



Doğal dil işleme yöntemleriyle metinden SQL sorgusu tahmini üzerine bir çalışma

A study on text-to-SQL query prediction with natural language processing methods

Asım Sinan Yüksel¹ , Muhammed Abdulhamid Karabiyik^{2,*} 

^{1,2} Süleyman Demirel Üniversitesi, Bilgisayar Mühendisliği Bölümü, 32260, Isparta Türkiye

Öz

Bilgisayar bilimlerinde, kalıcı bilgiler sistematik bir şekilde veri tabanlarında tutulmaktadır. Veri tabanlarındaki bilgilere ulaşılabilmesi için belirli teknik birikimlere sahip olunması gerekmektedir. Çalışmamızda, doğal dille yapılmış sorgulardan SQL sorgusu tahmini yapılmıştır. Bu sayede teknik bir bilgi birikimi olmadan veri tabanları üzerinde sorgulamalar yapılabilmesi hedeflenmektedir. Çalışmamızda doğal dil işleme tekniklerinden faydalanmıştır. Doğal dil işlemenin ana konularından biri olan çoklu dil desteği, uygulamaya entegre edilmiştir. Doğal dilden SQL tahmini için uygulanan model, LSTM ağı kullanılarak spider veri setiyle eğitilmiştir. Yapılan SQL sorgusu tahminlerinde, %75 başarı oranına ulaşmıştır. Çoklu dil desteğiyle yapılan genel sistem değerlendirmesinde, başarı oranı %69.4' e ulaşmıştır.

Anahtar kelimeler: Doğal dil işleme, Yapay zekâ, Metinden SQL dönüşümü

1 Giriş

Yeni bir teknolojinin gelişimi, belirli adımları izlemektedir. Yeni bir teknoloji ilk oluşturulduğunda, sadece geliştiricileri tarafından etkili bir şekilde kullanılabilir. Zamanla teknik yeterlilikleri olan kişiler tarafından kullanılabilir. Gelişimini tamamlayan teknolojiye toplumun geneli tarafından kullanılmaktadır. Bilgisayar bilimlerinde üretilen birçok teknolojinin kullanımında, teknik yeterliliğe ihtiyaç duyulmaktadır. Doğal dil işlemenin (DDİ) gelişmesiyle beraber, önümüzdeki zamanlarda birçok teknoloji kullanımı için teknik yeterlilikler gerekmeceği açıktır.

Doğal dil işleme, insan bilgisayar etkileşiminde kullanılan en önemli alanlardan biridir. Bu sebeple çok geniş bir uygulama alanına sahiptir. Bu alanlara şu örnekleri verebiliriz; yazım düzeltme, metin okuma, yazar tahmini, metin özetleme, bilgi çıkarımı, metin ses dönüşümü, ses metin dönüşümü, sesli komutlar, diller arası çeviri vb. birçok alan örnek olarak verilebilir [2].

Bu çalışmada, doğal dil işleme tekniklerinden yararlanılarak çoklu dil desteği sağlayan, bir metinden SQL dönüşümü sistemi gerçekleştirilmiştir. Geliştirilen sistemin çoklu dil desteği Google Translate API'si kullanılarak uygulanmıştır. Metinden SQL dönüşümünde kullanılan modelin geliştirilmesinde yapay sinir ağı temelli LSTM

Abstract

In computer science, permanent information is kept in databases in a systematic way. In order to access the information in the databases, it is necessary to have certain technical knowledge. In our study, SQL query estimation was made from natural language queries. In this way, it is aimed to make queries on databases without any technical knowledge. In our study, natural language processing techniques were used. Multi-language support, which is one of the main subjects of natural language processing, is integrated into the application. The model applied for natural language SQL prediction is trained with the spider dataset using the LSTM network. In the SQL query estimations, it has reached 75% success rate. In the overall system evaluation with multilingual support, the success rate has reached 69.4%.

Keywords: Natural language processing, Artificial intelligent, Text to SQL

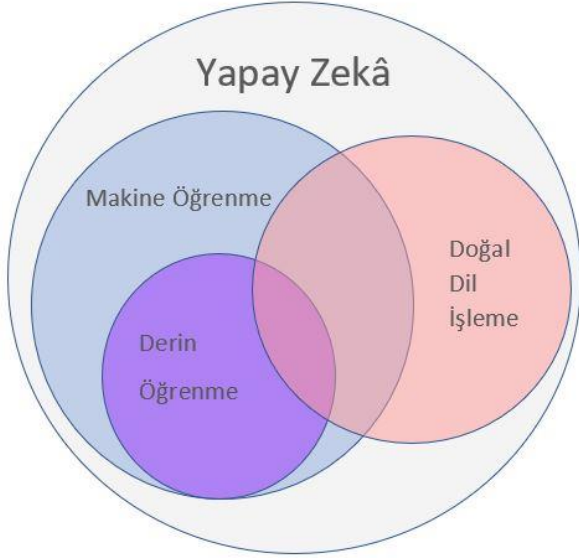
(Long Short Term Memory) modeli kullanılmıştır [3]. Modelin eğitiminde spider veri setinden faydalanılmıştır [4]. Anlamsal ayrıştırma tabanlı olarak geliştirilen, metinden SQL dönüşümü sistemlerinde farklı yaklaşımlar mevcuttur. Çalışmamızdaysa, yarı otoregresif bir model olan SmBoP (Semi-autoregressive Bottom-up Semantic Parsing)'dan yararlanılmıştır [5]. SmBoP, Lily (Language, Information, and Learning at Yale) laboratuvarı tarafından yapılan kıyaslamalarda %71.1 doğruluk oranıyla 3. Sırada yer almaktadır. Çalışmamızda SmBop python programlama dilini desteklemesi, karmaşık yapıda olmayan veri tabanlarındaki başarılı sonuçları ve çoklu dil desteğinin entegre edilebilmesinden dolayı tercih edilmiştir [6].

