

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE GÖRSEL BENZERLİKLERİN
BULUNMASI VE MÜŞTERİ SEPET ANALİZİ İLE E-
TİCARET ALIŞVERİŞLERİ İÇİN ÜRÜN ÖNERİSİ

Esra PULAT

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Sistem Mühendisliği Programı

Danışman

Prof. Dr. Selin SONER KARA

Temmuz, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME İLE GÖRSEL BENZERLİKLERİN
BULUNMASI VE MÜŞTERİ SEPET ANALİZİ İLE E-
TİCARET ALIŞVERİŞLERİ İÇİN ÜRÜN ÖNERİSİ**

Esra PULAT tarafından hazırlanan tez çalışması 11.07.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Sistem Mühendisliği Programı **YÜKSEK LİSANS** olarak kabul edilmiştir.

Prof. Dr. Selin SONER KARA
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Selin SONER KARA, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Doğan ÖZGEN, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Selin YALÇIN, Üye
Beykent Üniversitesi

Danışmanım Prof. Dr. Selin SONER KARA sorumluluğunda tarafımca hazırlanan “Derin Öğrenme ile Görsel Benzerliklerin Bulunması ve Müşteri Sepet Analizi ile E-ticaret Alışverişleri için Ürün Önerisi” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Esra PULAT

İmza



Bu çalışma, “...Yıldız Teknik Üniversitesi Bilimsel Araştırma Proje Koordinatörlüğü’nün 1234A...” numaralı projesi ile desteklenmiştir.



Desteklerini esirgemeyen aileme

TEŐEKKÜR

Bu tez alıŐmasının hazırlanmasında ve tamamlanmasında desteęini esirgemeyen, bilgi ve tecrübeleriyle bana yol gsteren, her aŐamada yanımda olan deęerli tez danıŐmanım Prof. Dr. Selin Soner Kara'ya en iten teŐekkürlerimi sunarım.

Ayrıca, alıŐmam boyunca desteklerini esirgemeyen aileme ve arkadaşlarıma da teŐekkür ederim.

Esra PULAT



İÇİNDEKİLER

TEŞEKKÜR	v
SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	1
2 LİTERATÜR	4
2.1 Derin Öğrenme	4
2.2 Müşteri Sepet Analizi	10
2.3 Müşteri Ürün Önerisi.....	13
3 YAPAY ZEKA VE GÖRSEL BENZERLİK	16
3.1 Derin Öğrenme Modellerinin Yapay Zeka İçindeki Yeri.....	16
3.1.1 Derin Öğrenme Yaklaşımları	17
3.1.1.1 Denetimli Öğrenme.....	18
3.1.1.2 Denetimsiz Öğrenme	19
3.1.1.2.1 Kümeleme	19
3.1.1.3 Yarı Denetimli Öğrenme	20
3.2 Görsel Benzerlik Alanında Kullanılan Örnek Derin Öğrenme Modelleri .	20
3.2.1 CLIP	20
3.2.2 FashionCLIP.....	22
3.2.3 CLIP ve FashionCLIP Modellerinin Çalışma Prensipleri	22
4 MÜŞTERİ SEPET ANALİZİ	24
4.1 Apriori	24
4.2 FP-Growth	25
5 GÖRSEL BENZERLİKLER İLE E-TİCARET SATIŞ VERİLERİ ÜZERİNDEN MÜŞTERİ SEPET ANALİZİ UYGULAMASI	27
5.1 Ürün Görsel Benzerliklerinin Bulunması.....	27

5.2 SonularınValidasyonu.....	27
5.2.1 Yapısal Benzerlik Endeksi	27
5.2.2 ok lekli Yapısal Benzerlik Endeksi.....	28
3.2.3 ÖYBE alıřma Prensibi	28
5.3 Apriori Algoritmasının Uygulaması.....	29
5.4 FP-Growth Algoritmasının Uygulaması.....	32
4 SONU	33
KAYNAKA	35
TEZDEN ÜRETİLMİř YAYINLAR	41



SİMGE LİSTESİ

$S(A)$	A işleminin destek değeri
V_i	Bir görselin derin öğrenme modelindeki temsilcisi
I_i	Girdi resmi
b	Hata (bias)
Destek (i)	i değişkeninin destek değeri
v_i	i görselinin vektörel olarak temsili
v_j	j görselinin vektörel olarak temsili
A	Sigmoid fonksiyonunun çıktısı
W_1	Yapay sinir ağı ağırlık değeri
W_2	Yapay sinir ağı ağırlık değeri
X_1	Yapay sinir ağı girdi değişkeni
X_2	Yapay sinir ağı girdi değişkeni
Z	Yapay sinir ağının çıktısı

KISALTMA LİSTESİ

CLIP	Contrastive Language-Image Pretraining (Karşıt Dilli Görüntü Ön Eğitimi)
ÇÖGBA	Çevrimiçi Ölçeklenebilir Görüntü Benzerliği Algoritması
ÇÖYBE	Çok Ölçekli Yapısal Benzerlik Endeksi
DVM	Destek Vektör Makineleri
FP-Growth	Frequent Pattern Growth (Sık Örüntü Büyümesi)
VTBM	Vikipedia Tabanlı Görüntü Metinleri
XOR	Exclusive OR (Özel Veya)
YEB	Yapısal Benzerlik Endeksi



ŞEKİL LİSTESİ

Şekil 2.1 Yapay sinir ağı.....	4
Şekil 2.2 Görüntü eğitme	6
Şekil 3.1 Derin öğrenmenin yapay zeka içindeki yeri.....	13
Şekil 3.2 Makine öğrenmesi yöntemleri.....	14
Şekil 3.3 Makine öğrenmesinde modeli eğitme ve test etme.....	15
Şekil 3.4 Makine öğrenmesinde metin ve görsel eşleştirme.....	17
Şekil 4.1 Örnek Karar Ağacı.....	22
Şekil 5.1 ÇÖYBE değerlerinin yoğunluk grafiği.....	25
Şekil 5.2 Benzerlik dahil edildiğinde Apriori algoritmasının sonuçları.....	27
Şekil 5.3 Klasman bazında Apriori algoritmasının sonuçları.....	27
Şekil 5.4 Benzerlik dahil edildiğinde FP-Growth algoritmasının sonuçları.....	28

TABLO LİSTESİ

Tablo 2.1 Perceptron modeli örneği.....	6
Tablo 4.1 FP-Growth örneği.....	21
Tablo 5.1 ÇÖYBE değer aralıkları.....	24
Tablo 5.2 Apriori sonuçları.....	30
Tablo 5.3 FP-Growth sonuçları.....	32



Derin Öğrenme ile Görsel Benzerliklerin Bulunması ve Müşteri Sepet Analizi ile E-ticaret Alışverişleri için Ürün Önerisi

Esra PULAT

Endüstri Mühendisliği Anabilim Dalı

Sistem Mühendisliği Programı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Selin SONER KARA

Bu çalışmanın ilk aşamasında, e-ticaret platformlarında kullanılan ürünlerin görsel benzerliklerini tespit etmek amacıyla derin öğrenme yöntemlerinin kullanılması hedeflenmiştir. Derin öğrenme, karmaşık veri yapılarını analiz etme ve ürünlerin görsel özelliklerini detaylı bir şekilde inceleyerek görsel benzerlikleri ortaya çıkarma yeteneğine sahip güçlü bir yapay zeka teknolojisidir. Bu aşamada, derin öğrenme algoritmaları kullanılarak ürünlerin görsel özellikleri ayrıntılı bir şekilde analiz edilmiş ve benzerlik kriterleri belirlenmiştir. Ardından, belirlenen benzerlik kriterleri ve derin öğrenme kullanılarak ürünler arasındaki görsel benzerlikler matematiksel olarak hesaplanmış ve benzer ürünler tespit edilmiştir.

Çalışmanın ikinci aşamasında ise, müşteri sepet analizi gerçekleştirilerek müşterilerin alışveriş davranışları incelenmiştir. Müşteri sepet analizi, müşterilerin geçmiş alışveriş deneyimlerine dayanarak alışveriş sepetine eklenen ürünler arasındaki ilişkileri belirlemektedir. Bu analiz, müşterilere kişiselleştirilmiş ürün önerileri sunmak için ürünlerin birlikte satın alınma olasılıklarını değerlendirmek amacıyla kullanılmıştır.

Sonuç olarak, bu çalışma, e-ticaret platformlarında derin öğrenme yöntemleri kullanılarak ürün görsel benzerliklerini tespit etme ve müşteri sepet analizi yapma yoluyla kişiselleştirilmiş alışveriş deneyimleri sunmada önemli bir adımı temsil etmektedir. Bu yöntemlerin etkili bir şekilde kullanılması, müşteri memnuniyetini ve e-ticaret platformlarının rekabet gücünü artırabilir. Ayrıca, müşterilerin aradıkları ürünleri bulamadıklarında, geçmiş alışveriş alışkanlıklarına dayalı ürün

önerileri sunmak müşteri kaybını azaltarak satışları artırabilir. Bu çalışmanın bulguları, e-ticaret platformlarının geliştirilmesi ve müşteri deneyimlerinin iyileştirilmesi için değerli bir kaynak olabilir.

Anahtar Kelimeler: Müşteri sepet analizi, derin öğrenme, görsel benzerlik, Apriori, FP-Growth



Finding Visual Similarities with Deep Learning and Product Recommendation for E-commerce Shopping with Customer Basket Analysis

Esra PULAT

Department of Industrial Engineering

Master of Science

Supervisor: Prof. Dr. Selin SONER KARA

In the first stage of this study, deep learning methods were aimed to be utilized to detect the visual similarities of the products used in e-commerce platforms. Deep learning is a powerful technology in the field of artificial intelligence, capable of analyzing complex data structures and revealing visual similarities by examining visual features of the products in detail. In this stage, deep learning algorithms were employed to thoroughly analyze the visual characteristics of the products and determine similarity criteria. Subsequently, using the identified similarity criteria and deep learning, the visual similarities between products were mathematically calculated, and similar products were identified.

In the second stage of the study, customer basket analysis was conducted to examine the shopping behaviors of customers. Customer basket analysis determines the relationships between the products added to the baskets based on customers' past shopping experiences. This analysis was used to provide personalized product recommendations to customers by evaluating the likelihood of products being purchased together in shopping baskets.

In conclusion, this study represents an important step in providing personalized shopping experiences by detecting product visual similarities and conducting customer basket analysis in e-commerce platforms using deep learning methods. Effectively utilizing these methods can increase customer satisfaction and enhance the competitiveness of e-commerce platforms. Furthermore, offering product recommendations based on customers' past shopping habits when they cannot find the products they are looking for can improve customer satisfaction and

increase sales. The findings of this study can serve as a valuable resource for the development and enhancement of e-commerce platforms and customer experiences.

Keywords: Customer basket analysis, deep learning, visual similarity, Apriori, FP-Growth



YILDIZ TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF SCIENCE AND ENGINEERING

1 GİRİŞ

E-ticaret sektörü günümüzde hızla büyümektedir. Bu büyüme ile birlikte müşterilere kişiselleştirilmiş alışveriş deneyimleri sunmak giderek daha önemli hale gelmiştir. Kişiselleştirilmiş ürün önerileri ile hem müşteri memnuniyetini artırma hem de satışları iyileştirme amaçlanmaktadır. Bu doğrultuda, derin öğrenme teknikleri ve müşteri sepet analizi gibi ileri veri analizi yöntemleri, e-ticaret platformlarında sunulan hizmetlerin kalitesini arttırmak için etkili araçlar olarak öne çıkmaktadır. Bu araçlarla müşterilerin geçmiş alışverişleri analiz edilerek müşteri davranışları bulunabileceği gibi, aldıkları ürünler de görsel özelliklerine göre analiz edilebilmektedir.

Karmaşık veri yapılarının analiz edilmesinde derin öğrenme metodu iyi bir performans sergilemektedir. Ayrıca derin öğrenme, yapay zeka ve makine öğrenimi alanında da önemli bir yer tutmaktadır. Görsel verilerin analize edilmesi açısından ise, derin öğrenme algoritmaları, ürünlerin görsel özelliklerini ayrıntılı bir şekilde inceleme ve benzerlerini belirleme konusunda oldukça gelişmişlerdir. Bu sayede e-ticaret platformlarında, ürün görsellerinin analiz edilmesi ve bu doğrultuda kullanıcıların ilgisini çekebilecek benzer ürünleri önermek önemli bir avantaj sağlayabilmektedir. Bu çalışmanın birinci aşamasında, derin öğrenme yöntemleri kullanılarak ürünlerin görsel benzerlikleri tespit edilmiş ve bu sayede kullanıcıların ilgisini çekebilecek ürün önerileri oluşturulmuştur.

Derin öğrenme yöntemlerinin çıkış noktası 1943 yılında ilk yapay sinir ağınnı modellenmesine kadar dayanmaktadır. Yapay sinir ağları ilk defa 1943 yılında bir sinir hekimi olan Warren McCulloch ve matematikçi Walter Pitts tarafından modellenmiştir (McCulloch ve Pitts, 1943). Bu model, tıpkı biyolojik bir sinir ağı gibi girdi olarak geçmiş verileri almakta ve bu girdilerden öğrenerek bir çıktı oluşturmayı amaçlamaktadır. Zaman içinde yapay sinir ağlarının öğrenme yetenekleri daha da gelişmiştir. Derin öğrenme modellerinin de çalışma mantığı bir sinir ağında olduğu gibi modele verilen eğitim verisinden öğrenme üzerine kuruludur. Modeller, eğitim verisi ile eğitildikten sonra, test verisi üzerinde

öğrenme kabiliyetleri test edilir. Yapılan testlerin sonuçları ile modelin ne kadar başarılı çalıştığı bulunmaktadır. Modelde kullanılan eğitim datasının büyüklüğü de modelin başarısını etkilemektedir. Günümüzde ayrıca önceden eğitilmiş modeller üzerinde çalışmalar da yapılabilmektedir. Bu sayede önceden büyük veri ile eğitilmiş modeller kullanılarak çalışmaların performansı arttırılabilmektedir.

