

TÜRKÇE NİYET SINIFLANDIRMAYA DAYALI BİR SOHBET ROBOTU GELİŞTİRİLMESİ

ÖZET

Bu çalışmada, müşteri hizmetleri süreçlerini dijitalleştirmek amacıyla, doğal dil işleme (NLP) teknikleri kullanılarak Türkçe destekli bir chatbot geliştirilmiştir. Veri toplama, ön işleme, eğitim ve test aşamalarını kapsayan bu projede, BERT ve LSTM gibi derin öğrenme modelleri PyTorch ve Hugging Face kütüphaneleri aracılığıyla uygulanmıştır. Kullanıcı sorularının doğru sınıflandırılması ve uygun yanıtların üretilmesi hedeflenmiştir. Eğitim verisi üzerinde gerçekleştirilen modellemeler sonucunda chatbot, yüksek doğruluk oranlarına ulaşarak müşteri deneyimini iyileştirme potansiyelini ortaya koymuştur. Elde edilen sonuçlar, Türkçe doğal dil işleme alanında yeni uygulamalar geliştirilmesine katkı sağlamaktadır.

Anahtar Kelimeler: *Sohbet Robotu, BERT, LSTM, NLP, Derin Öğrenme*

GİRİŞ

Yapay zeka (YZ), son yıllarda teknolojinin en hızlı gelişen ve dikkat çeken alanlarından biri haline gelmiştir. Görüntü işleme, doğal dil işleme, planlama gibi birçok alt disiplini kapsayan geniş bir yelpazeye sahip olan yapay zeka; tıp, finans, denetim, otomasyon ve robotik gibi pek çok sektörde verimliliği artırmakta ve karmaşık görevlerin başarıyla yerine getirilmesini sağlamaktadır (Pirim, 2006, s.84; Şentürk, 2023, s.57).

Yapay zekânın iş dünyasında bir değer aracı olarak kabul görmesi, ilk kez 1984 yılında Texas Üniversitesi'nde düzenlenen Ulusal Yapay Zeka Konferansı'na dayanmaktadır. Önceki yıllarda akademik çevrelerin hâkim olduğu bu etkinliğe, 1984'te katılımcıların %75'inin iş dünyasından olması, teknolojinin ticarileşmesinde bir dönüm noktası olmuştur (Berberoğlu, 2023, s.86).

Günümüzde yapay zeka teknolojileri, internet, matbaa ve elektriğin toplumsal etkileriyle karşılaştırılabilir ölçüde geniş bir dönüşüm yaratmaktadır. McCartney'e (2023) göre yapay zeka, dijital çağın en kritik teknolojilerinden biri haline gelmiş ve iş dünyasında sağladığı dönüşümle önemli bir kırılma noktası oluşturmuştur (Barba vd., 2024, s.2). Bu dönüşümün en dikkat çekici uygulamalarından biri ise chatbot teknolojileridir.

Chatbotlar, genel olarak doğal dil işleme teknolojisi ya da önceden tanımlanmış veri setleri aracılığıyla, kullanıcılarla sesli ya da yazılı olarak etkileşim kurabilen bilgisayar yazılımlarıdır (Altun ve Seferoğlu, 2024, s.485). Yapay zekânın konuşma sistemlerine entegrasyonu, bu tür yazılımların kullanıcı deneyimini önemli ölçüde iyileştirmesini sağlamıştır.