Çalışmamız genel olarak doğal dil işleme problemlerinden makine çevirisine odaklanmıştır. Makine çevirisi olarak çalışmamızda çoklu dil desteği ve metinden SQL'e dönüşüm vardır. Çoklu dil desteğinde 33 adet doğal dilden İngilizceye çeviri mevcuttur. Yapılan deneyde, Türkçeden İngilizceye yapılan çeviri işlemlerinden %83.3'lik bir başarıya ulaşılmıştır. Bir diğer Makine Çeviri konusu olan metinden SQL'e dönüşüm probleminde, spider veri seti içerisinde bulunan veri tabanları üzerinde yapılan metinden SQL sorgusu dönüşümünde %75'lik bir başarı sağlanmıştır. Sistemin genelinde yapılan deneyde ise Türkçe

girilen bir doğal dil sorgusunun SQL' e dönüşümünde %69.4'lik bir başarı oranına ulaşılmıştır.

2 Doğal dil işleme

Doğal dil işleme, insanların konuşma dillerini analiz eden, anlamaya çalışan bir yöntemdir [7]. Yapay zekanın alt kolu olarak görülebilecek olan DDİ, aynı zamanda makine öğrenmesi ve alt kolu olan derin öğrenme yöntemlerini de kullanmaktadır. Şekil 1'de DDİ'nin hiyerarşik yapısı gösterilmektedir.



Şekil 1. Doğal dil işleme hiyerarşik yapısı.

DDİ, amaç ve yöntemlere göre kendi içinde 2 grupta incelenebilir. Bunlar; doğal dil oluşturma (Natural Language Generation), doğal dil anlama (Natural Language Understanding) konularıdır. DDİ konuları giriş ve çıkış değerlerini içermektedir. Doğal dil anlama, bilgisayar sistemine gönderilen giriş değerini anlamak için çalışırken, doğal dil oluşturma bilgisayar sisteminin sonuçlarını insanların anlayacağı bir şekilde sunmaya çalışmaktadır [8].

Alan Turing tarafından 1950 yılında ortaya konan Turing testi, bir makinenin düşünüp düşünemediğini anlayabilmeyi amaçlamaktadır. Bu testte sorulan sorulara cevap veren bir insan ve bir bilgisayar sistemi vardır. Cevap verenin insan mı yoksa bilgisayar mı olduğuna karar verilemiyorsa, test başarılı kabul edilmektedir [9]. Bu testle beraber yapay zekâ ile ilgili birçok problem ortaya çıkmıştır. Bunlardan birisi de doğal dil işlemenin temel konusu olan insan bilgisayar iletişimidir.

DDİ'nin temelleri 1940 ve 1960 yılları arası atılmıştır. Bu dönemde çalışmalar makine çevirisi üzerine odaklandı. İlk olarak İngilizce-Rusça çeviri üzerine ilkel bir uygulama geliştirilmiştir. Bu dönemin sonunda, Teddington Uluslararası Dillerin Makine Çevirisi ve Uygulamalı Dil Analizi Konferansında DDİ için temel olan konular ortaya çıkmıştır. Bu konular ise; morfoloji, söz dizimi, anlam, yorumlama ve oluşturma olarak belirlenmiştir [10].

1960 ve 1970 yılları arasına geldiğinde DDİ alanında somut ilerlemeler yaşanmıştır. Bu ilerlemeler DDİ alanında

çalışanları motive etmiştir. Eş zamanlı ilerleyen yapay zekâ gelişmeleriyle beraber DDİ, yapay zekâ yöntemlerini kullanmaya başlamıştır. Dönemin önemli projelerinden birisiyse ARPA (Advanced Research Projects Agency) konuşma anlama projesidir [11]. Konuşma anlama projesinde, en başarılı sonuç Harpy sistemi tarafından alınmıştır. Harpy sisteminde 1.000 kelimelik bir sözlük yapısı kullanılmıştır. Sistem basit düzeyde kurulan konuşma cümlelerinin %90'lık bir bölümünü anlamayı başarmıştır [12].

1970 ve 1980 yılları arasında, hesaplamalı dilbilgisi teorisi çok önemli bir alan haline gelmiştir. Bu alan doğal dil üzerinde etkileri bulunan vurgu, tonlama, niyet gibi etkenlerin anlam üzerine etkilerini incelemektedir [13]. Bu dönemde Stanford Araştırma Enstitüsü (SRI) tarafından geliştirilen Çekirdek Dil Motoru ön plana çıkmaktadır. SRI Çekirdek Dil Motoru, anlamsal ve ilişkisel bir yaklaşım oluşturmuştur. SRI çekirdek dil motorunun geliştirilmesiyle birlikte, cümlenin öğeleri belirlenmiş, öğelerin sıralamaları tespit edilmiş ve kelimeler anlamsal olarak sınıflandırılmıştır [14].

1980' den makine öğrenmesi yönteminin gelişmesine kadar olan dönemde, DDİ gelişiminde ortaya atılan temel metodların çoğunluğu, teorik uygulamalardan pratiğe dönmeye başlamıştır. Farklı dillerde doğal dil çalışmaları yapılmıştır [15]. 2000'li yıllardan sonra makine öğrenmesinin alt kolu olan derin öğrenme yaygınlaşmaya başlamıştır. Derin öğrenme, birçok alan için yenilikçi çözümler getirmiştir. DDİ süreçlerinde derin öğrenme metodları etkili olarak kullanılmaktadır.

2.1 Doğal dil işlemenin uygulama alanları

DDİ uygulamalarını, gündelik hayatımızda sıklıkla kullanılmaktadır. Çevrimiçi bankacılık işlemlerindeki sesli yanıt sistemleri, metin düzenleme araçları, arama motorları gibi örnekler verilebilir. Büyük firmalar da DDİ konusuna büyük yatırımlar yapmaktadır. Google Assist, Siri, Alexa gibi uygulamalar günümüzde oldukça popülerdir.

Metin sınıflandırma konusu DDİ'nin önemli problemlerinden biridir. Özellikle günümüzde etiketlenilmemiş metinlerde kullanımı çok fazladır. Nigam ve arkadaşlarının yaptığı çalışmada, Makine Öğrenmesi tekniklerinden faydalanılarak metin sınıflandırma yapılmıştır. Etiketli metinlerle eğitilen sistem Sade Bayes sınıflandırıcılarıyla kategorilere ayrılmıştır [16].