Çalışmada diğer kullanılan bir yöntem müşteri sepet analizidir. Müşteri sepet analizi, e-ticaret platformlarında müşteri davranışlarını anlamak ve analiz etmek için kullanılan önemli bir veri analizi yöntemidir. Müşterilerin geçmiş alışveriş verileri incelenerek, sepetlerine ekledikleri ürünler arasındaki ilişkiler ortaya konabilmektedir. Bu analizler, müşterilerin gelecekteki alışveriş davranışlarını tahmin etmek ve onlara kişiselleştirilmiş ürün önerileri sunmak için kullanılabilir. Çalışmanın ikinci aşamasında, müşteri sepet analizi yapılarak müşterilerin alışveriş alışkanlıkları detaylı bir şekilde incelenmiş ve bu bilgiler doğrultusunda kişiselleştirilmiş ürün önerileri geliştirilmiştir.

Müşteri sepet analizinde en çok kullanılan iki yöntem Apriori ve FP-Growth (Frequent Pattern Growth – Sık Desen Büyümesi) algoritmaları kullanılmaktadır. Apriori ilk defa 1994 yılında Rakesh Agrawal ve Ramakrishnan Srikant tarafından oluşturulmuştur. Apriori algoritması ile bir veri kümesinde sık tekrar eden öğeler ve ilişki kuralları belirlenebilmektedir. FP-Growth ise 2000 yılında Jiawei Han vd. tarafından kullanılmaya başlanmıştır. Bu yöntem, Apriori ile aynı amaçla çalışmakta olup büyük veriyi tek seferde tarayarak bir örüntü oluşturmaya çalıştığı için Apriori'ye göre daha performanslı çalışmaktadır.

E-ticaret gibi online ya da farklı satış platformlarında da envanter yönetimi gibi farklı alanlarda müşterilerin alışverişlerinin analiz etmek için çeşitli analiz yöntemleri uygulanmaktadır. Uygulanan bu yöntemlerin amacı müşteriye en uygun ürünü sunabilmek ve böylece müşteri memnuniyetini ve satışları arttırmak olabilmektedir. Müşterilerin kişisel ve geçmiş verileri analiz ederek ürün önerisinde bulunmak en yaygın yöntemdir. Bu analizlerde gelişmiş yapay sinir ağları, derin öğrenme modelleri ve veri kümesindeki öğelerin birbirleri ile olan ilişkilerini ortaya çıkarmak için çeşitli birliktelik algoritmaları kullanılabilir.

Bu çalışma, derin öğrenme ve müşteri sepet analizi gibi veri analizi yöntemini bir araya getirerek, e-ticaret platformlarından müşterilere daha etkili ve kişiselleştirilmiş

alışveriş deneyimleri sunmak hedeflemektedir. Derin öğrenme yöntemleri, ürünlerin görsel özelliklerinin detaylı bir şekilde analiz edilmesini sağlayarak benzer ürünlerin tespit edilmesine olanak tanımaktadır. Bu görsel benzerliklerin analizi, müşterilerin ilgisini çekebilecek alternatif ürünlerin belirlenmesi için kullanılabilir. Müşteri sepet analizi ise, müşterilerin alışveriş alışkanlıklarını ve sepetlerindeki ürünler arasındaki ilişkileri ortaya koyarak, gelecekteki alışveriş davranışlarını tahmin etmeye ve kişiselleştirilmiş ürün önerileri sunmaya yardımcı olmaktadır.

Sonuç olarak, bu çalışmada, e-ticaret platformlarının müşteri memnuniyetini artırmak ve rekabet avantajı sağlamak için derin öğrenme ve müşteri sepet analizi yöntemlerini nasıl etkin bir şekilde kullanabileceğini gösterilmiştir. Bu yöntemlerin başarılı bir şekilde uygulanması, müşterilerin aradıkları ürünleri daha kolay bulmalarını sağlayarak alışveriş deneyimlerini iyileştirebilir ve e-ticaret gibi platformların satışlarını artırabilir.

2.1 Derin Öğrenme

Makine öğrenimi, mevcut bilgilerle bir problemi çözmek için model oluşturma ve eldeki verilerle bir çıktı üretme sürecidir. Bu modeller, yapay sinir ağları, karar ağaçları, kümeleme, regresyon ve derin öğrenme gibi farklı algoritmaları kullanarak verilerden öğrenmeyi adım adım gerçekleştirmekte ve anlamlı bir çıktı üretmeye çalışmaktadırlar.

Derin öğrenme yöntemi, görüntülerin işlenmesinde, doğal dil anlamada ve nesne tanıma gibi alanlarda kullanılabilir. Bu yöntemin temel amacı, öğrenilen bilgileri yeni veri kümelerine uygulamak için iyi bir genelleme yapabilmektir. En küçük hatayı bulma zorunluluğu olmayan bu yöntemin optimum sürede en iyi sonuca ulaşması amaçlanmaktadır (Seyyayer vd., 2020).

Derin öğrenme kavramı, 1940'lardan beri geliştirilen yapay sinir ağlarına dayanmaktadır. Derin öğrenme, insan beynindeki sinir ağlarını taklit eden makine öğrenmesi alanının bir alt dalıdır. Bir görevi çözmek için eğitim verisi üzerinde eğitim yapılarak derin öğrenme modelleri oluşturulur. 1943 yılında sinir hekimi Warren McCulloch ve matematikçi Walter Pitts tarafından yayımlanan 'Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap' başlıklı makale, ilk yapay sinir ağı modelini tanımlamıştır. Bir yapay sinir ağının düşüncesürecini modellemek için "eşik mantığı" olarak adlandırdıkları bir algoritma kullanmışlardır. Eşik mantığı (Threshold Logic), bir girişin belirli bir eşiğin üstünde veya altında olmasına bağlı olarak çıktı üreten bir mantık türüdür. Bu tür bir mantık, girişlerin belirli bir eşik değerini aştığında veya altında kaldığında farklı çıktılar üretir. Bu yapay sinir ağı modeli günümüzde hala sıklıkla kullanılmaktadır (McCulloch ve Pitts, 1943).

Yapay sinir ağları genellikle girdi, varsa gizli ve çıktı olmak üzere üç temel katmandan oluşmaktadırlar. Her bir katmanın içinde nöronlar ve ağırlık diye adlandırılan nöronların bağlantıları ve aktivasyon fonksiyonu bulunmaktadır.

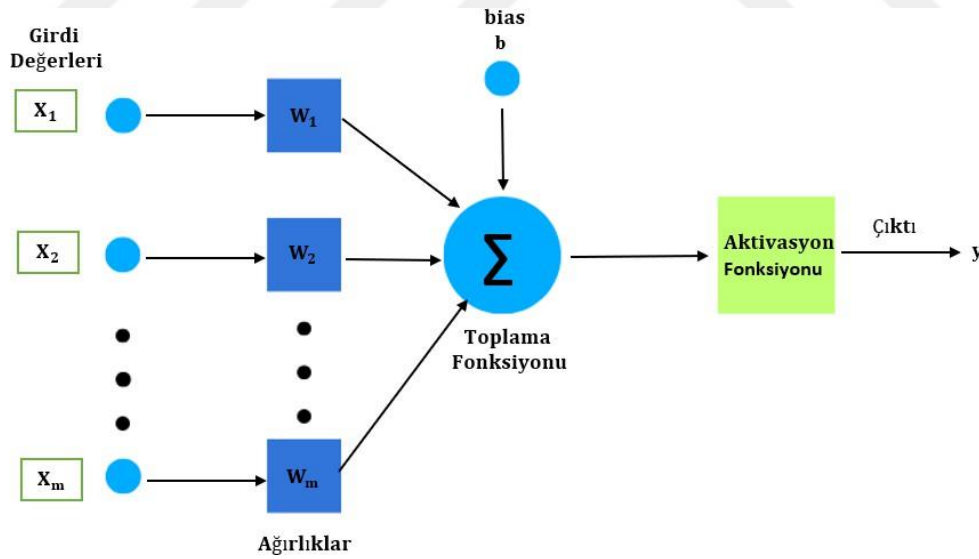
Şekil 2.1'de gösterildiği gibi girdi katmanında, sinir ağına dışarıda gelen veriler alınır. Örneğin, görüntü işleme amacıyla yapılan bir uygulama için, görüntünün her bir pikseli bir girdi nöronunu temsil edebilmektedir. Gizli katmanlar, girdi

verilerindeki karmaşık özellikleri çıkarmak ve bu özellikleri temsil etmek için kullanılır. Bu katmanlar özellikle, derin öğrenme modellerinde kullanılmaktadır. Çıktı katmanı sinir ağının tahmin veya sınıflandırma işlemlerini yapmaktadır. Bu katmandaki çıktı nöronları, ağın çıktısını vermektedir. Aktivasyon fonksiyonu çıktıyı belirli bir aralığa sıkıştırmak için kullanılır. Ağırlıklar, her bir nöronun diğer nöronlar ile arasındaki bağlantıları temsil eder. Hata, nöronların aktivasyon fonksiyonuna eklenen nöronun aktivasyonunu ayarlayan bir sabittir.

Örneğin; X_1 ve X_2 girdilerini W_1 ve W_2 ağırlıkları ile 2.1 nolu denklemdeki gibi çarpıldıktan sonra b (bias) yani hata ile toplandığında Z diye bir toplam elde edilir. Ancak bu toplamı belirli bir aralığa, 0-1 gibi, sıkıştırmak gerekebilir. Bunun için genellikle sigmoid aktivasyon fonksiyonu kullanılır ve böylece 2.2 nolu denklemdeki gibi A diye bir çıktı elde edilir.

$$Z = W_1 x X_1 + W_2 x X_2 + b \quad (2.1)$$

$$A = \frac{1}{(1 + e^{-z})} \quad (2.2)$$



Şekil 2.1 Yapay sinir ağı

1957’de Amerikalı bir psikolog ve bilgisayar bilimci olan Frank Rosenblatt tarafından basit bir yapay sinir ağı modeli olan ve makine öğrenmesi alanında önemli bir dönüm noktası olan Perceptron modelini ortaya atılmıştır. Bu model ile veriler doğrusal olarak ayrılabilen ve sınıflandırma yapılabilenkti. Örneğin

Tablo 2.1'deki tabloda olduğu gibi X_1 ve X_2 girdilerine ve W_1 ve W_2 ağırlıkları ile veriler doğrusal olarak ayrılarak 0 ya da 1 olacak şekilde bir sınıflandırma yapılmakta ve Z çıktısı üretilmektedir (Polatbilek, O. ,2020).

Tablo 2.1. Perceptron modeli örneği

X_1	X_2	W_1	W_2	b	Z
0	0	0.5	0.5	0	0
0	1	0.5	0.5	0	0
1	0	0.5	0.5	0	0
1	1	0.5	0.5	0	1

Bernard Widrow ve Ted Hoff 1960'da biraz daha gelişmiş başka yapay sinir ağı olan Adaline modelini geliştirmişlerdir. Perceptron modelinde eşik değerine göre sonuç ya 1 ya 0 olmakta iken Adaline'da ise girdilerin ağırlıklarına göre hata ve modelin sonucu hesaplanmaktadır. Bu hata sonuçlarına göre ağırlıklar güncellenmektedir (Widrow vd, 1995).

Henry J. Kelley 1960'da, derin öğrenme ve yapay sinir ağlarının eğitiminde yaygın olarak kullanılan Geri Yayılım Modelini geliştirmiştir. Geri Yayılım Modeli, yapay sinir ağlarında kullanılan bir öğrenme algoritmasıdır. Bu model, ağırlıkların ve hataların eğitim verisine göre ayarlanmasını sağlar, böylece ağ belirli bir görevi daha iyi gerçekleştirebilir hale gelir. İlk olarak 1970'lerde geliştirilen geri yayılım, yaygın olarak kullanılan ve derin öğrenme alanında önemli bir rol oynayan bir algoritmadır. Temel olarak, geri yayılım modeli, ağın çıktılarının gerçek değerlerle karşılaştırılması sonucunda oluşan hata sinyalini geriye doğru, katmanlardan başlayarak ağın içine doğru ileterek her bir ağırlığın ve hatanın güncellenmesini sağlar. Geri yayılım modeli, derin öğrenme alanında yaygın olarak kullanılan ve birçok uygulamada başarılı sonuçlar veren önemli bir öğrenme algoritmasıdır (Mizutani vd., 2000).

Ivakhnenko (1965), özellikle sınıflandırma ve regresyon problemlerinde kullanılan Grup Veri İşleme Yöntemi'ni geliştirmiştir. Bu yöntemin temel fikri, veriler arasındaki ilişkileri keşfetmek için farklı girdi değişkenlerinin grupları oluşturarak

değişken gruplarını kademeli olarak bir araya getirmektir. Bu sayede karmaşık olan problemler modellenmeye çalışılmıştır.

