
NİCEL KARAR YÖNTEMLERİ

Editör: Dr.Öğr.Üyesi Mehmet Akif KARA

NİCEL KARAR YÖNTEMLERİ

Editör

Dr. Öğr. Üyesi Mehmet Akif KARA

yaz
yayınları

2024

NİCEL KARAR YÖNTEMLERİ

Editör: Dr. Öğr. Üyesi Mehmet Akif KARA

© YAZ Yayınları

Bu kitabın her türlü yayın hakkı Yaz Yayınları'na aittir, tüm hakları saklıdır. Kitabın tamamı ya da bir kısmı 5846 sayılı Kanun'un hükümlerine göre, kitabı yayınlayan firmanın önceden izni alınmaksızın elektronik, mekanik, fotokopi ya da herhangi bir kayıt sistemiyle çoğaltılamaz, yayınlanamaz, depolanamaz.

E_ISBN 978-625-6104-91-4

Ekim 2024 – Afyonkarahisar

Dizgi/Mizanpaj: YAZ Yayınları

Kapak Tasarım: YAZ Yayınları

YAZ Yayınları. Yayıncı Sertifika No: 73086

M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar/AFYONKARAHİSAR

www.yazyayinlari.com

yazyayinlari@gmail.com

info@yazyayinlari.com

İÇİNDEKİLER

MATLAB Uygulamalı MEREC Yöntemi ile Kriter Ağırlıklandırma.....	1
<i>Mehmet Akif KARA</i>	
Kümeleme Analizi ile OECD Ülkelerinin Makroekonomik Göstergelere Göre Sınıflanması	16
<i>Aylin ALKAYA</i>	
Uzaktan Eğitimde Ders Materyali, Sınav ve Program Değerlendirmenin Öğrenme Memnuniyeti Üzerine Etkisinin Yapısal Eşitlik Modeliyle İncelenmesi	40
<i>Münevver GÜNDÜZ, Mehmet YILDIZ, Metin BAYRAM</i>	
Naive Bayes Algorithm and R Application	74
<i>Serkan KARDEŞ</i>	

"Bu kitapta yer alan bölümlerde kullanılan kaynakların, görüşlerin, bulguların, sonuçların, tablo, şekil, resim ve her türlü içeriğin sorumluluğu yazar veya yazarlarına ait olup ulusal ve uluslararası telif haklarına konu olabilecek mali ve hukuki sorumluluk da yazarlara aittir."

MATLAB UYGULAMALI MEREC YÖNTEMİ İLE KRİTER AĞIRLIKLANDIRMA

Mehmet Akif KARA¹

1. GİRİŞ

İşletmelerin gerek gündelik yaşam da gerekse de stratejik politikalarını planlama süreçlerinde sıklıkla karar verme problemleri ile karşılaştığı aşîkârdır. İnsan kaynakları temin ve seçimi, tedarikçi seçimi, malzeme seçimi vb. önemli seçim işlemleri başta olmak üzere işletmeler için hayati önem taşıyan karar problemleri söz konusudur. Karar problemlerinde birden fazla kriter ve birden fazla alternatif vardır. Dolayısı ile bu sürecin bilimsel bir şekilde sürdürülmesi elzemdir. Karar analizi, karar vericilerin bilimsel ve optimum düzeyde karar almalarını sağlamaktadır. Karar teknikleri esasında karar alma sürecine destek olan araçlardır. Karar vericinin yerini almazlar.

Çok kriterli karar verme problemleri başta işletme, lojistik, endüstri mühendisliği olmak üzere sosyal ve fen bilimlerinde son yıllarda sıkça kullanılan yöntemlerdir. Literatürde geliştirilen farklı yöntemler ile birlikte analizler gerçekleştirilmektedir. Kriterler, seçim ya da sıralama yapılacak olan karar problemleri için alternatifler üzerindeki önem dereceleri nedeniyle karara etkisi bulunan en önemli faktörlerden birisidir. Dolayısı ile çok kriterli karar verme problemlerinde kriterlerin ağırlıklarının belirlenmesi önemli bir aşamadır.

Ağırlıklandırma işlemi, kriterlere verilen önem derecelerinden ibarettir (Bircan, 2020). Bu ağırlık değerleri [0,1]

¹ Dr.Öğr.Üyesi, Giresun Üniversitesi, İİBF, İşletme Bölümü, akifkara28@gmail.com, ORCID: 0000-0003-4308-9933.

aralığında bulunmaktadır. Karar verme aşamalarında değerlendirilen kriterlerin önem derecelerinin belirlenmeleri, kriter ağırlıklandırma yöntemleriyle yapılmaktadır.

Kriter ağırlıklarının belirlenmesi için objektif, subjektif ve hibrit/entegre kriter ağırlıklandırma yöntemleri vardır. Subjektif yöntemler, kişisel yargılara dayanmaktadır. Bu yöntemlerde uzman görüşlerine başvurulmaktadır. Bu tarz yöntemlerin en önemli dezavantajı öznel değerlendirme içermesi ve bu değerlendirmelerin yanıltıcı olabilmesidir. Objektif yöntemler de ise kriter ağırlıkları, karar verici tarafından herhangi bir müdahaleye fırsat vermeden, matematiksel modeller aracılığıyla belirlenir (Şahin, 2022).

Literatürde kriter ağırlıklandırma işlemleri için SWARA, Entropi, CILOS, IDOCRIW, DEMATEL, SIMOS, CRITIC, LBWA, SMART, ROC, MEREC, BWM, MW, SD gibi yöntemler sıklıkla kullanılmaktadır. Bu kitap bölümünde, objektif kriter ağırlıklandırma yöntemleri arasında yer alan MEREC yöntemi tarihsel gelişimi, matematiksel adımları, MATLAB programında hazırlanan uygulama kodları ile birlikte aktarılacaktır.

2. MEREC YÖNTEMİ

MEREC yöntemi, 2021 yılında Keshavarz-Ghorabae, Amiri, Zavadskas, Turskis ve Antucheviciene tarafından geliştirilmiştir. Çok kriterli karar problemleri arasında kriterlerin ağırlıklarının belirlenmesi için kullanılan objektif yöntemlerden birisidir.

Bu yöntemin uygulanabilmesi için diğer yöntemlerde olduğu gibi karar matrisine ihtiyaç vardır. Ardından karar matrisi diğer yöntem adımları gibi öncelikle normalize edilmektedir. Bu yöntemi diğer yöntemlerden ayıran en önemli özelliği kriter

ağırlıkları belirlenirken kriterlerin kaldırma etkilerini dikkate almasıdır. Yöntem 6 adımdan oluşmaktadır.

1. Adım: Karar matrisinin oluşturulması

İlk adımda n tane alternatif ve m tane kriterden oluşan karar matrisi oluşturulmaktadır.

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (1)$$

2. Adım: Karar matrisinin normalize edilmesi

Karar matrisi Eşitlik (2) kullanılarak normalize edilir.

$$x_{ij}^x = \begin{cases} \frac{\min x_{ij}}{x_{ij}} & \text{eğer } j \in \text{fayda kriter ise} \\ \frac{x_{ij}}{\max x_{ij}} & \text{eğer } j \in \text{maliyet kriter ise} \end{cases} \quad (2)$$

3. Adım: Alternatiflerin genel performans değerlerinin hesaplanması

Her bir alternatifin toplam performans değeri Eşitlik (3) kullanılarak hesaplanır.

$$S_i = \ln \left(1 + \left(\frac{1}{m} \sum_j |\ln (n_{ij}^x)| \right) \right) \quad (3)$$

4. Adım: Her bir kriterin kaldırılması ile alternatiflerin performans değerlerinin hesaplanması

Her bir kriter ayrı ayrı çıkarılarak alternatiflerin performansı belirlenir. Bu hesaplama için Eşitlik (4) kullanılır.

$$S'_{ij} = \ln \left(1 + \left(\frac{1}{m} \sum_{k, k \neq j} |\ln (n_{ik}^x)| \right) \right) \quad (4)$$

5. *Adım: Mutlak sapmaların toplamının hesaplanması*

Bu adımda mutlak sapmaların toplamı hesaplanır. j. kriterin çıkarılma etkisini göstermek üzere, adım 1-3 ve adım 1-4'ten elde edilen değerlere dayalı olarak j. kriterin çıkarılma etkisi belirlenir.

$$E_j = \sum_i |S'_{ij} - S_i| \quad (5)$$

6. *Adım: Değerlendirme kriterlerinin ağırlıklarının elde edilmesi*

Bu adımda, her bir kriterin objektif ağırlığı Adım 1-5'in çıkarılma etkileri kullanılarak hesaplanır.

$$w_{j,merec} = \frac{E_j}{\sum_k E_k} \quad (6)$$

3. MEREC YÖNTEMİ LİTERATÜR İNCELEMESİ

MEREC yöntemi ortaya koyulduğu tarihten itibaren farklı uygulama alanlarında kullanılmıştır. İlgili problemlerde kriterlerin ağırlıklarının belirlenmesi için farklı yöntemlerle entegre bir biçimde uygulanmış ve başarılı sonuçlar elde edilmiştir. Yöntem hem uluslararası yayınlarda hem de Türkçe dilinde yapılan çalışmalarda farklı yöntemlerle bir arada kullanılmaktadır. Tablo 1'de Türkçe yayın dilinde yayınlanan 2024 yılındaki çalışmaların bazıları verilmektedir.

Tablo 1. Türkçe Yayın Dilinde Yayınlanan Araştırmalar

Yazar	Yöntem	Konu
Altıntaş (2024)	MEREC- WEBDA	Ülkelerin sürdürülebilir kalkınma kapasiteleri
Turanboy, Sarıkaya ve Arsu (2024)	MEREC- MAIRCA	Şehir hastanelerinin kapasite performansları
İnce, Teciner ve Ecer (2024)	MEREC- CODAS	G20 ülkelerinin lojistik performansları
Sezgin, A., Aytekin, S., & Sakarya, Ş. (2024).	MEREC- MARCOS	Finansal performans
Şeyranlioğlu, O., Kara, M. A., & Çilek, A (2024)	MEREC- COPRAS	Finansal performans
Gürlər, H. E. (2024)	MEREC- MOORA	AB ülkelerinin iklim değişikliğine uyum performansı
Taşcı, M. Z. (2024)	MEREC- CRADİS	DASK
Taşcı, M. Z. (2024)	PSI-MEREC- ARAS	Finansal performans

Tablo 1’de görüldüğü üzere son yıllarda MEREC yönteminin ARAS, CRADİS, COPRAS, CODAS, MAIRCA, MARCOS, MOORA ve WEBDA gibi farklı çok kriterli karar verme yöntemleriyle entegre olarak kullanıldığı görülmektedir.

Tablo 2’de Web of Science indeksinde 2024 yılında yayınlanan çalışmaların bazıları gösterilmektedir.

Tablo 2. Web of Science İndeksinde Yayınlanan Çalışmalar

Yazar	Yöntem	Konu
Kara vd. (2024a)	MEREC-RBNAR	Finansal performans
Kara vd. (2024b)	MEREC-AROMAN	Sürdürülebilir rekabetçilik düzeyi
Raj vd. (2024)	MEREC-MABAC	Lazer kaplama işlem optimizasyonu
Fan vd. (2024)	MEREC-MABAC	Giyilebilir sağlık teknolojisi cihazları
Asker (2024)	MEREC-COPRA	Finansal performans
Mastilo vd. (2024)	MEREC-MARCOS	Finansal gösterge analizi
Arshad vd. (2024)	MEREC-ARAS	Kahve barista kabulü
Mohamed vd. (2024)	MEREC-RAM	İHA seçimi
Ecer ve Güneş (2024)	MEREC-CRITIC- CoCoSo	Bilgi iletişim teknoloji düzeyi
Kumar vd. (2024)	MEREC-TOPSIS	Kaplama malzeme seçimi
Elsayed vd. (2024).	MEREC-MAIRCA	Dijital ikiz teknoloji kullanımı

2024 yılı içerisinde MEREC yöntemi Web of Science indeksinde taranan uluslararası dergilerde sıklıkla kullanılmıştır. AROMAN, RBNAR, MAIRCA, CRITIC, TOPSIS, ARAS, RAM, MARCOS, MABAC, COPRA gibi yöntemlerle entegre bir biçimde farklı problemlerin çözümünde yararlanılmıştır.

4. MATLAB YAZILIMINDA MEREC FONKSİYONU

MEREC yönteminin MATLAB yazılımında kolayca işlem yapmasına olanak sağlayan kodlar tarafımdan hazırlanmıştır. MATLAB yazılımında tasarlanan MEREC fonksiyonu iki girdi ile çalışabilmektedir. Bu girdi değişkenleri aşağıdaki gibidir.

- **decisionMatrix (D):** Karar matrisi
- **Method (metot):** Kriterlerin maliyet ya da fayda yönlü olup olmadığının belirlenmesi.

Fonksiyon çıktı olarak aşağıdaki değişkenleri vermektedir.

- **Normalize karar matrisi (Dy):.**
- **Genel performans değerleri (S):**
- **Her bir kriterin kaldırılmasıyla alternatiflerin performans değerleri (Sy)**
- **Mutlak sapmaların toplamı (E)**
- **Kriter ağırlıkları (w)**

MEREC yöntemi adımlarının MATLAB yazılım programında hazırlanan kodları aşağıdaki gibidir:

```
function [w, E, S, Sy, Dy]=merec(D,metot)
```

```
% Created by: Mehmet Akif Kara
```

```
[m,n]=size(D);  
%metot=1 max  
%metot=0 min  
  
Dy1=min(D)./D;  
Dy2=D./max(D);  
for j=1:n  
    if metot(j)==1  
        Dy(:,j)=Dy1(:,j);  
    else  
        Dy(:,j)=Dy2(:,j);  
    end  
end  
for i=1:m  
    S(i)=log(1+mean(abs(Dy(i,:)))));  
end  
for i=1:m  
    for j=1:n  
        Sy(i,j)=(1+(1/n)*(sum(abs(log(Dy(i,:))))-  
abs(log(Dy(i,j))))));  
    end  
end  
for j=1:n  
    E(j)=sum(abs((Sy(:,j)-S(j))));  
end
```

```
w=E/sum(E);
```

```
end
```

Örnek Uygulama 1:

Örnek uygulamaları MATLAB yazılım programında doğru çalıştırabilmek için şu adımları izlemeniz gerekmektedir (Özçalıcı, 2021).

- i. Masaüstünde yeni bir klasör oluşturunuz.
- ii. Yukarıdaki MEREC fonksiyonunu bir .m dosyası olarak klasöre kaydediniz.
- iii. Yeni bir script oluşturunuz.
- iv. Örnek uygulamadaki kodları scripte yazınız ve çalıştırınız.

Örnek uygulamada Kara ve Şeyranlıoğlu (2023) yılında yapılan çalışmadaki veri seti kullanılacaktır. Çalışmada BİST Sürdürülebilirlik İndeksinde bulunan 22 şirket 3 kriter kullanılarak finansal performanslarına göre ENTROPİ ve GİA yöntemleriyle sıralanmaktadır. Çalışmada, Cari Oran (C1), Asit Test Oranı (C2), Nakit Oran (C3) kriter olarak kullanılmıştır. Çalışmada kullanılan veri seti açık kodları gösterilen MEREC fonksiyonu ile çalıştırıldığında;

```
function [w, E, S, Sy, Dy]=merec(D,metot)
```

```
>> D = [
```

0.593	0.294	0.189
0.493	0.362	0.186
0.700	0.245	0.270
0.278	0.819	0.046
0.278	0.238	0.237
0.769	0.328	1.000
0.237	1.000	0.032
0.279	0.494	0.083
0.534	0.366	0.140
0.909	0.279	0.443
0.843	0.268	0.466
0.603	0.234	0.592
0.522	0.498	0.098
0.636	0.275	0.145
1.000	0.125	0.250
0.530	0.264	0.365
0.569	0.434	0.101
0.579	0.279	0.178
1.000	0.245	0.205
0.486	0.347	0.127
0.311	0.645	0.067
0.972	0.158	0.614] ;

Çalışmada kullanılan kriterlerden C1 ve C3 fayda yönlü, C2 ise maliyet yönlüdür. Bu bilgi de Matlab uygulamasında metot değişkenine [1,0,1] şeklinde girilmektedir.

Fonksiyon çalıştırıldığında çıktı olarak; normalize karar matrisi (Dy), genel performans değeri (S), her bir kriterin kaldırılmasıyla alternatiflerin performans değerleri (Sy), mutlak sapmaların toplamı (E) ve kriter ağırlıkları (w) verilmektedir.

$$w = 0.375 \quad 0.338 \quad 0.285$$

Uygulama sonucunda kriter ağırlığı en yüksek olan C1 ile gösterilen Cari Oran kriteri olmaktadır. Sırasıyla; Asit Test Oranı ve Nakit Oran kriterleri yer almaktadır.

Örnek Uygulama 2:

Örnek uygulama 2’de Tablo 3’de gösterilen veri seti ile uygulama yapılacaktır. Veri seti Bircan (2020) çalışmasından alınmıştır. İlgili çalışmada kriterler CRITIC yöntemiyle ağırlıklandırılmıştır.

Karar problemi için m adet alternatif $A_m=6$ ve bu alternatiflere ait kriterler $K_n=5$ olmak üzere Tablo 3’de gösterilmektedir:

Tablo 3. Örnek Uygulama 2 için Karar Matrisi

Alternatifler/Kriterler	K1	K2	K3	K4	K5
A1	45	965	0.96	5400	0.15
A2	45	800	0.89	6200	0.36
A3	40	975	0.45	4800	0.28
A4	55	685	0.75	5100	0.32
A5	49	740	0.65	7200	0.18
A6	38	650	0.8	5500	0.1
	maks	maks	maks	min	maks

Öncelikle karar matrisi MATLAB yazılımında hazırladığımız kodlara uygun bir biçimde girdi fonksiyonu olarak “D” değişkenine girilmelidir.

Ardından kriterler maliyet ya da fayda fonksiyonu özelliğine göre “metot” değişkenine girilmelidir. Bu örnek için $\text{metot}=[1,1,1,0,1]$ şeklindedir.


Daha sonra `function [w, E, S, Sy, Dy]=merec(D,metot)` kodları çalıştırılarak “w” ile gösterilen kriter ağırlıkları çıktısı elde edilir.

$w = 0.2133 \quad 0.2149 \quad 0.1896 \quad 0.2139 \quad 0.1680$

Örnek uygulamaya ilişkin işlem adımları Resim 1’de gösterilmektedir. İlk olarak MATLAB yazılımında sol alt köşede yer alan “workspace” bölümüne girdilerimizi yüklüyoruz. Bu çalışmada için “D” ve “metot” girdilerine ilişkin verileri yükledikten sonra “editör” kısmında yer alan `Merec.m` fonksiyonunu açıyoruz. Daha sonra “Command Window”


kısına “ $[w, E, S, Sy, Dy]=mrec(D,metot)$ ” fonksiyonunu yazıyoruz ve çalıştırıyoruz.

Resim 1. MATLAB Yazılımında Girdi Değişkenleri



Fonksiyonu çalıştırdıktan sonra istediğimiz çıktılar hem “workspace” hem de “command window” kısımlarında yer almaktadır. Resim 2’de gösterilmektedir.

Resim 2. MATLAB uygulamasında Çıktı Değişkenleri



KAYNAKÇA

- Altıntaş, F.F. (2024). Avrupa Birliği ülkelerin sürdürülebilir kalkınma performanslarının MEREC tabanlı WEBDA yöntemi ile analizi. *Ordu Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Araştırmaları Dergisi*, 14(1), 117-137.
- Arshad, M. W., Suryono, R. R., Rahmanto, Y., Sumanto, S., Sintaro, S., & Setiawansyah, S. (2024). Combination of objective weighting method using MEREC and a new additive ratio assessment in coffee barista admissions. *TIN: Terapan Informatika Nusantara*, 5(3), 220-231.
- Asker, V. (2024). Financial performance analysis using the MEREC-based COBRA method: an application to traditional and low-cost airlines. *Gospodarka Narodowa. The Polish Journal of Economics*, 318(2), 35-52.
- Bircan, H. (edt.) (2020). *Çok kriterli karar verme problemlerinde kriter ağırlıklandırma yöntemleri*. Ankara: Nobel Yayınları.
- Ecer, F., & Güneş, E. G7 ülkelerinin bilgi iletişim teknoloji düzeylerini belirleme: MEREC-CRITIC entegre ağırlıklı CoCoSo metodolojisi. *Journal of Mehmet Akif Ersoy University Economics and Administrative Sciences Faculty*, 11(1), 219-242.
- Elsayed, A., Arain, B., & Sallam, K. M. (2024). Exploring the application of digital twin technology in the energy sector using MEREC and MAIRCA methods. *Neutrosophic Systems with Applications*, 19, 15-29.
- Fan, J., Lei, T., & Wu, M. (2024). MEREC-MABAC method based on cumulative prospect theory for picture fuzzy

- sets: Applications to wearable health technology devices. *Expert Systems with Applications*, 255, 124749.
- Gürler, H. E. (2024). Avrupa Birliği ülkelerinin iklim değişikliğine uyum performanslarının bütünsel MEREC-MOORA yaklaşımıyla değerlendirilmesi. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*, 11(2), 366-393.
- İnce, Ö., Çetiner, B., & Ecer, F. (2024). G20 ülkelerinin COVID-19 öncesi ve COVID-19 dönemi lojistik performanslarının kıyaslanması: MEREC ve CODAS entegre yaklaşımı. *Journal of Transportation and Logistics*, 8(2), 112-147.
- Kara, K., Özyürek, H., Yalçın, G. C., & Burgaz, N. (2024a). Enhancing financial performance evaluation: The MEREC-RBNAR hybrid method for sustainability-indexed companies. *Journal of Soft Computing and Decision Analytics*, 2(1), 236-257.
- Kara, K., Yalçın, G. C., Acar, A. Z., Simic, V., Konya, S., & Pamucar, D. (2024b). The MEREC-AROMAN method for determining sustainable competitiveness levels: A case study for Turkey. *Socio-Economic Planning Sciences*, 91, 101762.
- Keshavarz-Ghorabae, M. et al., (2021). Determination of objective weights using a new method based on the removal effects of criteria (MEREC). *Symmetry*, 13(4).
- Kumar, S., Ahijith Kumar, P. V., Bharati, K., Patnaik, L., Ranjan Maity, S., & Łepicka, M. (2024). Coating material selection for bulk metal forming dies: A MEREC-integrated approach with multiple MCDM methods. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 1-16.