Bilgisayar kullanıcılarının çok sık rastladığı konulardan biri olan yazım denetimi, DDİ konularından biridir. Yazım denetimiyle ilgili olarak yaygın birçok metin düzenleyici program içeriğinde yazım denetimine yer vermektedir. WhiteLaw ve arkadaşları, yaptıkları çalışmada dil bağımsız otomatik bir yazım düzeltme uygulaması üzerine çalışmışlardır. Çalışma, web sitelerindeki yazım kurallarını temel olarak düzeltme ve hata tespiti yapmaktadır [17].

Sesli konuşma DDİ'nin önemli bir giriş değeridir. Gündelik kullanımda olan Google Assist, Siri gibi uygulamalarda sıkça rastlanmaktadır. Bu sebeple konuşma tanıma konusu üzerine çok fazla araştırma yapılmaktadır. Xiong ve arkadaşlarının geliştirmiş oldukları Microsoft Etkileşimli Konuşma Tanıma Sistemi buna örnek

gösterilebilir. Yapılan sistem CNN (Convolutional Neural Network) ve BLSTM (Bidirectional Long Short-Term Memory) modelleri kullanarak oluşturulmuştur [18]. Karşılıklı yapılan bir konuşmanın tanımlanması, konuşma tanımanın zor kısımlarından biri olarak görülmektedir [19].

Karakter tanıma, DDİ giriş değerlerinden bir tanesidir. Karakter tanıma, el yazısı tanıma, resim üzerindeki yazıları okuma gibi alanlarda kullanılmaktadır. Qadri ve Asif'in araç plakaları üzerine yapmış oldukları optik karakter tanıma çalışmaları bu alana örnek gösterilebilir [20].

Makine çevirisi DDİ'nin ilk problemlerinden biridir. Yıllar içinde kendini çok fazla geliştirmiş DDİ alanlarından biridir. Makine çevirisine örnek olarak, Google translate, yandex translate gibi çeviri uygulamalarını gösterebiliriz. Han ve arkadaşlarının yaptığı simültane çeviri uygulaması, makine çevirisi üzerine farklı bir uygulama olarak gösterilebilir. Amaç olarak yabancı bir dilde yapılan konuşma, video görüntüsü, ses kaydı gibi girdi değerlerini anlık olarak hedef dile çevirmeyi amaçlamıştır [21].

İnsan bilgisayar etkileşiminde, önemli bir konu soru cevaplama değildir. DDİ'nin ana konularından biri olan soru cevaplama konusunda IBM Watson sistemi geliştirilmiştir. IBM Watson, geniş konularda soruları cevaplayabilmektedir. IBM Watson, Jeopardy adlı bilgi yarışmasına katılmıştır. IBM Watson, bu yarışmanın daha önceki kazananlarıyla mücadele etmiş ve yarışmayı rekor kırarak kazanmıştır [22].

2.2 Doğal dil işlemede ön işlemler

DDİ için kullanılacak olan giriş değerleri belirli ön işlemlerden geçirilmektedir. Bu işlemler, dilin işlenmesi için gerekli standartları sağlamak için önemlidir. Ön işlemede kullanılan yöntemlere bu bölümde kısaca yer verilmiştir. Ön işleme yöntemleri, ana probleme göre değişkenlik gösterebilmektedir.

Yazım kontrolü (Spelling Corrector), özellikle giriş değerinin doğruluğunu sağlaması için önemlidir. Giriş değerinde yapılan yazım yanlışları, dilbilgisi sıralamaları ve anlamsal çıkarımlarda hatalara sebep olabilir [23]. Yazım düzenleme, hatasız metin tabanlı iletişim ve metin işleme için çok önemli bir ön işleme adımındır [24].

Doğal dil olarak sisteme dahil edilen giriş değerinin işlenebilmesi için parçalara bölünmesi gerekmektedir [25]. Bu bölme işlemi iki aşamalı düşünülebilir. Birinci aşama, Cümle Bölme (Sentence Splitter), giriş değeri birden fazla cümleden oluşan metinleri cümlelere bölme işleminin yapılmasıdır [26]. İkinci aşama, Bölütleme (Tokenization), giriş değeri olan cümlelerde kullanılan tüm parçaları ayrıştırarak sembolleştirir [27]. Bölütleme işleminden sonra cümle içerisinde kullanılan kelime, bağlaç ve noktalama işaretleri ayrı birer parça olarak kullanılabilir.

Konuşma parçası etiketleme (Part of Speech Tagging), cümledeki sözcüklerin sıfat, zamir, fiil vb. kullanımlarının etiketlenmesi işlemidir [28]. Bu ön işlem özellikle metin oluşturma gibi problemlerdeki sözdizimi uygulamalarında kullanılmaktadır [29].

Kök Bulma (Word Stemming), kelimenin en temel haline getirilme işlemidir. Kök bulma metin özetleme, sınıflandırma ve kümeleme gibi problemlerin çözümünde

kullanılan bir ön işlemdir. Kök hale getirilmiş bir kelime, ekli bir kelimedenden daha geniş bir anlamı kapsamaktadır [30]. Geniş bir anlamı kapsayan kök, kendinden türeyen bütün alanları kapsamaktadır. Bu sebeple, genelden özele bir yönlendirme yapmaya imkân sağlamaktadır. Genelden özele bir yaklaşım, soru cevap ve metin oluşturma problemlerinde çözüm kolaylığı sağlamaktadır.

İsimlendirilmiş varlık tanıma (Named Entity Recognition), cümle içinde kullanılan sözcüklerin önceden belirlenmiş sınıflara göre etiketlenmesidir [31]. Bu etiketler her çalışmada farklılıklar gösterir, ancak genellikle özel isim, bitki, nesne vb. şekillerde karşımıza gelmektedir [32].