1969'da MIT'de çalışan Marvin Minsky ve Seymour Papert, Perceptron ile çözülemeyen XOR problemini ortaya atmışlardır. XOR problemi Tablo 2.2'de olduğu gibi girdilerin sadece bir tanesi doğru olduğunda bir sonuç üretebilmektedir, girdilerin ikisi de doğru ya da yanlış olduğunda sonuç üretmemektedir. XOR problemleri doğrusal olarak ayırlamadıklarından Perceptron modellerini çözmede yetersiz kalmaktadırlar. 1990'ın başına kadar gerek o zamanki bilgisayarların alt yapısının yetersiz kalması gerekse yapay sinir ağları modellerinin basit kalması sebepleri ile derin öğrenme alanındaki çalışmalar durağanlığa girmiştir. Çok katmanlı sinir ağlarının doğrusal olmayan ilişkileri öğrenebilmesi ile XOR problem çözülebilmiştir. Bu dönemde yaşanan ilerlemeler ile yapay zeka ve makine öğrenmesi alanında yapılan çalışmalar artmıştır (Nitta, T. ,2003).

Tablo 2.2. XOR problemi örneği

X₁	X₂	Z
0	0	0
0	1	1
1	0	1
1	1	0

1986 yılında Rumelhart vd., geri yayılım algoritmasını bulmuşlardır. Bu algoritma ile ağın hata oranını azaltmak ve başarısını arttırmak için geriye dönük olarak ağırlık ve hatalar güncellenebilmektedir (Arı, A. vd. ,2017).

1995'te Vapnik vd., makine öğrenmesi alanında sınıflandırma ve regresyon problemlerini çözmek için bir Destek Vektör Makineleri (DVM) tanıtıldı. Bu model ile hem doğrusal hem de doğrusal olmayan veri kümelerinde çalışarak sınıflandırma problemlerini çözebilmektedir (Tan, Y., ve Wang, J. ,2004).

Hinton ve Ruslan'ın 2006 yılında derin sinir ağları alanında önemli katkıları olmuştur. Derin sinir ağına eklenen gizli katmanlara sahip olan bu sinir ağları ile daha karmaşık ilişkiler öğrenilebilmektedir (Şeker, A. vd. ,2017).

Derin Öğrenme'nin bir sonraki önemli adımını, bilgisayarların işlem gücünün artması ve grafik işlem birimlerinin geliştirilmesiyle 1999 yılında gerçekleştirmiştir. Grafik işlem birimleri, işlem hızını 10 yılda 1000 kat artırarak veri işleme sürelerini büyük ölçüde azaltmıştı. Bu dönemde, sinir ağları destek vektör makineleriyle rekabet etmeye başladı. Sinir ağları, aynı veri setini kullanarak destek vektör makinelerine göre daha iyi sonuçlar sunmasına rağmen dahayavaştı. Bununla birlikte, yapay sinir ağları, daha fazla eğitim verisi ekledikçe sürekli olarak gelişme avantajına sahiptir. Stanford Üniversitesi'nde yapay zeka profesörü olan Fei-Fei Li vd. (2009), ImageNet'i tanıttı ve 14 milyondan fazla etiketlenmiş görüntüden oluşan ücretsiz bir veritabanı oluşturdu. İnternete etiketlenmemiş görüntüler çok fazlaydı ve yapay sinir ağlarını eğitmek için etiketlenmiş görüntülerin kullanılması gerekiyordu.

2012'de AlexNet'in ImageNet yarışmasında büyük bir başarı elde etmesi, derin öğrenmenin popülerliğini artırdı ve görsel benzerlikle ilgili çalışmaların daha fazla dikkat çekmesine yol açtı. AlexNet'in başarısından sonra, birçok araştırmacı ve grup, benzer derin öğrenme tekniklerini görüntü benzerlik araması, görsel eşleştirme ve görüntü sınıflandırma gibi çeşitli görevlerde kullanmaya başladı. Bu alandaki araştırmaların hızla yayılmasıyla, görsel benzerlikle ilgili derin öğrenme yöntemleri 2010'ların ortalarından itibaren giderek daha yaygın hale geldi. Görsel benzerlikle ilgili derin öğrenme yöntemleri, bugün birçok uygulama alanında kullanılmakta ve sürekli olarak geliştirilmektedir. Bu teknikler, arama motorlarından medya içeriği işleme ve tıbbi görüntüleme alanına kadar geniş bir alanda uygulanmaktadır (Alom vd., 2018).

Günümüzde Yapay Zeka'nın evrimi, Derin Öğrenme ile sıkı sıkıya bağlantılıdır ve gelişmeye devam etmektedir. Karpathy ve Fei-Fei (2015), Şekil 2.2'deki gibi görüntü ve cümleler ile oluşturdukları veri kümesini eğiterek verilen görüntü bölgelerinin doğal dil açıklamalarını üretmişlerdir.



Şekil 0.2 Görüntü eğitme

Faghri vd. (2017), benzer şekilde verilen bir görüntüyü, kayıp fonksiyonu en az olacak şekilde doğru bir şekilde açıklayacak bir model üzerinde çalıştılar, Kayıp fonksiyonu, bir makine öğrenimi modelinin eğitimi sırasında, gerçek değerlerle tahmin edilen değerler arasındaki farkı ölçen bir metriktir. Çalışmalarının sonucunda, önerilen yeni kayıp fonksiyonu, performansı önemli ölçüde artırdığı görülmüştür.

2021 yılında önceden eğitilmiş derin öğrenme modellerinde artış oldu. Yao vd. ince detaylara odaklanan ve kelimeleri ve görüntü yamalarını daha hassas bir şekilde eşleştiren bir yapıya sahip FILIP (büyük ölçekli İnteraktif Dil-Görüntü Önceden Eğitim -Fine-grained Interactive Language-Image Pre-training) modelini tanıttılar.

Zeng vd (2021), verilen görsellerdeki nesnelere metne aktarmayı sağlayan X-VLM modelini geliştirdiler. X-VLM modeli, özellikle görüntü dil modellerinin kullanıldığı görevlerde, önceki yöntemlere kıyasla daha iyi sonuçlar elde etmiştir.

Wan vd. (2014), İçerik Tabanlı Görüntü Arama alanında evrimsel sinir ağı kullanmışlardır. Derin modellerin sınıflandırma veya benzerlik öğrenme amacıyla yeniden eğitilmesi durumunda, geri alım performansının ve bunun sonucunda modelin bulunduğu sonuçların doğruluğunun önemli ölçüde arttığını bulmuşlardır.

Diğer yandan, e-ticaretteki görüntü-metin eşleştirme görevi, genel veri kümelerinden farklı zorluklar içerir. Özellikle, ürün açıklamaları genellikle parçalı cümlelerden oluşmayabilirken, ürün görüntülerinde çok fazla nesne olabilmektedir. Bu özellikler, genel alan modellerinin e-ticaret verilerine doğrudan uygulanmasını zorlaştırmaktadır.

Chechik ve Shalit (2010), büyük veri kümelerinde görüntü benzerlik öğrenimi için ÇÖGBA (OASIS - Online Algorithm for Scalable Image Similarity) adlı çevrimiçi

bir model oluřturdular. Bu model, büyük veri kümelerinde hızlı ve doğru sonuçlar elde etmiştir. Yapılan insan değerlendirmeleri, ÇÖGBA'nın büyük ölçekli veri kümelerinde anlamlı benzerlikler öğrenebildiğini göstermektedir.

Wu vd. (2015), bir veri kümesindeki öğeler arasındaki benzerlik metriğini iyileřtirmek için çoklu sinir ağlarını birleřirerek kullanmışlardır. Yapılan deneyler sonucunda önerilen yöntem etkin sonuçlar vermiştir.

Bell ve Bala (2015), evriřimli sinir ağı kullanarak girdi olarak ürün resimlerini alıp, bunlara benzer ürünleri bulan bir görsel arama uygulaması yapmışlardır.

CLIP, OpenAI tarafından Ocak 2021'de tanıtıldı. Bu model, metin ve görüntü verilerini aynı uzayda temsil etmek için kontrastif öğrenme prensiplerinedayarak eğitildi. CLIP, geniş bir nesne tanıma ve metin anlama yeteneğiyle öne çıktı ve çeşitli görsel ve dil görevlerinde etkileyici sonuçlar gösterdi (Carlsson vd., 2022). FashionClip modeli de, moda verileri üzerinde eğitilmiş bir CLIP modelidir.

2.2 Müşteri Sepet Analizi

Müşteri sepet analizi, bir işletmenin müşterilerinin alışveriş sepetlerindeki ürünleri inceleyerek alışveriş davranışlarını anlamak için kullandığı bir analiz yöntemidir. Bu analiz, müşterilerin satın alma alışkanlıklarını, tercihlerini ve eğilimlerini belirlemek için kullanılır. Müşteri sepet analizi genellikle e-ticaret siteleri veya perakende mağazaları gibi işletmelerde kullanılarak, stok yönetimini geliřtirmek, pazarlama stratejilerini optimize etmek ve müşteri memnuniyetini artırmak amacıyla kullanılır. Bu analiz genellikle geçmiş satın alma verilerinin incelenmesiyle gerçekleştirilir ve işletmelerin daha etkili kararlar almasına yardımcı olur.

Müşteri sepet analizlerinde en çok kullanılan yöntemler Apriori ve FP-Growth algoritmalarıdır. Rakesh Agrawal, veri madenciliği ve veritabanı sistemleri alanında çalışmış bir bilim adamıdır, özellikle Microsoft ve IBM arařtırma merkezlerinde önemli roller üstlenmiştir. Agrawal, sık görülen desenlerin keşfi ve veri madenciliği algoritmaları üzerine yoğunlaşarak alanda önemli katkılar sağlamıştır. Özellikle FP-Growth ve Apriori gibi sık görülen desenlerin keşfi için kritik algoritmaların geliřtirilmesinde etkili olmuştur.

Apriori algoritması, Rakesh Agrawal ve Ramakrishnan Srikant tarafından 1994 yılında "Fast Algorithms for Mining Association Rules" başlıklı bir makalede tanıtılmıştır. Bu çalışma, IBM Almaden Araştırma Merkezi'nde gerçekleştirilmiştir. Birliktelik analizi ve veri madenciliği alanında temel bir Teknik olan Apriori algoritması tanıldıktan sonra geniş bir alandan kullanılmaya başlanmıştır. Pazar sepeti analizi gibi alanlarda sıkça kullanılan bu algoritma, veri kümesindeki öğeler arasındaki ilişkileri ortaya çıkararak birlikte satma olasılığı yüksek ürünler gibi çıktılar üretebilir (Agrawal ve Srikant, 1994).

2000'lerin başlarından itibaren, internet alışverişi ve çevrimiçi perakendecilik hızla yaygınlaşmaya başladı. Bu durum, müşteri sepet analizinin önemini artırdı, çünkü çevrimiçi alışveriş platformları, müşteri davranışlarını daha ayrıntılı olarak takip etme ve analiz etme imkanı sağladı.

Mansura ve Kuncoroa (2012), yapay sinir ağlarını kullanarak küçük ve orta ölçekli işletmeler için envanter yönetimini geliştirmeye odaklandılar. Uyguladıkları yöntem ile en sık satan ürünleri envanterde tutabilmek için öneri sistemi kurdular.

Mustakim vd. (2018), FP-Growth algoritmasıyla Market Basket Analysis önerilmiştir ve bu yöntem, bir market zincirinde ürün yerleşimini ve malzeme bulunurluğu planlamasını belirlemek için kullanılmıştır. Deneysel sonuçlar, FP-Growth algoritmasının tüketici alışveriş desenini hızlı ve etkili bir şekilde analiz edebildiğini ve marketin gelirini artırabildiğini göstermektedir.

Kurnia (2019), veri madenciliği ve apriori algoritmaları ile, O! Fish restoranının satış desenlerini analiz etmede kullanmıştır. Çalışmasında, tüketici satın alma desenlerinde ürün birliktelik kuralları belirleyerek, doğru hedefe yönelik ve etkili promosyon stratejileri geliştirmiştir.

Hossain vd. (2019), FP-Growth ve Apriori algoritmalarını performans yönünden incelemişlerdir. Biri Fransız bir perakende mağazasından diğeri bir fırın dükkanından alınan iki farklı veri seti üzerinde çalışmışlardır. Sonuçlara göre FP-Growth algoritması için daha hızlı ve pratik sonuçlar çıkarmıştır.

Pathan vd. (2019), kural seti oluşturarak ve Apriori algoritması ile müşteri sepet analizi yapmışlardır. Sonuç olarak, bu karşılaştırma, her iki yöntemin de benzer sonuçlar ürettiğini göstermişlerdir.

Adnyana vd. (2020), gıda stoklarının tedariki için müşteri Sepet analizinin Apriori algoritmasını ele aldıkları bir çalışma yapmışlardır. Bir kahve zinciri için yaptıkları çalışmada müşteri sepet analizinin sonuçlarına göre hangi ürünleri daha fazla tutmaları gerektiğini ve ne kadar sipariş verilmesi gerektiğini belirlemişlerdir (Adnyana vd., 2020).

Qisman vd. (2021) tarafından yapılan bir çalışmada bilgisayar ve aksesuarları satan bir firma için ürün yerleşimlerinin planlanması gerekmektedir. Apriori algoritması ile müşteri sepet analizi yapılmıştır. Araştırma, laptop şarj cihazı alan müşterilerin klavye ve laptop alanların ise fare de aldığını göstermiştir (Qisman vd., 2021).

