilik Dergisi, S, 2.

Park, J., Shin, K., Chang, T. W., ve Park, J., 2010 "An Integrative Framework For Supplier Relationship Management." Industrial Management ve Data Systems.

Parker, D. B., 1982 Learning Logic. Invention Report S81-64, File 1. Paolo Alto, CA: Stanford University, O Ce of Technology Licensing.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... ve Duchesnay, E., 2011 "Scikit-Learn: Machine Learning In Python."The Journal of Machine Learning Research, 12, 2825-2830.

Prajogo, D., ve Olhager, J., 2012 "Supply Chain Integration and Performance: The Effects of Long-Term Relationships, Information Technology and Sharing, and Logistics Integration." International Journal of Production Economics, 135(1), 514–522.

Prechelt, L., 1998 "Automatic Early Stopping Using Cross Validation: Quantifying The Criteria." Neural Networks, 11(4), 761-767.

Qian, N., 1999 "On The Momentum Term In Gradient Descent Learning Algorithms." Neural Networks, 12(1), 145-151.

Rezaei, J., ve Ortt, R., 2013 "Supplier Segmentation Using Fuzzy Logic." Industrial Marketing Management, 42(4), 507-517.

Rosenblatt, F., 1958 "The Perceptron: A Probabilistic Model For Information Storage and Organization In The Brain." Psychological Review, 65(6), 386.

Ruder, S., 2017 "An Overview of Multi-Task Learning In Deep Neural Networks." Arxiv Preprint Arxiv:1706.05098.

Rumelhart, David E., Geoffrey E. Hinton, and Ronald J. Williams., 1986 "Learning Representations By Back-Propagating Errors." Nature 323.6088, 533-536.

Sanayi ve Teknoloji Bakanlığı Kalkınma Ajansları Genel Müdürlüğü, 2021 "Tekstil Sektörü Analiz Raporu ve Kılavuzu TR31 Bölgesi (İzmir)." Sanayi ve Teknoloji Bakanlığı Kalkınma Ajansları Genel Müdürlüğü, 2021, Ankara.

Sandelands, E., 1994 "Taking The Sourness Out of Sourcing." International Journal of Physical Distribution ve Logistics Management, 24(3), 47.

Schmidhuber, J., 2019 "Unsupervised Minimax: Adversarial Curiosity, Generative Adversarial Networks, and Predictability Minimization." ArXiv Preprint arXiv:1906.04493, 102-103.

Scikit-learn, 2022 2022 Underfitting vs. Overfitting. 18 Şubat 2022 tarihinde https://scikit-learn.org/stable/auto_examples/model_selection/plot_underfitting_overfitting.html adresinden erişildi.

Seth, D., ve Rastogi, S., 2019 "Application of vendor rationalization strategy for manufacturing cycle time reduction in engineer to order (ETO) environment: A case study." Journal of Manufacturing Technology Management, 30(1), 261–290.

Shalev-Shwartz, S., Shammah, S., ve Shashua, A., 2016 "Safe, Multi-Agent, Reinforcement Learning For Autonomous Driving.". Arxiv Preprint Arxiv:1610.03295.

Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... ve Dieleman, S., 2016 "Mastering The Game of Go With Deep Neural Networks and Tree Search". Nature, 529(7587), 484-489.

Skansi, S., 2018 Introduction To Deep Learning: From Logical Calculus To Artificial Intelligence. Springer.

Skinner, B. F., 1938 The Behavior of Organisms: An Experimental Analysis. Appleton-Century.

Song, J., 1992 Hybrid genetic/gradient learning in multi-layer artificial neural networks. Wayne State University.

Spekman, R. E., Kamauff, J. W., ve Salmond, D. J., 1994 "At Last Purchasing Is Becoming Strategic." Long Range Planning, 27(2), 76-84.

Steinbuch, K., 1961 "Die Lernmatrix." Kybernetik, 1(1), 36-45.

Stevens, G. C., 1989 "Integrating The Supply Chain." International Journal Of Physical Distribution & Materials Management.

Stork, D. G., Duda, R. O., Hart, P. E., ve Stork, D., 2001 Pattern Classification. A Wiley-Interscience Publication.

Şekerli, E. B., 2019 "Ticari Havayolu Taşımacılığı Sektöründe Makine Öğrenmesi Uygulamalarının İncelenmesi." Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi, 22(2), 405-419.

Taha, H. A., 2010 Operations Research: An Introduction.

Tettamanzi, A., ve Tomassini, M., 2013 Soft Computing: Integrating Evolutionary, Neural, and Fuzzy Systems. Springer Science ve Business Media.

Trent, R. J., 2005 "Why Relationships Matter." Supply Chain Management Review, V. 9, No. 8 (Nov. 2005), P. 53-59: İll.

Tripathy, A., Agrawal, A., ve Rath, S. K., 2016 "Classification of Sentiment Reviews Using N-Gram Machine Learning Approach." Expert Systems With Applications, 57, 117-126.

TRT Haber, 2021 Toyota Üretime Ara Verecek. 25 Nisan 2022 tarihinde https://www.trthaber.com/haber/ekonomi/toyota-uretime-ara-verecek-609819.html adresinden erişildi.

TRT Haber, 2022 Avrupa'nın En Büyük Otomobil Fabrikalarından Biri Üretimi Durdurdu. 25 Nisan 2022 tarihinde https://www.trthaber.com/haber/dunya/avrupanin-en-buyuk-otomobil-fabrikalarindan-biri-uretimi-durdurdu-666118.html adresinden erişildi.

Turban, E., Aronson, J. E., ve Liang, T. P., 2005 Decision Support Systems and Intelligent System,(Sistem Pendukung Keputusan Dan Sistem Cerdas) Ed. 7. Jld. 2.

Tzortzis, G., ve Likas, A., 2014 "The Minmax K-Means Clustering Algorithm." Pattern Recognition, 47(7), 2505-2516.

Uyanık, S., ve Çelikel, D. C., 2019 "Türk Tekstil Endüstrisi Genel Durumu." Teknik Bilimler Dergisi, 9(1), 32-41.

Van Weele, A. J., 2001 Purchasing and Supply Chain Management: Analysis, Planning and Practice. Thomson Learning.

Vassilvitskii, S., ve Arthur, D., 2006 k-means++: The advantages of careful seeding. In Proceedings of The Eighteenth Annual ACM-SIAM Symposium On Discrete Algorithms (pp. 1027-1035).

EKLER

16.12.2021

İLGİLİ MAKAMA

İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme (İktisat) Anabilim Dalı'nda öğrenim görmekte olan 2501210357 numaralı Zeynep Korkmaz isimli öğrenciye, Yapay Sinir Ağları Yaklaşımı İle Tedarikçi Portföy Analizi başlıklı tezi için, firmamız tarafından akademik amaçlarla kullanılmak üzere veri kullanım izni verilmiştir.

Gereğini arz ederim.

Akın Raşel Fantezi Örme Kumaş San. Tic. A.Ş

Finans Müdürü

Arzu BERBER

AKIN RAŞEL FANTEZİ ÖRME
KUMAŞ SAN.TİC.A.Ş.
Balıhoca Mah.Büyükkanştıran OSB Cad.
No:4/1 Çorlu/Tekirdağ Muratlı/TEKİRDAĞ
Tel:0282 373 73 73 - 0282 373 75 75
Muratlı VD.027 069 34 65