Matematiksel temsil, doğal dil üzerinde aritmetik işlemleri gerçekleştirebilmemiz için gerekli bir ön işlemdir. Matematiksel temsilde kelimelerin vektörlere dönüşümü gerçekleştirilir [33]. Vektör dönüşümü yapılırken çeşitli alt yöntemlerden faydalanılmaktadır. Bu alt yöntemlerden gereksiz kelimeler (Stop Words), anlamsal etkisi olmayan cümle parçalarının ön işleme aşamasında çıkarılması işlemidir [34]. Matematiksel temsil için kullanılan vektörlerin boyutlarının aşırı büyümesini önleyerek performansa olumlu etkileri olmaktadır. Doğal dil, anlamsal yönden ele alındığında tek kelime üzerinden işlem yapmak yanıltıcı olmaktadır. Doğal dilde kullanılan isim tamlamaları, sıfat tamlamaları gibi kelime gruplarına da dikkat etmek gerekmektedir. Bu tip durumlarda n-gram algoritması ve sözlükler kullanılabilir [35].

2.3 Doğal dil işlemede kullanılan kütüphaneler ve araçlar

Yaklaşık yarım asırlık DDİ çalışmalarının sonucu olarak, günümüzde kullanıma açılmış birçok yazılım kütüphanesi mevcuttur. Bu bölümde yaygın olarak DDİ sürecinde kullanılan kütüphaneler incelenmiştir. Tablo 1'de yaygın kullanılan DDİ kütüphanelerinin karşılaştırmaları gösterilmektedir.

DDİ için geliştirilen kütüphanelerin çoğunda ön eğitilmiş dil modelleri desteklenmektedir. Google tarafından yayınlanan BERT (Bidirectional Encoder Representations From Transformers) adı verilen dil modeli paydaşlarından farklılık göstermektedir. Bu dil modeli kelimeleri tek tek işlemek yerine bütün olarak ele alarak ilişkisel bir işleme yöntemi geliştirmiştir. BERT kullanılarak yapılmış çalışmalarda başarı oranlarının yüksek olduğu görülmektedir.

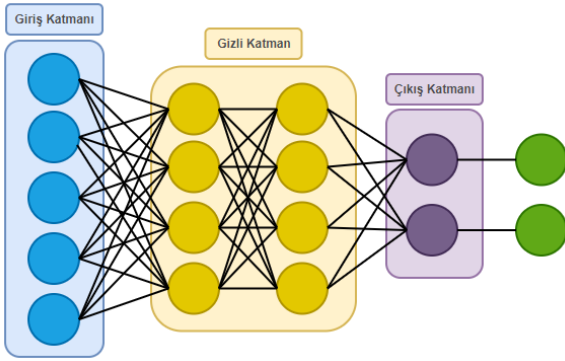
Doğal dil ifadelerinin tekrarlı yapıları göz önüne alındığında sık kullanılan yöntemlerden birisi de RNN (Recurrent Neural Network)'dir. RNN yinelemeli bir yapay sinir ağı modelidir. RNN, diğer sinir ağı modellerinden farklı olarak giriş çıkış değerleri arasındaki ilişkidir. RNN giriş çıkış değerleri arasındaki ilişkiler, tekrarlı yapıda olan doğal dil ifadeleri için performans artışı sağlamaktadır.

Geri beslemeli bir sinir ağı olan RNN, giriş ifadelerinin uzun olduğu durumlarda performans olarak yeterli gelmemektedir. Bu sebeple, LSTM (Long Short Term Memory) sinir ağı modeli geliştirilmiştir.

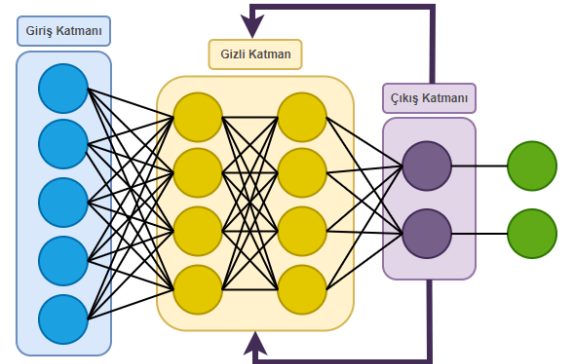
Tablo 1. Yaygın kullanılan DDİ kütüphaneleri ve işlem destekleri

	NLTK	SpaCy	Sparc NLP	OpenNLP	Stanford Core NLP	Zemberek	İTÜ NLP
Bölütme	x	x	x	x	x	x	x
Konuşma Parçası Etiketleme	x	x	x	x	x	x	x
İsimlendirilmiş Varlık Tanıma	x	x	x	x	x	x	x
Yazım Kontrolü			x				x
Kök Bulma	x	x	x	x	x	x	x
Ön Eğitilmiş Modeller	x	x	x	x	x		x
Programlama Dili	Python	Python	Java,Python	Java	Java	Java	Java
Türkçe Desteği						x	x

Şekil 2’de sinir ağı modeli ve Şekil 3’te yinelemeli sinir ağı modeli gösterilmektedir [36].



Şekil 2. Sinir ağı modeli




Şekil 3. Yinelemeli sinir ağı modeli.

Genel olarak LSTM, RNN modeline çok yakın bir modeldir. LSTM modelinde, hangi bilgileri gerekli hangi bilgileri diğer hücrelere taşıyacağına karar veren kapılar mevcuttur. Bu kapılar uzun olan doğal dil ifadelerinin işlenmesine yardımcı olmaktadır. LSTM, DDİ işlemlerinde çok sık kullanılan bir modeldir. Şekil 4’te RNN ve LSTM modelleri gösterilmiştir [37].

Doğal dil ifadelerinin işlenmesinde, derin öğrenmeden yararlanılacak durumlar için hazırlanmış kütüphaneler mevcuttur. Bunların en çok kullanılanlarına ise; AllenNLP,

Fairseq, ParlAI ve Pattern kütüphaneleri örnek gösterilebilir [38-41].



Şekil 4. RNN ve LSTM çalışma modeli.