Yapay zeka kavramının temelleri, ünlü İngiliz matematikçi ve mantıkçı Alan Turing tarafından 1950'li yıllarda atılmıştır. Turing, makinelerin düşünme yetisine sahip olup olamayacağını sorgulayarak bu alandaki ilk adımları atmıştır (Pirim, 2006, s.89). 1994 yılında Michael Mauldin, geliştirdiği ilk Verbot ile "ChatterBot" terimini literatüre kazandırmıştır (Prakash vd., 2020, s.1709). Chatbotların tarihindeki ilk örnek ise, 1966 yılında MIT profesörü Joseph Weizenbaum tarafından geliştirilen ELIZA'dır. Bir psikolog gibi davranan bu yazılım, kullanıcı girdilerini anahtar kelimelerle eşleştirerek önceden belirlenmiş kalıplarla yanıt üretmiştir (Kuruca vd., 2022, s.102). Ardından 1972'de geliştirilen PARRY ise, yapay zekânın psikiyatri gibi hassas alanlarda kullanımına dair önemli bir örnek olmuştur. 1980'li yıllardan itibaren chatbot teknolojileri, makine öğrenmesine dayalı yaklaşımlarla gelişimini sürdürmüştür. Bu dönemde geliştirilen Jabberwacky ve A.L.I.C.E (Artificial Linguistic Internet Computer Entity) gibi sistemler, doğal dil işleme teknikleriyle daha gerçekçi etkileşimler sunmaya başlamıştır (Albayrak vd., 2018, s.1). 2000'li yıllarda ise dijital asistanların yükselişiyle birlikte, günlük yaşamda yardımcı olan chatbotlar ön plana çıkmıştır. Örneğin SmarterChild, AOL ve MSN gibi platformlarda yaygın olarak kullanılmış, sonrasında Apple tarafından geliştirilen Siri ile bu alan büyük bir ivme kazanmıştır (Koçak, 2024, s.146). 2010'lu yıllardan itibaren derin öğrenme ve büyük dil modelleri (LLM) ile donatılmış chatbotlar ortaya çıkmıştır. Bu sürecin en önemli adımlarından biri, OpenAI tarafından geliştirilen ChatGPT'nin 2022'nin sonunda tanıtılması olmuştur. ChatGPT, yüksek kapasiteli doğal dil işleme becerileri sayesinde kullanıcılarla gerçekçi ve anlamlı diyaloglar kurabilen bir model olarak dikkat çekmiştir (Şentürk, 2023, s.70). ChatGPT'nin ardından Gemini, DeepSeek, Grok gibi gelişmiş modeller de kullanıcılarla daha doğru, doğal ve kapsamlı iletişim kurabilen sistemler olarak geliştirilmiştir. Bu yeni nesil chatbotlar, daha gerçekçi etkileşimler sunmakta ve kullanıcı taleplerine daha doğru yanıtlar verebilmektedir. (Demirkol, 2023, s.296).

Bugün iş dünyasında chatbotlar, özellikle müşteri hizmetleri ve dijital pazarlama gibi alanlarda yaygın biçimde kullanılmaktadır. Manuel olarak gerçekleştirilmesi zor ve zaman alıcı görevler, bu sistemler sayesinde ölçeklenebilir ve hızlı bir şekilde tamamlanabilmektedir (Berberoğlu, 2023, s.91). Yapay zeka destekli chatbotlar; insan dilini anlama, doğru ve hızlı

yanıtlar üretme gibi yetenekleriyle ön plana çıkmakta, gelişmiş Doğal Dil İşleme (NLP) teknikleri sayesinde kullanıcı niyetlerini analiz ederek daha etkili bir iletişim sunmaktadır (Koçak, 2024, s.142). Bu sayede, müşteri ilişkileri yönetiminde önemli avantajlar sağlamakta, sorunlara anında çözüm sunarak müşteri memnuniyetini artırmaktadır. Nitekim, 2022 ile 2026 yılları arasında chatbotlar aracılığıyla gerçekleştirilen müşteri etkileşimlerinin 3,5 milyardan yaklaşık 10 milyara ulaşması beklenmektedir (Juquelier vd., 2025, s.1).

Bu çalışma kapsamında geliştirilen chatbot, Bera Şirketi için müşteri hizmetleri süreçlerini dijitalleştirmek amacıyla tasarlanmıştır. Chatbotun temel amacı; şirkete proje talebinde bulunmak isteyen müşterilere rehberlik etmek, kariyer başvuru süreçlerinde destek sağlamak ve şirketin faaliyetleri ile geliştirdiği uygulamalar hakkında bilgi sunmaktır. Böylece, geleneksel telefonla iletişim yöntemine kıyasla süreçlerin daha hızlı, etkili ve zamandan tasarruf sağlayacak şekilde yürütülmesi hedeflenmektedir.