- Mastilo, Z., Štilić, A., Gligović, D., & Puška, A. (2024). Assessing the banking sector of Bosnia and Herzegovina: An analysis of financial indicators through the MEREC and MARCOS methods. *Journal of Central Banking Theory and Practice*, 13(1), 167-197.
- Mohamed, M., Salam, A., Ye, J., & Yong, R. (2024). Single-valued neutrosophic mcdm approaches integrated with MEREC and RAM for the selection of uavs in forest fire detection and management. *Neutrosophic Systems with Applications*, 19, 1-14.
- Özçalıcı, M. (2021). *Matlab ile çok kriterli karar verme teknikleri*. Ankara: Nobel Yayınları.
- Raj, D., Maity, S. R., & Das, B. (2024). Optimization of process parameters of laser cladding on AISI 410 using MEREC integrated MABAC method. *Arabian Journal for Science and Engineering*, 49(8), 10725-10739.
- Sezgin, A., Aytekin, S., & Sakarya, Ş. (2024). Finansal performansın ölçülmesinde Piotroski F-Skoru Bileşenleri ve çkkv yöntemlerinin bağlantısı: MEREC tabanlı MARCOS uygulaması. *Ekonomi Politika ve Finans Araştırmaları Dergisi*, 9(2), 367-395.
- Şahin, M. (2022). *Güncel ve uygulamalı çok kriterli karar verme yöntemleri*. Ankara: Nobel Bilimsel Eserler.
- Şeyranlıoğlu, O., Kara, M. A., & Çilek, A. (2024). MEREC ve COPRAS yöntemleri ile piyasa çarpanlarına dayalı borsa performans değerlendirmesi: bist-30 pay endeksi uygulaması. *Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(1), 141-167.
- Taşcı, M. Z. (2024). MEREC ve CRADIS yöntemlerini içeren entegre bir çkkv modeli ile dask özelinde bir uygulama. *Doğuş Üniversitesi Dergisi*, 25(1), 35-53.

- Taşcı, M. Z. (2024). Milli reasürans şirketi'nin finansal performansının PSI-MEREC-ARAS modeliyle değerlendirilmesi. *Journal of Financial Politic & Economic Reviews/Finans Politik & Ekonomik Yorumlar*, 61(667).
- Turanboy, C., Sarıkaya, B., & Arsu, T. (2024). Şehir hastanelerinin kapasite performansının MEREC ve MAIRCA yöntemleri ile değerlendirilmesi. *İşletme*, 5(1), 81-103.

KÜMELEME ANALİZİ İLE OECD ÜLKELERİNİN MAKROEKONOMİK GÖSTERGELERE GÖRE SINIFLANMASI

Aylin ALKAYA¹

1. GİRİŞ

Makroekonomik göstergeler ekonomik teoriler ve ideolojilerle ilişkilidir. Makroekonomik göstergelerin birbiriyle bağlantılı olduğu belirlenebilmektedir. Enflasyon, GSYİH büyümesi, kamu açıkları devletin ekonomi yönetiminin merkezinde yer almaktadır (Mügge, 2016). Ekonomi alanındaki politika kararları ancak ekonomik koşulların doğru tahmin edilmesine dayanır (Hall ve Cook, 2017). Ülke ekonomilerinin performansı makroekonomik göstergeler aracılığıyla değerlendirilir. Politika yapıcılar makroekonomik göstergeleri ekonominin seyrini incelemek için kullanmaktadır.

Çalışma kapsamında makroekonomik göstergelere göre kümeleme analizi ile OECD (Ekonomik İşbirliği ve Kalkınma Örgütü) üye ülkeleri için sınıflanmaların yapılması amaçlanmaktadır. Kümeleme analizinde amaç ülkeleri, bireyleri, toplumları vb. birimleri araştırma konusunu oluşturan değişkenlere göre sınıflandırmaya çalışmaktır. Sınıflamalar yapılmasıyla ülkelerin profilleri hakkında çıkarsamalarda bulunulabilmektedir. Hangi ülkelerin araştırma değişkenlerine göre daha başarılı oldukları ya da olmadıkları hakkında yorum

¹ Doç. Dr., Nevşehir Hacı Bektaş Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü Sayısal Yöntemler Anabilim Dalı, aylin@nevsehir.edu.tr, ORCID: 0000-0001-5932-5553.

yapılabilmektedir. Böylece, makroekonomik göstergelere göre ülkelerin değerlendirmelerine olanak sağlanmış olmaktadır.

Çalışmada öncelikli olarak makroekonomik göstergelere göre ülke sınıflamaların yapılmaya çalışıldığı literatürdeki ulaşılabilen çalışmalara yer verilmiştir. İzleyen bölümlerde sırasıyla çalışmada yer verilen makroekonomik göstergeler hakkında bilgi aktarılmıştır. Çalışma yöntem bölümüyle devam ettirilmiş ve bulgular bölümüne yer verilmiştir. Çalışma sonuç bölümüyle sonlandırılmıştır.

2. LİTERATÜR

Bu bölümde makroekonomik göstergeleri bakımından ülke sınıflamalarının yapılmasının amaçlandığı literatürde yer alan çalışmalara yer verilmiştir.

**Tablo 1. Makroekonomik Göstergeleri Ülke Sınıflamaları
Literatürü**

ARAŞTIRMACI	ÜLKE	DEĞİŞKEN	YÖNTEM
Yılmaz ve Kaya (2005)	Avrupa Birliği (AB) ülkeleri, Bulgaristan, Romanya ve Türkiye	Uzun dönem faiz oranı, enflasyon, GSYİH, toplam kamu borçlarının gayri safi yurtiçi hasılaya oranı, bütçe dengesinin gayri safi yurtiçi hâsılaya oranı	Kümeleme analizi
Erkekoğlu (2007)	AB ülkeleri, Bulgaristan ve Romanya	Ekonomik göstergeler, eğitim, sağlık, demografik, bilgi ve haberleşme teknolojileriyle	Kümeleme analizi
Gligor ve Ausloos (2008)	15 AB ülkesi	Gayri Safi Yurtiçi Hâsıla (GSYİH), tüketim, yatırımlar, ticaret	Kümeleme analizi, Hareketli Ortalama Minimum Uzunluk Yolu
Kurnoga Zivadinovic, Dumicic ve Casni (2009)	AB ülkeleri ve Hırvatistan	GSYİH, toplam istihdam oranı, karşılaştırmalı fiyat seviyeleri, yaşlı çalışanların istihdam oranı, uzun vadeli işsizlik ve AB ile ilişkili olarak ifade edilen ulusal ekonomilerin verimliliği ortalaması	Kümeleme analizi

Nicel Karar Yöntemleri

Soldic-Aleksic (2012)	AB ülkeleri	Genel ekonomik altyapı, istihdam, ekonomik reform, sosyal uyum, yenilik ve araştırma, çevre makroekonomik göstergeleri	Kohonen kendi kendini organize eden harita (SOM) tekniği
Acar (2013)	OECD ülkeleri	Kadın istihdam, toplam işsizlik, genç işsizlik, uzun süreli işsizlik oranları	Çok boyutlu ölçekleme analizi
Arıç ve Erkekoğlu (2013)	AB ülkeleri ve Türkiye	Net ticaret haddi, cari işlemler dengesi, enflasyon, işsizlik oranı, kişi başına düşen GSYİH, gini katsayısı, toplam talep artışı ihracat değer indeksi ve başka göstergeler	Kümeleme analizi
Bulum vd. (2013)	Dünya Ticaret Örgütü Üyesi 200 ülke	İthalat ve ihracat miktarları	Kümeleme analizi
Uygur (2013)	Türkiye ve Türkiye'nin doğrudan yatırım ve dış ticaret ilişkisi içerisinde olduğu 90 ülke	Doğrudan yatırım, ihracat ve ithalat	Rank Korelasyonu ve Kümeleme Analiz
Ertaş ve Atık (2016)	AB ülkeleri, Türkiye	Ekonomi, işgücü piyasası, endüstri-ticaret-hizmetler, görelî gelişme düzeyi, Ar-Ge ve teknoloji, tarım, demografik faktörler, nüfus, sağlık, sosyal koruma, eğitim olarak sosyo-ekonomik göstergeleri	Kümeleme analizi
Turan vd. (2016)	Türkiye ve Ortadoğu ülkeleri	Enflasyon, ithalat, ihracat, gayri safi milli gelir, GSYİH, yurtdışı net gelir, döviz kuru, brüt tasarruf, toplam nüfus ve nüfus artışı	Kümeleme analizi
Koşar (2018)	Türkiye ve Türkiye'nin 2018 yılı son on yıllık periyotta en çok ithalat-ihracat yaptığı 20 ülke	Ihracat miktarı, ithalat miktarı	Kümeleme analizi
Özsarı ve Boz (2019)	OECD ülkeleri	GSYİH, gayri safi milli tasarruflar, enflasyon, işsizlik oranı, toplam yatırım, ithalat ve ihracat hacmi, cari işlemler dengesi, genel devlet toplam harcamaları, genel devlet gelirleri, genel devlet brüt borcu	Çok boyutlu ölçekleme analizinde
Yüzbaşı Künc (2018)	AB ülkeleri ve Türkiye	GSYİH, işsizlik ve ihracat/ithalat oranı	Kümeleme analizi
Akdamar (2019)	OECD ülkeleri	İstihdam oranı, işgücü piyasası güvensizliği,	Kümeleme analizi

		kişisel kazanç, uzun dönem işsizlik oranı	
Özari ve Demirkale (2019)	Kırılgan beşli ülkeleri ve Türkiye	borsa endeksi, döviz kuru (Dolar/Euro), faiz ve enflasyon oranı	Kümeleme analizi
Çağdaş (2020)	Dünyanın en büyük 20 ekonomisi	Enflasyon, işsizlik ve ekonomik büyüme oranı	Kümeleme analizi
Çılgin ve Kurt (2021)	Türk Cumhuriyetleri ve Türkiye	İthalat, ihracat verileri ve dış ticaretin temel belirleyicileri	Kümeleme analizi
Giray Yakut vd. (2021)	Türkiye ve Türkiye ile benzer yapı sergilediği saptanan ülkeler	Enflasyon, ekonomik büyüme, dış ticaret ve karbon dioksit emisyonu	Kümeleme analizi
Pelit (2023)	Ekonomik İş Birliği Teşkilatı, Karadeniz Ekonomik İş Birliği, EFTA, OECD ve Avrupa Birliği ülkeleri	İhracat miktarı, ithalat miktarı	Kümeleme analizi

3. TEMEL MAKROEKONOMİK GÖSTERGELER

Fiyatlar genel düzeyinde oluşan yıllık değişim oranı enflasyon oranına karşılık gelmektedir (Güzel ve Murat, 2019). Birçok ülke enflasyonu transfer ödemelerindeki yıllık artışları belirlemek için kullanmakta olduğundan enflasyon hesaplaması önemli bir konudur (Mügge, 2016). Her ülkenin temel hedefi olan sürdürülebilir ekonomik büyüme için enflasyon ekonomik koşullara yönelik önemli bir değişken olarak görülmektedir (Oikawa ve Ueda, 2018; Feldkircher ve Siklos, 2019: Aktaran: Muhammad vd., 2021). Teorik olarak enflasyon, ekonomi alanında zaman içinde artış gösteren tüm genel fiyatların parasal bir olgusudur (Setiartiti ve Hapsari, 2019). Enflasyon fiyat istikrarının bir göstergesidir ve genel fiyat düzeyindeki sürekli artışa karşılık gelmektedir (Önalın, 2019). Fiyat artışıyla nüfusun gerçek gelirini tükettiği için enflasyon istenmeyen bir durumdur (Zaman, 2007). OECD veri tabanında enflasyon tüketici fiyat endeksi (TÜFE) ile ölçülmektedir. Bu ölçümle enflasyon belirli hane grupları tarafından satın alınan mal ve hizmetlerin fiyat değişimidir (OECD, 2024a). Bu çalışma kapsamında enflasyon oranı TÜFE üzerinden değerlendirmeye alınmıştır.

Mal ve hizmet ticareti, ülkede ikamet edenler ile ülkede ikamet etmeyenler arasındaki mal ve hizmet işlemidir (OECD, 2024b). Mal ve hizmet ihracatı ve ithalatı, bir ülkenin yerleşikleri ile dünyanın geri kalanı arasında mal ve hizmet mülkiyetinin değişmesini içeren tüm işlemleri kapsamaktadır (Trading Economics, 2024). Mal ve hizmetlerdeki net ticaret, mal ve hizmet ithalatının mal ve hizmet ihracatına karşı mahsup edilmesiyle elde edilir (World Bank, 2024). Uluslararası ticaret, mal ve hizmetlerin farklı ülkelerin şirketleri tarafından alınması ve satılmasıdır, mal ve hizmetlerin tümü uluslararası pazarda alınıp satılır. Uluslararası ticaret, farklı ülkelerin pazarlarında bulunan mal ve hizmetlere ulaşımını ve pazarın daha rekabetçi olmasını sağlar. Bunun sonucu olarak da pazarda oluşan rekabet daha ucuz ürünlerle ve rekabetçi fiyatlandırmayla sonuçlanabilir. Uluslararası ticaretin, küresel ekonominin artışında önemli yeri olmuştur (Heakal, 2024). Uluslararası ticaret, ekonomik büyümeyi sağlamada mal ve hizmetler için dış talebi artırmada önemli bir potansiyele sahiptir (EUROSTAT, 2024a). Uluslararası ticaret, dünya ekonomisine entegrasyonun ve ticari açıklığın bir göstergesidir. Uluslararası ticaretin gelişmiş ve gelişmekte olan ülkeler için ekonomik büyümeyi arttırdığına yönelik çok sayıda ampirik kanıt bulunmaktadır (Sandri vd., 2016).

Gayri safi yurtiçi hasıla (GSYİH), ulusal gelirin, çıktının ve büyümenin en yaygın bilinen ölçüsüdür (Hameed, 2010). Bir ülkede mal ve hizmet üretimiyse belirli bir dönemde oluşturulan katma değerin bir ölçüsüdür (OECD, 2024c). Üretilen tüm mamul mal ve hizmetlerin toplam parasal veya piyasa değeridir. Belirli bir ülkenin yurtiçi üretiminin kapsamlı bir ölçümü olarak ülkenin ekonomik durumunun puan düzeyini belirtir (Investopedia, 2024). Hizmetlere harcanan toplam tutarı (ithalat hariç) veya üretimden sağlanan geliri ölçer (OECD, 2024c). Bir ülkenin sınırları içinde üretilen tüm çıktıyı hesaba katar. GSYİH

ekonominin büyüklüğü ve ekonominin nasıl performans gösterdiği hakkında bilgi sağladığı için önemli bir göstergedir (IMF, 2024). GSYİH, hükümet, çeşitli kurum ve kuruluşlar tarafından yatırımlar yapmak ve temel ekonomik politikalar ortaya koymak için kullanılan bir göstergedir (EUROSTAT, 2024b). GSYİH, belirli bir yıl içinde o bölgede üretilen tüm mal ve hizmetlerin toplam değeri olarak tanımlanır ve ekonomide dolaşan üretimin piyasa değerini ölçmek için tasarlanmıştır (Salmah vd., 2019).

Doğrudan yabancı yatırım özellikle ülkeye girişler, teknolojik dışsal ekonomiler, verimlilikte iyileşmenin ve büyümenin önemli bir kaynağı olarak görülmekte olup literatürde kapsamlı bir şekilde incelenmiştir (Bayraktar, 2013). Doğrudan yabancı yatırım (DYY), küreselleşmenin odağındadır ve ekonomiler için sermaye, hizmet, mal ve bilgi transferi için önemli bir bağıntı oluşturur (OECD, 2024d). DYY, bir ülkedeki bir işletmenin başka bir ülkede bir işletme operasyonu kurmasıyla gerçekleşmektedir. Bunun için de şirketin tamamen kendisine ait yerel bir şirket satın alarak, yeni bir iştirak kurarak veya ev sahibi ekonomide bir ortak girişimle oluşturulur (Moran, 2012). Uluslararası Para Fonu'nun Ödemeler Dengesi El Kitabı, DYY'yi "yatırımcının kendi ekonomisinden farklı bir ekonomide faaliyet gösteren bir işletmede kalıcı bir çıkar elde etmek için yapılan bir yatırım, yatırımcının amacı işletmenin yönetiminde etkili bir söz sahibi olmaktır" şeklinde tanımlamıştır (Moosa, 2003). DYY, bir firmanın yabancı bir pazarda faaliyet göstermesine ve mal ve hizmet sunmasına olanak tanıyan bir sermaye, teknoloji, yönetim ve girişimcilik paketidir (Farrell, 2008; Aktaran: Almfraji ve Almsafir, 2014).

EUROSTAT, yatırım olarak da adlandırılmakta olan brüt sabit sermaye oluşumunu, "sabit varlıklara belirli bir dönemde yapılan yatırımlardan, elden çıkarmalar düşüldükten sonra, yerleşik üreticilerin yatırımlarından oluşur." olarak

tanımlamaktadır (EUROSTAT, 2024c). Sabit sermaye oluşumu, bir işletmenin bir yıldan uzun süre elinde bulundurduğu tesis, mülk, ekipman gibi verimli süreçte kullandığı varlıkları kapsamakta olup üretken süreçte kullanılan hammaddeleri içermemektedir (Esener vd., 2017). Sabit sermaye oluşumu ülkedeki tüm sabit sermaye yatırımlarını ifade etmekte olup özel ve kamu sektöründeki iyileştirme ve yenileme amacıyla amaçlı sabit sermaye yatırımlarını kapsamaktadır (Aliyev vd., 2024).

4. ÇALIŞMANIN YÖNTEMİ

Çalışma kapsamında kümeleme analizi uygulaması yapılmıştır. Çok değişkenli analiz tekniklerinden biri olan kümeleme analizinin amacı nesneleri ya da bireylerin temel özelliklerine dayalı olarak gruplandırmaktır. Kümeleme analiziyle gruplanmamış veriler benzerliklerine göre gruplandırılarak araştırmacıya özet bilgi sunulmaktadır (Kalaycı, 2010). Kümeleme analizi, genel olarak birimler kümesini, aynı grupta birbirine benzeyen birimler olacak şekilde farklı gruplardaki birimlerin birbirine benzemediği şekilde, birbirini dışlayan, kapsamlı gruplara ayırmayı amaçlar (Chatfield ve Collins, 2000). Birimlerin sınıflamalarının yapılması, ait oldukları grupların (kitlelerin) belirlenmesi ile uğraşan kümeleme analizinde sınıflama, nümerik taksonomi sözcükleriyle ifade etmek amacıdır ve Q analiz tekniği olarak literatürde sınıflanmaktadır. Kümeleme analizinde küme kavramı uzaklık ve benzerlik kavramlarını çağrıştırmaktadır (Tatlıdil, 1996). Bununla birlikte, birimlerin sınıflamaları yerine değişkenleri kümelemek de mümkündür. Bu yönüyle kümeleme analizi faktör analizine bir alternatif yöntemdir.

Kümeleme analizi doğal gruplamaları hakkında açık bilginin olmadığı durumlarda kitleye ait tahminlerin elde edilmesinde yararlanılan bir yöntemler topluluğudur (Özdamar,

1999). Kümeleme analizinde temelde bir grup birey veya nesnede herhangi bir 'doğal grupta' olup olmadığını görmekle ilgilenilir.

Kümeleme analizinde genellikle $n \times p$ veri matrisi varken tüm birim çiftleri için benzerlik veya benzemezlik ölçerek karşılaştıran elemanları olan $n \times n$ matrisi üzerinde çalışılmaktadır (Chatfield ve Collins, 2000).

