

VERİ ANALİTİĞİ

E-TİCARET TIKLAMA AKIŞINDAN ÜRÜN ÖNERİ SİSTEMİ

FATMA AYDIN

1. Proje Özeti

Bu projede, gerçek bir e-ticaret clickstream veri setindeki kullanıcı davranışlarından yararlanılarak kullanıcının bir sonraki etkileşime gireceği ürünü tahmin etmeyi amaçlayan **session-based ürün öneri sistemi** geliştirilmiştir.

Çalışmada kullanıcıların view, cart ve purchase etkileşimleri kullanılarak kullanıcı oturumları oluşturulmuş ve problem **Implicit-Feedback Sequential / Session-Based Next-Item Recommendation** problemi olarak ele alınmıştır.

Proje yalnızca model geliştirme ile sınırlandırılmamış; veri analizi, veri ön işleme, session oluşturma, model geliştirme, model karşılaştırma, cold-start analizi, hata analizi ve model değerlendirme aşamalarını kapsayan uçtan uca bir çalışma olarak tasarlanmıştır.

Modelleme sürecinde Popularity, Weighted Popularity, Item-Item Co-occurrence, Weighted Co-occurrence ve First-Order Markov Chain yaklaşımları karşılaştırılmıştır. Projenin son geliştirme aşamasında content-aware ve hibrit recommendation yaklaşımlarının kullanılması, model ağırlıklarının validation seti üzerinde optimize edilmesi ve final modelin test seti üzerinde değerlendirilmesi planlanmıştır.

Modelleme tamamlandıktan sonra sistemin sunum katmanı için **Streamlit**, analitik raporlama ve model performansının görselleştirilmesi için ise **Power BI** kullanılması hedeflenmiştir.

2. Problem Tanımı

E-ticaret platformlarında kullanıcılar bir satın alma işlemi gerçekleştirmeden önce birçok farklı ürünle etkileşime girmektedir.

Tipik bir kullanıcı oturumu:

View → View → Cart → View → Purchase gibi farklı davranışlardan oluşabilmektedir.

Bu davranışların sıralı yapısı kullanıcının mevcut ilgisi hakkında önemli bilgiler taşımaktadır.

Projenin temel araştırma sorusu:

Kullanıcının mevcut session içerisindeki geçmiş ürün etkileşimlerinden yararlanarak bir sonraki etkileşime gireceği ürün tahmin edilebilir mi? şeklinde belirlenmiştir.

Bu doğrultuda sistemin temel amacı kullanıcının geçmiş ürün etkileşimlerini kullanarak **Top-K ürün önerisi** oluşturmaktır.

3. Veri Seti ve Veri Yapısı

Projede gerçek kullanıcı davranışlarından oluşan e-ticaret clickstream verisi kullanılmıştır.

Veri seti yaklaşık **2,1 milyon kullanıcı–ürün etkileşimi** içermektedir.

Temel değişkenler:

- event_time
- event_type
- product_id
- category_id
- category_code
- brand
- price
- user_id
- user_session

şeklindedir.

Kullanıcı etkileşimleri:

- view
- cart
- purchase

olmak üzere üç temel davranıştan oluşmaktadır.

EDA sonucunda etkileşimlerin büyük çoğunluğunun view olduğu, cart ve özellikle purchase davranışlarının daha seyrek gerçekleştiği görülmüştür.

Bu yapı nedeniyle problem explicit rating recommendation yerine **implicit-feedback recommendation** olarak ele alınmıştır.

4. Veri Analizi ve EDA

İlk aşamada veri setinin yapısı ve modelleme açısından taşıdığı riskler incelenmiştir.

Analiz kapsamında:

- veri boyutu,
- eksik değerler,

- duplicate kayıtlar,
- event dağılımları,
- kullanıcı davranışları,
- ürün etkileşim sayıları,
- session yapısı,
- kategori dağılımları,
- fiyat davranışları,
- kullanıcı ve ürün cold-start problemi,
- long-tail ürün dağılımı,
- bot/anormal kullanıcı davranışları

incelenmiştir.

Veri setinde güçlü bir **long-tail ürün dağılımı** bulunduğu görülmüştür. Bazı ürünler çok yüksek etkileşim alırken ürünlerin önemli bir bölümü oldukça az kullanıcı etkileşimine sahiptir.

Bu bulgu, yalnızca en popüler ürünleri öneren sistemlerin ciddi bir **popularity bias** oluşturabileceğini göstermiştir.