Geliştirilen chatbotun hedef kullanıcı kitlesi, Bera Şirketi ile proje, kariyer veya iş birliği amacıyla iletişim kurmak isteyen bireyler ve kurum temsilcileridir. Chatbotun başlıca işlevleri arasında; müşteri sorularına hızlı ve doğru yanıtlar sunmak, başvuru süreçlerinde kullanıcıyı yönlendirmek ve şirketin sunduğu hizmetler hakkında bilgilendirme yapmak yer almaktadır. Bu sayede hem müşteri memnuniyetinin artırılması hem de şirket çalışanlarının üzerindeki operasyonel yükün azaltılması amaçlanmaktadır.

YÖNTEM

Bu çalışmada, Türkçe dilinde doğal dil anlayışı gerektiren bir sohbet robotu (chatbot) sistemi geliştirilmiştir. Sistem geliştirme süreci; veri seti oluşturma, ön işleme, model mimarisi tasarımı ve eğitim aşamaları gibi temel adımlardan oluşmaktadır. Çalışmada modern derin öğrenme teknikleri kullanılmış olup, özellikle BERT (Bidirectional Encoder Representations from Transformers) ve LSTM (Long Short-Term Memory) gibi güçlü modellerin birleşiminden oluşan bir hibrit mimari tasarlanmıştır.

Çalışmada kullanılan veri seti, firmanın müşteri hizmetleri kanallarından (SSS bölümü, şirketin sosyal medya hesapları) toplanan gerçek kullanıcı etkileşimlerinden oluşturulmuş, etiketli (supervised) bir veri setidir. Veri seti, tag (her soru grubu için belirlenmiş etiketler), patterns (kullanıcıların sorabileceği farklı ifade biçimindeki soru örnekleri), responses (Chatbot'un vereceği yanıtlar) olarak üç ana bileşenden oluşmuştur. Veri setinde 68 tag, 1166 pattern ve 76 cevap metni bulunmaktadır. Şekil 1 'de veri setinden bir kesit gösterilmiştir.


```
{
  "tag": "siber_saldiri_tespiti_ve_mudahale",
  "patterns": [
    "Siber saldırıları nasıl tespit ediyorsunuz?",
    "IDS ve IPS sistemleriniz nasıl çalışır?",
    "Olay müdahale süreci nasıl işliyor?",
    "7/24 güvenlik izleme sisteminiz var mı?"
  ],
  "responses": [
    "Sistemlerinizi 7/24 izleyerek potansiyel tehditleri erken tespit ediyor ve anında müdahale yöntemleri ile zarar görmenizi engelliyoruz."
  ]
}
```

Şekil.1: Veri setinden örnek kesit

Veri seti üzerinde çeşitli ön işleme adımları gerçekleştirilmiştir. Öncelikle, metin verileri, Türkçe diline özel olarak optimize edilmiş dbmdz/bert-base-turkish-cased modeline ait tokenizer kullanılarak tokenleştirilmiştir. Model girdilerinin boyutlarını standartlaştırmak amacıyla maksimum sekans uzunluğu 64 token ile sınırlandırılmış, tüm girişlerin uzunluklarının eşitlenmesi için padding ve truncation işlemleri uygulanmıştır. Sınıflandırma işlemleri için etiketler, LabelEncoder yöntemi kullanılarak sayısal değerlere dönüştürülmüştür. Veri setinde mevcut olan sınıf dengesizliği problemi, RandomOverSampler tekniği ile giderilerek sınıflar dengelenmiştir. Son olarak, veriler eğitim ve test olmak üzere %80-%20 oranında, sınıf dağılımının korunmasını sağlayan stratify=True parametresi kullanılarak ikiye ayrılmıştır.

Model geliştirme ve veri işleme süreçlerinde Python programlama dili kullanılmıştır. Derin öğrenme modellerinin oluşturulması için PyTorch kütüphanesinden yararlanılmıştır. BERT tabanlı modellerin kullanımı ve ince ayar (fine-tuning) işlemleri için Hugging Face tarafından geliştirilen Transformers kütüphanesi tercih edilmiştir. Ayrıca, veri işleme, etiket kodlama, veri artırma ve model değerlendirme gibi işlemler için Scikit-learn kütüphanesi kullanılarak sürecin desteklenmesi sağlanmıştır.

Model mimarisi Şekil 2 de gösterilmiştir.