3 Metinden SQL sorgusu tahmini üzerine yapılan çalışmalar

Metinden SQL sorgusu tahmini üzerine yapılan çalışmalar, veri tabanında bulunan tablolar ve bu tabloların aralarındaki ilişkilerine göre ele alınmaktadır. Öncü çalışmalar tek tablo üzerinde sorgu tahmini yaparken, gelişmiş çalışmalar ilişkisel tablolar üzerinde sorgu tahmini yapmaktadır. Çalışmaların performansları ve eğitimleri için gereklilik duyulan bir araç da veri setleridir. Çalışmamızın bu bölümünde Metinden SQL tahmini konusunda kullanılan veri setleri ve uygulanan modeller açıklanmıştır.

3.1 Veri setleri

WikiSQL, doğal dil ifadesiyle yapılmış sorgulara karşılık gelen SQL cümlelerini içinde barındıran bir veri setidir. Bu veri setinde 24.241 tablo üzerinde gerçekleştirilen 80.654 etiketlenmiş sorgu bulunmaktadır. WikiSQL veri seti, SQL sorgusu tahmini için pekiştirmeli öğrenme yöntemini kullanan bir sistem için tasarlanmıştır [42].

Spider, büyük ölçekli ve karmaşık veri tabanı sistemleri üzerinde çalışan bir veri setidir. Veri seti bünyesinde 200 veri tabanı bulundurmaktadır. Bu veri tabanları ilişkili tablolar içermektedir. Veri seti 10.181 soru ve 5.693 adet benzersiz SQL sorgusuna sahiptir. Spider veri setinin bir diğer avantajı tek bir alana odaklanmamış olmasıdır. Veri setinde sinema, alışveriş, spor vb. 138 farklı alanda veri

tabanı mevcuttur. Spider veri seti özellikle anlamsal ayrıştırma yöntemiyle geliştirilmiş tahmin sistemlerinde, kıyaslama veri seti olarak kullanılmaktadır [4].

Sparc, Yale Üniversitesi öğrencisi olan 14 kişilik bir ekip tarafından geliştirilmiştir. Bu ekip aynı zamanda spider veri setinin de geliştiricileridir. Spider veri seti temel alınarak oluşturulmuştur. Veri setinde odaklanılan nokta bir doğal dil sorusuna karşılık gelen birden fazla SQL sorgusu olmasıdır. Yapılan güncel veri setinde 12 binin üzerinde soru ve SQL sorgusu karşılığı bulunmaktadır [43].

ATIS (Air Travel Information System), hava yolları alanında oluşturulmuş bir veri setidir. Üzerinde 25 adet ilişkisel tablo vardır. Doğal dil sorularına karşılık gelen sorgular, kısıtlı bir tablo havuzu ve tek bir alanda olması veri setinin tercih edilmemesine neden olmaktadır [44].

Veri setlerini farklı özellikleriyle de ele alabiliriz. Bunları veri kaynağı, soruların anlamsal kategoriye göre bağlamları, sorgu türleri ve kaynaklar arası ilişkiler olarak kısaca değerlendirebiliriz. Açıklamasını yaptığımız veri setlerinin özet özellikleri Tablo 2’de gösterilmiştir.

Tablo 2. Veri setlerinin özet özellikleri

Veri Seti	Bağlam	Kaynak	Sorgu	İlişkisel Yapı
ATIS	Var	Veri Tabanı	SQL	Hayır
WikiSQL	Yok	Tablo	SQL	Evet
Spider	Yok	Veri Tabanı	SQL	Evet
SparC	Var	Veri Tabanı	SQL	Evet

3.2 Uygulamalar

TypeSQL, şema tabanlı bir SQL sorgusu tahmin uygulamasıdır. Şema tabanlı sorgu tahminlerinde, SQL cümlelerinin sıralaması bir tablo olarak düşünülür. Tabloda uygun boşluklar doğal dil ifadesi olan giriş değerleri işlenerek doldurulur. Ön işlem olarak isimlendirilmiş varlık tanıma kullanılmaktadır. İsimlendirilmiş varlık tanımda, SQL’in fonksiyon ve anahtar kelimeleri sınıf olarak ele alınmıştır. Bu ön işlem aracılığıyla tabloda fonksiyon ve anahtar kelimeler doldurulmaya çalışılmaktadır. TypeSQL’de veri seti olarak WikiSQL kullanılmıştır [45].

RatSQL, ilişkisel veri tabanları üzerine çalışan bir uygulamadır. Çalışma, temeline ilişkili tabloların anahtar alanlarını koymaktadır. Büyük ve karmaşık veri tabanlarında, anahtar alanlar tablo sayısının azaltılması alt tablo seçiminin doğruluğunu arttırmaktadır. Sorgu tahmini, anlamsal ayrıştırma kullanılarak ağaç yapısıyla oluşturulan hiyerarşik bir model üzerinde gerçekleştirilmektedir. Sistem testleri WikiSQL ve Spider veri setleri üzerinde gerçekleştirilmiştir [46].

EditSQL, karmaşık veri tabanları üzerinde SQL sorgusu tahmini yapmaktadır. Uygulamada anlamsal ayrıştırma kullanılmıştır. Anlamsal ayrıştırma modeli, 3 adet kodlama katmanından, 3 adet kod çözücü katmanından oluşmaktadır. Kodlama katmanları doğal dil ifadesinden, veri tabanı tablo ve alanlarının çıkarımını yapmaktadır. Kod çözücü

katmanları ise kodlama katmanından aldıkları değerler ile SQL sorgusu tahmini yapmaktadır. Kod çözücü katmanlarında derin öğrenme modeli olan LSTM kullanılmaktadır. Çalışmada karmaşık yapıların örneklenmesinden dolayı Sparc veri seti kullanılmıştır [47].