Aldino vd. (2021), Toko Warga adlı bir bakkalın işlem verileri üzerinde yapılan bir analizde, birliktelik kuralları madenciliği (Market Basket Analysis) yöntemi kullanılmıştır. Fp-Growth ve Apriori algoritmalarıyla karşılaştırma yapılarak, Fp-Growth algoritmasının daha iyi sonuçlar verdiği belirlenmiştir. Bu yöntemin, tüketici satın alma desenlerini belirlemek ve promosyon stratejilerini geliştirmek için kullanılabileceğini öne sürmüşlerdir.

Nurmayanti vd. (2021), dağcılık ve doğa malzemeleri satan bir mağaza için Apriori ve FP-Growth algoritmaları ile müşteri sepet analizi yapmışlardır. Çalışmanın sonucunda Apriori algoritmasının daha fazla sonuç ürettiği görülmüştür.

Idris vd. (2022), tarafından yapılan bir çalışmada, bakkallarda yapılan alışveriş desenlerini aramak ve ardından mevsimlere göre analiz etmek için müşteri sepet analizi uygulanmıştır. Araştırmanın amacı, tüketici işlem davranışlarını belirlemede ve müşteri sepet analizinde elde edilen verilere dayanarak birkaç mevsimde tüketici işlemlerinin miktarını hesaplamada Apriori ve FP-Growth yöntemlerini karşılaştırmaktır. Çalışmanın sonuçlarına göre, FP-Growth, Apriori göre daha iyi performansa sahip olmakla birlikte, daha fazla bellek kullanmaktadır (Idris et al., 2022).

Rosli ve Teo'nun (2022) çalışması, "Market Basket Analysis using Apriori Algorithm: Grocery Items Recommendation" başlığı altında 3. Auckland Uluslararası Sosyal Bilimler, Eğitim, Girişimcilik ve Teknoloji Konferansı'nda sunulmuştur. Çalışma, market sepeti analizi için Apriori Algoritması'nın kullanımını ele almaktadır ve bu algoritma üzerinden market alışveriş öğeleri

önerisi sunmaktadır. Araştırma, geçmiş market alışveriş veri setine dayanarak Apriori Algoritması'nın kullanımının başarılı olduğunu ve önerilen öge setlerini etkin bir şekilde belirlediğini göstermektedir.

Tripathi ve Pandey'in (2022), kozmetik ürünlerin birlikte satın alınma desenlerini belirlemek için müşteri sepeti analizini yapmışlardır., yapılmıştır. Çalışmada Apriori Algoritması kullanılmıştır. Elde edilen sonuçlar, kozmetik ürünler arasındaki ilişkileri ve birlikte satın alınma olasılıklarını ortaya koymaktadır. Elde edilen sonuçlar, ek satın almaları teşvik etmek için ekranlar tasarlamak, özel fırsatlar sunmak ve yeni ürün paketleri oluşturmak için kullanılabilir.

Rao ve Kiran (2023), sağlık alanında müşteri sepet analizi uygulanması yapmışlardır. Çalışmalarında, Apriori algoritmasını kullanarak bir bölgede birlikte sıkça görülen hastalıkları bulmayı amaçlamışlardır. Böylece, bir bölgedeki sakinlerin sıkça ortaya çıkan hastalıklara daha dikkatli olmalarını ve sağlıklarını korumak için gerekli önlemleri almalarını sağlayabilir. Ayrıca, doktorlara hastaları tedavi etmek için gereken ilaçlarla hazır olmalarında yardımcı olabilir. Bu çalışma, sağlık sektöründe müşteri sepet analizinin sağlık hizmetlerindeki önemini vurgulamaktadır (Rao ve Kiran, 2023).

Saputra vd. (2023), Silvia Anggun Rahayu, Taqwa Hariguna, FP-Growth algoritması ile yapılan müşteri sepet analizi yaparak, müşteri satın alma modellerini belirlemişlerdir, müşteri ihtiyaçlarına uygun ürün önerileri yaparak ve satışları arttırmayı amaçlamışlardır.

2.3 Müşteri Ürün Önerisi

Dong vd. (2013), AHP, K-means kümeleme, pazar sepeti analizi ve uzman sistem temelli bir yaklaşımı birleştirerek akıllı bir giyim öneri sistemi tasarımı önermişlerdir. Veri tabanı yönetimi ve uzman sistem teknolojisinin kapsamlı bir şekilde kullanılmasıyla, önerilen sistem müşteri alışveriş deneyimini iyileştirmek için kural tabanlı bir çözüm sunmaktadır.

Hsiao ve Li (2014), mevcut e-ticaret alışveriş siteleri öneri sistemlerinde kullanıcı profilleri ve kullanıcıların arattığı metinler kullanarak önerilerde bulunulur. Ancak, kullanıcı niyetlerinin ve ürünler arasındaki görsel benzerliğin göz ardı edilmesi nedeniyle bu yaklaşımlar kullanıcılara ilgisiz öneriler üretebilir.

Çalışmalarında, ürün çeşitliliğini ve görsel benzerliği dikkate alan etkileşimli bir ürün önerisi yöntemi önermişlerdir. Bu yöntem, kullanıcının gerçek niyetini etkileşimli bir şekilde yakalamayı ve kullanıcının gerçek ürün ilgi alanlarına dayanarak ürün önerisi sonuçlarını iyileştirmeyi amaçlamaktadır. GrabCut görüntü segmentasyon algoritması ile ürünlerin görsel özellikleri renk üzerinden kırmızı-yeşil-mavi değerleri ile tanımlanmaktadır. Müşteri bilgileri ve alışveriş tercihlerindeki renk özelliklerine göre önerilen algoritma, deneysel olarak değerlendirilmiş ve geleneksel yaklaşımlara göre öneri doğruluğunu önemli ölçüde artırdığı gösterilmiştir.

Kiapour vd. (2015), online alışveriş sitelerinden ve sokak görüntülerinden oluşan 2 farklı data seti oluşturmuşlardır. Bu veri seti ile gerçek dünyadan verilen bir görüntünün online alışveriş sitesinde benzer bir ürünün derin öğrenme yöntemiyle bulabilmesini amaçlamışlardır. Yaptıkları deneylerde, öğrenilmiş benzerlik ölçüsünün mevcut derin öğrenme tabanlı temsil kullanarak elde edilen modellere göre önemli ölçüde daha iyi performans sergilediğini göstermektedir.

Peifeng vd. (2016), kullanıcının boyu, benzerliği, kıyafet deseni, gerçek zamanlı hava durumu gibi çok boyutlu faktörlere göre yapılan karar matrisi ürün önerisinde bulunmayı amaçlamışlardır. Bu çalışmaları, kullanıcıların kişisel giyim kombinasyonlarını optimize etmelerine, giyimleri etkili bir şekilde yönetmelerine, giyim ve giyim anlayışlarını güçlendirmelerine olanak tanıyarak tatmin edici sonuçlar elde etmiştir.

Heinz vd. (2017), tekrar eden yapısıyla bilinen bir yapay sinir ağı türü olan RNN ile Zalando adlı online moda platformunda sık alışveriş yapan 100.000 müşterinin satış verileri üzerinde yapılan deneyimleri incelemişlerdir. Zamanla değişen müşteri stili ve alışveriş alışkanlıklarına göre öneri sunmayı amaçlamışlardır .

Hwangbo vd. (2018), müşteri geçmiş alışveriş bilgileri ve mevsimsellik etkisi ile bir ürün öneri modeli tasarlamışlardır. Bu öneri sisteminin performansı geleneksel filtreleme sistemlerinden daha etkili olduğunu sonucuna varılmıştır.

Garude vd. (2019), K-means ve karar ağacı ile müşteri cilt renk tonuna ve müşteri bilgilerine göre öneri yapılabilir bir sistem üzerinde çalışmışlardır. Öneri sisteminin cilt tonu ve uygun duruma dayalı olarak kullanıcılara kıyafet önerileri

sunmayı amaçladığını ve gelecekte daha geniş bir kapsama ve daha yüksek doğruluk seviyelerine ulaşmayı hedeflediğini göstermektedir.

Wan ve Niu (2019), Geleneksel giyim alışveriş sitelerinde geniş bir seçenek arasından uygun giysileri seçmekte zorlanan müşteriler için, müşteri tercihlerini Analitik Hiyerarşi Prosesi (AHP) tekniği ile analiz eden, giysilerin korelasyonlarına göre küme oluşturan ve pazar sepetini analiz eden bir sistem geliştirilmişlerdir.

AY vd. (2019), ayakkabı satışı yapılan online bir alışveriş sitesinde benzer görüntüleri bulmak için iki yapay sinir ağından oluşan bir görüntü algoritması kullanmışlardır. Kullanılan bu derin öğrenmeye dayalı model ile hassasiyet ve zaman açısından üstün performans elde etmişlerdir.

Hiriyannaiyah vd. (2022), çalışmalarında, görsel öneri için benzerlik metrikleri kullanarak bir derin öğrenme tabanlı model önermişlerdir. Önerdikleri bu yöntem ile, görsel ve metinsel öneri sistemleri ile kullanıcı profillerinin hem görsel hem de metinsel açıdan birleştirmek için kullanılabilir.

Yapay Zeka ve Görsel Benzerlik


3.1 Derin Öğrenme Modellerinin Yapay Zeka İçindeki Yeri

Yapay zeka, belirli görevleri yerine getirmek için insan düşünme biçimini taklit eden ve topladıkları bilgiler ile kendilerini geliştirebilen sistemlerdir. Bu sistemler, öğrenme, algılama, karar verme, dil anlama ve problem çözme gibi birçok alanda araştırma ve geliştirme yapabilmektedirler.

Makine öğrenimi, bir bilgisayarın veriden öğrenerek belirli bir görevi yerine getirmeyi amaçlayan yapay zeka altında bir alandır. İstatistiksel yöntemler kullanılarak modeller oluşturulması ve bu modellerin eğitilerek sonuçların iyileştirilmesi ile makine öğrenimi yapılmaktadır.

Yapay sinir ağları, biyolojik sinir sistemlerinden örnek alınarak tasarlanmış matematiksel modellerdir. Giriş verilerini işleyerek ve karmaşık ilişkileri öğrenerek çıktı üretmek amaçlanmaktadır. Bu alanda çalışan araştırmacıların ana hedefi insan düşünme sistemine yakın zeki sistemlerin tasarlanması olmuştur. İnsan düşünme sistemini modellemek ve insan karar alma sistemini yapay zeka sistemlerine uyarlamaya çalışmışlardır. 1943'te ilk yapay sinir ağının modellenmesinden sonra, daha gelişmiş modeller ilerleyen yıllarda yapılmıştır (İnik, Ö., ve Ülker, E. 2017).

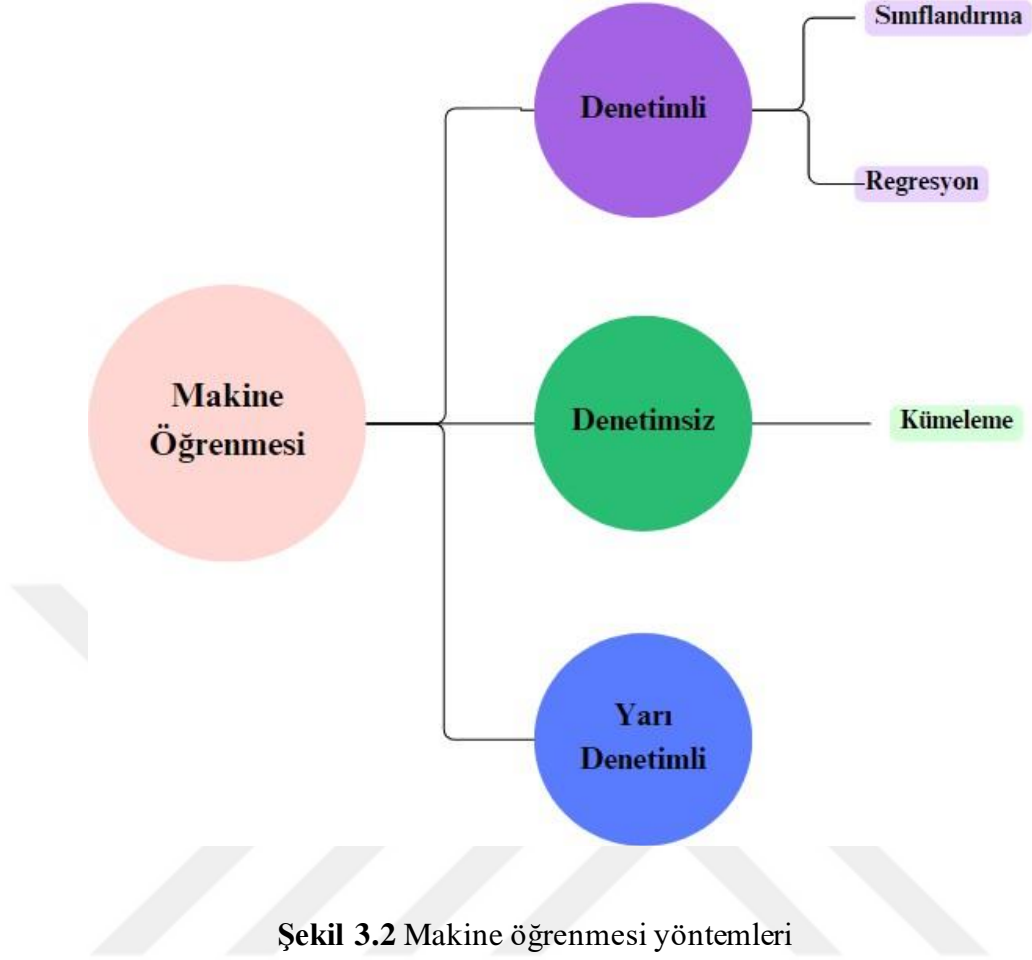
Derin öğrenme ise, Şekil 3.1'de gösterildiği gibi karmaşık görevleri gerçekleştirmek için çok katmanlı sinir ağlarını kullanan bir makine öğrenimi alt dalıdır. Büyük veri kümelerinden öğrenme yeteneğiyle daha çok bilinse de görüntü tanıma, doğal dil işleme ve yapay zeka gibi pek çok alanlarda kullanılmaktadır. Derin öğrenme modelleri ilk defa 2012 yılında yapılan Büyük Ölçekli Görsel Tanıma Yarışması'ndaki ortaya atılan modellerin hata oranlarının ciddi miktarda düşük olması ile popülerliği artmış ve bu yıldan sonra derin öğrenme alanında yapılan çalışmalar da artış göstermiştir.