Şekil 2: Model mimarisi

1. Tokenizasyon (Girdi Metninin Tokenlara Ayrılması)

Modelin ilk adımı, kullanıcıdan alınan doğal dil girdisinin, makinenin anlayabileceği şekilde parçalanmasıdır. Bu işlemde, Türkçeye özel olarak eğitilmiş bir BERT tokenizer kullanılmıştır. Bir dil çalışmasında harfler, kelimeler ve onlardan oluşan cümleler bilgisayarın gözünde -her konuda olduğu gibi- sayılardan oluşurlar. Her bir kelimenin sadece kendisine ait olan sayısal değerlerdir bunlar. Bu işleme parçalara ayırma denir (Tokenization)(Demirkol, 2023, s. 296). Tokenlar, modelin giriş katmanında kullanılmak üzere vektör temsillerine dönüştürülür. Bu işlem sayesinde model, metni matematiksel temsillere dönüştürerek daha verimli işleyebilir hale gelir.

2. Transformer Katmanı- BERT (Bağlamsal Temsillerin Elde Edilmesi)

Tokenlara ayrılmış veriler, BERT modeli aracılığıyla bağlamsal temsillere dönüştürülür. BERT, Transformer mimarisi üzerine kuruludur ve özellikle dilin bağlamını iki yönlü olarak (hem geçmiş hem de gelecek) analiz etme yeteneğine sahiptir. Modelin temelini oluşturan self-attention mekanizması, her bir kelimenin diğer tüm kelimelerle olan ilişkisini analiz ederek bağlamsal vektörler üretir. Bu sayede model, her bir kelimeye ait anlamı, cümlenin tüm yapısı içinden dinamik biçimde çıkarabilir. Elde edilen temsiller, her bir token'ın bağlamsal vektörünü ifade eder ve bir sonraki aşamada kullanılmak üzere LSTM katmanına aktarılır.

3. LSTM Katmanı (Zaman Bağlı Bağlamsal Bilginin İşlenmesi)

Bu çalışmada, BERT modelinden elde edilen çıktı vektörleri, zaman bağımlılıklarının ve uzun vadeli bağlamsal ilişkilerin daha etkili bir şekilde öğrenilmesi amacıyla iki katmanlı, çift yönlü (bidirectional) ve dropout uygulamalı bir LSTM ağına verilmiştir. İlgili LSTM yapısı, zaman serisi verilerindeki ardışık bağımlılıkları modellemek ve bağlamsal bilgiyi derinlemesine yakalamak üzere tasarlanmıştır. Modelde katman sayısı 2 olarak belirlenmiş, gizli katman boyutu (hidden size) 256 birim olarak seçilmiş ve aşırı öğrenmeyi önlemek amacıyla %20 oranında dropout uygulanmıştır. Bu katmandan elde edilen çıktıların boyutu [batch_size, sequence_length, 512] şeklindedir.

4. ReLU Aktivasyonu

LSTM katmanından elde edilen vektörler, sınıflandırıcı katmanda doğrusal olmayan biçimde işlenir. Bu aşamada kullanılan ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, negatif değerleri sıfıra indirirken pozitif değerleri olduğu gibi geçirir. Bu katmanda, LSTM'den gelen bilgiler daha karmaşık temsillere dönüştürülerek nihai sınıflandırma için uygun hale getirilir.

5. Softmax Sınıflandırma ve Etiket Tahmini

Modelin son aşamasında, işlenmiş temsiller kullanılarak kullanıcı girdisine en uygun etiket sınıfının belirlenmesi hedeflenmiştir. Bu amaçla, çıktı boyutunda sırasıyla $512 \rightarrow 256 \rightarrow \text{Num_classes}$ dönüşümleri gerçekleştirilmiş ve ara katmanlarda %30 oranında dropout uygulanarak modelin aşırı öğrenmeye karşı dayanıklılığı artırılmıştır. Nihai sınıflandırma işlemi, her bir sınıfa ilişkin olasılık değerlerinin hesaplanmasını sağlayan softmax normalizasyon fonksiyonu aracılığıyla gerçekleştirilmiştir. Bu sayede, model her bir sınıf için ait olma olasılığını üretmiş ve en yüksek olasılık değerine sahip sınıf etiketi modelin tahmini olarak kullanıcıya sunulmuştur. Eğitim sürecinde, sınıflar arasındaki dengesizliği dikkate alarak hata hesaplamalarının adil bir şekilde yapılabilmesi için sınıf ağırlıklı CrossEntropyLoss kayıp fonksiyonu kullanılmıştır.