Kümeleme analizinde $n \times p$ boyutlu veri matrisinde uzaklık veya benzerlik ölçütlerine göre birimler arası uzaklık hesaplamaları yapılır. Kümeleme analizinde kümelerde yer alacak birimlerin ya da değişkenlerin belirlenmesinde uzaklık ve benzerlik ölçülerinden yararlanılmaktadır. Euclidean uzaklığı, Mahalanobis uzaklığı, Kareli Euclidean uzaklığı, Hotelling T2 uzaklığı, Minkowski uzaklığı, Chebychev uzaklığı en yaygın kullanılan uzaklık ölçüleridir. Gamma benzerlik ölçüsü ve Jaccard benzerlik ölçüsü kümeleme analizlerinde başvurulan yöntemlerdir. Literatür incelemelerinden en çok kullanılan uzaklık ölçüsünün Euclidean uzaklığı olduğu görülmektedir. Euclidean uzaklığı X_i ve X_j birim değerleri için d boyutlu koordinatlarla gösterilen uzaklık ölçüsüdür ve aşağıda yer alan formülle belirlenir (Everitt and Dunn, 2001):

$$d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (1)$$

Kümeleme analizinin temel bazı amaçları şöyle belirtilebilir (Tatlídil, 1996): Hipotez testi, Aykırı değer bulma, Veri indirgeme, Veri yapısının netleştirilmesi, Gruplar için ön tahmin. Kümeleme analizi uygulama aşamaları ise şöyledir (Özdamar, 1999): (1) Veri matrisinin belirlenmesi. Değişkenlerin ya da birimlerin doğal sınıfları hakkında kesin bilgi olmadığında kitleden alınan n sayıda birimin p tane değişkenine ait gözlemlerin belirlenmesidir. (2) Uzaklık/Benzerlik matrisinin

elde edilmesi. Değişkenlerin/birimlerin birbirilerine olan farklılık ya da benzerliklerine gösteren bir benzerlik ölçüsüyle değişkenlerin/birimlerin birbirilerine göre uzaklıklarının belirlenmesidir. (3) Seçilen bir kümeleme yöntemiyle uzaklık/benzerlik matrisine dayalı olarak değişkenlerin ya da birimlerin kümelerine ayrılmasıdır. (4) Belirlenen kümelerin yorumlanması, küme yapısına dayalı oluşturulan hipotezlerin doğrulanması amacıyla gerekli olan analitik yöntemlerin uygulanmasıdır.

Kümeleme analizi yöntemleri genel çerçevede hiyerarşik (aşamalı) ve hiyerarşik olmayan (aşamalı olmayan) kümeleme analizi yöntemleri olarak iki grupta sınıflanmaktadır. Hiyerarşik kümeleme analizi yöntemleri birimlerin ya da değişkenlerin birbirilerine olan benzerliklerini dikkate alarak küme uzaklık ölçülerine dayalı belirli düzeylerde birleştirilmesini amaçlamaktadır. Birimler ya da değişkenler farklı aşamalarda bir araya getirilerek gruplandırmalar yapılmaya çalışılır (Özdamar, 1999). Hiyerarşik kümeleme analizi yöntemlerinde küme sayısı çalışmanın başlangıcında bilinmemektedir.

Hiyerarşik kümeleme yöntemler, birleştirici veya ayırıcı yöntemler olarak iki sınıfa ayrılır. Birleştirici yöntemlerde birim sayısı n kadar kümeyle başlanır, yani her birim kendi kümesini oluşturur. Ardışık adımlarda en yakın (en benzer) iki küme birleştirilir, böylece küme sayısı her adımda bir azalır. Son adımda tüm birimler tek bir küme oluşturur. Ayırıcı yöntemlerde, başlangıçta tüm gözlemleri içeren tek bir küme olur. Ardışık adımlarda, birbirine en az benzeyen birimler ayrılır ve son adımda birim sayısı kadar küme elde edilmiş olunur. Yaygın olarak kullanılan programların çoğu birleştirici yapısındadır (Afifi vd., 2020). Çalışma kapsamında uygulama için birleştirici hiyerarşik kümeleme analizi yöntemi kullanılmıştır.

Hiyerarşik olmayan kümeleme analizi yöntemlerinde analizler aşamalı olmayan yapıda çeşitli hesaplamalar yapılması yoluyla kümelerin belirlenmesini içermektedir. Bu yöntemlerde küme sayısı araştırma esnasında bilinmektedir. Analiz sonucu oluşacak küme sayısı hakkında önsel bilgi varsa hiyerarşik olmayan kümeleme analizi yöntemleri kullanımı daha tercih edilmektedir. Hiyerarşik kümeleme yöntemler küçük veri setlerine için uygun iken hiyerarşik olmayan kümeleme analizi yöntemleri çok büyük veri setlerine uygulamaları yapılabilmektedir (Alpar, 2011).

5. BULGULAR

Çalışmanın bulgularını, OECD üye ülkeleri² için makroekonomik göstergelere göre kümeleme analizi sonuçları oluşturmuştur. Kümeleme analizinin uygulanmasında veri matrisini oluşturacak değişkenlere karar verilmesinde literatürden yararlanılmıştır. Çalışmanın değişkenlerini makroekonomik göstergelerden enflasyon ((TÜFE), Toplam, Yıllık büyüme oranı (%)), mal ve hizmet ticareti (Net ticaret, Milyon ABD doları, 2022), GSYİH (Kişi başına düşen GSYİH, cari ABD doları), doğrudan yabancı yatırım ((DYY -Küresel DYY akışları, milyar ABD doları), yatırım (Brüt Sabit Sermaye Oluşumu, toplam, yıllık büyüme oranı (%)) oluşturmuştur. Çalışmada OECD üye ülkelerinden ABD, Kolombiya, Kosta Rika ülkeleri için bazı değişken bilgilerine ulaşamadığından bu ülkelerin verileri analizlere dâhil edilmemiştir. Çalışma verileri OECD veri tabanından alınmıştır. Tüm çalışma değişkenlerine ait en güncel

² OECD üye ülkeleri: “Türkiye, Amerika Birleşik Devletleri (ABD), Fransa, Kanada, Avusturya, İngiltere, Belçika, Almanya, İtalya, Hollanda, İsveç, İspanya, Portekiz, Norveç, İzlanda, İsviçre, Danimarka, Yunanistan, İrlanda ve Lüksemburg, Japonya, Güney Kore, Finlandiya, İsrail, Letonya, Kolombiya, Litvanya, Avustralya, Estonya, Yeni Zelanda, Çekya, Macaristan, Slovenya, Polonya, Kosta Rika, Şili, Slovakya ve Meksika”

veriler 2022 yılına ait olduğu için kümeleme analizine en güncel veriler dâhil edilmiştir. Verilere ilişkin önsel küme sayısı bilgisi olmadığı için hiyerarşik kümeleme analizi uygulanmasına karar verilmiştir. Verilerin analizi IBM SPSS Statistics 24 paket programında gerçekleştirilmiştir.

5.1.Normal Dağılım ve Korelasyon Katsayısı İncelemesi

Kümeleme analizinde değişkenler analizi çoklu bağıntı sorunu olmaması istenilmektedir. Değişkenler arası ilişkilerin belirlenmesinde hangi yöntemin kullanılacağına karar vermede öncelikli olarak veride normal dağılım incelemesi yapılmaktadır. Shapiro-Wilk testi için “H₀: Veri Normal dağılımlıdır.” “H₁: Veri Normal dağılımlı değildir.” hipotez testi sınaması yapılmaktadır. Tablo 2’de Shapiro-Wilk testi sonuçları yer almaktadır. Tablo 2’den görüldüğü üzere tüm değişkenler için önem düzeyleri $p < 0,05$ olduğu için H₀ hipotezi reddedilmiştir.

Tablo 2. Shapiro-Wilk Testi Bulguları

Değişken	Shapiro-Wilk		
	İstatistik	sd	p
GSYIH	0,823	35	0,000
DYY	0,541	35	0,000
Enflasyon	0,468	35	0,000
Yatırım	0,929	35	0,025
Ticaret	0,811	35	0,000

Değişkenlerin normal dağılımlı olmadığına karar verildiği için değişkenler arası ilişkilerin araştırılmasında Spearman korelasyon katsayı değerlerine bakılabilmektedir. Tablo 3 incelendiğinde değişkenler arası korelasyon katsayılarının 0,80 ve üzeri değerli olmaları, dolayısıyla da çoklu bağıntı sorunu olmadığı belirlenmiştir. Bu nedenle, kümeleme analizinde değişken çıkarılması yoluna gidilmemiştir.

Tablo 3. Spearman Korelasyon Katsayı Değerleri

	GSYİH	DYY	Enflasyon	Yatırım	Ticaret
GSYİH	1,000	-0,069	-0,488**	-0,120	0,349*
DYY		1,000	-0,402*	0,003	-0,225
Enflasyon			1,000	0,081	0,089
Yatırım				1,000	-0,073
Ticaret					1,000


*İlişki 0,05 ve **ilişki 0,01 düzeyinde anlamlıdır.

Çalışmanın değişken ölçüm düzeyleri farklı olduğu için kümeleme analizi aşamasında veride standartlaştırma uygulanmıştır. Kümeleme analizi uygulamasında uzaklık ölçüsü olarak literatürde sıklıkla başvurulmuş Euclidean uzaklığı kullanılmış ve birleştirici kümeleme yöntemlerinden en yoğunlukla kullanılan Ward yöntemi uygulanmıştır.

5.2.Ward Yöntemi Bulguları

Birleştirici hiyerarşik kümeleme yöntemlerinden biri olan Ward yöntemiyle ülkelerin çalışma verilerine dayalı kümelenmeleri belirlenmesi amaçlanır. Hangi ülke hangi başka ülkelerle aynı kümede sınıflanacak belirlenmeye çalışılmaktadır. Ward yöntemiyle belirlenen ağaç diyagramı Şekil 1’de sunulmuştur. Şekil 1’deki ağaç diyagramına dayalı genel bir değerlendirme yapıldığında Lüksemburg ve Türkiye’nin diğer ülkelerden ayrı olarak tek başlarına birer küme oluşturdukları görülmektedir. Ağaç diyagramı incelendiğinde 6 düzeyinde sekiz küme oluşmaktadır; 8 düzeyinde altı küme oluşmaktadır ve 11 düzeyinde ise beş küme oluşmaktadır. Çalışma kapsamında beş, altı ve sekiz küme sayısı alınarak ülke sınıflamaları değerlendirmeye alınmıştır.

**Şekil 1. Kümeleme Analizi Ward Yöntemi Kullanılarak
Oluşturulan Ağaç Diyagramı**



Şekil 1’den tüm küme sayıları için inceleme yapıldığında Lüksemburg ve Türkiye’nin 16. düzeye kadar her durumda tek başına ayrı birer küme oluşturdukları görülmektedir. Tablo 4’te beş, altı ve sekiz küme sayısı olduğundaki ülke sınıflamaları sunulmuştur.

Tablo 4. Kümeleme Analizi Ward Yöntemi Ülkelerin Küme Üyelikleri

Ülke numarası	ÜLKE	8 KÜME	6 KÜME	5 KÜME
1	Avustralya	1	1	1
2	Avusturya	2	2	1
3	Belçika	2	2	1
4	Kanada	1	1	1
5	Şili	2	2	1
6	Çekya	2	2	1
7	Danimarka	2	2	1
8	Estonya	3	1	1
9	Finlandiya	2	2	1
10	Fransa	1	1	1
11	Almanya	4	3	2
12	Yunanistan	5	4	3
13	Macaristan	2	2	1
14	İzlanda	2	2	1
15	İrlanda	6	3	2
16	İsrail	5	4	3
17	İtalya	5	4	3
18	Japonya	1	1	1
19	Kore	4	3	2
20	Letonya	2	2	1
21	Litvanya	2	2	1
22	Lüksemburg	7	5	4
23	Meksika	5	4	3
24	Hollanda	6	3	2
25	Yeni Zelanda	2	2	1
26	Norveç	6	3	2
27	Polonya	2	2	1
28	Portekiz	2	2	1
29	Slovakya	2	2	1
30	Slovenya	2	2	1
31	İspanya	2	2	1
32	İsveç	2	2	1
33	İsviçre	6	3	2
34	Türkiye	8	6	5
35	Birleşik Krallık	5	4	3

Çalışma kapsamında altı küme sınıflaması incelemesi yapılmıştır. Küme sayısı altı alındığında ülkelerin kümelere göre dağılımı Tablo 5’te sunulmuştur.

Tablo 5. Kümeleme Analizi Altı Küme Sınıflaması

Küme	Ülkeler	Kümedeki ülke sayısı
1	Avustralya, Kanada, Estonya, Fransa	4
2	Avusturya, Belçika, Şili, Çekya, Danimarka, Finlandiya, Macaristan, İzlanda, Letonya, Litvanya, Yeni Zelanda, Polonya, Portekiz, Slovakya, Slovenya, İspanya, İsveç	17
3	Almanya, İrlanda, Kore, Hollanda, Norveç, İsviçre	6
4	Yunanistan, İsrail, İtalya, Meksika, Birleşik Krallık	5
5	Lüksemburg	1
6	Türkiye	1

Türkiye ve Lüksemburg’un tek başlarına ayrı birer küme oluşturdukları görülmektedir. Kümelere ilişkin makroekonomik göstergelere ait tanımlayıcı istatistikler değerlendirmelerinde Türkiye’nin tüm ülke kümeleri arasında en olumsuz gösterge değerlerine sahip olduğu, Lüksemburg’un ise tüm ülke kümeleri arasında en iyi gösterge değerlerine sahip ülke olduğu belirlenmiştir.

Ülke sınıflamalarına yönelik her bir değişken için kümeler arasında farklılık olup olmadığı tek yönlü varyans analiziyle araştırılmıştır. Her bir değişken için belirlenen tek yönlü varyans analizi bulguları Tablo 6’da yer almaktadır. Araştırmada varyans analizi için kurulan genel hipotez; “ H_0 : Kümeler arasında araştırma değişkeni bakımından farklılık yoktur.” ve “ H_1 : Kümeler arasında araştırma değişkeni bakımından farklılık vardır.” olup hipotez testi sınaması yapılmaktadır. F değerlerine karşılık gelen tüm önem düzeylerine bakıldığında $p < 0,05$ olarak belirlenmektedir. Dolayısıyla H_0 hipotezi reddedilmektedir. Araştırma değişkenlerine göre kümeler arasında anlamlı farklılık olduğu yorumu yapılabilir.

Tablo 6. Tek Yönlü Varyans Analizi Bulguları

Değişken	F	p
GSYİH	9,115	0,000
DYY	40,572	0,000
Enflasyon	50,491	0,000
Yatırım	11,819	0,000
Ticaret	27,195	0,000

6. SONUÇ

Ülkelerin ekonomi alanındaki durumlarının temel göstergeleri makroekonomik verilerdir. Ülkelerin yatırımları çekebilme, küresel düzeyde rekabet edileme, finans piyasalarını geliştirme makroekonomi alanında başarı gösterilebilmesi beklentisine dayanmaktadır (Eyüboğlu, 2017). Makroekonomi alanındaki gelişmelerin takip edilmesi ülkelerin değerlendirmelerinin yapılabilmesinde belirleyici rol oynamaktadır. Ekonomi alanında en çok konuşulan makroekonomik göstergelerin başında GSYİH ve enflasyon gelmektedir. Ülkelerin ekonomi alanında ne kadar güçlü olduğu bu iki göstergeye dayalı değerlendirilebilmektedir. Çalışma kapsamında GSYİH ve enflasyon incelemeye alınmakla birlikte makroekonomik göstergelerden mal ve hizmet ticareti, yatırımlar, doğrudan yabancı yatırımlar literatür çalışmalarına dayalı çalışmaya dahil edilmiştir. Seçilen göstergeler ülkelerin küresel düzeyde değerlendirilmesinde belirleyici faktörlere karşılık gelmektedir.

Çalışmada amaç OECD ülkelerinin makroekonomik göstergeler açısından sınıflamalarının araştırılması olmuştur. Çok değişkenli istatistiksel analiz tekniklerinden kümeleme analizi ile makroekonomik göstergelere göre OECD üye ülkelerinin sınıflamalarının yapılmaya çalışılmıştır. Ülke sınıflamaların yapılmasında kümeleme analizi uygulanmıştır. Kümeleme analizinde Ward yöntemi kullanılmıştır. Kümeleme analizi

sonucu Ward yöntemiyle belirlenen ağaç diyagramında farklı düzeyler için farklı küme sayıları altında ülke sınıflamaları incelemesi yapılmıştır. Küme detaylandırmasında altı küme sınıflaması incelemesi gerçekleştirilmiştir. Altı küme sınıflamasında ve bununla birlikte sekiz ve beş küme sınıflamasında da Türkiye ve Lüksemburg'un tek başlarına ayrı birer küme oluşturdukları görülmüştür. Kümeleme analizi sonucu makroekonomik göstergelere dayalı birbirine en benzer iki ülkenin Avusturya ve Belçika olduğu belirlenmiştir. Kümeleme işlemlerinin en son aşamasında Avustralya ve Almanya birleştirilen iki ülke olmuştur. Gelişmiş ülke kategorisinde yer alan Lüksemburg ile gelişmekte olan ülkeler kategorisinde yer alan Türkiye makroekonomik göstergeler açısından birbirine en az benzeyen ülkeler arasındadır. Gelişmekte olan ülkeler grubunda yer alan Türkiye'nin ekonomi alanında gelişim göstermesi ve Lüksemburg'daki gelişimleri takip ederek uygulamaya koyması önem arz etmektedir.

KAYNAKÇA

- Acar, A. B. (2013). İşgücü piyasası temel göstergeleri bakımından çok boyutlu ölçekleme analizi ile türkiye ile diğer OECD ülkelerinin karşılaştırılması. İ. Ü. İşletme Fakültesi İşletme İktisadı Enstitüsü Yönetim Dergisi, 24(75), 121-144.
- Afifi, A., May, S., Donatello, R. A. & Clark, V. A. (2020). *Practical Multivariate Analysis*. New York: CRC Press Taylor & Francis Group
- Akdamar, E. (2019). OECD Ülkelerinin Bazı İş Gücü Piyasası Göstergeleri Kullanılarak Kümeleme Analizi ve Çok Boyutlu Ölçekleme Analizi ile İrdelenmesi. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 11(20), 50-65.
- Aliyev, P., Ağırkaya, M. B. & Çelik, Ş. (2024). Uluslararası ekonomik ilişkilerin Türkiye’de sabit sermaye oluşumu üzerine etkileri. Paradigma: İktisadi ve İdari Araştırmalar Dergisi, 13(1), 56-68.
- Almfraji, M. A. & Almsafir, M. K. (2014). Foreign Direct Investment and Economic Growth Literature Review from 1994 to 2012. *Procedia - Social and Behavioral Sciences*, 129, 15 May 2014, 206-213.
- Alpar R. (2011). *Çok değişkenli istatistiksel yöntemler*. Ankara: Detay Yayıncılık.
- Arıç, K., H., & Erkekoğlu, H. (2013). AB Ülkeleri ve Türkiye’nin Makro Ekonomik Göstergeler Bakımından İstatistiksel Analizi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 14(2), 291-306.
- Bayraktar, N. (2013). Foreign Direct investment and Investment Climate. *Procedia Economics and Finance*, 5, 83 – 92.

- Bulum, A., Ersöz, F. & Ersöz, T. (2013). Dünya Ticaret Örgütü (WTO) Üyesi Ülkelerin Uluslararası Ticaret Hacimleri Üzerine Bir Çalışma. *Nevşehir Bilim ve Teknoloji Dergisi*, 2(2), 153-165.
- Çağdaş, Y. (2020). Koronavirüs (COVID-19) Salgınının Ekonomi Ve Kamu Maliyesine Etkilerinin Kümeleme Analizi İle İncelenmesi. *Ekonomi, Politika & Finans Araştırmaları Dergisi*, 5(Özel Sayı), 137-163.
- Chatfield, C & Collins, A. J. (2000). *Introduction to Multivariate Analysis*. USA: Chapman & Hall/CRC A C R C Press Company.
- Çılgin, C., & Kurt, A. S. (2021). Dış Ticaret Verileri İçin Kümeleme Analizi: Türkiye, Azerbaycan ve Kazakistan Örneği. *Sosyoekonomi*, 29(48), 511-540.
- Erkekoğlu, H. (2007). AB'ye Tam Üyelik Sürecinde Türkiye'nin Üye Ülkeler Karşısındaki Görelî Gelişme Düzeyi: Çok Değişkenli İstatistiksel Bir Analiz. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14(2), 28- 50.
- Ertaş, S. A. & Atik, H. (2016). Kalkınma Göstergeleri Bakımından Türkiye'nin Avrupa Birliği Ülkeleri Arasındaki Yeri: İstatistiksel Bir Analiz. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 48, Temmuz-Aralık, 199-218.
- Esener, S. Ç., Darıcı, B. & Karadağ, Y. (2017). Kamu Harcamaları, Doğrudan Yabancı Sermaye Yatırımları ve Dışa Açıklık Seviyesinin Sabit Sermaye Oluşumu Üzerindeki Etkileri. 2. Mediterranean International Congress on Social Sciences (MECAS II). International Vision University Ohrid, October 2017, s. 553-570.
- EUROSTAT (2024a). World trade in goods and services - an overview. <https://ec.europa.eu/eurostat/statistics->

explained/index.php?title=World_trade_in_goods_and_services_-_an_overview (E.T.: 12.09.2024).

EUROSTAT (2024b). Beginners: GDP - What is gross domestic product (GDP)? <https://ec.europa.eu/eurostat/statistics-explained/> (E.T.: 12.09.2024).