Şekil 3.1 Derin öğrenmenin yapay zeka içindeki yeri

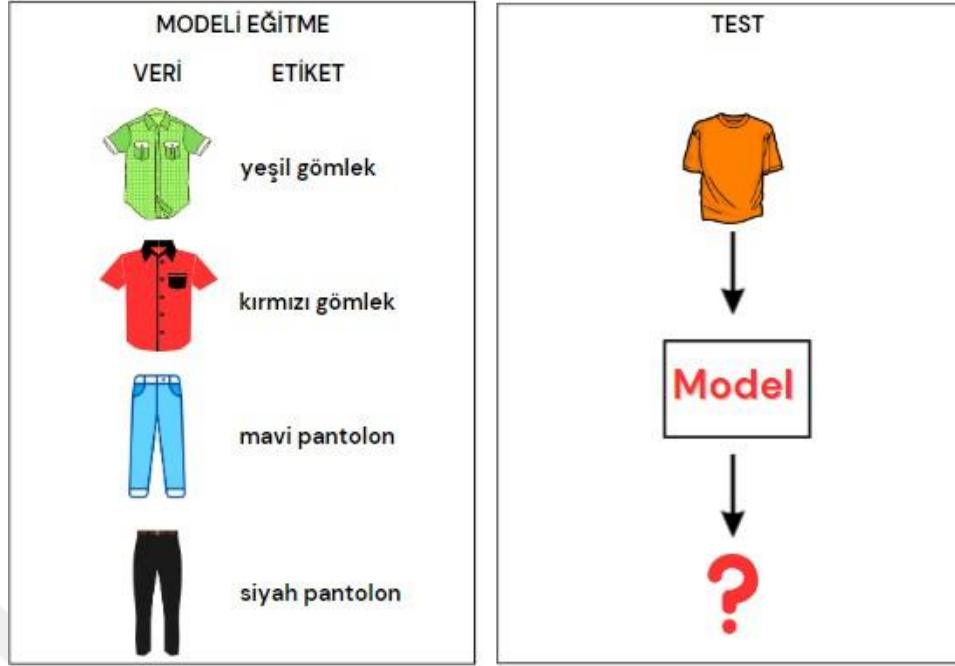
3.1.1 Derin Öğrenme Yaklaşımları

Derin öğrenme yöntemleri ile büyük veriden anlamlı veriler çıkararak, hata oranının en az olabileceği modeller tasarlanmaktadır. Makine öğrenmesinin bir alt sınıfı olan derin öğrenme Şekil 3.2'deki gibi denetimli, denetimsiz yarı denetimli veya kısmen denetimli öğrenme şeklinde sınıflandırılabilir. Bu sınıflandırmalarının etiketli olup olmamasına göre yapılmaktadır. Etiketli veri ile sınıflandırma yapılabilmektedir, denetimli öğrenme yöntemlerinde etiketli veriler kullanılırken, denetimsiz öğrenme tekniklerinde etiketsiz veriler üzerinden kümeleme yapılmaktadır. Yarı denetimli yöntemlerde ise hem etiketli hem etiketsiz veri kullanılmaktadır (Yılmaz, P., 2022).



3.1.1.1 Denetimli Öğrenme

Denetimli öğrenme, etiketlenmiş veri kullanarak modellerin eğitildiği bir öğrenme yöntemidir (Chechik ve Shalit, 2010). Bu yöntemde, eğitim verileri, modelin bir öğretmen gibi eğitilmesine olanak sağlar. Şekil 3.3'te modele örnek resimler ve tanımları öğretilerek test amacıyla verilen kıyafetin özelliklerini söylemesi beklenmektedir. Denetimli öğrenme, genellikle regresyon ve sınıflandırma problemlerinde kullanılır. Regresyon problemleri örneğin, bir evin fiyatını tahmin etmek gibi genellikle sürekli bir çıktı tahmini yapmayı amaçlar. Sınıflandırma problemleri ise, bir girdiyi belirli bir sınıfa veya kategoriye atayan bir model oluşturmayı amaçlar. Sınıflandırma problemlerine, bir e-postanın spam veya spam olmayan olarak sınıflandırılması örnek olarak verilebilir (Gökalp, 2022).



Şekil 3.3 Makine öğrenmesinde modeli eğitme ve test etme

3.1.1.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketlenmemiş verilerdeki iç görüleri ve ilişkileri ortaya çıkarır. Eğitim sürecinde etiketsiz veriler kullanılır ve sistem bu verilerden anlamlar çıkararak öğrenir. Sonuçlar önceden bilinmez ve eğitim ve gözetim dışı sonuçlar üretebilir. Denetimsiz öğrenme modeli, verileri gruplayarak benzerlik veya farklılıkları belirler. Örneğin, meyve verilerinden muzları ve elmaları ayrı gruplara ayırabilir ve benzer veya farklı olanları listeleyebilir. Bu sistemler, YouTube video önerileri, Facebook arkadaşlık önerileri, gruplar veya sayfaları ve Netflix video önerileri gibi çeşitli alanlarda kullanılabilir (Gökalp, 2022).

3.1.1.2.1 Kümeleme

Kümeleme, öncesinde herhangi bir etiketleme yapılmayan verileri bir araya getirerek bunların gruplanmasını sağlayan bir yöntemdir. Bu doğrultuda benzer özelliklere sahip veriler bir arada toplanarak kümelenebilmektedir. Örneğin, müşteri segmentasyonu yapabilmek için kümeleme yöntemi ile benzer özelliklere sahip müşteriler gruplanabilir (Gökalp, 2022).

3.1.1.3 Yarı Denetimli Öğrenme

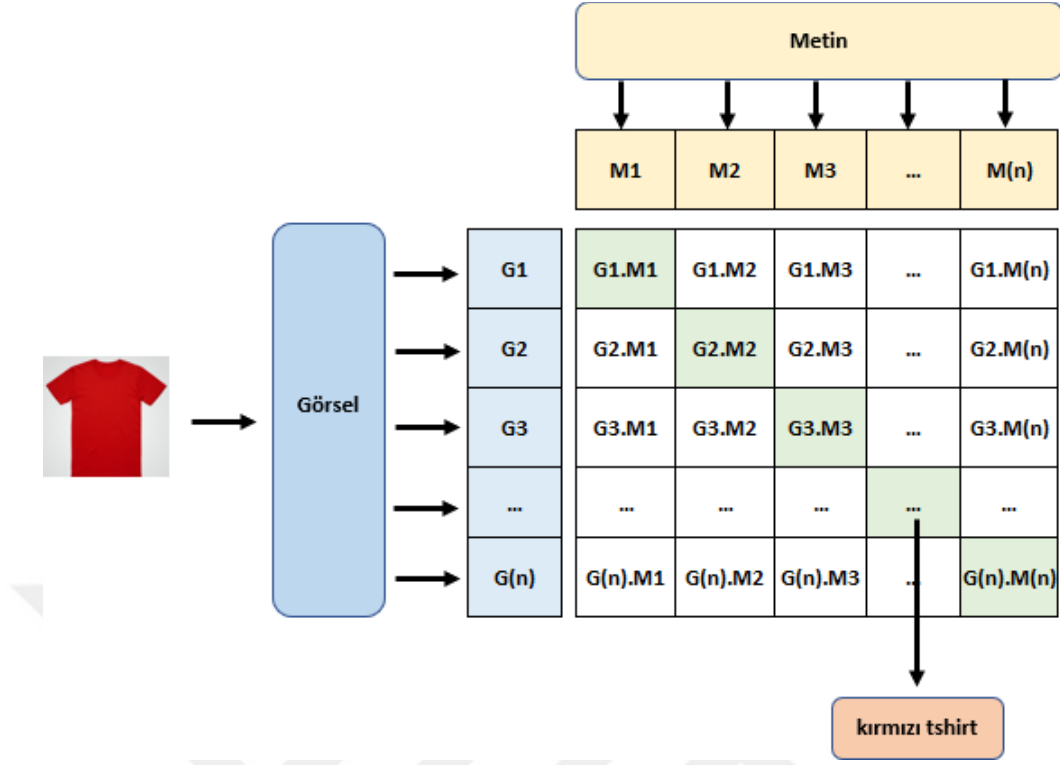
Bu yöntemde, hem denetimli hem de denetimsiz öğrenmeyi bir arada kullanılmaktadır. Küçük miktarda etiketli veri ve büyük miktarda etiketsiz veri kullanılarak sistemlerin eğitilmesine mantığına dayanmaktadır. İlk olarak, kısmen eğitilmiş bir makine öğrenimi algoritması etiketli verilerle eğitilir. Daha sonra, bu kısmen eğitilmiş algoritma etiketsiz verileri etiketler. Bu sürece sahte etiketleme (psödo-etiketleme) denilmektedir. Bu yöntemin avantajı, büyük miktarda etiketli veriye ihtiyaç duyulmamasıdır. Özellikle, insanlar tarafından okunup etiketlenmesi çok zaman alacak uzun belgeler üzerinde çalışırken bu yöntem kullanılabilir (Kızılkaya, Y. vd., 2018).

3.2 Görsel Benzerlik Alanında Kullanılan Örnek Derin Öğrenme Modelleri

3.2.1 CLIP

Son yıllarda, doğrudan görseller ve bunların açıklamaları eğitilme üzerine kurulu ile ham metinden öğrenme tabanlı ön eğitim yöntemleri, doğal dil işleme alanında büyük bir dönüşüm yaşatmıştır. Doğal dil işlemede, insan dilinin bilgisayarlar tarafından anlaşılması, yorumlanması ve işlenmesine odaklanılmaktadır.

Bu yöntemler, metinleri işlemek için hesaplama gücünün artmasıyla birlikte geniş çapta kullanılabilir hale gelmişlerdir. Doğal dil denetimiyle eğitilmiş bir model olan CLIP 2021 tarihinde OpenAI tarafından geliştirilmiştir. Bu model ile hem metin hem görsel veri eş zamanlı olarak analiz edilebilmektedir. CLIP modeli, görüntü sınıflandırma, içerik arama, doğal dil işleme ve bilgisayarla görme sistemlerinde kullanılmaktadır. Bu alanda yapılacak olan çalışmalar modellerin öğrenme yeteneklerini ve yaygınlığını arttırması beklenmektedir (Carlsson, F. vd., 2022).



Şekil 3.4 Makine öğrenmesinde metin ve görsel eşleştirme

Şekil 3.4'te gösterildiği gibi girilen metinler ile görseller eşleştirilerek modeller eğitilir. Bu eğitilmiş modeller sayesinde 'kırmızı tshirt' gibi bir metin girildiğinde model görseller içerisinde buna benzer bir görseli bulabilir.

CLIP modeli, Doğal Dil Denetimi ile görüntüleri anlamak için doğal dil talimatlarını kullanma fikrine dayanmaktadır. Bu modelde, görüntü ve metin eşleştirmesi yaparak bir model eğitilir. Bu yöntem, standart etiketleme yöntemlerine göre daha kolay olmaktadır. Çünkü doğal dilin zengin kaynağını kullanır. Bu sayede model, internet üzerindeki metinlerden pasif olarak öğrenir ve sadece nesnelere tanımakla kalmaz, aynı zamanda bunları doğal dilde ifade ederek esnek bir şekilde yeni görevlere adapte olabilir.

Yeterince büyük bir veri seti oluşturmak, bilgisayar görüşü ve doğal dil işleme gibi çeşitli alanlarda sağlam modellerin eğitilmesi için önemlidir. Bu amaçla araştırmacılar, geniş kapsamlı ve çeşitli bir veri seti olan VTBM'yi (WBT-Wikipedia based Image Text) oluşturarak modelleri eğitmişlerdir. VTBM, internetten toplanan 400 milyon (görüntü, metin) çiftinden oluşmaktadır.

CLIP, yaygın nesnelere tanımda başarılı olsa da, soyut veya karmaşık görevlerde zorlanmaktadır. Özellikle, resimlerdeki nesne sayısını tahmin etme veya en yakındaki aracın konumunu belirleme gibi görevlerde performansı düşük kalabilmektedir. Aynı şekilde, daha detaylı sınıflandırma görevlerinde, örneğin araba modellerini veya çiçek türlerini ayırt etme başarısız olabilmektedir. Ön eğitim veri setinde bulunmayan resimlere karşı performansı sınırlı olabilmektedir. Örneğin, el yazısı rakamları tanımak gibi farklı görevlerde başarısı insanların performansının oldukça altında kalmıştır.