BULGULAR ve YORUMLAR

Bu bölümde, chatbotun eğitim süreci, kullanılan metrikler ve sonuçlar sunulacaktır. Chatbotun başarı performansını değerlendirmek için farklı testler gerçekleştirilmiş ve modelin doğruluğu, F1 skoru ve ROC-AUC oranları analiz edilmiştir.

<i>Model Adı</i>	<i>Val acc</i>	<i>Val fl</i>	<i>ROC-AUC</i>
<i>BERT</i>	0.8590	0.8530	0.9878
<i>LSTM</i>	0.5427	0.5316	0.9185
<i>Hibrit Model</i> <i>(BERT+LSTM)</i>	0.8590	0.8545	0.9923

Bu çalışmada LSTM, BERT ve BERT-LSTM hibrit modellerinin performansları karşılaştırılmıştır. Elde edilen sonuçlar Tablo 1'de özetlenmiştir.

LSTM modeli, sıralı veri üzerinde öğrenme kabiliyetine sahip olmasına rağmen (Hochreiter & Schmidhuber, 1997), doğruluk ve F1 skoru açısından (%54.27 doğruluk, %53.16 F1) diğer modellere kıyasla düşük bir performans sergilemiştir. Bu durum, LSTM'nin dil modelleme görevlerinde sınırlı temsil kapasitesinden kaynaklanmaktadır. Buna karşılık, LSTM modelinin doğruluk ve F1 skorları daha düşük olmasına rağmen ROC-AUC değerinin yüksek olması, modelin sınıflar arasındaki ayrımı iyi yaptığı ancak belirli eşik değerlerinde hatalar yaptığına işaret etmektedir. Bu durum, (Goodfellow vd. 2016) tarafından da belirtildiği üzere, özellikle sıralı veri işleyen modellerde eğitim sürecinin erken aşamalarında gözlemlenebilmektedir.

BERT modeli ise, transformer tabanlı yapısı sayesinde (Devlin vd., 2019) dil anlayışı konusunda üstün performans göstermiştir. %85.90 doğruluk ve %85.30 F1 skoru ile BERT, özellikle sınıflandırma görevlerinde etkili sonuçlar üretmiştir. Ancak, yapılan gözlemler BERT modelinin sohbet sırasında anlam bütünlüğünü tam koruyamadığını, bazı yanıtlarının semantik olarak doğru görünse de içerik açısından hatalı olabileceğini ortaya koymuştur. Bu durum, BERT'in temel mimarisinin girişlerin zamansal bağlam ilişkilerini doğrudan modellememesiyle ilişkilendirilebilir (Sun vd., 2020).

Hibrit model (BERT-LSTM), her iki mimarinin güçlü yönlerini birleştirerek daha dengeli bir yapı sunmuştur. Hibrit model, %85.90 doğruluk ve %85.45 F1 skoru ile BERT modeliyle benzer sınıflandırma başarımı elde etmiş, ancak sohbet sırasında içerik tutarlılığı ve bağlama uygunluk açısından üstünlük sağlamıştır. Bu sonuç, önceki çalışmalarla da uyumlu şekilde, transformer tabanlı temsilin LSTM gibi sıralı modellerle desteklendiğinde bağlamsal anlama kapasitesinin arttığını göstermektedir (Yang vd., 2019).

Sonuç olarak, hibrit modelin yalnızca sınıflandırma metriklerinde değil, kullanıcı deneyimi açısından da daha üstün performans gösterdiği tespit edilmiştir. Bu da, özellikle diyalog sistemlerinde zamansal bağlamı modellemenin, salt dil temsilinden daha etkili sonuçlar doğurduğunu desteklemektedir.