EUROSTAT (2024c). Glossary: Gross fixed capital formation (GFCF). <https://ec.europa.eu/eurostat/statistics-explained/>

Everitt, B. S., & Dunn, G. (2001). *Applied multivariate data analysis*. John Wiley & Sons Ltd.

Eyüboğlu, K. (2017). Türk Dünyasında Yer Alan Ülkelerin Makro Performanslarının Karşılaştırılması. *Bilig*, (83), 331-350.

Giray Yakut S., Özdemir Yazgan S. D., Bacaksız N. E. & Fikir H. (2021). Enerji kullanımı ve başlıca makroekonomik göstergeler etkileşimi ve bu etkileşim bağlamında Türkiye'nin dünya içindeki yeri. *Journal of Life Economics* , 8(2), 247-261.

Gligor, M. & Ausloos, M. (2008). Convergence and Cluster Structures in EU Area according to Fluctuations in Macroeconomic Indices. *Journal of Economic Integration*. 23(2), 297-330.

Güzel, S. & Murat, D. (2019). Yönetişim ve Ekonomik Performans Bağlamında OECD Ülkelerinin Konumları. *Akademik İncelemeler Dergisi*, 14(1), 315-344.

Hall, S. A. & Cook, T. R. (2017). Macroeconomic Indicator Forecasting with Deep Neural Networks (September 29, 2017). Federal Reserve Bank of Kansas City Working Paper No. 17-11.

- Hameed, I. (2010). Impact of Monetary Policy on Gross Domestic Product (GDP). *Interdisciplinary Journal of Contemporary Research in Business*, 3(1), 1348 - 1361.
- Heakal, R. (2024). Global Trade Guide. Investopedia. <https://www.investopedia.com/insights/what-is-international-trade/>
- IMF (2024). International Money Foundation. Measuring GDP. <https://www.imf.org/en/Publications/fandd/issues/Series/Back-to-Basics/gross-domestic-product-GDP>
- Investopedia (2024). What Is Gross Domestic Product (GDP)? <https://www.investopedia.com/terms/g/gdp.asp>
- Kalaycı, Ş. (2010). *SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri*. Ankara: Asil Yayın Dağıtım.
- Koşar, A. (2018). Türkiye'nin Son 10 Yılda En Çok İhracat ve İthalat Yaptığı Ülkelerin Hiyerarşik Kümeleme Analizi İle Gruplandırılması ve Değerlendirilmesi. *MAKÜ-BİFD*, 1(1), 17-28.
- Kurnoga Zivadinovic, N., Dumicic, K. & Ceh Casni, A. (2009). Cluster and Factor Analysis of Structural Economic Indicators for Selected European Countries. *Wseas Transactions on Business and Economics*, 6(7), 331-341.
- Moosa, I.A. (2003). *Foreign Direct Investment*. In: International Financial Operations. Finance and Capital Markets Series. London: Palgrave Macmillan.
- Moran, T. (2012). *Foreign direct investment*. The Wiley-Blackwell Encyclopedia of Globalization.
- Mügge, D. (2016) Studying macroeconomic indicators as powerful ideas, *Journal of European Public Policy*, 23:3, 410-427.

- Muhammad, A. M., Alaloul, W. S. & Liew, M.S. (2021). Impact of inflation rate on construction projects budget: A review. *Ain Shams Engineering Journal*, 12(1), 407-414.
- OECD (2024a). Inflation (average consumer prices) (CPI) definition.
<https://www.oecd.org/en/data/indicators/inflation-cpi.html> (E.T.: 10.09.2024).
- OECD (2024b). Trade in goods and services definition.
https://www.oecd-ilibrary.org/trade/trade-in-goods-and-services/indicator/english_0fe445d9-en (E.T.: 10.09.2024).
- OECD (2024c). Gross domestic product (GDP) definition.
https://www.oecd-ilibrary.org/economics/gross-domestic-product-gdp/indicator/english_dc2f7aec-en (E.T.: 10.09.2024).
- OECD (2024d). Foreign Direct investment.
<https://www.oecd.org/en/topics/sub-issues/foreign-direct-investment-fdi.html> (E.T.: 10.09.2024).
- Önalan, G. O. (2019). Makroekonomik Göstergeler Üzerinden Uluslararası Para Fonu Küresel Bölge Gruplarının Kompozisyonu. *İnsan Ve Toplum Bilimleri Araştırmaları Dergisi*, 8(3), 2128-2140.
- Özari, Ç. & Demirkale, Ö. (2019). K-Ortalamlar Kümeleme Yöntemi ile Temel Makroekonomik ve Finansal Göstergeler İle Değerlendirilmesi: Kırılgan Beşli Ülkelerinin Örneği. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 5(1), 22-32.
- Özdamar, K. (1999). *Paket programlar ile istatistiksel veri analizi (Çok değişkenli Analizler)*. Eskişehir: Kaan Kitabevi.

- Özsarı, S. H., & Boz, C. (2019). Comparison of Health Status and Macroeconomic Indicators in Organization for Economic Cooperation and Development Countries Using Multidimensional Scaling and TOPSIS. *Sağlık Bilimleri Ve Meslekleri Dergisi*, 6(3), 545-554.
- Pelit, İ. (2023). Türkiye'nin Ülke Gruplarına Göre İthalat ve İhracatının Kümeleme Analizi İle İncelenmesi: 2013-2022 Dönemi. *İşletme ve İktisat Çalışmaları Dergisi*, 11(2), 103-113.
- Salmah, N.N.A., Rahul Chauhan, R., Valianti, R. M. & Maseleno, A. (2019). Effect of GDP with respect to the Nominal and Real GDP of India: 2014-'15. *Opción, Año 35, Especial*, 19, 2337-2365.
- Sandri, S., Alshyab, N. & Ghazo, A. (2016). Trade in Goods and Services and Its Effect On Economic Growth –The Case of Jordan. *Applied Econometrics and International Development, Euro-American Association of Economic Development*, 16(2), 113-128.
- Setiartiti, L. & Hapsari, Y. (2019). Determinants of Inflation Rate In Indonesia. *Jurnal Ekonomi & Studi Pembangunan*, 20(1), 112-123.
- Soldic-Aleksic, J. (2012), The Visualization and Grouping of European Union Member States According to Structural Indicators: A Data-Driven Approach. *China-USA Business Review*, 11(5), 591-612.
- Tatlıdil H. (1996). *Uygulamalı Çok Değişkenli İstatistiksel Analiz*. Cem Web Ofset Ltd. Şti.
- Trading Economics (2024). Net Trade In Goods And Services (BoP, Current US\$) By Country. <https://tradingeconomics.com/country-list/net-trade-in->

goods-and-services-bop-us-dollar-wb-data.html(E.T.: 05.09.2024).

- Turan, K. K., Özari, Ç., & Demir, E. (2016). Kümeleme Analizi İle Türkiye ve Ortadoğu Ülkelerinin Ekonomik Göstergeler Açısından Karşılaştırılması. *İstanbul Aydın Üniversitesi Dergisi*, 8(29),143-165.
- Uygun, S. (2013). Ülkemizin Dış Ticaret ve Doğrudan Yurt Dışı Yatırımlarında Tercih Ettiği Ülkeler İçin Rank Korelasyonu ve Kümeleme Analizi. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 32(2), 95-112.
- World Bank (2024). Net trade in goods and services (BoP, current US\$). <https://databank.worldbank.org/metadataglossary/all/series?search=Trade%20in%20goods%20and%20services> (E.T.: 01.09.2024).
- Yılmaz, Ö. & Kaya, V. (2005). Genişleme Sürecindeki Avrupa Birliği: Ekonomik Performansa Dayalı Kümeleme Analizi. *Current Perspectives in Social Sciences*, 5(1), 361-376.
- Yüzbaşı Künc, G. (2018). Veri Madenciliği Tekniklerinin Bilgi Ekonomisi Değişkenlerine Uygulanması. Doktora Tezi, İstanbul: İstanbul Üniversitesi.
- Zaman, C. (2007). Practical Guide for Using Main Macroeconomic Indicators. Available at SSRN: <https://ssrn.com/abstract=1019869> or <http://dx.doi.org/10.2139/ssrn.1019869>

UZAKTAN EĞİTİMDE DERS MATERYALİ, SINAV VE PROGRAM DEĞERLENDİRMENİN ÖĞRENME MEMNUNİYETİ ÜZERİNE ETKİSİNİN YAPISAL EŞİTLİK MODELİYLE İNCELENMESİ

Münevver GÜNDÜZ¹

Mehmet YILDIZ²

Metin BAYRAM³

1. GİRİŞ

Uzaktan eğitim öğrencilere esneklik, erişim kolaylığı, zaman ve mekandan bağımsız öğretim imkanı sunması nedeniyle son yıllarda daha yaygın olarak kullanılmaktadır (Efiloğlu Kurt, 2015; Aşçı ve Toktaş, 2021). Özellikle COVID-19 pandemisi sırasında, uzaktan eğitim modeline olan talep büyük ölçüde artmış ve bu eğitim modeli, geleneksel eğitim sistemlerine kıyasla daha esnek, erişilebilir ve geniş çapta kabul gören bir öğrenme yöntemi olarak benimsenmiştir (Bozkurt, 2020). Uzaktan eğitimde öğrenci memnuniyeti, sınav başarısı ve ders materyallerinin kalitesi, uzaktan eğitim yönteminin başarısını belirleyen en önemli faktörler arasındadır (Laurillard, 2002; Garrison, 2011). Yükseköğretimde uzaktan eğitim derslerinin

¹ Öğr. Gör. Dr., Sakarya Uygulamalı Bilimler Üniversitesi, Uzaktan Eğitim Uygulama ve Araştırma Merkezi, munevvergunduz@subu.edu.tr, ORCID: 0000-0003-1358-8803.

² Öğr. Gör., Sakarya Uygulamalı Bilimler Üniversitesi, Uzaktan Eğitim Uygulama ve Araştırma Merkezi, mehmetyildiz@subu.edu.tr, ORCID: 0000-0002-9523-3805.

³ Dr. Öğr. Üyesi, Sakarya Üniversitesi, İşletme Fakültesi, İşletme Bölümü, metinbayram@sakarya.edu.tr, ORCID: 0000-0002-9483-7850.

kalitesini belirlerken öğrenci memnuniyeti önemli bir kriter olarak ele alınmaktadır (Alqurashi, 2018; Dziuban vd., 2015). Öğrencilerin aldıkları eğitim hizmetlerinden memnun kalmaları, programın amaçlarına ulaşılması bakımından büyük öneme sahiptir (Cazan & Maican, 2023). Öğrencilerin program memnuniyeti, programın kalitesine, ders içeriklerinin sunumuna ve sınav değerlendirme yöntemlerine bağlıdır (Yuebo, Halili & Abdul Razak, 2024).

Bu çalışma, öğrenci memnuniyeti, çevrimiçi öğrenme ortamlarında sunulan materyallerin kalitesi, öğrencilerin sınav başarıları ve programa yönelik değerlendirmeleri arasındaki nedensellik ilişkilerini incelemeyi amaçlamaktadır. Ayrıca, programa yönelik değerlendirmelerin, öğrencilerin genel öğrenme memnuniyeti üzerindeki dolaylı etkileri de araştırılmaktadır. Bu amaçla alanyazın bilgisiyle uyumlu nedensellik ilişkileri çerçevesinde bir yapısal eşitlik modeli (YEM) tasarlanmıştır. Bu YEM'i oluşturan yapılar arasında anlamlı ilişki olup olmadığı Kısmi En Küçük Kareler Yöntemi (KEKK) kullanılarak analiz edilmiştir.

Çalışmanın bundan sonraki bölümlerinde alanyazın ve hipotez geliştirme, araştırmanın evren ve örnekleme, veri toplama süreci ve kullanılan analiz yöntemleri açıklanmaktadır. Sonra araştırmanın analizleri sonucunda elde edilen bulgular sunulmaktadır. Son olarak bulgular kısmında elde edilen hipotez sonuçları, alanyazındaki diğer çalışma sonuçları ile tartışılmakta, benzerlik ve farklılıklar ortaya konulmaktadır. Ayrıca diğer çalışmalara yol gösterici nitelikte sonuç ve öneriler de sunulmaktadır.

2. ALANYAZIN

2.1. Uzaktan Eğitim Ders Materyalleri

Uzaktan eğitimde ders materyalleri, öğrenme sürecinin etkinliğini artırmak ve öğrencilerin ilgisini çekmek için çeşitli formatlarda sunulmaktadır. Bu materyaller, öğrencilerin konuyu daha iyi anlamalarını sağlamak amacıyla farklı duyuşsal kanalları hedefleyerek öğrenme deneyimini zenginleştirmektedir. Görsel içerikler, metin, çizim, fotoğraf ve grafikler aracılığıyla kavramların daha anlaşılır hale gelmesini sağlamaktadır. İşitsel materyaller ise sözlü sunumlar, müzik ve sesler yoluyla öğrenmeyi pekiştirir ve öğrencilere işitsel katılım yoluyla farklı bir deneyim sunmaktadır. Görsel-işitsel kaynaklar, videolar ve TV programları, materyallerin hem işitsel hem de görsel unsurlarını birleştirerek daha zengin bir öğrenme ortamı oluşturmaktadır (Toxirjonovich & Qizi, 2022).

Uzaktan eğitim görsel, işitsel, görsel-işitsel ve multimedia içeriğini etkili bir şekilde kullanabilir. Uzaktan eğitim, etkili öğretim materyalleri için multimedia içeriğinden yararlanır. Multimedia, içeriği ilgi çekmek ve açıklamak için uzaktan eğitimde çok önemlidir. Multimedia materyalleri ise metin, görüntü, ses ve animasyonları entegre ederek etkileşimli ve çekici bir öğrenme ortamı sunmaktadır (Toxirjonovich & Qizi, 2022). Uzaktan eğitimde multimedia dikkat çeker ve katılımcıları motive eder. Multimedia, bilginin anlaşılmasını, hafızasını ve uygulamasını geliştirir (Bogdanović, 2012).

Dijital formatlar da uzaktan eğitimin ayrılmaz bir parçası haline gelmiştir. E-kitaplar, simülasyonlar ve animasyonlar, teknolojinin sunduğu imkanları kullanarak öğrencilerin derslere daha fazla dahil olmalarını sağlamaktadır (Kör, Aksoy & Erbay, 2014; Gujjar & Malik, 2007). Özellikle COVID-19 pandemisi ile birlikte uzaktan eğitimdeki artış, ders materyallerinin uyarlanması gerekliliğini daha da ön plana çıkarmıştır (Gugliano

& Sainz, 2021). Bu materyallerin öğrenci dostu olması ve öğrencilerin ihtiyaçlarına hitap etmesi, etkili bir uzaktan eğitim deneyimi sunmanın anahtarıdır (Venkatraman, 2011). Ancak, bu materyallerin niteliği ve öğrenci ile etkileşim düzeyi, farklı formatlar kullanıldığında bile sürekli olarak değerlendirilmesi ve uyarlanması gereken önemli bir zorluk olarak karşımıza çıkmaktadır.

2.2. Uzaktan Eğitimde Sınav Değerlendirme

Uzaktan eğitimde sınav değerlendirmesi, öğrenci başarısının ölçülmesinde kritik bir rol oynamaktadır. Sanal öğrenme ortamları, sınavlar ve diğer değerlendirme yöntemleri aracılığıyla öğrenci performansını takip etmek ve geri bildirim sağlamak için önemli fırsatlar sunar (Archer, Crispim & Cruz, 2016; Diamadis & Polyzos, 2008). Bu değerlendirme süreci, öğrencilerin öğrenme gelişimini izlemek ve eksikliklerini gidermek açısından büyük bir öneme sahiptir. Araştırmalar, çoktan seçmeli sınavların, uzaktan eğitimde açık uçlu sorulara kıyasla daha yüksek öğrenci başarı oranları sağladığını göstermektedir (Yılmaz & Toker, 2022). Çoktan seçmeli sınavlar, eğitmenler tarafından tercih edilmekte ve öğrenci başarısıyla güçlü bir ilişki göstermektedir. Lisansüstü eğitimde ise performansa dayalı değerlendirmeler, sorumluluk alma ve son teslim tarihine uyum gibi becerileri geliştirmek amacıyla kullanılmaktadır (Polat vd., 2022). Ancak, her iki formatın da avantajları ve dezavantajları bulunmaktadır; bu nedenle sınav değerlendirme sürecinin sürekli gözden geçirilmesi ve iyileştirilmesi gerekmektedir.

Uzaktan eğitimde sınav değerlendirmesi, teknolojik yetersizlikler, motivasyon eksikliği ve dijital okuryazarlık gibi zorluklarla da karşı karşıyadır (Uzun, Aktaş & Akay, 2023; Yılmaz, 2017). Teknik sorunlar, özellikle çevrimiçi sınavlarda adil ve güvenilir bir değerlendirme yapmayı zorlaştırabilir. Bu

sorunların üstesinden gelmek için alternatif değerlendirme yöntemlerinin çevrimiçi platformlara entegre edilmesi ve eğitmen ve öğrencilere yönelik dijital okuryazarlık eğitimlerinin verilmesi önerilmektedir (Yılmaz, 2017).

Teknolojinin sınav değerlendirmesine entegrasyonu da önemli bir faktördür. Görsel-işitsel araçlar ve etkileşimli teknolojiler, öğrenci katılımını artırarak sınav süreçlerini daha etkili hale getirebilir. Özellikle ses, video ve dijital araçların kullanımı, öğrencilerin öğrenme deneyimlerini zenginleştirerek sınav değerlendirmesinin güvenilirliğini artırabilir (Armağan & Yiğit, 2017).

Alanyazında, ders materyallerinin öğrencilerin sınav performanslarını doğrudan etkilediği sıklıkla vurgulanmaktadır. Öğrencilerin öğrenme sürecinde, özellikle uzaktan eğitimde, farklı formatlarda sunulan ders materyalleri ile ders içeriğini anlamaları ve sınavlarda başarılı olmaları arasında doğrudan bir ilişki bulunmaktadır (Venkatraman, 2011; Toxirjonovich & Qizi, 2022). Uzaktan eğitim ders materyallerinin, öğrencilerin sınav başarısı üzerinde büyük bir etkisi olduğu alanyazında çeşitli çalışmalarla desteklenmiştir. Özellikle kaliteli e-kitaplar, simülasyonlar, video içerikleri ve animasyonlar gibi dijital materyaller, öğrencilerin ders içeriklerini daha iyi anlamalarına yardımcı olarak sınavlarda daha başarılı olmalarını sağlamaktadır (Kör vd., 2014; Gujjar & Malik, 2007). Gugliano ve Sainz (2021) COVID-19 pandemisi sürecinde uzaktan eğitim materyallerinin uyarlanması, öğrencilerin derslere daha fazla dahil olmalarını sağladığını ve bu durumun sınav başarılarını artırdığını göstermiştir.

Bu bilgiler ışığında;

H₁: Çevrimiçi öğrenme ortamlarında sunulan materyal (M) öğrencilerin sınav değerlendirmesini (D) olumlu etkilemektedir.

2.3. Uzaktan Eğitim Programının Değerlendirilmesi

Uzaktan eğitim programları, özellikle erişim kısıtlılığı yaşayan öğrenciler için eğitimde önemli fırsatlar sunmaktadır. Bu programlar, esnek yapısı sayesinde öğrencilerin iş, aile ve diğer sorumluluklarıyla eğitimlerini dengelemelerine olanak tanımaktadır (Garrison, Anderson & Archer, 2010). Uzaktan eğitim, öğrencilerin hem mesleki hem de kişisel gelişimlerine katkı sağlaması açısından oldukça faydalı bir öğrenme modeli olarak görülmektedir. Programlar, özellikle küresel kriz dönemlerinde eğitimde alternatif bir model olarak hızla benimsenmiştir (Bozkurt, 2020).

Programdaki derslerin dönemlere uygun bir şekilde planlanması, öğrencilerin öğrenme sürecindeki iş yüklerini dengeli bir şekilde yönetmelerine olanak tanımaktadır. Araştırmalar, derslerin düzenli bir şekilde sunulmasının öğrencilerin öğrenme motivasyonunu artırdığını ve başarıyı olumlu yönde etkilediğini göstermektedir (Alkan & Özdemir, 2023; Means, Bakia & Murphy, 2014). Bu bağlamda, ders yükünün dengeli dağıtımı, öğrencilerin programı daha rahat takip etmelerini ve derslere zaman ayırmalarını kolaylaştırmıştır. Öğrenciler, derslerin dönemlere dağılımının başarılı olduğu programlarda, daha yüksek memnuniyet düzeylerine ulaşmaktadır.

Derslerin programın genel amacı ile uyumlu bir şekilde tasarlanması, programın etkili bir yapı sunduğunun göstergesidir. Araştırmalar, eğitim programlarının içerikleri ve hedefleri arasında tutarlılık olmasının, öğrenme çıktılarına olumlu yönde etkilediğini ortaya koymaktadır (Biggs & Tang, 2011). Öğrenciler, programın amacına uygun ders içerikleriyle karşılaştıklarında, öğrenme süreçlerine daha etkin katılım sağlamak ve bu da öğrenme memnuniyetlerini artırmaktadır.