Son olarak, CLIP'in sınıflandırıcıları, kelimelerin veya ifadelerin hassasiyetine duyarlı olabilir ve kısmen iyi sonuçlar elde etmek için manuel ayarlamalar gerektirebilir. Bu nedenle, CLIP'in güçlü yönlerinin yanı sıra dikkate alınması gereken bazı sınırlamaları bulunmaktadır (Radford vd., 2021).

3.2.2 FashionCLIP

CLIP, görsel ve metinsel veriler arasındaki ilişkiyi anlamak için büyük bir veri kümesinde önceden eğitilmiştir. Bu model, çoklu görevler için kullanılabilir ve çeşitli uygulamalarda görüntü ve metin verileri arasında bağlantı kurabilir. FashionCLIP ise modanın özel verileri üzerinde önceden eğitilmiş bir CLIP modelidir. Bu tür modeller, belirli bir alandaki veriler üzerinde eğitilmiştir, Bu da modanın özel gereksinimlerine daha iyi uyan bir model olmasını sağlamaktadır (Wang vd., 2023).

Moda endüstrisinde genel ve ölçeklenebilir makine öğrenimi temsillerinin geliştirilmesi için FashionCLIP gibi büyük ölçekli modeller kullanılabilir ve bu sayede birbiri ile benzer olan görseller eşleştirilebilir (Chia vd., 2022).

3.2.3 CLIP ve FashionCLIP Modellerinin Çalışma Prensipleri

CLIP modeli, resimleri vektörlere dönüştürürken renk, desen ve doku gibi görsel özelliklere bakmaktadır. CLIP'in temel gücü, görselleri anlamlandırma ve bu anlamları metinlerle ilişkilendirme yeteneğinden gelmektedir. Bu süreçte, resimlerin çeşitli görsel özellikleri, derin öğrenme modelinin farklı katmanları tarafından çıkarılır ve sonrasında vektörel olarak temsil edilir.

Renk özelliklerini çıkarırken model, resmin renk dağılımlarını ve kombinasyonlarını öğrenir. Desen ve doku özelliklerini çıkarırken, çizgiler, kıvrımlar ve belirli desenler gibi, resimlerdeki desenleri ve dokuları analiz eder.

Resmin görsel özellikleri çıkarıldıktan sonra, model bu özellikleri bir vektöre dönüştürülür.

V_i , yüksek boyutlu verilerin daha düşük boyutlu, anlamlı temsilleridir. CLIP modeli bağlamında bu temsiller bir resmin veya metnin model tarafından çıkarılan ve yüksek boyutlu bir vektör şeklinde temsil edilen özellikleridir. Bu vektör, orijinal girdinin anlamını, içeriğini ve diğer önemli özelliklerini kodlar. Temsiller, benzerlik araması, sınıflandırma, kümeleme ve ilişkilendirme çeşitli görevlerde kullanılabilir.

$$V_i = CLIP(I_i) \quad (3.1) \quad (1.1)$$

(3.1) nolu denklemde gösterildiği gibi V_i bir resmin temsilcisi ve I_i girdi resmini temsil etmektedir. Görsel benzerlikleri hesaplamak için temsiller arasındaki benzerlik ölçümlerinde en yaygın olarak kosinüs benzerliği kullanılır. (3.2) denklemde kosinüs benzerliğinin hesaplanması verilmiştir. Burada, $v_i \cdot v_j$, $v_i \cdot v_j$ vektörlerin iç çarpımı, $\|v_i\|$ ve $\|v_j\|$ ise vektörlerin normlarıdır.

$$\text{Kosinüs benzerliği}(v_i, v_j) = \frac{v_i \cdot v_j}{\|v_i\| \|v_j\|} \quad (3.2)$$

Sonuç olarak CLIP modeli, görsellerin benzerliğini bulmak için güçlü bir araçtır. Model, resimleri vektör temsillerine dönüştürür ve bu temsilleri karşılaştırarak benzerlikleri hesaplar. Kosinüs benzerliği bu karşılaştırmalar için yaygın olarak kullanılan bir metriktir (Özköse vd., 2023).

4.1 Apriori

Apriori algoritması, sık öge kümelerinin belirlenmesi için ve veri madenciliğinde birliktelik kurallarının tespit edilmesinde kullanılmaktadır. Bu algoritma, öge kombinasyonları için kuralları bulmayı amaçlayan bir veri madenciliği tekniğidir (Aldino vd., 2021). Temel metodolojisi aşağıdaki gibidir.

Destek değeri (Support), bir ögenin veri kümesindeki tekrar etme miktarı ya da olasılığı şeklinde tanımlanabilir. Destek değeri, minimum gereksinimi karşılayan öge kombinasyonunu belirlemek için kullanılır (Nengsih, 2015). Bir ögenin destek değeri (4.1)'deki denklem kullanılarak elde edilir. Buradaki A işlemi, bir ürünün satıldığı fişler olabilir. Bir ürünün sattığı fişlerin sayısı, toplam fiş sayısına bölünerek A işlemi için destek değeri yani A işleminin olasılığı $S(A)$ olarak bulunur.

$$S(A) = \frac{A \text{ işleminin miktarı}}{\text{Toplam işlem miktarı}} \quad (4.1)$$

Güven aralığı (Confidence), birliktelik kuralının ne kadar doğru olduğunu gösteren bir metriktir. Örneğin, "A" ürününü alan müşterilerin %80'inin aynı alışverişte "B" ürününü de almışlarsa, bu durumda, "A" ürününü alan bir müşterinin "B" ürününü alma olasılığı %80 olmaktadır. Güven aralığı, (4.2) nolu denklem ile hesaplanmaktadır (Nengsih, 2015).

$$\text{Güven aralığı} = \frac{A \text{ ve B işleminin miktarı}}{A \text{ işleminin miktarı}} \quad (4.2)$$

Apriori algoritmasında sık tekrar eden öğeler belirlenirken aşağıdaki adımlar sırasıyla uygulanır:

1. Denklem (4.1)'de hesaplandığı gibi her bir ögenin destek değeri bulunur.
2. Eldeki verinin özelliklerine göre minimum destek değeri belirlenir.
3. Bu minimum destek değerinin üstünde olan öğeler alınır.
4. Her bir ögenin diğer öğelerle ilişkisine bakabilmek için veri büyükse bir matris oluşturulabilir. (4.2)'deki denklemdeki gibi her öge için güven alımları hesaplanır.

5. Bu işlemler daha büyük sık öge kümesi oluşturulamayana kadar iterative olarak tekrar eder.
6. Sık öge kümeleri ile kurallar belirlenir.

Apriori algoritması basit ve kolay uygulanabilir bir algortima olmasına rağmen büyük veri kümeleri üzerinde performansı olabilmektedir. Bu algoritma perakende, e-ticaret, pazarlama, ve envanter yönetimi gibi farklı alanlarda kullanılabilir (Eker, M. vd., 2015).

4.2 FP-Growth

Sık Örüntü Büyüme Algoritması (Frequent Pattern Growth), bir veri setinde en sık görülen öge kümelerini belirlemek için kullanılan algoritmaların başında gelmektedir. FP-Growth algoritması, Apriori algoritmasına alternatif olarak geliştirilmiş bir yöntemdir (Sidhu vd., 2014).

Algoritmanın çalışma adımları bir örnek üzerinden aşağıdaki Tablo 4.1 'deki örnek ile açıklanabilir.

Tablo 4.1. FP-Growth örneği

Fiş No	Ürünler
1	A,B,D,E
2	B,C,E
3	A,B,C,E
4	B,E
5	A,B,C,E

Öncelikle, her ürünün destek değeri hesaplanır. Destek değeri, bir ögenin bir veri kümesinde ne kadar sıklıkla bulunduğunu gösterir ve i ögesinin destek değeri $Destek(i)$ olarak (4.3) nolu denklemdeki gibi hesaplanır.

$$Destek(i) = \frac{Veri kümesindeki i ögesinin toplam sayısı}{Toplam Veri Kümesi} \times 100\% \quad (4.3)$$

Örnek için Destek değerleri:

$\text{Destek}(A)=3$

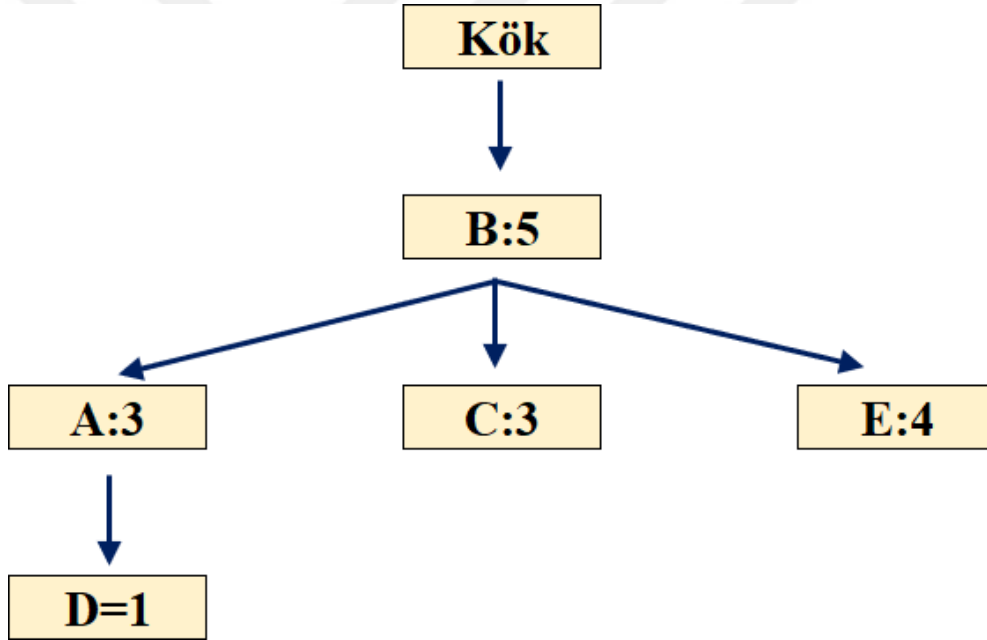
$\text{Destek}(B)=5$

$\text{Destek}(C)=3$

$\text{Destek}(D)=1$

$\text{Destek}(E)=4$

Ardından FP-Tree'nin kök düğümü kök olarak başlatılır. Her işlem sırasıyla Sık tekrar eden ağaca eklenir. Şekil 4.1'de gösterildiği gibi B, en sık tekrar eden öğedir, B düğümü altında A ve C 3, E ise 4 defa tekrar etmiştir. D öğesi ise A ve B'nin altında 1 defa tekrar etmiştir.



Şekil 4.1. Örnek Karar Ağacı

Sonuç olarak FP-Growth algoritması, veri setinde sık öge kümelerini bulmak için etkili bir yöntemdir. Veri seti üzerinde yapılan adımlarla, sık öğelerin ve ilişkili kümelerin hızlı ve verimli bir şekilde tespit edildiği gösterilmiştir. Bu yöntem, büyük veri setleri üzerinde sık öge kümeleme problemlerini çözmek için yaygın olarak kullanılan bir algoritmadır. FP-Growth algoritması ile veri kümesine tekrar tekrar bakmaya gerek kalmadan sık öge kümeleri belirlenebilir, bu sebeple performans açısından daha iyi bir yöntemdir (Said vd., 2009).

Görsel Benzerlikler ile E-Ticaret Satış Verileri Üzerinden Müşteri Sepet Analizi Uygulaması

5.1 Ürün Görsel Benzerliklerinin Bulunması

Çalışmada, yurt içi, yurt dışı ve e-ticaret alanlarında faaliyet gösteren bir hazır giyim firmasına ait ürünlerin görsel bilgileri ve Nisan 2023 – Nisan 2024 tarihleri arasındaki 1 yıllık E-ticaret fiş satış verileri kullanılmıştır. Verilen derlenmesinde ve analiz edilmesinde SQL, Python ve R programları kullanılmıştır.

Uygulamanın ilk aşamasında ürün görselleri derin öğrenme modeline verilerek görsel benzerleri bulunmuştur, sonraki aşamada ise bulunan bu görsel benzerlikler dikkate alınarak fiş bilgileri ile müşteri sepet analizi yapılarak beraber satma olasılığı yüksek ürünler bulunarak E-ticaret sitesinde ürün önerisinde bulunulması amaçlanmıştır. Görsel benzerlikleri bulmak için sırasıyla aşağıdaki işlemler yapılmıştır.

Her bir ürün, bir üst hiyerarşide ürün grubuna bağlıdır. Ürün sayısının az olduğu ürünler bu datadan çıkarılmış ve ürünlere ait resimler indirilmiştir.

Önceden eğitilmiş CLIP ve FashionCLIP derin öğrenme modelleri kullanarak renk, şekil ve doku özelliklerine göre özellik vektörleri çıkartılmıştır.

CLIP ve FashionCLIP modelleri ile benzerlik skorları kosinüs benzerliği (5.1)'deki denklem ile hesaplanarak önerilen 20419 benzer ürün çifti bulunmuştur.

$$\text{Kosinüs benzerliği}(v_i, v_j) = \frac{v_i \cdot v_j}{\|v_i\| \|v_j\|} \quad (5.1)$$

Sonuçlar üzerinde yapılan deneysel gözlemlerde, verilen datadaki farklı ürünleri içeren görsellerde tek bir ürüne ait nesne olmamasından kaynaklı olarak sonuçların farklı bir yöntem ile validasyonu yapılmıştır.