Model Doğruluk ve Kayıp Oranları

Modelin eğitim sürecinde, her epoch sonunda kayıp (loss) ve doğruluk (accuracy) oranları izlenmiştir. Eğitimde elde edilen doğruluk oranı, modelin öğrenme sürecinin nasıl ilerlediğini göstermektedir. Kayıp oranı ise modelin yanlış tahminlerde bulunma oranını belirtmektedir. Aşağıdaki tabloda, epochlar boyunca kayıp ve doğruluk oranlarını göstermektedir:


Epoch	Train Loss	Val Loss	Train Accuracy	Val Accuracy	Train F1	Val F1	ROC-AUC
1	2.9869	1.7538	0.2533	0.5427	0.2526	0.4879	0.9783
2	0.9060	0.8966	0.7546	0.7265	0.7485	0.7076	0.9912
3	0.3997	0.8592	0.8784	0.7778	0.8772	0.7622	0.9911
4	0.2343	0.7907	0.9381	0.8162	0.9379	0.8154	0.9930
5	0.1387	1.0420	0.9614	0.7991	0.9613	0.7850	0.9901
6	0.0997	0.9150	0.9754	0.8590	0.9754	0.8545	0.9923

Modelin eğitim ve doğrulama performansı değerlendirildiğinde, literatürde overfitting göstergeleri arasında yer alan belirgin eğitim-doğrulama kaybı farkının bulunmadığı gözlemlenmiştir (Goodfellow vd., 2016). Eğitim kaybı epochlar ilerledikçe düzenli bir şekilde azalmış, doğrulama kaybı ise dalgalanmalar göstermesine rağmen genel olarak düşüş eğilimini sürdürmüş ve dramatik bir artış sergilememiştir. Eğitim ve doğrulama doğruluk oranları arasındaki farkın sınırlı kalması, modelin yalnızca eğitim verisini ezberlemediğini, aynı zamanda genelleme yeteneğini de koruduğunu göstermektedir (Bishop, 2006). Ayrıca, eğitim ve doğrulama F1 skorları birbirine yakın seyretmiş, son epoch itibarıyla eğitim F1 skoru 0.9754, doğrulama F1 skoru ise 0.8545 olarak ölçülmüştür. Literatürde %10-15 arasındaki F1 skoru farklarının sağlıklı bir öğrenme sürecini yansıttığı belirtilmektedir (Chollet, 2018). ROC-AUC skorları da 0.9783 ile 0.9923 arasında yüksek seviyelerde seyretmiş olup, modelin sınıflar arasında güçlü bir ayırım yapabildiğini ortaya koymaktadır (Fawcett, 2006). Tüm bu metrikler dikkate alındığında, modelin overfitting yapmadığı, eğitim ve doğrulama veri kümeleri üzerinde başarılı bir performans sergilediği ve yüksek genelleme kapasitesine sahip olduğu sonucuna varılmaktadır.

Chatbot Arayüzü ve Sohbet Süreci

Modelin sohbet arayüzü, kullanıcılarla doğal dilde etkileşim kurabilecek şekilde tasarlanmıştır. Kullanıcılar, sisteme metin tabanlı sorular yazarak yanıtlar alabilmektedir.

Arayüz, kullanıcıların sorularını metin olarak göndermelerine ve chatbot'un yanıtlara verdiği yanıtları hızlı bir şekilde görmelerine olanak sağlar. Bu etkileşim, chatbot'un doğruluğu ve hızını test etmek için önemli bir parametreyi oluşturmuştur.



(a)

(b)

Şekil 2: a,b görsellerinde chatbot konuşmasının ekran görüntüleri

SONUÇ

Bu çalışmada, Bera Şirketi için müşteri hizmetleri süreçlerini dijitalleştirmek ve daha etkin hale getirmek amacıyla Türkçe dilinde doğal dil anlayışına sahip bir chatbot geliştirilmiştir. Chatbot, modern derin öğrenme yöntemleri kullanılarak tasarlanmış; özellikle BERT ve LSTM mimarilerinin güçlü yönlerinin birleştirildiği hibrit bir yapı oluşturulmuştur.

Sistem, firmanın gerçek müşteri etkileşimlerinden oluşturulan ve çeşitli ön işleme adımlarından geçirilen özel bir veri seti üzerinde eğitilmiştir. Geliştirilen chatbot; müşteri taleplerine hızlı ve doğru şekilde yanıt verme, başvuru süreçlerinde yönlendirme sağlama ve şirket hizmetleri hakkında bilgilendirme yapma işlevlerini başarıyla yerine getirmiştir. Bu sayede, hem müşteri deneyiminin iyileştirilmesi hem de şirket çalışanlarının üzerindeki operasyonel yükün azaltılması hedeflenmiş ve önemli ölçüde başarı sağlanmıştır.