Uzaktan eğitim programları, öğrencilerin mesleki gelişimlerine de önemli katkılar sağlamaktadır. Programdaki derslerin teorik bilgi ile pratik uygulamayı dengeli bir şekilde sunması, öğrencilerin mesleki yeterliliklerini artıran önemli bir unsurdur (Swan, Garrison & Richardson, 2009). Özellikle mesleki becerilere yönelik ders içerikleri, öğrencilerin mezun olduktan sonraki kariyer hayatlarında başarılı olmalarına olanak tanımaktadır. Bu bağlamda, öğrenciler, programdaki derslerin mesleki açıdan kendilerine önemli katkılar sunduğunu düşünmekte ve bu durum da genel program memnuniyetini artırmaktadır.

Uzaktan eğitim programlarının başarısını belirleyen bir diğer önemli faktör, ders içeriklerinin çeşitliliğidir. Programların farklı öğrenme stillerine hitap eden okuma materyalleri, e-içerikler, videolar ve diğer interaktif öğrenme araçları ile zenginleştirilmesi, öğrencilerin derslere olan ilgisini artırmaktadır (Toxirjonovich & Qizi, 2022). Öğrenciler, derslerde sunulan bu çeşitlilik sayesinde daha kolay öğrenmekte ve programın genel başarısına olan katkıları olumlu yönde artmaktadır. Öğrencilerin bireysel ihtiyaçlarına uygun tasarlanmış programlar, onların öğrenme süreçlerine daha fazla katılım göstermelerine olanak tanır ve öğrenme deneyimlerini zenginleştirir.

Uzaktan eğitim programları, öğrencilere bir üst öğretim seviyesine hazırlık açısından da önemli avantajlar sunmaktadır. Programların, eleştirel düşünme, problem çözme ve araştırma becerilerini geliştirecek nitelikte tasarlanması, öğrencilerin lisans veya lisansüstü eğitime geçişlerini kolaylaştırmaktadır (Garrison & Cleveland-Innes, 2005). Öğrenciler, bu becerilerle donatıldıklarında, akademik kariyerlerinde daha başarılı olma eğilimindedirler. Programın bu yönü, öğrencilerin hem akademik hem de mesleki açıdan kendilerini daha yetkin hissetmelerine katkıda bulunmaktadır.

Öğrencilerin ders materyallerinin programın amacına uygun olup olmadığına ilişkin algısı, programın genel başarısını belirleyen önemli bir faktördür. Araştırmalar, ders içeriklerinin programın hedeflerine uygun ve kaliteli olduğu durumlarda, öğrencilerin programa daha fazla katılım gösterdiğini ve memnuniyetlerinin arttığını göstermektedir (Venkatraman, 2011).

Programdaki ders materyallerinin çeşitliliği ve kalitesi, öğrencilerin derslere olan ilgisini artırmada önemli bir rol oynamaktadır. Okuma materyalleri, e-içerikler, videolar gibi farklı formatlarda sunulan içerikler, öğrencilerin farklı öğrenme stillerine hitap ederek programı daha etkili bir hale getirmektedir (Toxirjonovich & Qizi, 2022).

Ders materyallerinin mesleki ve akademik açıdan öğrencilere katkı sağlaması, uzaktan eğitim programlarının kalitesini belirleyen önemli bir göstergedir. Programın mesleki gelişime katkı sunduğu ve öğrencilere bir üst öğretim seviyesine hazırlık sağladığı düşüncesi, ders içeriklerinin kalitesiyle doğrudan ilişkilidir (Swan vd., 2009).

Uzaktan eğitim materyallerinin içeriği ve kalitesi, programın genel değerlendirilmesinde önemli bir rol oynamaktadır. Programdaki ders materyallerinin öğrencilerin ihtiyaçlarına uygunluğu, çeşitliliği ve amaca uygunluğu, programın başarısını doğrudan etkilemektedir (Venkatraman, 2011; Toxirjonovich & Qizi, 2022).

Bu bilgiler ışığında;

H₂: Çevrimiçi öğrenme ortamlarında sunulan materyal (M) öğrencilerin program yönelik değerlendirmesini (PD) olumlu etkilemektedir.

Araştırmalar, sınavların ders içerikleriyle tutarlılığı ve öğrencilerin sınav başarısının, programın genel

değerlendirilmesiyle yakından ilişkili olduğunu göstermektedir. Öğrencilerin sınavlarda başarılı olabilmeleri, derslerin içeriklerinin doğru ve etkili bir şekilde sunulmasıyla mümkündür (Yılmaz & Toker, 2022). Programın kalitesi, öğrencilere sunulan ders içerikleri ile sınavlardaki başarıları arasında tutarlılık sağladığında, öğrenciler programı daha olumlu değerlendirmektedir.

Ders içeriklerinin sınavlarda ölçülmesi, öğrenci başarısının değerlendirilmesinde en önemli faktörlerden biridir. Derslerin programın amacına uygunluğu ve bu amacın sınavlarla ölçülmesi, programın genel yapısına ilişkin olumlu ya da olumsuz bir izlenim bırakmaktadır (Biggs & Tang, 2011).

Öğrenciler, sınavların ders materyalleriyle uyumlu olduğu ve sınav başarılarının adil bir şekilde değerlendirildiği programları daha olumlu değerlendirme eğilimindedirler. Araştırmalar, öğrencilerin sınav başarılarının yüksek olduğu programlarda genel program memnuniyetinin de arttığını göstermektedir (Alkan & Özdemir, 2023).

Bu bilgiler ışığında;

H₃: Çevrimiçi öğrenme ortamlarında öğrencilerin sınav başarısını değerlendirmesi (D) öğrencilerin program yönelik değerlendirmesini (PD) olumlu etkilemektedir.

2.4. Öğrenme Memnuniyeti

Uzaktan eğitimde öğrenme memnuniyeti, teknolojiye erişim, ders tasarımı ve etkileşim gibi temel unsurlardan etkilenmektedir. Bu faktörler, öğrencilerin uzaktan eğitim deneyimini nasıl algıladığını belirlemede kritik rol oynamaktadır.

Teknoloji, uzaktan eğitimde öğrenme memnuniyetini belirleyen en önemli unsurlardan biridir. İyi bir internet bağlantısı ve dijital araçların kolayca kullanılabilir olması, öğrencilerin öğrenme süreçlerine aktif olarak katılmalarını sağlar.

Araştırmalar, internet erişiminin yüksek olması durumunda, öğrencilerin derse olan ilgisinin ve memnuniyet düzeylerinin arttığını göstermektedir (Cavite & Marcial, 2022). Bu bulgu, uzaktan eğitimde teknolojinin kullanımının öğrenci memnuniyetine nasıl katkı sağladığını açıkça ortaya koymaktadır.

Derslerin iyi tasarlanmış olması ve öğrencilerin kendi hızlarında öğrenmelerine olanak tanınması, uzaktan eğitimde öğrenme memnuniyetini artıran bir diğer önemli faktördür. Esnek kurs tasarımı, öğrencilerin dersleri kendi programlarına göre ayarlamalarına imkan tanımakta ve bu durum, öğrenci memnuniyetini doğrudan etkilemektedir (França vd., 2022). Ayrıca, ders içeriğinin öğrencilerin ihtiyaçları ve beklentileri ile uyumlu olması, öğrenme deneyimini daha anlamlı hale getirir ve memnuniyet düzeylerini yükseltmektedir.

Öğrencilerin memnuniyetini belirleyen bir diğer faktör, öğretim elemanları ile olan etkileşimleridir. Öğrenci-öğretmen etkileşimi, öğrenen-içerik etkileşimi ve ders sırasında sorulara verilen geri bildirimler, öğrencilerin derse olan bağlılıklarını ve motivasyonlarını artırmaktadır (Lysitsa & Mavroeidis, 2023). Düzenli etkileşim ve zamanında alınan geri bildirimler, öğrencilerin ders içeriğini anlamalarını kolaylaştırmakta ve öğrenme sürecini daha etkili kılmaktadır. Bunun yanı sıra, öğrencilerin kendilerini aktif hissetmeleri, derse katılımlarını ve dolayısıyla memnuniyetlerini iyileştirmektedir (Rodionova, Kashchenko & Lebedeva., 2024).

Uzaktan eğitimde öğrenme memnuniyeti, teknolojiye erişim, derslerin esnekliği ve öğretmen-öğrenci etkileşimleri gibi unsurlar tarafından şekillenmektedir. Bu unsurların her biri, öğrencilerin uzaktan eğitimde başarılı olmalarını sağlayan kritik bileşenlerdir. Eğitimciler, bu faktörleri dikkate alarak uzaktan eğitim programlarını iyileştirebilmekte ve öğrenci memnuniyetini artırabilmektedir (Siswanto vd., 2023).

Özetle, uzaktan eğitim programlarının başarılı olması, ders içeriklerinin amaca uygunluğu, derslerin dengeli bir şekilde planlanması, mesleki ve akademik gelişime olan katkısı ve ders çeşitliliği gibi unsurlara bağlıdır. Bu unsurların her biri, öğrencilerin programdan memnuniyetini artırmakta ve programın genel başarısına katkı sağlamaktadır.


Bu bilgiler ışığında;

H₄: Çevrimiçi öğrenme ortamlarında programa yönelik değerlendirmesi (PD) öğrenme memnuniyetini (OM) olumlu etkilemektedir.

2.5. Araştırma Modeli

Bu bilgiler ışığında çalışma kapsamında uzaktan eğitimde ders içeriklerinin, değerlendirmenin ve program yapısının öğrencilerin uzaktan eğitime yönelik kişisel memnuniyetiyle ilişkisi ortaya çıkarılmaya çalışılmıştır. Bu amaçla Alanyazın taramasına dayanarak önerilen model Şekil 1'de gösterilmektedir.

Şekil 1. Tasarlanan KEKK-YEM modeli



Not: D=Başarı Değerlendirme; M=Materyal; OM=Öğrenme Memnuniyeti,
D=Programın Değerlendirilmesi

3. YÖNTEM

3.1. Evren ve Örneklem

Bu çalışma, 2022-2023 akademik yılı Bahar döneminde bir Türk üniversitesinde lisans ve ön lisans programlarına kayıtlı öğrenciler üzerinden gerçekleştirilmiştir. Bu üniversitede toplamda 28.500 civarında öğrenci eğitim almaktadır. Çalışmaya 526 gönüllü öğrenci katılmıştır. Bu durumda, katılım oranı %1.85 olarak gerçekleşmiştir. Yazıcıoğlu ve Erdoğan (2004:50) çalışmasında görüleceği üzere, %5 örneklem hatası ile en az 381 öğrencinin katılması yeterli örneklem büyüklüğünü göstermektedir. Bu bağlamda %5 örneklem hatası ile 526 öğrenciden oluşan örneklem yaklaşık 28.500 öğrenciden oluşan ana kütleyi temsil etme yeteneğine sahiptir.

Katılımcıların demografik bilgileri Tablo 1'de sunulmuştur. Katılımcıların %43'ü kadın, %57'si erkek, %44'ünün 17-20 yaşında, %41'inin 21-23 yaşında, ve %15'inin 24 yaş üstü olduğu görülmüştür. Katılımcıların %77'si birinci öğretim öğrencisi olup, %52'si ön lisans, %48'i ise lisans öğrencisidir. Öğrencilerin %76'sı akıllı telefon, %73'ü dizüstü bilgisayar kullanmaktadır. Masaüstü bilgisayar ve tablet kullanımı daha düşük oranlarda kalmıştır.

Tablo 1. Katılımcı profili

Demografik Bilgiler		Frekans	Oran (%)
Cinsiyet	Kadın	226	43.0
	Erkek	300	57.0
Yaş	17- 20 arası	231	43.9
	21-23 arası	215	40.9
	24 ve üzeri	80	15.2
Öğrenim Türü	I. Öğretim	405	77.0
	II. Öğretim	121	23.0
Öğrenim Düzeyi	Ön lisans	273	51.9
	Lisans	253	48.1
Teknoloji	Telefon	404	76.8
Sahiplik	Dizüstü Bilgisayar	382	72.6
Durumu	Masaüstü Bilgisayar	121	23.0
	Tablet	57	10.8

3.2. Veri Toplama

Veriler, Eygü ve Karaman (2013) tarafından geliştirilen "Uzaktan Eğitimde Memnuniyet Anketi" kullanılarak toplanmıştır. Araştırmanın değişkenleri Tablo 2'de verilmektedir. Anket, üniversitenin öğrenim yönetim sistemi üzerinden çevrimiçi olarak uygulanmıştır. Öğrencilerden anketi dönem sonunda doldurmaları istenmiş ve katılım tamamen gönüllülük esasına dayanmıştır.

Tablo 2. Araştırmanın değişkenleri

Öğrenme Memnuniyeti	
OM1	Uzaktan eğitim kişiler için iyi bir öğrenme fırsatı sunar.
OM2	Uzaktan eğitim öğrencinin kendi hızında öğrenmesini sağlar.
OM3	Uzaktan eğitim öğretim uygulamaları açısından öğrenciyi daha aktif hale getirir.
OM4	Uzaktan eğitimde derslerin içeriğini öğrenme için yeterli buluyorum.
OM5	Derste öğretim elemanı tarafından dinleniliyor ve soru çözümüne cevap alabiliyorum.
OM6	Uzaktan eğitimde verilen dersi anladım ve öğrendim.
Programın Değerlendirilmesi	
PD1	Uzaktan eğitim programının açılması benim için büyük bir fırsattı.
PD2	Programdaki derslerin dönemlere dağılımı iyi yapılmıştı.
PD3	Bu programın mesleki açıdan iyi olduğunu düşünüyorum.
PD4	Dersler programın amacına uygundu.
PD5	Ders içerikleri programın amacına uygundu.
PD6	Program iyi bir şekilde tasarlanmıştı.
PD7	Programdaki ders içerik çeşitleri (okuma, e-çerik, video vb.) yeterliydi.
PD8	Program bir üst öğretime (lisans-lisansüstü) eğitime hazırlayacak nitelikteydi.
PD9	Programda yer alan tüm dersler gerekliydi.
Materyal	
M1	Okuma metinleri yeterince bilgilendiriciydi.
M2	E-ders paketleri tek başıma öğrenmemi destekleyiciydi.
M3	Ders kaynaklarında öğrencilere kazandırılacak bilgi, beceri ve davranışları içeren amaçlar belirtilmişti.
M4	Ders kaynakları güncel bilgileri kapsamaktaydı.
M5	Ders kaynaklarındaki konular birbirleriyle tutarlıydı.
Başarı Değerlendirme	
D1	Sınavdaki sorular ders içerikleriyle tutarlıydı.
D2	Final sınavları bilgi seviyemi değerlendirecek nitelikteydi.
D3	Programdaki sınavların güvenilir olduğunu düşünüyorum.

Kaynak: (Eygü ve Karaman, 2013)

3.3. Veri Analizi

Verilerin analizi, bağımsız değişkenler (ders materyalleri, program yapısı) ile bağımlı değişken (öğrenci memnuniyeti) arasındaki ilişkileri incelemek amacıyla Yapısal Eşitlik Modeli (YEM) kullanılarak gerçekleştirilmiştir. Analizlerde SmartPLS 4.0 yazılımı kullanılmış ve Ringle, Wende ve Becker (2022) tarafından önerilen KEKK-YEM yöntemi uygulanmıştır. Hipotezlerin anlamlılığını test etmek için 1.500 alt örneklem ile önyükleme (bootstrapping), yöntemi kullanılmıştır.

Ayrıca, modelin geçerliliği ve güvenilirliği; yakınsak geçerlilik, ayrışan geçerlilik ve iç tutarlılık güvenilirliği gibi ölçütlerle değerlendirilmiştir. Öngörücüler arasındaki çoklu doğrusal bağlantıyı ortadan kaldırmak için Varyans Şişirme Faktörleri (VIF) incelenmiştir. Yapısal model, yol katsayıları (β), t-değerleri ve anlamlılık düzeyleri ($p < 0.05$) temel alınarak değerlendirilmiş, 1.96'dan büyük t-değerleri istatistiksel olarak anlamlı kabul edilmiştir. Ayrıca, model uyumu Standardize Kök Ortalama Kare Hata (SRMR), Normalleştirilmiş Uyum İndeksi (NFI) ve Uyum İyiliği İndeksi (GoF) indeksleriyle belirlenmiştir.

4. BULGULAR

4.1. Çoklu Doğrusallık Sorunu

Bağımsız değişkenler arasında çoklu doğrusal bağlantı problemi olup olmadığı, gözlenen değişkenlere ait varyans şişkinlik faktörü (VIF) değerine bakılarak karar verilmektedir (Sönmez Çakır, 2020). VIF değerinin 5.000'in altında olması, bir bağımsız değişken ile diğer bağımsız arasında çoklu doğrusal bağlantı problemi olmadığını göstermektedir (Ringle vd., 2022). KEKK-YEM algoritması çalıştırılarak elde edilen analiz bulguları, PD4 ve PD5'in VIF değerlerinin sırasıyla 5.605 ve 5.511 olmak üzere eşik değerin üstünde olduğunu göstermiştir

(Tablo 3). Eşik değerin üstünde en büyük VIF değerine sahip olan PD4 veri setinden çıkarılarak KEKK-YEM algoritması tekrar çalıştırılmış ve bağımsız değişkenlerin VIF değerleri eşik değer 5.000'in altında bulunmuştur (Tablo 3).

Tablo 3. Bağımsız Değişkenler Arasında Çoklu Doğrusallık Probleminin Değerlendirilmesi

Bağımsız Değişkenler	VIF Değerleri	
	Adım1	Adım2
D1	1.801	1.801
D2	1.946	1.946
D3	1.840	1.840
M1	2.650	2.650
M2	2.156	2.156
M3	3.267	3.267
M4	3.291	3.291
M5	2.843	2.843
OM1	4.744	4.744
OM2	2.933	2.933
OM3	3.902	3.902
OM4	3.063	3.063
OM5	1.477	1.477
OM6	3.378	3.378
PD1	2.000	1.999
PD2	2.109	2.107
PD3	2.518	2.471
PD4*	5.605	
PD5	5.511	3.205
PD6	3.454	3.417
PD7	3.368	3.367
PD8	2.841	2.815
PD9	1.962	1.907

NOT: *Eşik değerin üstünde olduğundan veri setinden çıkarılmıştır. Değişkenler için Tablo 2'ye bakınız


4.2.Dış Ölçüm Modelinin Değerlendirilmesi

Ölçüm modeli; yakınsama geçerliliği ve iç tutarlılık geçerliliği ve ayrışma geçerliliği olmak üzere iki başlık altında incelenmektedir. Yakınsama geçerliliğinin testi için KEKK-YEM algoritması çalıştırılmıştır. Yakınsama geçerliliğinin tatminkar

olabilmesi için gösterge yükü değerlerinin 0.700'ü, gösterge güvenirliği değerlerinin 0.500'ü (Sarstedt, Ringle & Hair, 2021) ve gizil yapılara ait açıklanan ortalama varyans (AVE) değerlerinin 0.500'ü geçmesi gerekmektedir (Fornell ve Larker, 1981). İlk analiz bulguları OM5 (0.651) dışında kalan tüm gösterge yükleri 0.700'den büyük bulunmuştur (Şekil 2).

OM5'in faktör yükü eşik değerin altında 0.651 olarak bulunduğundan veri setinden çıkarılarak analiz tekrarlanmış ve geri kalan tüm gösterge yükü değerleri 0.721–0.924, gösterge güvenirliği değerleri 0.519–0.854 ve AVE değerleri 0.654–0.798 arasında bulunarak yakınsama geçerliliği sağlanmıştır (Tablo 4).

Şekil 2. KEKK-YEM Algoritmasının İlk Analiz Bulguları



Not: Değişkenler için Tablo 2'ye bakınız

Tablo 4. Yakınsama Geçerliliğinin Değerlendirilmesi

Gizil Değişken	Gözlenen Değişken	Gösterge yükleri	Gösterge güvenirliği	AVE
D	D1	0.853	0.728	0.739
	D2	0.872	0.761	
	D3	0.854	0.729	
M	M1	0.866	0.750	0.737
	M2	0.814	0.663	
	M3	0.897	0.805	
	M4	0.869	0.755	
	M5	0.844	0.713	
OM	OM1	0.924	0.854	0.798
	OM2	0.863	0.744	
	OM3	0.906	0.822	
	OM4	0.882	0.779	
	OM6	0.889	0.791	
PD	PD1	0.734	0.539	0.654
	PD2	0.782	0.612	
	PD3	0.796	0.634	
	PD5	0.856	0.733	
	PD6	0.851	0.724	
	PD7	0.870	0.757	
	PD8	0.848	0.718	
	PD9	0.721	0.519	

Not: Değişkenler için Tablo 2'ye bakınız.

İç tutarlılık güvenirliğinin tatminkar olabilmesi için gizil değişkenlerin Cronbach's alpha, Birleşik Güvenirlik rho_a katsayısı ve Birleşik Güvenirlik rho_c katsayısının 0.700 eşik değerinden büyük olması önerilmektedir (Sarstedt vd., 2021). Analiz bulguları gizil yapılara ait Cronbach's alpha 0.824–0.924, rho_a katsayıları 0.824–0.940 ve rho_c katsayıları 0.895–0.952 aralığında bulunarak modelin iç tutarlılık güvenirliği sağlanmıştır (Tablo 5).

Tablo 5. İç Tutarlılık Güvenirliğinin Değerlendirilmesi

Gizil Değişken	Cronbach's alpha	rho_a	rho_c
D	0.824	0.824	0.895
M	0.911	0.913	0.933
OM	0.937	0.940	0.952
PD	0.924	0.926	0.938

Not: Değişkenler için Tablo 2'ye bakınız.