5.2 Sonuçların Validasyonu

5.2.1 Yapısal Benzerlik Endeksi

YEB (Yapısal Benzerlik Endeksi) görüntü benzerliği ölçümü için kullanılan bir metriktir. İki görüntü arasındaki benzerliği sayısal olarak değerlendirmek için kullanılır. YEB, insan görsel sisteminin algısal özelliklerini dikkate alarak, iki

görüntü arasındaki yapısal benzerliği değerlendirir. YEB, görüntüler arasındaki parlaklık, kontrast ve desen gibi yapısal benzerliklerini ölçer. Bu üç bileşenin birleşimi, görüntüler arasındaki genel benzerliği sağlar. YEB değeri, 0 ile 1 arasında bir değer alır, 1'e daha yakın değerler daha yüksek benzerliği gösterir.

5.2.2 Çok Ölçekli Yapısal Benzerlik Endeksi

ÇÖYBE, (MSSIM- Multi-Scale Structural Similarity Index) YEB'in geliştirilmiş bir versiyonudur. ÇÖYBE, görüntüler arasındaki yapısal benzerliği değerlendirmek için YEB'in çok ölçekli bir yaklaşımını kullanır. ÇÖYBE, YEB'in tek bir ölçekli değerlendirmesini genişleterek, farklı ölçeklerdeki yapısal benzerlikleri dikkate alır. Görüntüyü farklı ölçeklerde küçültüp büyütür yapılan çok ölçekli analiz, daha kapsamlı bir benzerlik ölçümü sağlar. Bu, görüntüler arasındaki detayların ve yapısal özelliklerin daha iyi değerlendirilmesine olanak tanır. ÇÖYBE, görüntü kalitesi değerlendirmesi, görüntü sıkıştırma, görüntü restorasyonu ve diğer görüntü işleme uygulamalarında kullanılır. Özellikle, insan görsel sistemine daha yakın bir benzerlik ölçümü sağlamak için YEB'e kıyasla dahagelişmiş sonuçlar sunmaktadır.

5.2.3 ÇÖYBE Çalışma Prensipleri

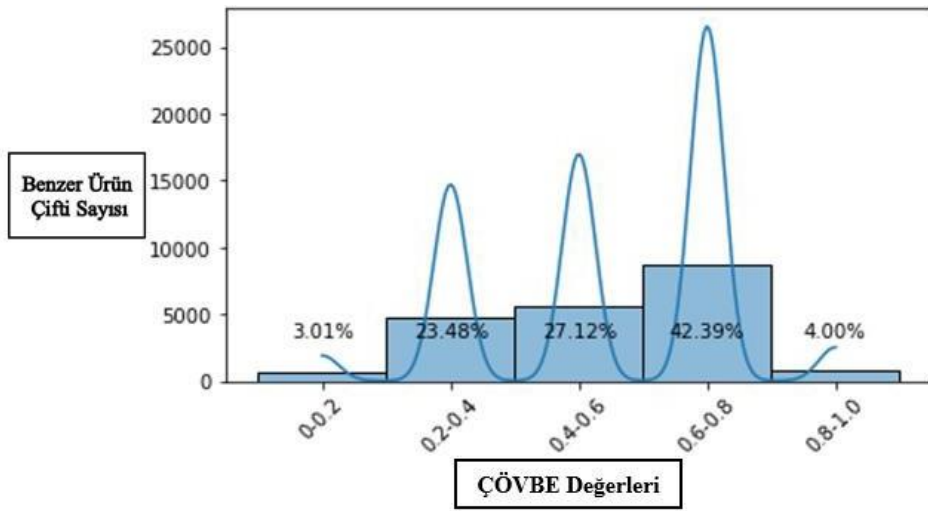
Giriş görüntülerinin (genellikle orijinal ve karşılaştırma görüntüleri) farklı ölçeklerdeki versiyonları oluşturulur. Bu, her bir görüntünün farklı düzeylerdeki detaylarını ele almayı sağlar.

Her ölçekte, giriş görüntülerinin farklı özelliklerini yakalamak için parlaklık, kontrast ve yapısal benzerlik temel özellikler hesaplanır.

Daha sonra, her ölçekteki bu üç özellik arasındaki benzerlik ölçülür ve birleştirilerek genel bir benzerlik skoru hesaplanır. Bu, ÇÖYBE skorunu oluşturur. ÇÖYBE skoru, her ölçekte elde edilen benzerlik skorlarının ortalamasıdır. Bu sayede, farklı ölçeklerdeki farklı detay seviyelerini dikkate alarak genel bir yapısal benzerlik ölçümü yapılır. ÇÖYBE'nin yapısal benzerlik için değer aralıkları Tablo 2'deki gibidir.

Tablo 5.1 ÇÖYBE değer aralıkları

ÇÖYBE Aralığı	Yapısal Benzerlik
1	İki resim birbirine tamamen benzerdir. Pikseller arasındaki yapısal benzerlik mükemmeldir.
0.9 - 1	İki resim çok benzerdir. Yapısal benzerlik yüksektir.
0.7 - 0.9	İki resim birbirine benzerdir. Yapısal benzerlik orta düzeydedir.
0.5 - 0.7	Yapısal benzerlik düşüktür.
< 0.5	Pikseller arasındaki yapısal benzerlik çok düşüktür.



Şekil 5.1. ÇÖYBE değerlerinin yoğunluk grafiği

Sonuç olarak Şekil 8’de gösterildiği gibi birbiri ile %0.4 ve daha yüksek oranda benzer olan 15010 ürün çifti bulunmuştur. Benzerlikler, müşteri fiş analizinde girdi olarak kullanılacaktır.

5.3 Apriori Algoritmasının Uygulanması

Apriori algoritması, birliktelik analizi için sıkça kullanılan bir algoritmadır. Bu algoritma, bir veri kümesindeki örüntüler arasındaki ilişkileri belirlemek için kullanılır. Apriori algoritması, belirli bir destek ve güven eşiği üzerinde sıkça bulunan örüntüleri tanımlamak için çalışır.

Apriori Algoritması, sık geçen öğeler madenciliği alanında en çok kullanılan algoritmadır. Bir öğenin ne kadar tekrar ettiğini gösteren *Destek* (support) değeri (5.1) nolu denklemdeki gibi hesaplanır.

$$\text{Destek değeri} = \frac{\text{Frekans (Tekrar Sayısı)}}{\text{Toplam Girdi Sayısı}} \quad (5.1)$$

Nisan 2023- Nisan 2024 tarihleri arasında, bir fişte en az iki ürün satan toplam 696 bin fiş verisi kullanılmıştır. Bu fiş verileri öncesinde benzerlik durumu dahil edilerek ardından dahil edilmeden bakılmıştır. Sonrasında her bir ürüne ait bir üst hiyerarşi olan klasmana çıkılarak fiş – klasman bazında bir veri oluşturulmuştur. Burada benzer olan ürünler aynı klasmanda olduğundan tekrardan benzerlik dahil edilip bakılmamıştır.

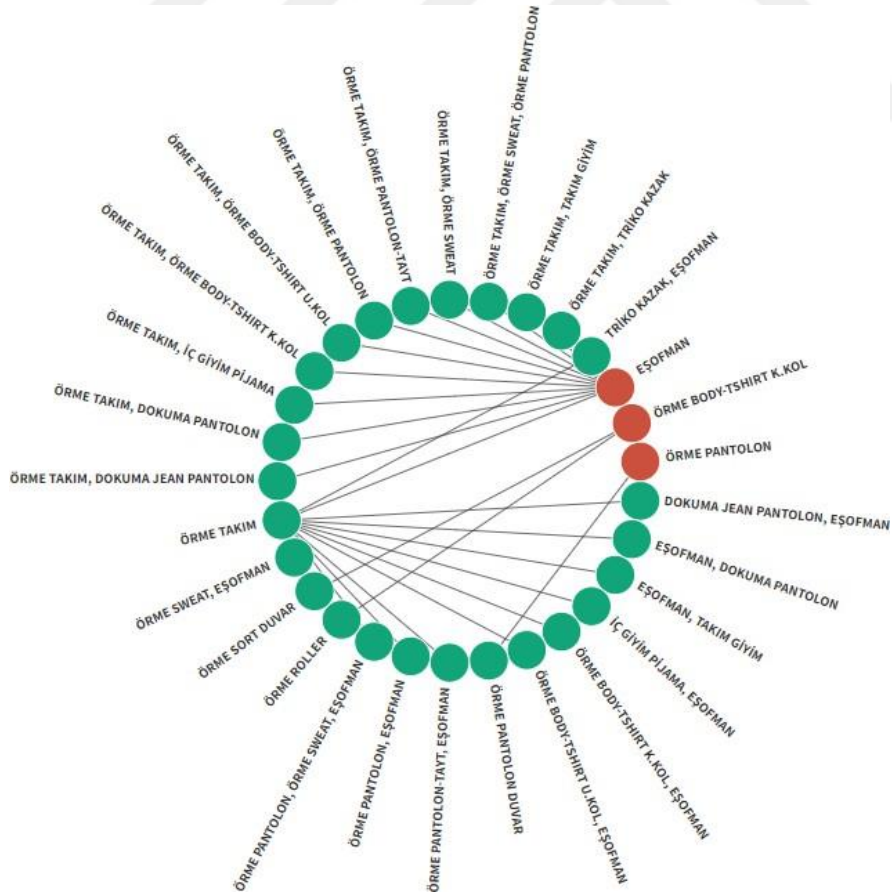
Tablo 5.2. Apriori sonuçları

Uygulama	Kural	Destek Değeri	Güven Aralığı
1. Benzerlik dahil edilerek, ürün bazında	23	0.001	0.4
2. Benzerlik dahil edilmeden, ürün bazında	0	0.001	0.4
3. Klasman bazında	27	0.001	0.4

Tablo 5.2’te özetlendiği gibi Apriori yöntemi kullanılarak ve benzerlik dahil edilerek, Şekil 5.1’deki gibi ürün bazında çıktı sonuçlarına göre farklı renklerdeki basic ürünler ve alt / üst olarak takımlanabilir ürünlerin beraber satma olasılığı yüksek çıkmıştır. Benzerlik dahil edilmeden bakıldığında aynı güven aralığında sonuç çıkmamıştır. Klasman bazında ise Şekil 5.2’deki gibi alt ve üst olarak takımlanabilir klasmanların beraber satma olasılığı yüksek çıkmıştır.



Şekil 5.2 Benzerlik dahil edildiğinde Apriori algoritmasının sonuçları



Şekil 5.3 Klasman bazında Apriori algoritmasının sonuçları

5.4 FP-Growth Algoritmasının Uygulanması

FP-Growth algoritması, sık tekrar eden ağaç adı verilen bir veri yapısını kullanır. Bu ağaç, veri kümesini sık görülen öğelerin sık görülen desenlerini çıkarmaya çalışmaktadır. FP-Growth, önce veri setini tek bir tarama ile analiz eder ve bir ağaç oluşturur. Daha sonra, algoritma bu ağaçtaki sık öge kümeleri belirlemektedir.

Destek değeri düşükse, Apriori algoritması daha fazla işlem yapmaktadır. Bu sebeple Apriori algoritması performans olarak FP-Growth'tan daha yavaş kalmıştır. FP-Growth, veriyi daha sıkı bir şekilde filtrelediği için daha az sayıda kural çıkarabilmektedir ancak çıkardığı kurallar daha yüksek kaliteli olabilmektedir.

Tablo 5.3 FP-Growth sonuçları

Uygulama	Kural	Destek Değeri	Güven Aralığı
1. Benzerlik dahil edilerek, ürün bazında	6	0.001	0.4
2. Benzerlik dahil edilmeden, ürün bazında	0	0.001	0.4
3. Klasman bazında	27	0.001	0.4



Şekil 5.4 Benzerlik dahil edildiğinde FP-Growth algoritmasının sonuçları

FP-Growth yöntemi uygulandığında ise Tablo 5.3'te özetlendiği gibi benzerlikler dahil edildiğinde Şekil 5.4'te gösterildiği gibi Apriori'ye göre daha az sonuç çıkarmıştır, benzerlik dahil edilmeden ise sonuç çıkarmamıştır. Klasman bazında ise Apriori ile aynı sonuçları çıkarmıştır.

Bu çalışmada, derin öğrenme yöntemleri ve müşteri sepet analizi yöntemleri beraber kullanılarak, e-ticaret platformlarında müşterilere alışveriş önerileri sunmak amaçlanmıştır. Çalışmanın ilk aşamasında, derin öğrenme algoritmaları ile ürünlerin görsel özellikleri analiz edilmiş ve görsel olarak benzer ürün çiftleri bulunmuştur. Derin öğrenme modelinde kullanılan ürün görsellerinde birden fazla ürüne ait görsel olduğu için sonuçların doğruluğu tekrardan bir görüntü işleme yöntemi ile kontrol edilerek birbiri ile benzer olabilecek ürün çiftleri tespit edilmiştir.

Çalışmanın ikinci aşamasında ise, müşteri sepet analizi yöntemleri kullanılarak müşterilerin alışveriş davranışları incelenmiştir. Müşteri sepet analizi yöntemi ile önceki aşamada bulunan benzer ürün çiftlerinin bulunduğu satış bilgileri analiz edilmiştir. Müşterilerin geçmiş alışveriş bilgileri inceleyerek sepetlerindeki ürünler arasındaki ilişkileri belirlemiş ve bu bilgilere göre müşterilere beraber satın alabilecekleri ürün önerilerinde bulunmak amaçlanmıştır.