Çalışmanın sonucunda, yapay zeka tabanlı chatbotların, doğru veri hazırlığı, etkili model mimarisi seçimi ve dil özelliklerine uygun ön işleme teknikleriyle birleştirildiğinde, müşteri hizmetleri gibi yoğun etkileşim gerektiren alanlarda yüksek verimlilik ve kullanıcı memnuniyeti sağlayabileceği görülmüştür.

Gelecekte, chatbotun yeteneklerinin artırılması adına; sesli etkileşim desteğinin eklenmesi, daha geniş kapsamlı veri setleriyle modelin güçlendirilmesi ve sürekli öğrenme mekanizmalarının entegre edilmesi gibi iyileştirme çalışmaları önerilmektedir. Böylece, chatbot sistemi daha dinamik, ölçeklenebilir ve kullanıcı ihtiyaçlarına daha duyarlı bir yapıya kavuşabilecektir.

KAYNAKÇA

- 1) A. G. H. Pirim, “YAPAY ZEKA”, Yaşar Üniversitesi E-Dergisi, c. 1, sy. 1, ss. 81–93, 2006, doi: 10.19168/jyu.72783.
- 2) Şentürk, Ö. (2023). İÇ DENETİM FAALİYETLERİNDE YAPAY ZEKADAN BEKLENTİLER: CHATGPT UYGULAMASI ÖRNEĞİ. TIDE AcademIA Research, 4(2), 51-82.
- 3) Berberoğlu, B. M. (2023). YÖNETİMDE YAPAY ZEKA. Scientific Journal of Innovation and Social Sciences Research, 3(2), 81-96.
- 4) Atienza-Barba, M., Meseguer-Martínez, Á., Barba-Sánchez, V., & Álvarez-García, J. (2024). Chatbots and Organizational Outcomes: Attitude, Usage, Management Support, and Organizational Routines. *Profesional de la información*, 33(5).

- 5) ALTUN, E., & SEFEROĞLU, S. S. (2024). An Innovative Tool in Education: An Examination of the Role and Future of Chatbots in Teaching. *Inonu University Journal of the Faculty of Education (INUJFE)*, 25(2).
- 6) Prakash, K. B., Nagapawan, Y. V. R., Kalyani, N. L., & Kumar, V. P. (2020). Chatterbot implementation using transfer learning and LSTM encoder-decoder architecture. *International Journal*, 8(5), 21.
- 7) Kuruca, Y., Üstüner, M., & Şimşek, I. (2022). Dijital pazarlamada yapay zekâ kullanımı: Sohbet robotu (Chatbot). *Medya ve Kültür*, 2(1), 88-113.
- 8) Albayrak, N., Özdemir, A., & Zeydan, E. (2018, May). An overview of artificial intelligence based chatbots and an example chatbot application. In *2018 26th signal processing and communications applications conference (SIU)* (pp. 1-4). IEEE.
- 9) Koçak, G. (2024). Pazarlama 5.0 ve Yapay Zekâ Destekli Sohbet Robotları: Kavramsal Bir İnceleme. *Çağ Üniversitesi Sosyal Bilimler Dergisi*, 21(2), 136-157.
- 10) Demirkol, Z. (2023). Herkes İçin Yapay Zeka. Destek Yayınları
- 11) Juquelier, A., Poncin, I., & Hazée, S. (2025). Empathic chatbots: A double-edged sword in customer experiences. *Journal of Business Research*, 188, 115074.
- 12) Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- 13) Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019, June). Bert: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies, volume 1 (long and short papers)* (pp. 4171-4186).
- 14) Sun, C., Qiu, X., Xu, Y., & Huang, X. (2019, October). How to fine-tune bert for text classification?. In *China national conference on Chinese computational linguistics* (pp. 194-206). Cham: Springer International Publishing.
- 15) Yang, Z., Dai, Z., Yang, Y., Carbonell, J., Salakhutdinov, R. R., & Le, Q. V. (2019). Xlnet: Generalized autoregressive pretraining for language understanding. *Advances in neural information processing systems*, 32.

- 16) Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- 17) Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- 18) Chollet, F., & Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.
- 19) Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.