Ölçeklerin ayrışma geçerliği Fornell-Larcker kriter testi ile incelenmiştir. Bir gizil değişkenin AVE karekökü, diğer gizil değişkenler arasındaki korelasyondan büyükse Fornell & Larcker (1981) kriterine göre ayrışma geçerliği sağlanmıştır. Tablo 6'da görüleceği üzere D, M, OM ve PD gizil yapıların AVE karekökü değerleri sırasıyla 0.860, 0.859, 0.893 ve 0.809 olarak bulunmuş olup bu değerler satır ve sütunda gösterilen diğer gizil yapılar arasındaki korelasyon değerlerinden daha büyüktür. Dolayısıyla Fornell & Larcker kriter testine göre ayrışma geçerliliği sağlanmıştır.

Tablo 6. Fornell-Larcker Kriter Testine Göre Ayrışma Geçerliliğinin Değerlendirilmesi

Gizil Değişken	D	M	OM	PD
D	0.860			
M	0.773	0.859		
OM	0.578	0.639	0.893	
PD	0.743	0.803	0.777	0.809

Not: Değişkenler için Tablo 2'ye bakınız.

4.3.İç Ölçüm Modelinin Değerlendirilmesi

İç ölçüm modelinin değerlendirilmesinde sırasıyla şu yöntem izlenmiştir. Öncelikle yapısal modelin çoklu doğrusallık sorunları olmak üzere, sırasıyla modelin açıklayıcı gücü, etki büyüklüğü, uyum iyiliği indeksleri, hipotez testi ve yapısal model ilişkilerinin önem düzeyleri incelenmiştir.

Çoklu doğrusallık sorunlarının olup olmadığı varyans şişkinlik faktörü (VIF) değerleri ile incelenmektedir. Şayet

modeldeki nedensellik ilişkileri çerçevesinde gizil değişkenler arasındaki $VIF < 3.000$ olması, çoklu doğrusallık sorunu olmadığını göstermektedir (Sarstedt vd., 2021). Test sonuçları öngörücü yapılar arasındaki VIF değerlerinin 1.000–2.486 aralığında olduğunu göstermiştir. Dolayısıyla öngörücü yapılar arasında çoklu doğrusallık sorunu oluşmamıştır (Tablo 7).

Modelin açıklama gücü içsel gizil yapıların R^2 değerlerine bakılarak test edilebilmektedir. Birçok sosyal bilim disiplinlerine göre R^2 değerleri 0.75 ise büyük, 0.50 ise orta ve 0.25 ise zayıf şeklinde yorumlanmaktadır (Sarstedt vd., 2021). Şekil 2’deki gizil değişkenleri gösteren daire içindeki değerler aynı zamanda R^2 değerlerini göstermektedir. Modelimizde D içsel değişkeni M içsel değişkeni tarafından %59.8 ($R^2=0.598$), PD içsel değişkeni D ve M dışsal değişkenleri tarafından %60.4 ($R^2=0.604$) ve OM içsel değişkeni PD dışsal değişkeni tarafından %71.5 ($R^2=0.715$) olmak üzere büyük ve orta oranda açıklamaktadır (Tablo 7).

Etki büyüklüğü f^2 değerlerine bakılarak test edilebilmektedir. Şayet modelde yer alan bir dışsal değişken modelden çıkarılırsa, onun etkilemiş olduğu içsel değişkenin R^2 değeri ne oranda etkilendiğini f^2 değerine bakılarak karar verilmektedir. Cohen (1988), 0.020–0.140 arasındaki f^2 değerlerinin zayıf, 0.150–0.340 arasındaki f^2 değerlerinin orta ve 0.340’tan büyük f^2 değerlerinin ise yüksek düzeyde etkiye sahip olduğunu bildirmektedir. Tablo 7’de görüleceği üzere $M \rightarrow D$ ilişkisinin f^2 değeri 1.486 (yüksek etki), $D \rightarrow PD$ ilişkisinin f^2 değeri 0.089 (zayıf etki), $M \rightarrow PD$ ilişkisinin f^2 değeri 0.571 (yüksek etki) ve $PD \rightarrow OM$ ilişkisinin f^2 değeri 1.526 (yüksek etki) bulunmuştur. Özellikle PD dışsal değişkenini etkileyen içsel değişkenlerden M’nin modelden çıkarılması PD’nin R^2 değeri olumsuz yönde yüksek düzeyde etkilendiği görülmektedir.

Tablo 7. Çoklu Doğrusallık Sorunu, Modelin Açıklama Gücü ve Etki Büyüklüğünün Değerlendirilmesi

Nedensellik ilişkileri	Çoklu doğrusallık sorunu (VIF)	Modelin açıklama gücü(R^2)	Etki büyüklüğü (f^2)
M→ D	1.000	0.598	1.486**
D→ PD	2.486	0.604	0.089*
M→ PD	2.486		0.571**
PD→ OM	1.000	0.715	1.526**

NOT: *zayıf etki, **yüksek etki. Değişkenler için Tablo 2'ye bakınız

Modelin uyum iyiliği; SRMR, NFI ve GoF indekslerine bakılmak suretiyle incelenmiştir. SRMR<1.000 olması (Schermelleh-Engel, Moosbrugger ve Müller, 2003), NFI > 0.900 olması (Raykov & Marcoulides, 2006) ve GoF>0.36'dan olması (Wetzels vd., 2009) modelin iyi bir uyum iyiliğine sahip olduğunu göstermektedir. Modelin SRMR değeri 0.083 (iyi uyumlu), NFI değeri ise 0.844 (iyi uyuma yakın) ve GoF indeksi 0.684 (iyi uyumlu) bulunmuştur (Tablo 8). Dolayısıyla SRMR ve GoF değerleri göz önünde bulundurulduğunda modelimiz tatminkâr bir uyum iyiliğine sahiptir.

Tablo 8. Uyum İyiliği İndekslerinin Değerlendirilmesi

İndeks	Doyurulmuş Model	Tahmini Model	Sonuç
SRMR	0.083	0.083	İyi uyumlu
NFI	0.844	0.844	İyi uyuma yakın
GoF	$R^2 \text{ ort.} = (0.598+0.604+0.715)/3 = 0.639$ $AVE \text{ ort.} = (0.739+0.737+0.798+0.654)/4 = 0.732$ $GoF =$ $\sqrt{R^2 \text{ ort.} \times AVE \text{ ort.}} = \sqrt{0.639 \times 0.732} = 0.684$		İyi Uyumlu

Hipotezleri test etmek üzere SmartPLS 4.0 yazılımında 1500 alt örnekleme sahip bir önyükleme prosedürü uygulanmıştır. Hipotezlerin anlamlılığı güven aralığı %95 olacak şekilde $p<0.050$ anlam düzeyinde β ve T istatistiği değerlerine bakılarak değerlendirilmektedir. T -istatistiği 1.96 değerinden

daha büyük ise hipotezler istatistiksel olarak anlamlıdır (Sönmez Çakır, 2021).

Hipotez testi sonucunda T -istatistiği değerleri 1.96'dan büyük ($M \rightarrow D$, $T=36.129$; $p<0.001$; $M \rightarrow PD$, $T=16.4987$; $p<0.001$; $D \rightarrow PD$, $T=6.002$; $p<0.001$; $PD \rightarrow OM$, $T=38.130$; $p<0.001$) bulunmuştur (Tablo 9). Dolayısıyla tüm hipotezler $p<0.001$ anlam düzeyinde çok güçlü bir şekilde desteklenmiştir. Modeldeki dolaylı ilişkiler $M \rightarrow PD \rightarrow OM$ ve $D \rightarrow PD \rightarrow OM$ yollarının anlamlılığı ayrıca test edilmiştir. Test sonucunda T -istatistiği değerleri sırasıyla 14.741 ve 5.910 bulunmuştur (Tablo 9). Bu itibarla $M \rightarrow PD \rightarrow OM$ ve $D \rightarrow PD \rightarrow OM$ dolaylı ilişkileri $p<0.001$ anlam düzeyinde istatistiksel olarak çok güçlü bir şekilde desteklenmiştir.

Tablo 9. Hipotez Testi Bulguları


	Yol katsayısı (β)	Standart Sapma	T İstatistiği	P değeri	%95 Güven Aralıkları (çarpıklık düzeltilmiş)	Anlamlı mı? ($p<0.001$)
Direk etkiler						
$H_1: M \rightarrow D$	0.773	0.021	36.129	<0.001	[0.730;0.812]	Evet
$H_2: M \rightarrow PD$	0.636	0.039	16.498	<0.001	[0.561;0.712]	Evet
$H_3: D \rightarrow PD$	0.251	0.042	6.002	<0.001	[0.170;0.334]	Evet
$H_4: PD \rightarrow OM$	0.777	0.020	38.130	<0.001	[0.732;0.812]	Evet
Endirek etkiler						
$M \rightarrow PD \rightarrow OM$	0.494	0.034	14.741	<0.001	[0.429;0.560]	Evet
$D \rightarrow PD \rightarrow OM$	0.195	0.033	5.910	<0.001	[0.132;0.260]	Evet

Not: Değişkenler için Tablo 2'ye bakınız

Son olarak yapısal modeli oluşturan yol ilişkilerinin önem derecesi incelenmiştir. Modeldeki içsel gizil değişkenlerin öngörücüleri olan dışsal gizil değişkenlerin hangisi olduğu, ne oranda etkilediği aralarındaki yol katsayısı β değerine bağlı olarak değerlendirilmektedir. Modelde sadece PD gizil değişkeninin birden fazla öngörücüsü olup $M \rightarrow PD$ arasındaki β değeri 0.636 ve $D \rightarrow PD$ β değeri 0.251 olarak bulunmuştur (Şekil 3). Bu itibarla program değerlendirme üzerinde ders materyallerinin açık ara daha önemli olduğu bulunmuştur. Ayrıca D gizil yapısının öngörücüsü M ve OM gizil yapısının

öngörücüsü PD arasındaki β değerleri sırasıyla 0.773 ve 0.777 bulunmuştur (Şekil 3). Bu değerler oldukça yüksek olup ders materyallerinin öğrencilerin sınav değerlendirmesi ve program değerlendirmesinin de öğrenme memnuniyeti üzerinde önemli etkisi olduğu saptanmıştır.

Şekil 3. İç Ölçüm Modeli Bulguları



5. TARTIŞMA

Bu çalışmada çevrimiçi öğrenme ortamlarında sunulan materyallerin, öğrencilerin sınav başarıları değerlendirmesi ve programa yönelik değerlendirmeleri üzerinde olumlu etkisi olduğu saptanmıştır. Alanyazında benzer bulgulara ulaşan çeşitli çalışmalar, uzaktan eğitimde ders materyallerinin ve içerik çeşitliliğinin öğrencilerin memnuniyetini ve başarısını doğrudan etkilediğini ortaya koymaktadır. Ders materyallerinin öğrencilerin sınav performansı ve program memnuniyeti üzerindeki etkisi, önceki çalışmalarla uyumlu bir sonuçtur (Toxirjonovich & Qizi, 2022; Akmeşe vd., 2017).

Çalışmamızda ulaşılan bulgular, çevrimiçi öğrenme ortamlarında sunulan materyalin öğrencilerin sınav başarılarını olumlu yönde etkilediğini göstermektedir (H₁). Bu bulgu, Kör vd. (2014) tarafından yapılan çalışmayla uyumlu görülmektedir. Bu çalışmada, e-kitaplar, simülasyonlar ve video içerikleri gibi dijital materyallerin, öğrencilerin ders içeriklerini daha iyi anlamalarına yardımcı olduğu ve sınavlarda daha başarılı olmalarını sağladığı belirtilmiştir. Ayrıca, Gugliano ve Sainz (2021), COVID-19 pandemisi sürecinde uzaktan eğitim materyallerinin uyarlanmasının, öğrencilerin derslere daha fazla katılım sağlamasına ve sınav başarılarının artmasına yol açtığını vurgulamaktadır.

Bu çalışmada ayrıca, çevrimiçi öğrenme ortamlarında sunulan materyallerin, öğrencilerin programa yönelik değerlendirmelerini etkilediği saptanmıştır (H₂). Venkatraman (2011) ve Toxirjonovich & Qizi (2022) tarafından yapılan çalışmalar, ders materyallerinin kalitesinin ve öğrenci ihtiyaçlarına uygunluğunun, program memnuniyetini artırmada kritik bir rol oynadığını göstermektedir. Ders materyallerinin zengin içeriklerle sunulması ve öğrenci ihtiyaçlarına göre çeşitlendirilmesi, öğrencilerin programa olan ilgisini artırmakta ve bu da programın genel değerlendirilmesine olumlu yansımaktadır.

Araştırma bulgularımıza göre, öğrencilerin sınav başarısını değerlendirmesi, programa yönelik değerlendirmelerini de doğrudan etkilemektedir (H₃). Yılmaz & Toker (2022) çalışmaları da sınavların ders içerikleriyle tutarlılığı ve sınavların adil bir şekilde yapılmasının, öğrencilerin programı daha olumlu değerlendirmesine yol açtığını göstermektedir. Sınav başarılarının yüksek olduğu programlarda, genel program memnuniyetinin de daha yüksek olduğu sonucuna ulaşılmıştır (Alkan & Özdemir, 2023).

Çalışmamızda, çevrimiçi öğrenme ortamlarında programa yönelik değerlendirmenin öğrenme memnuniyetini etkilediği sonucuna ulaşılmıştır (H4). Wang vd. (2024) de benzer şekilde, uzaktan eğitimden memnun olmanın ve öğrencilerin program değerlendirmelerinin, bireysel performanslarına olumlu yansıdığını vurgulamaktadır. Öğrenciler, iyi yapılandırılmış ve amacına uygun olarak sunulan programlardan daha yüksek memnuniyet duymakta ve bu da genel öğrenme memnuniyetini artırmaktadır.

Çevrimiçi öğrenme ortamlarında sunulan materyallerin ve sınav başarılarının, programa yönelik değerlendirme aracılığıyla öğrenme memnuniyetine dolaylı etkisi olduğu bu çalışma ile doğrulanmıştır. Sunulan materyallerin kalitesi ve sınav değerlendirmelerinin etkinliği, öğrencilerin programı değerlendirme biçimlerini şekillendirmekte ve nihayetinde öğrenme memnuniyetine katkıda bulunmaktadır (Venkatraman, 2011; Toxirjonovich & Qizi, 2022; Yılmaz & Toker, 2022). Sunulan materyallerin ve sınav başarılarının programa yönelik değerlendirme aracılığıyla öğrenme memnuniyetini olumlu yönde etkilediği farklı yazarlar tarafından da ortaya konulmuştur (Biggs & Tang, 2011; Aydemir, 2018; Korucuk, 2020; Alkan & Özdemir, 2023; Yousaf vd., 2023).

Aydemir (2018) ve Korucuk, (2020) nitelikli program yapısı, derslerin sıralanması, içeriklerin düzenlenmesi ve ödev-sınav zamanlamalarının tutarlılığı, öğrencilerin motivasyonunu artırarak öğrenme memnuniyetini olumlu yönde etkilediğini bulmuştur. Biggs & Tang (2011) ise öğrencilerin programdan beklentileri karşılandığında ve ders içerikleri programın amaçlarına uygun olduğunda, öğrenciler öğrenme süreçlerinden daha fazla memnuniyet duyduğunu iddia etmektedir.

Bu bağlamda, sınav başarılarının programa yönelik değerlendirme aracılığıyla öğrenme memnuniyetine etkisi,

programların değerlendirilmesinde sınavların önemini vurgulamaktadır. Eğer sınavlar ders içerikleri ile uyumlu ve öğrencilerin bilgi seviyelerini doğru şekilde ölçen nitelikteyse, öğrenciler hem sınavlardan hem de programın genel yapısından memnuniyet duymakta ve bu da öğrenme memnuniyetlerini olumlu yönde etkilemektedir (Alkan & Özdemir, 2023). Yousaf vd. (2023) ise değerlendirme süreçlerinin öğrenci memnuniyeti üzerinde kritik etkisi olduğunu ve bu süreçlerin öğrencilerin genel program değerlendirmelerine katkı sunduğunu ortaya koyan çalışmasını desteklemektedir.

Bu çalışma, çevrimiçi öğrenme ortamlarında sunulan materyallerin öğrencilerin sınav başarılarını ve programa yönelik değerlendirmelerini olumlu yönde etkilediğini göstermektedir. Ayrıca, sınav başarıları ve program değerlendirmeleri arasında güçlü bir ilişki bulunmaktadır. Çevrimiçi eğitimde materyal kalitesi, sınav değerlendirme süreçleri ve program yapısı arasındaki bu ilişkiler, öğrenci memnuniyetini ve genel program başarısını artıran temel unsurlar olarak ortaya çıkmaktadır.

6. SONUÇ VE ÖNERİLER

Bu çalışma, çevrimiçi öğrenme ortamlarında sunulan materyallerin ve öğrencilerin sınav başarı değerlendirmelerinin, programa yönelik değerlendirmeler aracılığıyla öğrenme memnuniyeti üzerinde anlamlı bir etkisi olduğunu göstermiştir. Özellikle, ders materyallerinin kalitesinin öğrencilerin sınav başarısı üzerindeki olumlu etkisi vurgulanmış ve bu etkilerin öğrencilerin programa yönelik değerlendirmelerine yansıdığı görülmüştür. Ayrıca, öğrencilerin sınav başarılarını nasıl değerlendirdikleri, program hakkındaki genel memnuniyetlerini de etkilemektedir. Bu bulgular, uzaktan eğitimde materyal kalitesi, sınav başarısı ve program memnuniyeti arasındaki etkileşimlerin önemini ortaya koymaktadır.

Çalışmanın önemli bulgularından biri de, program memnuniyetinin öğrencilerin ders materyalleri ve sınav performanslarıyla doğrudan ilişkili olduğudur. Çevrimiçi öğrenme ortamında öğrenci memnuniyetini artırmak için hem içerik kalitesi hem de sınav değerlendirme süreçlerinin program yapısıyla uyumlu olması gerekmektedir.

Öğrenme memnuniyetinin artırılması hususunda eğitim kurumlarına önerilerimiz ise şunlardır;

- a) Ders içeriklerini zenginleştirmek için dijital kaynaklardan (e-kitaplar, etkileşimli videolar, simülasyonlar vb.) artan oranda yararlanabilir.
- b) Teknolojik araçların kullanımını artırmalı ve öğrencilere daha iyi bir dijital öğrenme deneyimi sunulabilir.
- c) Sınav sorularının ders içerikleriyle uyumlu olması için yapay zeka desteğinden faydalanılabilir.
- d) Sınav sorularının adil değerlendirilmesi için sınav güvenliğini yükseltecek ek yazılımların kullanılması sağlanabilir.
- e) Öğrencilerin öğrendiklerini etkin şekilde gösterebildikleri proje bazlı değerlendirme yöntemleri tercih edilebilir.
- f) Eğitimciler ve program yöneticileri, derslerin içerik ve yapısını düzenli olarak gözden geçirerek içerik güncellenmeli ve çeşitliliğinin arttırabilir.

Sonuç olarak, çevrimiçi öğrenme ortamlarında öğrenci memnuniyetini artırmak, ders materyallerinin kalitesi, sınav değerlendirme süreçleri ve program yapısının öğrenci ihtiyaçlarına uygun hale getirilmesiyle mümkündür. Bu unsurların uyum içinde çalıştığı programlar, öğrencilerin hem

akademik başarılarını hem de memnuniyet düzeylerini yükseltecektir.

KAYNAKÇA

- Akmeşe, Ö. F., Erbay, H., Emiroğlu, B. G., & Kör, H. (2017). Uzaktan eğitimde ders içeriği oluşturma platformu. Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 10(2), 1521-1546.
- Alkan, N. & Özdemir, S. M. (2023). Uzaktan eğitim sürecinde ilkökul öğrencilerinin matematik dersi öğrenme kayıplarına ilişkin öğretmen görüşleri. JRES, 10(2), 196-223. doi: <https://doi.org/10.51725/etad.1397515>
- Alqurashi, E. (2018). Predicting student satisfaction and perceived learning within online learning environments. Distance Education, 40(1), 133–148. doi: <https://doi.org/10.1080/01587919.2018.1553562>.
- Archer, A. B., Crispim, A. C., & Cruz, R. M. (2016). Assessment and Feedback of Students' Performance in Distance Education Courses. Avances en Psicología Latinoamericana, 34(3), 473-485. doi: 10.12804/APL34.3.2016.03
- Armağan, H., & Yiğit, T. (2017, July). Performance evaluation of the distance education system with fuzzy logic. In AIP Conference Proceedings (Vol. 1863, No. 1). AIP Publishing.
- Aşçı, T., & Toktaş, İ. (2021). Küresel Faktörlerin Türkiye'deki Uzaktan Eğitim Politikasına Etkisi: Fırsatlar ve Tehditler. Academic Perspective Procedia. 4(3), 46-58. doi: <https://doi.org/10.33793/acperpro.04.03.11>
- Aydemir, M. (2018). Uzaktan eğitim program, ders ve materyal tasarımı. Konya: Eğitim Yayınevi.
- Biggs, J. & Tang, C. (2011). Teaching for Quality Learning at University: What the Student Does. McGraw-Hill Education.