Derin öğrenme ve müşteri sepet analizi yöntemlerinin birleştirilmesi ile, e-ticaret platformlarında müşteri memnuniyetini artırılabilir. Derin öğrenme yöntemlerinin sağladığı görsel benzerlik analizi, müşterilerin beraber satın alabileceği ürünlerin daha doğru bir şekilde belirlenmesini sağlamıştır, müşteri sepet analizi ise müşterilerin alışveriş alışkanlıklarını daha iyi analiz ederek gelecekteki satın alma davranışlarını tahmin etmede önemli bir rol oynamıştır.

Sonuç olarak, bu çalışma, derin öğrenme ve müşteri sepet analizinin e-ticaret platformlarında etkili bir şekilde kullanılmasının, müşterilerde daha kişiselleştirilmiş ve memnuniyet verici alışveriş deneyimleri sunabileceğini göstermektedir. Bu yöntemlerin başarılı bir şekilde uygulanması, müşteri memnuniyetini artırarak e-ticaret platformlarının rekabet gücünü ve satışlarını artırabilir. Bu bulgular, e-ticaret platformlarının gelişimi ve müşteri deneyimlerinin iyileştirilmesi için bir kaynak olarak kullanılabilir.

Gelecekteki çalışmalarda, bu yöntemlerin farklı ürün kategorileri ve müşteri segmentleri için nasıl uygulanabileceđi daha derinlemesine incelenebilir ve böylece öneri sistemlerinin dođruluđu ve etkinliđi daha da artırabilir.



- Agrawal, R., & Srikant, R. (1994). Fast algorithms for mining association rules. In Proc. 20th int. conf. very large data bases, VLDB (Vol. 1215, pp. 487-499).
- Adnyana, M. S. I., Hartati, R. S., & Sudarma, M. (2020). Market Basket Analysis For Procurement Of Food Stock Using Apriori Algorithm And Economic Order Quantity. *International Journal of Engineering and Emerging Technology*, 5(2), 149-153.
- Aldino, A. A., Pratiwi, E. D., Sintaro, S., & Putra, A. D. (2021). Comparison of market basket analysis to determine consumer purchasing patterns using fp-growth and apriori algorithm. In 2021 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE) (pp. 29-34).
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., & Asari, V. K. (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. *arXiv preprint arXiv:1803.01164*.
- Arı, A., & Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 1(2), 55-73.
- Ay, B., Aydın, G., Koyun, Z., & Demir, M. (2019). A visual similarity recommendation system using generative adversarial networks. In 2019 international conference on deep learning and machine learning in emerging applications (Deep-ML) (pp. 44-48). IEEE.
- Bell, S., & Bala, K. (2015). Learning visual similarity for product design with convolutional neural networks. *ACM transactions on graphics (TOG)*, 34(4), 1-10.
- Carlsson, F., Eisen, P., Rekathati, F., & Sahlgren, M. (2022). Cross-lingual and multilingual clip. In Proceedings of the Thirteenth Language Resources and Evaluation Conference (pp. 6848-6854).
- Chechik, G., Sharma, V., Shalit, U., & Bengio, S. (2010). Large scale online learning of image similarity through ranking. *Journal of Machine Learning Research*, 11(3).
- Chia, P. J., Attanasio, G., Bianchi, F., Terragni, S., Magalhães, A. R., Goncalves, D., & Tagliabue, J. (2022). Contrastive language and vision learning of general fashion concepts. *Scientific Reports*, 12(1), 18958.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In 2009 IEEE conference on computer vision and pattern recognition (pp. 248-255). IEEE.
- Dong, A. H., Shan, D., Ruan, Z., Zhou, L. Y., & Zuo, F. (2013). The design and implementation of an intelligent apparel recommend expert system. *Mathematical problems in engineering*, 2013.
- Eker, M. E., Oktaş, R., & Kayhan, G. (2015). Apriori Algoritması ve Türkiye'deki Örnek Uygulamaları. *Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun*.

- Faghri, F., Fleet, D. J., Kiros, J. R., & Fidler, S. (2017). Vse++: Improving visual-semantic embeddings with hard negatives. arXiv preprint arXiv:1707.05612.
- Garude, D., Khopkar, A., Dhake, M., Laghane, S., & Maktum, T. (2019). Skin-tone and occasion oriented outfit recommendation system. In 2nd International Conference on Advances in Science & Technology (ICAST).
- Gökalp, Ö. M. (2022). Makine öğrenmesi. Gazi Üniversitesi, Gazi Bilişim Enstitüsü, Adli Bilişim Bölümü.
- Heinz, S., Bracher, C., & Vollgraf, R. (2017). An LSTM-based dynamic customer model for fashion recommendation. arXiv preprint arXiv:1708.07347.
- Hiriyanaiyah, S., Siddesh, G. M., & Srinivasa, K. G. (2022). Deep visual ensemble similarity (DVESM) approach for visually aware recommendation and search in smart community. *Journal of King Saud University-Computer and Information Sciences*, 34(6), 2562-2573.
- Hossain, M., Sattar, A. S., & Paul, M. K. (2019). Market basket analysis using apriori and FP growth algorithm. In 2019 22nd international conference on computer and information technology (ICCIT) (pp. 1-6). IEEE.
- Hsiao, J. H., & Li, L. J. (2014). On visual similarity based interactive product recommendation for online shopping. In 2014 IEEE international conference on image processing (ICIP) (pp. 3038-3041). IEEE.
- Hwangbo, H., Kim, Y. S., & Cha, K. J. (2018). Recommendation system development for fashion retail e-commerce. *Electronic Commerce Research and Applications*, 28, 94-101.
- Idris, A. I., Sampetoding, E. A., Ardhana, V. Y. P., Maritsa, I., Sakri, A., Ruslan, H., & Manapa, E. S. (2022). Comparison of Apriori, Apriori-TID and FP-Growth Algorithms in Market Basket Analysis at Grocery Stores. *The IJICS (International Journal of Informatics and Computer Science)*, 6(2), 107-112.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Ivakhnenko, A. G. (1971). Polynomial theory of complex systems. *IEEE transactions on Systems, Man, and Cybernetics*, (4), 364 -378.
- Karpathy, A., & Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3128-3137).
- Kızılkaya, Y. M., & Oğuzlar, A. (2018). Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili ile Kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*, 37(37), 90-98.
- Kiapour, M., Han, X., Lazebnik, S., Berg, A. C., & Berg, T. L. (2015). Where to buy it: Matching street clothing photos in online shops. In *Proceedings of the IEEE international conference on computer vision* (pp. 3343-3351).
- Kurnia, Y., Isharianto, Y., Giap, Y. C., & Hermawan, A. (2019). Study of application of data mining market basket analysis for knowing sales pattern (association of items) at the O! Fish restaurant using apriori algorithm. In *Journal of Physics: Conference Series* (Vol. 1175, No. 1, p. 012047). IOP Publishing.

- Mansur, A., & Kuncoro, T. (2012). Product inventory predictions at small medium enterprise using market basket analysis approach-neural networks. *Procedia Economics and Finance*, 4, 312-320.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133.
- Mizutani, E., Dreyfus, S. E., & Nishio, K. (2000). On derivation of MLP backpropagation from the Kelley-Bryson optimal-control gradient formula and its application. In *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. 2, pp. 167-172)*. IEEE.
- Mustakim, Herianda, D. M., Ilham, A., Daeng GS, A., Laumal, F. E., Kurniasih, N., & Rahim, R. (2018). Market Basket Analysis Using Apriori and FP-Growth for Analysis Consumer Expenditure Patterns at Berkah Mart in Pekanbaru Riau. In *Journal of Physics: Conference Series (Vol. 1114, p. 012131)*. IOP Publishing.
- Nengsih, W. (2015). A comparative study on market basket analysis and apriori association technique. In *2015 3rd international conference on information and communication technology (ICoICT) (pp. 461-464)*. IEEE.
- Nitta, T. (2003). Solving the XOR problem and the detection of symmetry using a single complex-valued neuron. *Neural Networks*, 16(8), 1101-1105.
- Nurmayanti, W. P., Sastriana, H. M., Rahim, A., Gazali, M., Hirzi, R. H., Ramdani, Z., & Malthuf, M. (2021). Market basket analysis with apriori algorithm and frequent pattern growth (Fp-Growth) on outdoor product sales data. *International Journal of Educational Research and Social Sciences (IJERSC)*, 2(1), 132-139.
- Özköse, Y. E., Gökçe, Z., & Duygulu, P. (2023, July). Alignment of Image-Text and Video-Text Datasets. In *2023 31st Signal Processing and Communications Applications Conference (SIU) (pp. 1-4)*. IEEE.
- Pathan, V., & Shende, P. P. (2019). A study on market basket analysis and association mining. In *Proceedings of National Conference on Machine Learning*.
- Peifeng, H., Yuzhe, C., Jingping, S., & Zhaomu, H. (2016). Smart wardrobe system based on android platform. In *2016 IEEE International Conference on Cloud Computing and Big Data Analysis (ICCCBDA) (pp. 279-285)*. IEEE.
- Polatbilek, O. (2020). Enriching contextual word embeddings with character information (Master's thesis, Izmir Institute of Technology (Turkey)).
- Qisman, M., Rosadi, R., & Abdullah, A. S. (2021). Market basket analysis using apriori algorithm to find consumer patterns in buying goods through transaction data (case study of Mizan computer retail stores). In *Journal of Physics: Conference Series (Vol. 1722, No. 1, p. 012020)*. IOP Publishing.
- Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., & Sutskever, I. (2021). Learning transferable visual models from natural language supervision. In *International conference on machine learning (pp. 8748-8763)*. PMLR.

- Rao, A. B., & Kiran, J. S. (2023). Application of market–basket analysis on healthcare. *International Journal of System Assurance Engineering and Management*, 14(Suppl 4), 924-929.
- Rosli, N., & Teo, N. H. I. (2022). Market Basket Analysis using Apriori Algorithm: Grocery Items Recommendation. In *3rd Auckland International Conference on Social Sciences, Education, Entrepreneurship and Technology 2022 (AICSEET 2022)* (pp. 61-68).
- Said, A. M., Dominic, P. D. D., & Abdullah, A. B. (2009). A comparative study of fp-growth variations. *International journal of computer science and network security*, 9(5), 266-272.
- Saputra, J. P. B., Rahayu, S. A., & Hariguna, T. (2023). Market basket analysis using FP-growth algorithm to design marketing strategy by determining consumer purchasing patterns. *Journal of Applied Data Sciences*, 4(1), 38-49.
- SEYYARER, E., AYATA, F., UÇKAN, T., & KARCI, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Computer Science*, 5(2), 90-98.
- Sidhu, S., Meena, U. K., Nawani, A., Gupta, H., & Thakur, N. (2014). FP Growth algorithm implementation. *International Journal of Computer Applications*, 93(8).
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Tan, Y., & Wang, J. (2004). A support vector machine with a hybrid kernel and minimal Vapnik-Chervonenkis dimension. *IEEE Transactions on knowledge and data engineering*, 16(4), 385-395.
- Tripathi, A., & Pandey, S. (2022). Market Basket Analysis of Cosmetic Products using Apriori Algorithm. *Journal Volume*, 2(1).
- Wan, J., Wang, D., Hoi, S. C. H., Wu, P., Zhu, J., Zhang, Y., & Li, J. (2014). Deep learning for content-based image retrieval: A comprehensive study. In *Proceedings of the 22nd ACM international conference on Multimedia* (pp. 157-166).
- Wan, S., & Niu, Z. (2019). A hybrid e-learning recommendation approach based on learners' influence propagation. *IEEE Transactions on Knowledge and Data Engineering*, 32(5), 827-840.
- Wang, X., Wang, C., Li, L., Li, Z., Chen, B., Jin, L., & Gao, M. (2023). Fashionklip: Enhancing e-commerce image-text retrieval with fashion multi-modal conceptual knowledge graph. In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 5: Industry Track)* (pp. 149-158).
- Widrow, B., & Lehr, M. A. (1995). Perceptrons, Adalines, and backpropagation. *Arbib*, 4, 719-724.
- Wu, P., Hoi, S. C., Zhao, P., Miao, C., & Liu, Z. Y. (2015). Online multi-modal distance metric learning with application to image retrieval. *IEEE Transactions on Knowledge and Data Engineering*, 28(2), 454-467.

- Yao, L., Huang, R., Hou, L., Lu, G., Niu, M., Xu, H., & Xu, C. (2021). Filip: Fine-grained interactive language-image pre-training. arXiv preprint arXiv:2111.07783.
- Yılmaz, P., Akçakaya, Ş., Özkaya, Ş. D., & Çetin, A. (2022). Machine Learning Based Music Genre Classification and Recommendation System. El-Cezeri, 9(4), 1560-1571.
- Zeng, Y., Zhang, X., & Li, H. (2021). Multi-grained vision language pre-training: Aligning texts with visual concepts. arXiv preprint arXiv:2111.08276.
- Zheng, O., Abdel-Aty, M., Wang, D., Wang, Z., & Ding, S. (2023). Chatgpt is on the horizon: Could a large language model be all we need for intelligent transportation. arXiv preprint arXiv:2303.05382.



TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. Soner Kara, S., & Pulat, E. (2024). Product recommendation in e-commerce shopping with product image similarities and customer basket analysis. 4th International Congress of Engineering and Natural Sciences Studies (ICENSS-2024), May 24-25, 2024, Ankara, Türkiye.