IncSQL, uygulaması SQL sorgusu tahmini için anlamsal ayrıştırmayı kullanmıştır. INCSQL, bi-LSTM kullanılan kodlayıcı katmanı ve LSTM kullanılan kod çözücü katmanından oluşmaktadır. Kodlayıcı katmanı birbiriyle etkileşimli 3 adet bi-LSTM ağını üzerinde barındırmaktadır. Kodlayıcı katmanında doğal dil ifadeleri SQL sorgusu için gerekli olacak özelliklerin çıkarımını yapmaktadır. Özellik çıkarımı işleminden sonra kod çözme katmanında SQL sorgusu tahmini yapılmaktadır. ATIS veri tabanının kısıtlı olmasından dolayı sistemde WikiSQL veri seti kullanılmıştır [48].

SmBoP, RatSQL sisteminin geliştirilmiş halidir. SmBoP, anlamsal ayrıştırmada kullanılan kod çözme adımı iyileştirmeler yapmaktadır. RatSQL’de kod çözümüne kadar anlamsal yaklaşımlar dikkate alınmazken, SmBoP kodlama ve kod çözmenin her aşamasında anlamsal bir sonuç çıkarmaktadır. SmBoP, veri seti olarak Spider kullanılmaktadır [5].

4 Metinden SQL sorgusu tahmini

Çalışmamızın bu bölümünde DDİ uygulamalarına örnek olması için, metinden SQL sorgusu üzerine bir uygulama geliştirilmiş ve geliştirme süreci incelenmiştir. Uygulamamızda DDİ yöntemlerinden makine çevirisi konusu üzerinde durulmuştur. Uygulamanın temel akışı Şekil 5’te gösterilmektedir.



Şekil 5. Uygulama Akışı

4.1 Kullanılan araçlar

Uygulamamızda, metinden SQL tahmini için SmBoP yöntemi kullanılmıştır. SmBoP, küçük ölçekli tablolara sahip veri tabanlarında performansı yüksek bir yöntemdir. Uygulamamızda çoklu dil desteği sağlanmıştır.

Google BERT geliştirildikten sonra makine çevirilerinin doğruluk oranları ciddi yükselişler gözlemlenmektedir. Çalışmamızda Google API’sinden faydalanarak makine çevirisi işlemleri gerçekleştirilmiştir.

4.2 Doğal dil ifadesi giriş işlemi

Metinden SQL tahmininde, model eğitimi için kullanılan veri setleri İngilizce olarak hazırlanmıştır. Sorgu tahmini

sisteminde giriş dili olarak İngilizce kullanılması gerekmektedir. Bu durumda oluşan giriş dili problemi, DDİ konusu olan makine çevirisiyle aşılmıştır. Giriş ifadelerinin ön işleme için NLTK kütüphanesinden yararlanılmıştır.

4.3 Makine çeviri işlemi

SQL sorgusu tahmin sistemimizde, dil bağımsız bir yapı oluşturmak için makine çevirisinden faydalanılmıştır. Makine çevirisinde, sektörün en önde gelen sistemlerinden olan Google Translate kullanılmıştır. Sisteme entegre edilen Google Translate API'si ile sistem 33 adet doğal dilde giriş işlemi yapılması sağlanmıştır.


4.4 Metinden SQL sorgusu tahmini

Ön işlemde geçirilen doğal dil ifadesi, derin öğrenme modeli olan LSTM için hazırlanmaktadır. Bu aşamada doğal dil ifadesinin matematiksel temsili yapılmıştır. Bu matematiksel temsil işlemi için AllenNLP kütüphanesinden yararlanılmıştır.

Uygulamada anlamsal ayrıştırma (semantic parsing) kullanılmıştır. Anlamsal ayrıştırma, son dönemlerde metin oluşturma, soru cevap gibi DDİ'nin ana konularda standart bir çözüm yolu haline gelmiştir [49]. Anlamsal ayrıştırma, giriş ifadesinin kodlanarak çıkış ifadesindeki karşılığının tespiti işlemi olarak özetlenebilir [50]. Uygulamamızda anlamsal ayrıştırma yöntemiyle, doğal dil ifadesine karşılık gelen SQL sorgusu tespit edilmiştir. Farklı kullanım türleri olan anlamsal ayrıştırmanın uygulamamızdaki aşamaları Şekil 6'da gösterilmiştir.

Sonuç ifadesinin elde edilmesinden bir önceki adım, SQL dil bilgisi yapısındaki sıralamaların düzenlenmesidir. Bu aşamada ağaç yapılarından faydalanılmıştır.

SQL dil bilgisi kuralları, kendi içerisinde hiyerarşik bir yapı barındırmaktadır. Karmaşık sorgularda, bu hiyerarşik yapı kendi içinde tekrarlanmaktadır. Kod çözme aşamasından elde edilen alan, tablo eşleşmeleriyle bu ağaç yapısında ilgili yerler doldurularak SQL sorgusu elde edilmektedir. Şekil 7'de ağaç yapısı gösterilmiştir.



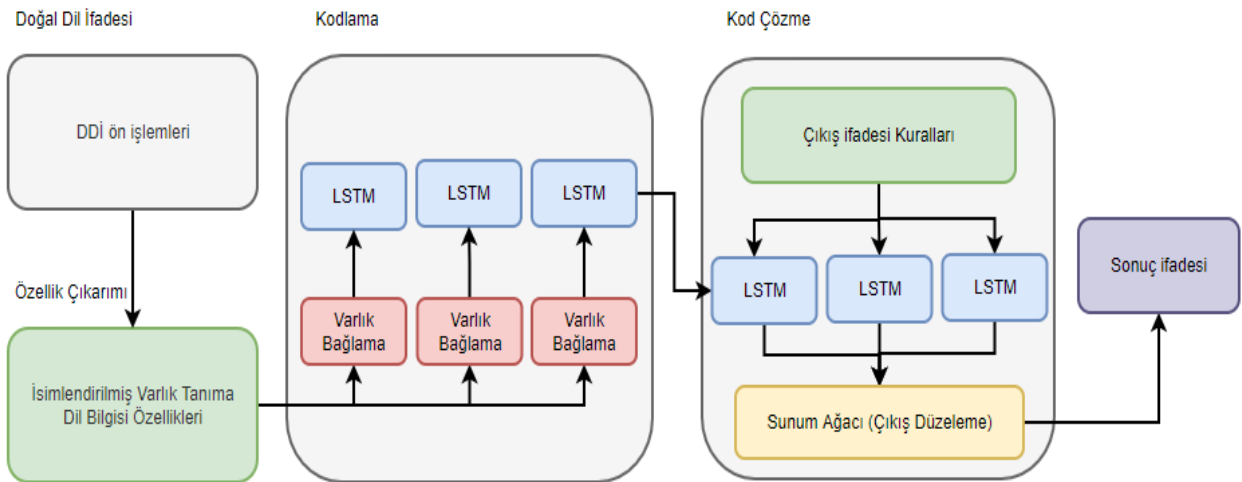
Şekil 7. SQL sorgusu için düzenlenmiş ağaç yapısı