- Bogdanović, M. (2012). Growing importance of distance education. *International Journal of Modern Education and Computer Science*, 3(3), 35-41.doi: 10.5815/IJMECS.2012.03.05
- Bozkurt, A. (2020). Koronavirüs (Covid-19) pandemi süreci ve pandemi sonrası dünyada eğitime yönelik değerlendirmeler: Yeni normal ve yeni eğitim paradigması, *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*. 6(3), 112-142.
- Cavite, F. A. M., & Marcial, D. E. (2022). Correlates of learning satisfaction and learning engagement in online distance education. *Information Technologies and Learning Tools*, 90(4), 118-35. doi: 10.33407/itlt.v90i4.4920
- Cazan, A. M., & Maican, C. I. (2023). Factors determining the use of e-learning and teaching satisfaction. *Comunicar*, 31(74), 89-100.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences*. Newyork: Routledge.
- Dziuban, C., Moskal, P., Thompson, J., Kramer, L., DeCantis, G., & Hermsdorfer, A. (2015). Student satisfaction with online learning: Is it a psychological contract? *Online Learning*, 19(2). doi: <https://doi.org/10.24059/olj.v19i2.496>
- Efiloğlu Kurt, Ö. (2015). Defining university students' perspectives on distance learning with integration of TAM and IS success model. *International Journal of Alanya Faculty of Business*, 7(3), 223-234.
- Diamadis, E. T., & Polyzos, G. C. (2008). Evaluating student learning in distance education. In *Online and Distance Learning: Concepts, Methodologies, Tools, and*

Applications (pp. 677-685). IGI Global. doi: 10.4018/978-1-59904-935-9.CH058

Eygü, H. ve Karaman, S. (2013). Uzaktan eğitim öğrencilerinin memnuniyet algıları üzerine bir araştırma. Kırıkkale Üniversitesi Sosyal Bilimler Dergisi, 3(1), 36-59.

Fornell, C. & Larcker, D. F. (1981). Structural equation models with unobservable variables and measurement error. Journal of Marketing Research. 18(1), 39-50.

França, P.C.S. Freitas, C. O. Pires, I. S. C. Ferreira, V. A. & Fabio, Tadeu, Lourenço, Guimarães, F. T. L. (2022). User satisfaction of distance learning courses in Brazil. Brazilian Journal of Development, 8(3), 16408-16438. doi: 10.34117/bjdv8n3-060

Garrison, D. R. & Cleveland-Innes, M. (2005). Facilitating cognitive presence in online learning: Interaction is not enough. American Journal of Distance Education, 19(3), 133-148.

Garrison, D. R., Anderson, T., & Archer, W. (2010). The first decade of the community of inquiry framework: A retrospective. Internet and Higher Education, 13(1), 5-9.

Garrison, D.R. (2011). E-Learning in the 21st Century: A Framework for Research and Practice (2nd ed.). Routledge. doi: <https://doi.org/10.4324/9780203838761>

Gugliano, B. F., & Sainz, R. L. (2021). Adaptando materiais didáticos do ensino presencial para o ensino remoto. Revista Educar Mais [Adapting courseware from classroom teaching to remote teaching], 5(3), 546-556. doi: 10.15536/REDUCARMAIS.5.2021.2381

Gujjar, A. A., & Malik, M. A. (2007). Preparation of instructional material for distance teacher education. Turkish Online

Journal of Distance Education, 8(1), 55-63. doi: 10.17718/TOJDE.88173

- Korucuk, B. (2020). Sınıf öğretmenleri gözüyle uzaktan eğitim memnuniyet faktörlerinin derecelendirilmesi yönelik bir çalışma: Giresun ili örneği. *Instructional Technology and Lifelong Learning*, 1(2), 189-202.
- Kör, H., Aksoy, H., & Erbay, H. (2014). Comparison of the proficiency level of the course materials (animations, videos, simulations, e-books) used in distance education. *Procedia-Social and Behavioral Sciences*, 141, 854-860. doi: 10.1016/J.SBSPRO.2014.05.150
- Laurillard, D. (2002). *Rethinking University Teaching: A Conversational Framework for the Effective Use of Learning Technologies* (2nd ed.). Routledge. doi: <https://doi.org/10.4324/9781315012940>
- Lysitsa, E., & Mavroeidis, I. (2024). Critical factors affecting student satisfaction in a distance learning environment. *European Journal of Open, Distance and E-Learning*, 25(1), 180-202. doi: 10.2478/eurodl-2023-0014
- Means, B., Bakia, M., & Murphy, R. (2014). *Learning Online: What Research Tells Us About Whether, When and How*. Routledge Taylor & Frances, New York. doi: 10.4324/9780203095959
- Polat, M., Polat, H., Süren, S., Saldüz, İ., Polat, İ., Polat, M., ... & Kılıç, B. (2022). Lisansüstü öğrencilerin lisansüstü eğitime ilişkin görüşleri. *The Journal of International Lingual Social and Educational Sciences*, 8(1), 42-57. doi: <https://doi.org/10.34137/jilses.1093081>
- Raykov, T. & Marcoulides, G. A. (2006). *A First Course in Structural Equation Modeling*. NJ: Lawrence Erlbaum Associates.

- Ringle, C. M., Wende, S., & Becker, J.-M. (2022). "SmartPLS 4." Oststeinbek: SmartPLS GmbH, <http://www.smartpls.com>.
- Rodionova, K. E., Kashchenko, E. S., & Lebedeva, M. Yu. (2024). Managing Satisfaction in synchronous online learning: results of a statistical study on the material of teaching Russian as a foreign language. *Perspektivy nauki i obrazovania – Perspectives of Science and Education*, 68 (2), 326-338. doi: 10.32744/pse.2024.2.20
- Sarstedt, M. Ringle, C.M. & Hair, J.F. (2021), Partial Least Squares Structural Equation Modeling, İçinde C. Homburg, M. Klarmann (Eds), 1-47, Springer, Cham.
- Schermelleh-Engel, K., Moosbrugger, H., & Müller, H. (2003). Evaluating the fit of structural equation models: Tests of significance and descriptive goodness-of-fit measures. *Methods of psychological research online*, 8(2), 23-74.
- Siswanto, D. P. Alamsyah, D. Morika, N. A. Othman, B. C. Wijaya & Adinda, P. G. "E-Learning Satisfaction: Analysis of the Support Factors," 2023 10th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE), Semarang, Indonesia, 2023, pp. 100-105, doi: 10.1109/ICITACEE58587.2023.10276458
- Sönmez Çakır, F. (2020). Kısmi En Küçük Kareler Yapısal Eşitlik Modellemesi (PLS-SEM) SmartPLS 3.2. Uygulamaları. Ankara: Gazi Kitabevi.
- Swan, K., Garrison, D. R., & Richardson, J. (2009). A constructivist approach to online learning: The community of inquiry framework. In C. R. Payne (Ed.), *Information technology and constructivism in higher*

education: Progressive learning frameworks Hershey, PA: IGI Global.

- Toxirjonovich, O. N. & Qizi, X. X. B. (2022). Growing importance of distance education. *Asian Journal of Research in Social Sciences and Humanities*, 12(1), 358-365. doi: 10.5958/2249-7315.2022.00062.4
- Uzun, N. B., Aktaş, M., & Akay, C. (2023). Measurement and Evaluation Challenges in Distance Education: Systematic Review and Qualitative Meta-Synthesis. *i-manager's Journal of Educational Technology*, 19(4), 1-23. doi: <https://doi.org/10.26634/jet.19.4.19368>
- Venkatraman, G. (2011). Relevant and Student-Friendly Course Materials for Distance Education Programmes: A Case Study. *English for Specific Purposes World*. 33(11), 1-4.
- Wang, Y. M., Wei, C. L., Chen, W. J., & Wang, Y. S. (2024). Revisiting the E-Learning Systems Success Model in the Post-COVID-19 Age: The Role of Monitoring Quality. *International Journal of Human-Computer Interaction*. 40(18), 5087-5102. doi: <https://doi.org/10.1080/10447318.2023.2231278>
- Wetzels, M. Odekerken-Schroder, G. & van Oppen, C. (2009). Using PLS Path Modeling for Assessing Hierarchical Construct Models: Guidelines and Empirical Illustration, *MIS Quarterly*, 3(1), 177-196.
- Yazıcıoğlu, Y. & Erdoğan, S. (2004). *SPSS Uygulamalı Bilimsel Araştırma Yöntemleri*, Ankara: Detay Yayıncılık.
- Yılmaz, E. O., & Toker, T. (2022). Analysing the effects of assessment and evaluation applications and exam formats in distance education. *International Journal of Psychology and Educational Studies*, 9(1), 165-176. doi: 10.52380/ijpes.2022.9.1.691

- Yılmaz, Y. U. (2017). An Assessment of Web Based Distance Education Course: According to Eastern Mediterranean University (Unpublished Master's thesis). Gazi Magusa: Eastern Mediterranean University.
- Yuebo, L., Halili, S. H., & Abdul Razak, R. (2024). Online learning success model for adults in open and distance education in Western China. Plos one, 19(2), e0297515. doi: <https://doi.org/10.1371/journal.pone.0297515>
- Yousaf, H. Q., Rehman, S., Ahmed, M., & Munawar, S. (2023). Investigating students' satisfaction in online learning: the role of students' interaction and engagement in universities. Interactive Learning Environments, 31(10), 7104–7121. doi: <https://doi.org/10.1080/10494820.2022.2061009>.

NAIVE BAYES ALGORITHM AND R APPLICATION

Serkan KARDEŞ¹

1. INTRODUCTION

Machine learning is a discipline based on the development of algorithms that enable systems to learn from data, make predictions, and make decisions (Mitchell, 1997). This method aims to allow the model to interact with data and discover specific patterns without the need for human intervention. This data-driven learning approach includes mathematical and statistical methods and is particularly significant today in the fields of big data and artificial intelligence (Alpaydın, 2020; Kardeş et al., 2024). In machine learning, there are different learning approaches such as supervised learning, unsupervised learning, and reinforcement learning (Goodfellow et al., 2016; Özdemir & Çelebi, 2023; Diamantopoulou et al., 2023).

One of the most common applications of machine learning is classification algorithms, which perform the task of categorizing given data into specific classes. These algorithms learn the relationships between classes based on a training dataset and assign class labels to new data (James et al., 2013). Common classification algorithms include Decision Trees, Logistic Regression, K-Nearest Neighbors (KNN), Artificial Neural Networks (ANN), and Support Vector Machines (SVM). These algorithms are often combined with various regularization

¹ Ress. Assist., Bursa Technical University, Faculty of Humanities and Social Sciences, Department of Business Administration, serkan.kardes@btu.edu.tr, ORCID: 0000-0002-4021-1975.

techniques to increase the model's accuracy and address issues like overfitting (Bishop, 2006).

The Naive Bayes algorithm is a simple yet powerful probability-based classification method that works on the basis of Bayes' theorem. This method relies on the assumption that each attribute is independent of the others. Although this simple assumption may not fully align with real-world situations in most cases, the Naive Bayes classifier can often perform better than expected (Zhang, 2004). Bayes' theorem allows for the calculation of the probability of an event based on available data through conditional probabilities (Russell & Norvig, 2016).

In this section, the workings of the Naive Bayes algorithm will be examined in detail. First, the general principles of machine learning and classification algorithms will be explained, followed by an in-depth discussion of the logic, working principles, mathematical model, and variations of the Naive Bayes algorithm. The advantages, disadvantages, and application areas of the algorithm will be comprehensively evaluated. Additionally, in the final section, an application known as Churn Analysis in the banking sector, which analyzes customer loss, will be demonstrated using the Naive Bayes algorithm with the R programming language.

2. NAIVE BAYES

Naive Bayes is a commonly used machine learning algorithm for classification problems and has been widely applied since the 1960s. Today, the Naive Bayes Classifier remains one of the popular methods.


This method estimates each variable based on Bayes' theorem and calculates the class membership functions of the variables. Although Bayes classifiers are statistical classifiers,

they predict the probability of an instance belonging to a particular class using class membership probabilities and assign the class accordingly. Therefore, the formulas used in the Naive Bayes classifier are based on Bayes' theorem (Ray, 2019). The probability values obtained are used to decide which class a variable belongs to. The advantage of the Naive Bayes algorithm is its simplicity and effectiveness; however, its disadvantage is that it requires the assumption of independence between classes and features. The Naive Bayes algorithm operates under the assumption that events are independent of each other and produces results by calculating the final probability values (Albon, 2018; Bramer, 2020).

Naive Bayes algorithms are probabilistic classification methods that apply Bayes' theorem based on independence assumptions. The model is easy to set up and does not require complex parameter estimations. Despite its simplicity, it often performs better than expected and achieves higher success compared to more complex methods (Zhou, 2020).

The Naive Bayes (NB) classifier is a probability-based classification method built on Bayes' theorem. The Bayes network models the possible relationships between dependent and independent variables using conditional probabilities. As shown in the diagram, "inputs" are represented as nodes, and their relationships are indicated by dashed lines. If nodes are not connected by dashed lines, the variables are assumed to be conditionally independent (Zhang, 2004).

Figure 1. Naive Bayes Structure



Bayes' theorem holds a significant place in probability calculations with its ability to perform classification tasks. Mathematically, it is based on conditional probabilities. When a new instance with specific attributes is given, the Naive Bayes algorithm predicts the probability of each class occurring based on the attributes of this instance (Özkan, 2016).

In the classification phase, the NB algorithm considers each attribute vector in the dataset as evidence for the class attribute and calculates the conditional probabilities, that is, the likelihood of each class having a particular value. Therefore, each class in Bayes classifiers has assigned probability values. Bayesian methods take into account features with low impact when making predictions. They are based on the assumption that a large number of features with relatively small contributions can combine to create strong classifiers (Albon, 2018).

The Naive Bayes Classifier can be trained quickly and easily, and it can be used as a model for comparative analysis. When variable selection is done correctly, Naive Bayes can perform on par with other statistical models like logistic regression and support vector machines, and in some cases, it may even achieve better results. However, Naive Bayes relies on a strong assumption of independence between predictors; therefore, if the model performs poorly, it may be due to dependencies among the predictors (Berrar, 2018).

Naive Bayes classifiers are used in many fields such as data mining, natural language processing, sentiment analysis, spam filtering, market basket analysis, face recognition, image processing, recommendation systems, text classification, and medical diagnosis (Şahinaslan et al., 2022).

2.1. Working Principle of the Model and Mathematical Model

When we examine the algorithm's operation, it calculates the probability (conditional probability) of a new data record having a specific target variable value using data records where the values of the target variable are known. Among the conditional probability values obtained, the highest one is assigned as the target variable value of the data record (Yager, 2006).

If the target variable is categorical, the frequencies of the target variable values are used in the probability calculation. However, when the target variable is a numerical variable, the probability calculation is performed using the probability density function of a normal distribution with mean μ and variance σ^2 . In this context, the mean and variance represent the mean and variance of the corresponding numerical variable values in the dataset (Han & Kamber, 2006).

While the data set X is defined with variable values as $(x_1, x_2, \dots, x_n)$, the target variable set C is defined to receive target variable values as $(C_1, C_2, \dots, C_m)$. Accordingly, the conditional probability based on the relevant variable value can be expressed as stated in equation (1).

$$P(C_i|X) = \frac{P(X|C_i).P(C_i)}{P(X)} \quad (1)$$

The probabilities given here mean the following:

- $P(C_i|X)$: The probability of event C occurring given that event X has occurred,
- $P(X|C_i)$: The probability of event X occurring given that event C has occurred,
- $P(C_i)$: The prior probability of event C ,

- $P(X)$: The prior probability of event X (Bishop, 2006; Koller, 2009).

As previously mentioned, due to the independence assumption of the algorithm, the probability $P(X|C_i)$ can be expressed as follows. The probability value in the denominator will remain constant for each target variable value (Han et al., 2023).

$$P(X / C_i) = \prod_{k=1}^n P(x_k / C_i) \quad (2)$$

In this case, taking into account the expression in the denominator, the target variable value with the highest probability is determined as the target variable value of the new data record. This approach is called Maximum A Posteriori Classification (MAP) and is expressed in the formula shown below (Luis et al., 2008).

$$\operatorname{argmax}_{C_i} = \{P(X / C_i).P(C_i)\} \quad (3)$$

In other words, the predicted value is the C_i for which $P(X|C_i)P(C_i)$ is the highest (Han et al., 2023).

2.2. Types of Naive Bayes Algorithm

The use of the Naive Bayes algorithm may vary depending on the structure of the dataset and the characteristics of the problem being analyzed. There are several types of this algorithm. Although these types fundamentally use Bayes' theorem, they differ based on different assumptions and calculation methods. These types are as follows:

- **Gaussian Naive Bayes:** Designed to work with continuous data, Gaussian Naive Bayes is based on the assumption that variables follow a normal distribution. This algorithm provides effective results on continuous

data. The Gaussian model classifies using normal distribution functions based on the mean and variance of the features. For example, in a patient dataset, predictions can be made based on continuous measured values related to a disease (e.g., blood pressure, age) (Murphy, 2012).

- **Bernoulli Naive Bayes:** This algorithm is developed specifically to work with binary data. This model evaluates whether a specific feature is present in an instance and operates based on only two outcomes. The Bernoulli model is often used successfully in text classification problems. For example, in document classification, predictions are made based on the presence or absence of each word in the document (Manning et al., 2008).
- **Multinomial Naive Bayes:** This algorithm is used in classification problems, especially with frequency-based data such as word counts. It assumes that the variables follow a multinomial distribution. This model calculates probabilities by considering the number of words or events in a text dataset. It finds wide application in text classification and natural language processing. It is particularly effective in detecting spam emails and document classification (McCallum & Nigam, 1998).
- **Complement Naive Bayes:** This variation is developed to show better performance, especially in datasets with imbalanced class distributions. This model calculates probabilities by taking into account the complement of each class to maintain balance between classes. It is used to achieve better results, particularly for the minority class in text classification problems (Rennie et al., 2003).
- **Categorical Naive Bayes:** This model works with categorical data for each feature and classifies based on

the assumption that such data is independent. It calculates separate probabilities for each categorical feature to reach results. It is an effective method, especially in datasets where there are many categorical variables (Friedman et al., 1997).

2.3. Advantages and Disadvantages of the Naive Bayes Algorithm

The Naive Bayes algorithm has both advantages and disadvantages.

2.3.1. Advantages

Simplicity: Among the most prominent advantages of the Naive Bayes classifier are its simplicity, computational efficiency, good performance in classification, and ability to handle categorical variables directly.

Performance: Naive Bayes often yields better results compared to more complex classifiers. This advantage is especially noticeable when the number of explanatory variables is high.

Speed: Once the model is built, its high execution speed enhances its usability in real-time series.

Versatility: The number of data points, whether few or many, does not matter. It performs effectively on datasets with high diversity, particularly those involving multi-class classification.

Level of Dependency: When the level of dependency between variables in the dataset is low, Naive Bayes produces more successful results compared to other methods.

Categorical Variables: Categorical variables have been observed to perform better than numerical variables.

Design and Usage: Despite its simple design, the Naive Bayes classifier is widely used due to its advanced performance.

Big Data: Naive Bayes classifiers show high prediction accuracy when working with big data due to their quick learning and testing processes (Rish, 2001; Han et al., 2012; Dangeti, 2017; Engin, 2023).

2.3.2. Disadvantages

Relationships Between Features: The Naive Bayes algorithm does not consider relationships between features in the dataset, which can sometimes result in lower performance compared to other methods.

Class Diversity: When the classes that need to be grouped based on the labels of data samples show too much variety, the accuracy rate of Naive Bayes may decrease.

Dependency of Variables: In reality, variables in a dataset may exhibit high interdependence, while the Naive Bayes algorithm assumes these variables are independent. This assumption may affect the accuracy of real-world data.

Zero Probability Issue: The model assigns a zero probability to categorical values that do not appear in the training dataset. This leads to the "zero-value problem," where if one probability is zero, the product of all probabilities also becomes zero, losing the meaning of the result.

Laplacian Smoothing: To overcome the zero probability issue, a technique known as "Laplacian smoothing" or "Laplace estimation" is used.

Continuous Data: Since the Naive Bayes algorithm does not work with continuous data, continuous variables must be converted to categorical ones (Domingos & Pazzani, 1997; Hastie et al., 2009; Murphy, 2012; Engin, 2023).

3. NAIVE BAYES APPLICATION IN R

In this part of the study, the Naive Bayes classification algorithm will be applied using the R programming language. The application will be based on Churn Analysis, which is known as customer attrition analysis in the banking sector. This analysis aims to predict customers who are likely to leave the bank, allowing the company to create various campaigns to prevent customer churn. Churn analysis is predicted using data mining, artificial intelligence, and machine learning techniques. The data used is from an open dataset on the Kaggle platform called "Predict Churning Credit Card Customers" (Goyal, 2020). The dataset consists of several explanatory variables that affect the risk of customer churn. The aim here is to predict in advance which bank customers are likely to leave the bank and to prevent this situation.

The dataset used in this study contains a total of 18 explanatory variables and 10128 observations. The variables include both continuous and categorical data. The variables and their types used in the study are presented in Table 1.