5. Veri Ön İşleme

Modelleme öncesinde veri seti recommendation problemine uygun hale getirilmiştir.

Bu süreçte:

- zaman değişkenleri düzenlenmiş,
- duplicate kayıtlar kontrol edilmiş,
- anormal kullanıcı davranışları incelenmiş,
- ürün ve kullanıcı kimlikleri hazırlanmış,
- interaction ağırlıkları oluşturulmuş,
- session sıraları korunmuş,
- recommendation için gerekli sequence yapıları hazırlanmıştır.

view, cart ve purchase davranışlarının kullanıcı niyetini farklı seviyelerde temsil ettiği varsayımıyla event ağırlıklandırması da değerlendirilmiştir.

Temel yaklaşım:

view < cart < purchase

şeklinde belirlenmiştir.

6. Chronological Train / Validation / Test Ayrımı

Recommendation sistemlerinde gelecekteki kullanıcı davranışlarının yanlışlıkla modele dahil edilmesi ciddi bir **data leakage** problemidir.

Bu nedenle veri setinde klasik random train-test split kullanılmamıştır.

Veriler zaman sırası korunarak:

Train → Validation → Test

şeklinde ayrılmıştır.

Training verisi modellerin öğrenilmesinde, validation verisi model ve hyperparameter seçiminde, test verisi ise final performans değerlendirmesinde kullanılacak şekilde tasarlanmıştır.

Bu yaklaşım gerçek bir recommendation sistemindeki:

geçmişten öğren → geleceği tahmin et

senaryosuna daha uygun bir değerlendirme sağlamaktadır.

7. Session-Based Sequence Preparation

Her kullanıcı session'ı zaman sırasına göre düzenlenmiştir.

Örneğin:

Ürün A → Ürün B → Ürün C → Ürün D

şeklindeki bir session:

History

Ürün A → Ürün B → Ürün C

Target

Ürün D

şeklinde değerlendirme örneğine dönüştürülmüştür.

Böylece recommendation sisteminin görevi kullanıcının geçmiş davranışından yararlanarak gerçek sonraki ürünü Top-K recommendation listesine yerleştirmek olmuştur.

8. Baseline Recommendation Modelleri

Geliştirilen kişiselleştirilmiş modellerin gerçekten değer sağlayıp sağlamadığını ölçebilmek amacıyla öncelikle baseline modeller kurulmuştur.

8.1 Pure Popularity

Training verisinde en fazla etkileşim alan ürünler bütün kullanıcılara önerilmiştir.

8.2 Weighted Popularity

view, cart ve purchase davranışlarının farklı kullanıcı niyetlerini temsil ettiği varsayımıyla event ağırlıkları kullanılarak ikinci bir popularity modeli oluşturulmuştur.

Bu modeller kişiselleştirme içermemekte ve daha gelişmiş modeller için karşılaştırma noktası oluşturmaktadır.

9. Item-Item Co-occurrence

İlk kişiselleştirilmiş recommendation yaklaşımı olarak **Item-Item Co-occurrence** geliştirilmiştir.

Model aynı session içerisinde birlikte etkileşim alan ürünlerin ilişkisini öğrenmektedir.

Kullanıcının session geçmişindeki ürünler kullanılarak ilişkili ürünlere skor verilmiş ve en yüksek skorlu ürünler Top-K recommendation olarak sunulmuştur.

Bu yöntem session içerisindeki yalnızca son ürüne değil, kullanıcının geçmişindeki birden fazla ürüne bakabilmesi nedeniyle güçlü sonuçlar vermiştir.

Mevcut modelleme sonuçlarında Pure Item-Item Co-occurrence:

- **HR@10 = 0,2882**
- **NDCG@10 = 0,1626**
- **MRR = 0,1366**

sonuçlarına ulaşmıştır.

Bu sonuçlar popularity baseline'a göre belirgin bir performans artışı göstermiştir.

10. Weighted Co-occurrence

Kullanıcı davranışlarının farklı önem seviyelerini recommendation ilişkilerine dahil etmek amacıyla Weighted Co-occurrence yaklaşımı da değerlendirilmiştir.

Ancak mevcut deneylerde Pure ve Weighted Co-occurrence arasında belirgin performans farkı oluşmamıştır.