4.5 Deneysel sonuçlar

Uygulamadaki deney sonuçları 3 aşamalı olarak değerlendirilmiştir. Birinci aşama olan makine çevirisi aşamasında, Türkçe-İngilizce çeviri sonuçları değerlendirilmiştir. İkinci aşama, İngilizce-SQL çevirisinin sonuçları değerlendirilmiştir. Üçüncü aşama ise uygulamanın tamamının sonuçları değerlendirilmiştir. Tablo 3'te spider veri setinde bulunan veri tabanlarına yönelik yapılan sorguların Türkçeden İngilizceye başarıları gösterilmiştir.

Tablo 3. Türkçeden İngilizceye çeviri sonuçları

Veri Tabanı	Sorgu Sayısı	Doğru Sayısı
Cinema	6	5
Academic	6	5
Restaurants	6	4
Soccer_1	6	5
Singer	6	6
Tvshow	6	5
Toplam	36	30



Şekil 6. Anlamsal ayrıştırma aşamaları

Makine çevirisi üzerinde 36 adet doğal dil ifadesi kullanılmıştır. Bu ifadelerin, 30 tanesine doğru çeviri elde edilmiştir. Hatalı olan ifadeler incelendiğinde ise iki doğal dilin dilbilgisi yapılarındaki uyumsuzluk ortaya çıkmaktadır. Türkçe olarak girilen 'çizgi film' ifadesinin, İngilizce karşılığı olarak 'cartoon' ifadesi beklenmektedir. Ancak 'çizgi film' ifadesini cümle içerisinde uygulamaya giriş değeri olarak verdiğimizde, sonuç ifade 'line movie' olmaktadır. Bu hata üzerine deneylerimizi genişleterek farklı cümleler içinde aynı ifadeyi kullandığımızda çevirinin başarılı olduğu gözlemlenmiştir.

İngilizce'den Türkçe'ye çeviri testlerinde %83.3 başarı oranına ulaşılmıştır. Başarısız olan çeviriler, özellikle Google BERT ve LSTM gibi modellerde kelimeler arası ilişkilerin istatistiksel oranlarına göre davranış sergilemesidir. Türkçeden İngilizceye çeviride kullanılan örnek cümleler **Tablo 4**'te gösterilmiştir.

Tablo 4. Türkçeden İngilizceye çeviri örnekleri

Türkçe	İngilizce
Hangi filmin bileti en ucuz?	Which movie ticket is the cheapest?
Hangi yayın en çok atfı almıştır?	Which publication is most cited?
Londra'da olan restoranları listele.	List the restaurants in London.
Hangi oyuncular sağ ayağını kullanıyor?	Which players use their right foot?
En çok para kazanan şarkıcı kim?	Who is the most money-winning singer?
En eski çizgi filmi getir.	Bring the oldest line movie.

İngilizce ifadelerin SQL sorgularına çevrilmesi üzerine yapılan deneyler, test veri tabanları üzerinde gerçekleştirilmiştir. Deneylerde, toplam 29 tabloya sahip 6 farklı veri tabanı kullanılmıştır. Veri tabanlarında tutulan veriler farklı konulardan oluşmaktadır. Veri tabanlarının konuları akademik, sinema, restoranlar, futbolcular, şarkıcılar ve televizyon şovlarıdır. **Tablo 5**'te İngilizce'den SQL sorgusuna yapılan dönüşüm sonuçları gösterilmektedir.

Tablo 5. İngilizceden SQL sorgusuna dönüşüm sonuçları

Veri Tabanı	Sorgu Sayısı	Doğru Sayısı
Cinema	6	5
Academic	6	4
Restaurants	6	4
Soccer_1	6	5
Singer	6	5
Tvshow	6	4
Toplam	36	27

Uygulamaya test amaçlı 36 adet İngilizce doğal dil ifadesi girilmiştir. Bu 36 ifadenin, yarısında karmaşık yarısında ise basit SQL sorguları beklenmektedir. Uygulama 10 adet yanlış SQL sorgusu ifade etmiştir. 9 adet yanlış SQL sorgusunun, 6 tanesi karmaşık yapıya sahipken 3 tanesi basit SQL sorgusudur. İngilizce'den SQL sorgusu dönüşümünde %75 başarı oranına ulaşılmıştır.

Deney sorguları spider veri seti üzerindeki veri tabanlarında gerçekleştirilmiştir. Yapılan deneylerde kullanılan veri tabanları incelendiğinde, veri tabanı mimarisi ve alan tanımlamalarının belirgin olması doğruluk oranını arttırdığı gözlemlenmiştir. Bu sebeple spider veri seti dışında kalan özel veri tabanlarında, tanımlamaların ve ilişkilerin belirgin olarak tasarlanması çalışmanın başarısını arttıracaktır. İngilizcen SQL sorgusu çevirisinde kullanılan örnek cümleler **Tablo 6**'da gösterilmiştir.