Table 1. Variables in the Model

Variable Code	Variable Name	Type	Variable
Attrition_Flag	Customer churn risk	Categorical	Dependent
Customer_Age	Customer age	Continuous	Explanatory
Gender	Gender	Categorical	Explanatory
Dependent_Count	Number of dependents of the customer	Continuous	Explanatory
Education_Level	Education level	Categorical	Explanatory
Marital_Status	Marital status	Categorical	Explanatory
Income_Category	Income level	Categorical	Explanatory
Months_on_Book	Customer's working time with the bank	Continuous	Explanatory
Total_Relationship_Count	Customer's total number of transactions	Continuous	Explanatory
Months_Inactive_12_Mon	Number of months the customer was inactive in the last 12 months	Continuous	Explanatory

Variable Code	Variable Name	Type	Variable
Contacts_Count_12_Mon	Customer's number of transactions in the last 12 months	Continuous	Explanatory
Credit_Limit	Credit limit	Continuous	Explanatory
Total_Revolving_Bal	Customer's total revolving balance	Continuous	Explanatory
Avg_Open_to_Buy	Customer's average purchase limit	Continuous	Explanatory
Total_Amt_Chng_Q4_Q1	Transaction amount changing from 4th quarter to 1st quarter	Continuous	Explanatory
Total_Trans_Amt	Total transaction amount	Continuous	Explanatory
Total_Trans_Ct	Total number of transactions	Continuous	Explanatory
Total_Ct_Chng_Q4_Q1	Number of transactions changed from 4th quarter to 1st quarter	Continuous	Explanatory
Avg_Utilization_Ratio	Customer's average utilization rate	Continuous	Explanatory

To use the Naive Bayes classification algorithm in R, several packages must be installed. The “caTools” library is used for splitting the data into training and test sets, the “e1071” library is used for the naiveBayes() function, the “corrplot” library is used for displaying the correlation matrix, the “tidyverse” library is for data preprocessing, and the “caret” library is for creating the confusion matrix. Categorical explanatory variables included in the model were converted to continuous variables before starting the analysis. Observations containing missing values were removed.

A correlation matrix is examined to investigate the linear relationships between explanatory variables.

cor(veri)

Figure 2. Correlation Matrix

Customer_Age	Gender	Dependent_Count	Education_Level	Marital_Status	Income_Category	Months_on_book
1.000000000	0.010568790	-0.128232119	-0.0018631007	-0.0054953100	0.03593230	0.791271157
0.010568790	1.000000000	-0.008120633	0.0166834874	-0.0100879957	-0.77824574	0.003813210
-0.128232119	-0.008120633	1.000000000	0.0085296113	0.0315291428	0.07264727	-0.112267979
0.0018631007	0.016683487	0.0085296113	1.000000000	0.0002534178	0.01341879	0.003025592
-0.0054953100	-0.0100879957	0.0315291428	0.0002534178	1.000000000	0.014097175	-0.005707340
0.035932300	0.072647272	-0.112267979	0.01341879	0.014097175	1.000000000	0.025287009
0.791271157	0.003813210	-0.003025592	-0.005707340	-0.025287009	0.02538701	1.000000000
Total_Relationship_Count	0.027060679	0.00565283	-0.043256705	-0.0036360495	0.0252844197	-0.0186418
Months_Inactive_12_mon	0.057869760	0.011281827	-0.027803699	0.0038738649	-0.0109827573	-0.01855124
Contacts_Count_12_mon	-0.023970583	-0.045244222	-0.020525434	-0.0213632372	-0.0010002968	0.02189288
Credit_Limit	0.024562991	-0.476471285	0.081378679	-0.0116272957	-0.0278329326	0.00018980
Total_Revolving_Bal	0.016375075	-0.020435936	-0.003831835	-0.0191503450	0.041719497	0.03141963
Total_Amt_Chng_Q4_Q1	-0.068976335	-0.034639351	-0.033220015	-0.0129100164	0.0394189917	0.01896278
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855
Total_Relationship_Count	0.027060679	0.00565283	-0.043256705	-0.0036360495	0.0252844197	-0.0186418
Months_Inactive_12_mon	0.057869760	0.011281827	-0.027803699	0.0038738649	-0.0109827573	-0.01855124
Contacts_Count_12_mon	-0.023970583	-0.045244222	-0.020525434	-0.0213632372	-0.0010002968	0.02189288
Credit_Limit	0.024562991	-0.476471285	0.081378679	-0.0116272957	-0.0278329326	0.00018980
Total_Revolving_Bal	0.016375075	-0.020435936	-0.003831835	-0.0191503450	0.041719497	0.03141963
Total_Amt_Chng_Q4_Q1	-0.068976335	-0.034639351	-0.033220015	-0.0129100164	0.0394189917	0.01896278
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855
Customer_Age	-0.027060679	0.00565283	-0.043256705	-0.0036360495	0.0252844197	-0.0186418
Gender	0.010568790	-0.008120633	0.0166834874	-0.0100879957	-0.77824574	0.003813210
Dependent_Count	-0.128232119	-0.008120633	0.0166834874	-0.0100879957	-0.77824574	0.003813210
Education_Level	0.0018631007	0.016683487	0.0085296113	0.0315291428	0.07264727	-0.112267979
Marital_Status	-0.0054953100	-0.0100879957	0.0315291428	0.0002534178	0.01341879	0.003025592
Income_Category	0.035932300	0.072647272	-0.112267979	0.01341879	0.014097175	-0.005707340
Months_on_book	0.791271157	0.003813210	-0.003025592	-0.005707340	-0.025287009	0.02538701
Total_Relationship_Count	0.027060679	0.00565283	-0.043256705	-0.0036360495	0.0252844197	-0.0186418
Months_Inactive_12_mon	0.057869760	0.011281827	-0.027803699	0.0038738649	-0.0109827573	-0.01855124
Contacts_Count_12_mon	-0.023970583	-0.045244222	-0.020525434	-0.0213632372	-0.0010002968	0.02189288
Credit_Limit	0.024562991	-0.476471285	0.081378679	-0.0116272957	-0.0278329326	0.00018980
Total_Revolving_Bal	0.016375075	-0.020435936	-0.003831835	-0.0191503450	0.041719497	0.03141963
Total_Amt_Chng_Q4_Q1	-0.068976335	-0.034639351	-0.033220015	-0.0129100164	0.0394189917	0.01896278
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855
Customer_Age	-0.027060679	0.00565283	-0.043256705	-0.0036360495	0.0252844197	-0.0186418
Gender	0.010568790	-0.008120633	0.0166834874	-0.0100879957	-0.77824574	0.003813210
Dependent_Count	-0.128232119	-0.008120633	0.0166834874	-0.0100879957	-0.77824574	0.003813210
Education_Level	0.0018631007	0.016683487	0.0085296113	0.0315291428	0.07264727	-0.112267979
Marital_Status	-0.0054953100	-0.0100879957	0.0315291428	0.0002534178	0.01341879	0.003025592
Income_Category	0.035932300	0.072647272	-0.112267979	0.01341879	0.014097175	-0.005707340
Months_on_book	0.791271157	0.003813210	-0.003025592	-0.005707340	-0.025287009	0.02538701
Total_Relationship_Count	0.027060679	0.00565283	-0.043256705	-0.0036360495	0.0252844197	-0.0186418
Months_Inactive_12_mon	0.057869760	0.011281827	-0.027803699	0.0038738649	-0.0109827573	-0.01855124
Contacts_Count_12_mon	-0.023970583	-0.045244222	-0.020525434	-0.0213632372	-0.0010002968	0.02189288
Credit_Limit	0.024562991	-0.476471285	0.081378679	-0.0116272957	-0.0278329326	0.00018980
Total_Revolving_Bal	0.016375075	-0.020435936	-0.003831835	-0.0191503450	0.041719497	0.03141963
Total_Amt_Chng_Q4_Q1	-0.068976335	-0.034639351	-0.033220015	-0.0129100164	0.0394189917	0.01896278
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855
Total_Trans_Amt	-0.045858870	-0.034648448	0.023235758	-0.0084362993	-0.0370659496	0.01966634
Total_Ct_Chng_Q4_Q1	-0.017599120	0.007335546	0.019081271	0.0241369232	-0.0014359905	-0.0110683
Avg_Utilization_Ratio	0.001296338	0.009002381	-0.042484926	0.007499152	0.0270982221	0.33780855

When examining the correlation matrix, variables with high correlation coefficients, which are thought to measure similar aspects, should be removed from the model. The following variables were removed:

```
veri$Avg_Open_To_Buy <- NULL
veri$Total_Trans_Ct <- NULL
```

- Avg_Open_To_Buy (Credit Limit): r=0.996
- Total_Trans_Ct (Total_Trans_Ct): r=0.81

Since the dependent variable in the Naive Bayes method needs to be categorical, the dependent variable in the dataset was converted to a factor:

```
veri$Attrition_Flag <- factor(veri$Attrition_Flag,
levels=c('AttritedCustomer', 'Existing Customer'),
labels=c(0,1))
```

To access information and descriptive statistics about the variables in the model, you can use the following code lines:

```
str(veri)
summary(veri)
```

Figure 3. Information about Variables

```
tibble [7,081 x 17] (S3: tbl_df/tbl/data.frame)
 $ Attrition_Flag      : Factor w/ 2 levels "0","1": 2 2 2 2 2 2 2 2 2 ...
 $ Customer_Age       : num [1:7081] 45 49 51 40 44 37 48 56 57 48 ...
 $ Gender             : num [1:7081] 1 2 1 1 1 1 1 1 2 1 ...
 $ Dependent_count    : num [1:7081] 3 5 3 3 2 3 2 1 2 4 ...
 $ Education_Level     : num [1:7081] 2 4 4 1 4 1 4 3 4 5 ...
 $ Marital_Status     : num [1:7081] 2 1 2 2 2 1 1 1 2 1 ...
 $ Income_Category    : num [1:7081] 3 1 4 3 2 3 4 4 1 4 ...
 $ Months_on_book     : num [1:7081] 39 44 36 21 36 36 36 36 48 36 ...
 $ Total_Relationship_Count: num [1:7081] 5 6 4 5 3 5 6 3 5 6 ...
 $ Months_Inactive_12_mon : num [1:7081] 1 1 1 1 1 2 3 6 2 2 ...
 $ Contacts_Count_12_mon : num [1:7081] 3 2 0 0 2 0 3 0 2 3 ...
 $ Credit_Limit       : num [1:7081] 12691 8256 3418 4716 4010 ...
 $ Total_Revolving_Bal : num [1:7081] 777 864 0 0 1247 ...
 $ Total_Amt_Chng_Q4_Q1 : num [1:7081] 1.33 1.54 2.59 2.17 1.38 ...
 $ Total_Trans_Amt    : num [1:7081] 1144 1291 1887 816 1088 ...
 $ Total_Ct_Chng_Q4_Q1 : num [1:7081] 1.625 3.714 2.333 2.5 0.846 ...
 $ Avg_Utilization_Ratio : num [1:7081] 0.061 0.105 0 0 0.311 0.113 0.144 0 0.279 0.078 ...
```

Figure 4. Descriptive Statistics

Attrition_Flag	Customer_Age	Gender	Dependent_count	Education_Level	Marital_Status
0:1013	Min. :26.00	Min. :1.000	Min. :0.000	Min. :1.000	Min. :1.000
1:6068	1st Qu.:41.00	1st Qu.:1.000	1st Qu.:1.000	1st Qu.:2.000	1st Qu.:1.000
	Median :46.00	Median :1.000	Median :2.000	Median :3.000	Median :2.000
	Mean :46.35	Mean :1.477	Mean :2.338	Mean :3.066	Mean :1.664
	3rd Qu.:52.00	3rd Qu.:2.000	3rd Qu.:3.000	3rd Qu.:4.000	3rd Qu.:2.000
	Max. :73.00	Max. :2.000	Max. :5.000	Max. :6.000	Max. :3.000
Income_Category	Months_on_book	Total_Relationship_Count	Months_Inactive_12_mon	Contacts_Count_12_mon	
Min. :1.000	Min. :13.00	Min. :1.000	Min. :0.000	Min. :0.000	
1st Qu.:1.000	1st Qu.:31.00	1st Qu.:3.000	1st Qu.:2.000	1st Qu.:2.000	
Median :2.000	Median :36.00	Median :4.000	Median :2.000	Median :2.000	
Mean :2.343	Mean :35.98	Mean :3.819	Mean :2.343	Mean :2.454	
3rd Qu.:4.000	3rd Qu.:40.00	3rd Qu.:5.000	3rd Qu.:3.000	3rd Qu.:3.000	
Max. :5.000	Max. :56.00	Max. :6.000	Max. :6.000	Max. :6.000	
Credit_Limit	Total_Revolving_Bal	Total_Amt_Chng_Q4_Q1	Total_Trans_Amt	Total_Ct_Chng_Q4_Q1	
Min. :1438	Min. :0	Min. :0.0000	Min. :510	Min. :0.0000	
1st Qu.:2498	1st Qu.:463	1st Qu.:0.6290	1st Qu.:2089	1st Qu.:0.5830	
Median :4287	Median :1282	Median :0.7350	Median :3831	Median :0.7000	
Mean :8493	Mean :1168	Mean :0.7606	Mean :4394	Mean :0.7115	
3rd Qu.:10729	3rd Qu.:1781	3rd Qu.:0.8580	3rd Qu.:4740	3rd Qu.:0.8180	
Max. :34516	Max. :2517	Max. :3.3970	Max. :17995	Max. :3.7140	
Avg_Utilization_Ratio					
Min. :0.0000					
1st Qu.:0.0260					
Median :0.1860					
Mean :0.2823					
3rd Qu.:0.5150					
Max. :0.9990					

The dataset has been split into training (80%) and test (20%) sets using the following code:

```
egitim_indeks <- createDataPartition(veri$Attrition_Flag,
p = .80, list = FALSE, times = 1)
egitim <- veri[egitim_indeks,]
test <- veri[-egitim_indeks,]
egitim_x <- egitim %>% dplyr::select(-Attrition_Flag)
```

```
egitim_y <- egitim$Attrition_Flag  
test_x <- test %>% dplyr::select(-Attrition_Flag)  
test_y <- test$Attrition_Flag
```

To create the Naive Bayes model, the `naiveBayes` function from the "e1071" library is used. Using the trained model and the test data, classification predictions can be made. To evaluate the model's performance, a confusion matrix is created by comparing the predicted values with the actual values. This matrix is a fundamental tool for measuring classification accuracy and the model's success. The following code lines accomplish this:

```
model=naiveBayes(x=egitim_x,  
                 y=egitim_y)  
tahmin=predict(model,newdata = test)  
sonuc=confusionMatrix(table(tahmin,test_y),mode =  
                        "everything")
```

Figure 5. Confusion Matrix and Statistics

```
Confusion Matrix and Statistics  
  
      test_y  
tahmin2  0    1  
0       13   48  
1      189 1165  
  
      Accuracy : 0.8325  
      95% CI   : (0.812, 0.8516)  
No Information Rate : 0.8572  
P-Value [Acc > NIR] : 0.9959  
  
      Kappa   : 0.035  
  
McNemar's Test P-Value : <2e-16  
  
      Sensitivity : 0.064356  
      Specificity : 0.960429  
Pos Pred Value   : 0.213115  
Neg Pred Value   : 0.860414  
Precision        : 0.213115  
Recall           : 0.064356  
F1               : 0.098859  
Prevalence       : 0.142756  
Detection Rate   : 0.009187  
Detection Prevalence : 0.043110  
Balanced Accuracy : 0.512393  
  
'Positive' Class : 0
```

When evaluating the model's prediction performance through the confusion matrix, it was tested on 1415 test data points. The model made a total of 1178 (1165+13) correct predictions and 237 (48+189) incorrect predictions. The accuracy rate of the model is observed to be 83.25%, the sensitivity rate is 6.43%, the precision rate is 21.31%, and the F1 score is 9.88%. Various strategies can be applied to improve these performance values.

4. CONCLUSION

The results obtained using the Naive Bayes classification algorithm in this study demonstrate that, despite its simplicity, the algorithm is quite effective in data classification tasks. Applications performed with the R programming language and the e1071 library have shown strong classification performances on both training and test datasets. The most important advantage of Naive Bayes is its ability to be trained and executed quickly, even on small datasets. Additionally, despite operating under the class independence assumption, it offers high accuracy rates in many applications.

The performance of the model can vary depending on the level of dependency among the features and the structure of the dataset. In particular, when the independence assumption is violated in reality, performance declines, and classification accuracy decreases. In such cases, it is recommended to apply more complex algorithms or methods such as feature engineering.

In conclusion, the Naive Bayes algorithm is a powerful method, especially for classification problems that require quick results on large datasets. Furthermore, paying attention to the structure of the dataset and the validity of the independence assumption will increase the model's success.

REFERENCES

- Albon, C. (2018). Machine learning with python cookbook: Practical solutions from preprocessing to deep learning. " O'Reilly Media, Inc."
- Alpaydın, E. (2020). Introduction to machine learning. MIT Press.
- Bishop, C. M. (2006). Pattern recognition and machine learning. Springer.
- Bramer, M. (2020). Principles of data mining. Springer.
- Berrar, D. (2018). Bayes' theorem and naive Bayes classifier. In Encyclopedia of bioinformatics and computational biology, 1, 403–412.
- Diamantopoulou, M. J., Özçelik, R., Koparan, B., & Alkan, O. (2023). Artificial intelligence as an alternative modelling strategy for reliable height-diameter predictions of mixed-oaks species. Turkish Journal of Agriculture and Forestry, 47(2), 228-241.
- Domingos, P., & Pazzani, M. (1997). On the optimality of the simple Bayesian classifier under zero-one loss. Machine Learning, 29(2-3), 103–130.
- Engin, M. (2023). Naive Bayes. Denetimli makine öğrenmesi algoritmaları: R ve Python uygulamaları. (1st edition), (pp. 281–294). Ankara: Nobel Yayınevi.
- Friedman, N., Geiger, D., & Goldszmidt, M. (1997). Bayesian network classifiers. Machine Learning, 29(2-3), 131–163.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.

- Goyal, S. (2020). Predict churning credit card customers. Kaggle. <https://www.kaggle.com/datasets/sakshigoyal7/credit-card-customers?select=BankChurners.csv>
- Han, J., & Kamber, M. (2006). Data mining: concepts and techniques. Morgan Kaufmann.
- Han, J., Pei, J., & Tong, H. (2023). Data mining concepts and techniques. Elsevier Inc.
- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). The elements of statistical learning: data mining, inference, and prediction. Springer, 2, 1-758.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning: With applications in R. Springer.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning. Springer, 112, 18.
- Kardeş, S., Özkan, U., Bayram, O., & Şahin, H. T. (2024). An artificial neural network (ANN) modelling approach for evaluating turbidity properties of paper recycling wastewater. BioResources, 19(3), 5003.
- Koller, D., & Friedman, N. (2009). Probabilistic graphical models: Principles and techniques. MIT Press.
- Luis, E., Gonzales, J. P. N., Castanon, M. A. G., & Menendez, R. M. (2008). Fault diagnosis of industrial systems with Bayesian networks and neural networks. In Advances in artificial intelligence. Springer-Verlag, 5317, 998–1008.
- Manning, C. D., Raghavan, P., & Schütze, H. (2008). Introduction to information retrieval. Cambridge University Press.
- McCallum, A., & Nigam, K. (1998). A comparison of event models for Naive Bayes text classification. In AAAI-98

workshop on learning for text categorization, 752(1), 41–48.

- Mitchell, T. M. (1997). Machine learning. McGraw-Hill. 1(9).
- Murphy, K. P. (2012). Machine learning: A probabilistic perspective. MIT Press.
- Özdemir K., & Çelebi, Ö. F. (2023). Dış ticarete yenilikçi teknolojiler ve uygulamalar. Dış ticaret teori ve uygulama. (1st edition), (pp. 81–104). Gazi Kitabevi.
- Özkan, Y. (2016). Veri Madenciliği Yöntemleri. (4 ed.). Papatya Bilim.
- Ray, S. (2019). A quick review of machine learning algorithms. In 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon) (pp. 35–39). IEEE.
- Rennie, J. D., Shih, L., Teevan, J., & Karger, D. R. (2003). Tackling the poor assumptions of Naive Bayes text classifiers. In Proceedings of the 20th international conference on machine learning (ICML-03) (pp. 616–623).
- Rish, I. (2001). An empirical study of the Naive Bayes classifier. In IJCAI 2001 workshop on empirical methods in artificial intelligence, 3, 41–46.
- Russell, S., & Norvig, P. (2016). Artificial intelligence: A modern approach. Pearson Education.
- Şahinaslan, Ö., Dalyan, H., & Şahinaslan, E. (2022). Naive Bayes sınıflandırıcısı kullanılarak YouTube verileri üzerinden çok dilli duygu analizi. Bilişim Teknolojileri Dergisi, 15(12), 221–229.
- Yager, R. R. (2006). An extension of the naive Bayesian classifier. Information Sciences, 176(5), 577–588.

- Zhang, H. (2004). The optimality of Naive Bayes. American Association for Artificial Intelligence, 1(2), 3.
- Zhou, H. (2020). Learn data mining through Excel. Apress.

NİCEL KARAR YÖNTEMLERİ

yaz
yayınları

YAZ Yayınları
M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar / AFYONKARAHİSAR
Tel : (0 531) 880 92 99
yazyayinlari@gmail.com • www.yazyayinlari.com