Veri setindeki etkileşimlerin büyük çoğunluğunun view olması nedeniyle event ağırlıklarının modele sağladığı ek bilginin sınırlı kaldığı değerlendirilmiştir.

11. First-Order Markov Chain

İkinci kişiselleştirilmiş yaklaşım olarak First-Order Markov Chain geliştirilmiştir.

Model:

item_t → item_t+1

geçişlerini training verisinden öğrenmektedir.

Markov modeli yaklaşık:

HR@10 = 0,1951

sonucuna ulaşarak popularity baseline'ı geçmiştir.

Ancak yalnızca son item geçişine odaklandığı için session geçmişinin daha geniş bölümünden yararlanan Co-occurrence yaklaşımının gerisinde kalmıştır.

12. Recommendation Sisteminin Değerlendirilmesi

Model performansını değerlendirmek için klasik accuracy yerine recommendation sistemlerine uygun ranking metrikleri kullanılmıştır.

Başlıca metrikler:

- HitRate@5
- HitRate@10
- HitRate@20
- NDCG@5
- NDCG@10
- NDCG@20
- MRR
- Catalog Coverage
- Fallback Rate

olarak belirlenmiştir.

Bu metrikler sayesinde yalnızca doğru ürünün önerilip önerilmediği değil, ürünün recommendation listesindeki sırası ve sistemin katalog çeşitliliği de değerlendirilmiştir.

13. Popularity Bias ve Catalog Coverage

Popularity baseline'ın katalogdaki çok küçük bir ürün grubuna yoğunlaştığı görülmüştür.

Buna karşılık Co-occurrence modelinin Catalog Coverage değeri yaklaşık:

%57,80

seviyesine ulaşmıştır.

Bu sonuç kişiselleştirilmiş recommendation yaklaşımının yalnızca tahmin performansını artırmadığını, aynı zamanda katalogdaki çok daha geniş bir ürün grubunu kullanıcılara sunabildiğini göstermektedir.

14. Cold-Start ve Fallback

Recommendation modelinin yeterli aday üretemediği durumlarda training verisinden oluşturulan popularity bilgisi fallback mekanizması olarak kullanılmıştır.

Co-occurrence modelinin fallback oranının yaklaşık **%1,1** seviyesinde kalması, modelin test örneklerinin büyük bölümünde doğrudan kişiselleştirilmiş recommendation üretebildiğini göstermiştir.

Bununla birlikte training verisinde hiç görülmeyen ürünlerde davranışsal ilişki öğrenilememesi nedeniyle item cold-start problemi sistemin önemli sınırlamalarından biri olarak belirlenmiştir.

Bu nedenle projenin final geliştirme aşamasında kategori, marka ve uygun olması durumunda fiyat bilgisinden yararlanan **content-aware fallback** yaklaşımının kullanılması planlanmıştır.

15. Hibrit Recommendation Yaklaşımı

Projenin final model geliştirme aşaması, mevcut recommendation sinyallerinin birlikte değerlendirilmesine yönelik olarak tasarlanmıştır.

Hibrit sistemde:

- Popularity,
- Co-occurrence,
- Markov transition,
- Category similarity,
- Brand similarity,
- uygun olması halinde Price similarity

sinyallerinin birlikte kullanılması hedeflenmiştir.

Model ağırlıklarının test setine bakılmadan validation seti üzerinde belirlenmesi ve seçilen final yapılandırmanın yalnızca final değerlendirme aşamasında test setine uygulanması planlanmıştır.

Bu sayede kişiselleştirme performansı ile cold-start dayanıklılığı arasında daha dengeli bir recommendation sistemi oluşturulması amaçlanmıştır.

16. Sistematik Hata Analizi

Model başarısının yalnızca genel metriklerle değerlendirilmesi yeterli görülmemiştir.

Bu nedenle recommendation performansının:

- session uzunluğu,
- ürün popülerliği,
- head/mid/long-tail ürün grupları,
- cold-start durumu,

- son kullanıcı etkileşim türü

gibi farklı segmentlerde incelenmesi proje tasarımına dahil edilmiştir.

Bu analizlerin amacı modelin hangi kullanıcı ve ürün gruplarında güçlü, hangi gruplarda zayıf olduğunu ortaya koymaktır.

17. GRU4Rec Kararı

Session-based deep-learning yaklaşımı olarak GRU4Rec değerlendirilmiştir.

Ancak mevcut veride session'ların oldukça kısa olması ve Co-occurrence gibi daha basit modellerin güçlü sonuç vermesi nedeniyle neural recommendation yaklaşımının sağlayacağı potansiyel performans artışının ek hesaplama maliyetine değmeyebileceği değerlendirilmiştir.

Bu nedenle GRU4Rec mevcut proje kapsamının dışında bırakılmıştır.

Daha uzun dönemli ve daha uzun kullanıcı session'ları içeren bir veri seti elde edilmesi durumunda yeniden değerlendirilmesi uygun görülmüştür.

18. Uygulama Katmanı – Streamlit

Modelleme tamamlandıktan sonra recommendation sisteminin son kullanıcı tarafından test edilebilmesi için **Streamlit tabanlı bir demo uygulaması oluşturulması** proje mimarisine dahil edilmiştir.

Uygulamada kullanıcının veya session'ın seçilmesi ve mevcut session geçmişinin modele verilmesi planlanmıştır.

Sistem bu bilgiye göre:

Top-5 / Top-10 ürün önerisi

üretecek şekilde tasarlanmıştır.

Örnek kullanıcı akışı:

Session geçmişi

Ürün A → Ürün B → Ürün C

↓

Recommendation Engine

↓

Önerilen Ürünler

1. Ürün X
2. Ürün Y
3. Ürün Z
4. Ürün K
5. Ürün L

Bu katmanın amacı geliştirilen recommendation algoritmasının yalnızca notebook içerisinde çalışan bir analiz olmaktan çıkarılarak kullanıcı tarafından etkileşimli biçimde test edilebilen bir prototipe dönüştürülmesidir.

19. Analitik Raporlama – Power BI

Model sonuçlarının iş birimleri tarafından daha kolay yorumlanabilmesi amacıyla **Power BI dashboard katmanı** proje mimarisine dahil edilmiştir.

Dashboard üç temel bölümden oluşacak şekilde tasarlanmıştır.

19.1 Genel Bakış

Bu bölümde:

- toplam etkileşim,
- toplam kullanıcı,
- toplam ürün,
- toplam session,
- View/Cart/Purchase dağılımı,
- ortalama session uzunluğu,
- kategori dağılımları

gibi temel KPI'ların sunulması planlanmıştır.

19.2 Model Performansı

Bu sayfada recommendation modellerinin:

- HR@5

- HR@10
- HR@20
- NDCG@10
- MRR
- Catalog Coverage
- Fallback Rate

metrikleri üzerinden karşılaştırılması hedeflenmiştir.

Bu sayede hangi modelin neden final model olarak seçildiği görsel olarak açıklanabilecektir.

19.3 Recommendation Analizi

Üçüncü dashboard sayfasının:

- Head/Mid/Long-tail performansı,
- session uzunluğuna göre başarı,
- cold-start performansı,
- kategori bazında recommendation,
- popularity bias,
- catalog coverage

gibi daha detaylı model davranışlarını göstermesi planlanmıştır.

Power BI böylece modelin çalıştırıldığı platform olmaktan ziyade recommendation sisteminin **analitik izleme ve karar destek katmanı** olarak konumlandırılmıştır.

20. Sistem Mimarisi

Projenin uçtan uca yapısı aşağıdaki şekilde tasarlanmıştır:

E-Ticaret Clickstream Verisi

↓

Python Veri Ön İşleme

↓

Session / Sequence Preparation

↓

Recommendation Models

↓

Model Evaluation & Selection

↓

Final Recommendation Engine

↙ ↘

Streamlit Demo **Power BI Dashboard**

Streamlit son kullanıcıya recommendation sonuçlarını göstermek, Power BI ise sistemin performansını analitik açıdan değerlendirmek için konumlandırılmıştır.

21. Production Ortamına Geçiş

Mevcut çalışma bir portföy/veri analizi projesi kapsamında offline recommendation sistemi ve prototip olarak tasarlanmıştır.

Gerçek bir e-ticaret production ortamında bir sonraki aşamada recommendation modelinin API olarak servis edilmesi ve web/mobile uygulamayla entegre edilmesi gerekir.

Canlı ortamda model başarısı yalnızca offline HR veya NDCG ile değil:

- Recommendation CTR,
- Add-to-Cart Rate,
- Conversion Rate,
- Revenue per Session,
- Average Order Value

gibi iş KPI'ları üzerinden değerlendirilmelidir.

Mevcut recommendation sistemi ile yeni model gerçek kullanıcı gruplarına ayrılarak A/B test ile karşılaştırılabilir.

22. Kullanılan Teknolojiler

Projede kullanılan ve planlanan temel teknolojiler:

Veri Analizi ve Modelleme

- Python
- Pandas
- NumPy
- Scikit-learn
- Jupyter Notebook / Google Colab

Recommendation

- Popularity-Based Recommendation
- Item-Item Co-occurrence
- Weighted Co-occurrence
- First-Order Markov Chain
- Hybrid Recommendation

Model Değerlendirme

- HitRate@K
- NDCG@K
- MRR
- Catalog Coverage
- Fallback Analysis

Sunum / Prototipleme

- Streamlit

Business Intelligence

- Power BI

Versiyon Kontrolü ve Portföy

- Git
- GitHub

23. Projenin Güçlü Yönleri

Projenin temel güçlü yönleri şunlardır:

1. Gerçek ve büyük ölçekli clickstream verisi kullanılması.
2. Recommendation probleminin session-based olarak ele alınması.

3. Random split yerine chronological split kullanılması.
4. Data leakage risklerinin dikkate alınması.
5. Baseline ve kişiselleştirilmiş modellerin karşılaştırılması.
6. Recommendation'a uygun ranking metriklerinin kullanılması.
7. Cold-start ve long-tail problemlerinin incelenmesi.
8. Popularity bias'ın ayrıca değerlendirilmesi.
9. Model karmaşıklığının veri yapısına göre belirlenmesi.
10. Streamlit ve Power BI katmanlarının sistem mimarisine dahil edilmesi.

24. Projenin Sınırlılıkları

Çalışmanın bazı sınırlılıkları bulunmaktadır.

Verinin tek aylık bir zaman penceresini kapsaması uzun dönemli kullanıcı tercihlerinin modellenmesini sınırlandırmaktadır.

Session'ların büyük bölümünün kısa olması gelişmiş sequential deep-learning yöntemlerinin potansiyel avantajını azaltmaktadır.

Training verisinde hiç görülmeyen ürünler için davranışsal ilişkiler öğrenilemediğinden item cold-start problemi tamamen ortadan kaldırılamamaktadır.

Son olarak mevcut değerlendirme offline metriklere dayanmaktadır. Gerçek iş etkisinin ölçülebilmesi için production ortamında A/B test yapılması gerekir.

25. Sonuç

Bu projede gerçek e-ticaret clickstream verilerinden yararlanılarak kullanıcının mevcut session geçmişine göre bir sonraki ürünü tahmin etmeyi amaçlayan uçtan uca bir recommendation sistemi geliştirilmiştir.

Veri analizi ve preprocessing aşamalarından sonra Popularity, Weighted Popularity, Item-Item Co-occurrence, Weighted Co-occurrence ve First-Order Markov Chain yaklaşımları değerlendirilmiştir.

Mevcut deneylerde **Pure Item-Item Co-occurrence**, **HR@10 = 0,2882**, **NDCG@10 = 0,1626** ve **MRR = 0,1366**sonuçlarıyla güçlü performans göstermiş ve popularity baseline'ın önemli ölçüde üzerine çıkmıştır.

Aynı zamanda yaklaşık **%57,80 Catalog Coverage** sağlayarak popularity tabanlı sistemlerde görülen yoğun popularity bias problemini azaltmıştır.

Projenin final geliştirme tasarımında davranışsal recommendation modellerinin kategori, marka ve uygun olduğunda fiyat bilgisiyle desteklenmesi; validation tabanlı tuning ile final modelin belirlenmesi öngörülmüştür.

Modelleme katmanının ardından recommendation sonuçlarının kullanıcıya sunulması için **Streamlit tabanlı interaktif demo**, model performansının ve kullanıcı davranışlarının analitik olarak izlenmesi için ise **Power BI dashboard**tasarlanmıştır.

Böylece çalışma yalnızca bir makine öğrenmesi notebook'u olmaktan çıkarılarak:

Veri → Analiz → Modelleme → Recommendation → Değerlendirme → Uygulama → Raporlama

süreçlerini kapsayan uçtan uca bir recommendation sistemi projesi olarak yapılandırılmıştır.

Bu proje; veri analizi, recommendation sistemleri, model değerlendirme, iş zekâsı ve uygulama geliştirme bileşenlerini aynı problem üzerinde birleştiren kapsamlı bir portföy çalışması niteliğindedir.