Tablo 6. İngilizceden SQL sorgusu çevirisi örnekleri

İngilizce	SQL sorgusu
Which movie ticket is the cheapest?	SELECT film.title FROM schedule JOIN film ON schedule.film_id = film.film_id ORDER BY schedule.price ASC LIMIT 1
Which publication is most cited?	SELECT publication.title FROM publication GROUP BY publication.pid ORDER BY COUNT(*) DESC LIMIT 1
List the restaurants in London.	SELECT restaurant.name FROM location JOIN geographic ON location.restaurant_id = geographic.city_name JOIN restaurant ON geographic.city_name = restaurant.city_name WHERE location.city_name = 'London'
Which players use their right foot?	SELECT DISTINCT player.player_name FROM player_attributes WHERE player_attributes.preferred_foot = 'right'
Who is the most money-winning singer?	SELECT singer.name FROM singer ORDER BY singer.net_worth_millions DESC LIMIT 1
Bring the oldest cartoon.	SELECT cartoon.title FROM cartoon ORDER BY cartoon.title ASC LIMIT 1

Uygulamanın tamamını kapsayan testlerimiz Türkçe doğal dil ifadesinden SQL sorgusu tahmini üzerine yapılmıştır. Yapılan testlerde 36 adet Türkçe ifadeden 25 adet doğru SQL sorgusu elde edilmiştir. **Tablo 7**'te uygulama geneli test sonuçları gösterilmektedir.

Tablo 7. Uygulama geneli test sonuçları

Veri Tabanı	Sorgu Sayısı	Doğru Sayısı
Cinema	6	5
Academic	6	4
Restaurants	6	4
Soccer_1	6	4
Singer	6	5
Tvshow	6	3
Toplam	36	25

Uygulama geneli yapılan test sonuçlarında %69.4 başarı oranına ulaşılmıştır.

5 Sonuçlar

Çalışmamız, DDİ'nin temel kavramları üzerine odaklanmıştır. DDİ'nin temel problemleri, çözüm yolları ve kullanım alanları hakkında genel literatür araştırması yapılmıştır. İnsan bilgisayar etkileşimi konusunun en önemli alanlarından biri olan DDİ, yapay zekanın birçok alanıyla yakından ilişkilidir.

Geliştirilen uygulamanın iki kısmı vardır. Bunlardan birinci aşama, çoklu dil desteğini sağlayabilmek için makine çevirisi uygulanan kısımdır. İkinci aşamaysa, SQL sorgusu tahmini kısımdır.

Birinci aşama olan makine çevirisinde, uygulama 33 adet dili desteklemektedir. Makine çevirisinde, uzun yıllardır süren çalışmalar ön eğitilmiş dil paketlerinin yaygın ve çeşitliliğini sağlamıştır. Ön eğitilmiş dil paketleri, doğal dillerin hem anlamsal hem dil bilgisi yapılarını üzerlerinde barındırmaktadır. Bu sebeple makine çevirisinin başarı oranları üst seviyelere ulaşmıştır. Uygulamanın genelinde kullanılan veri tabanlarına yönelik olan doğal dilde yapılan sorgu ifadeleri üzerinde yapılan test çalışmasında, makine çevirisi için doğruluk oranı %83.3 olarak tespit edilmiştir.

İkinci aşama olan doğal dil ifadesinde sorgu tahmini kısmında, anlamsal ayrıştırma uygulanmıştır. Doğal dil ifadesinin anlamsal ve dil bilimsel yapısının uygulamaya eklenmesi için Google BERT' ten yararlanılmıştır. Google BERT literatür çalışmalarında geleneksel dil modellerine göre daha başarılı sonuçlar vermiştir. Doğal dil ifadelerinin tekrarlı yapıları ve kelimeler arası ilişkilerin daha iyi işlenebilmesi için tekrarlı sinir ağı yapısı olan LSTM' den faydalanılmıştır. Yapılan testlerde SQL sorgusu tahmininde başarı oranı %75 olarak tespit edilmiştir. Uygulamanın tamamını kapsayan sorgularda ise başarı oranı %69.4 olarak tespit edilmiştir.

Metinden SQL sorgusu tahmini üzerine yapılan literatürdeki diğer çalışmalar İngilizce olarak yapılmıştır. Bu çalışmada, geliştirdiğimiz model ise çoklu dil desteğine imkân sağlamaktadır. Çoklu dil desteği, metinden SQL sorgusu tahmini üzerine yapılan çalışmalara farklılık kazandırmıştır.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %6

Kaynaklar

- [1] E. Adalı, Doğal dil işleme. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 5 (2), 2012.
- [2] R. C. Moore, Practical natural-language processing by computer. SRI International Menlo Park CA Artificial Intelligence Center, 1981.
- [3] Y. Yu, X. Si, C. Hu, and J. Zhang, A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures, Neural Computation, 31 (7), 1235–1270, 2019. https://doi.org/10.1162/neco_a_0_1199.
- [4] T. Yu et al., Spider: A Large-Scale Human-Labeled Dataset for Complex and Cross-Domain Semantic Parsing and Text-to-SQL Task. arXiv preprint arXiv:1809.08887, 2018.
- [5] O. Rubin and J. Berant, SmBoP: Semi-autoregressive Bottom-up Semantic Parsing arXiv preprint arXiv:2010.12412, 2020.
- [6] Spider: Yale Semantic Parsing and Text-to-SQL Challenge. <https://yale-lily.github.io/spider> (accessed May 11, 2022).
- [7] J. F. Allen, Natural Language Processing, Encyclopedia of Computer Science. John Wiley and Sons Ltd., Londra, 2003.
- [8] B. John and Z. Michael, Natural Language Generation. Oxford University Press, Oxford, 2012.
- [9] T. Alan M, Computing machinery and intelligence, in Parsing the turing test. Springer, Dordrecht, 2009.
- [10] M. A. Chéragai, Theoretical overview of machine translation. International Conference on Web and Information Technologies, pp. 160-169, Sidi Bel-Abbes, Algeria, 2012.
- [11] D. H. Klatt, Review of the ARPA speech understanding Project. The Journal of the Acoustical Society of America, 62 (6), 1345-1366, 1977.
- [12] M. Benzeghiba et al., Automatic speech recognition and speech variability: A review. Speech communication, 49(10-11), 763-786, 2007. <https://doi.org/10.1016/j.specom.2007.02.006>.
- [13] K. Frank, Gradience in grammar: Experimental and computational aspects of degrees of grammaticality. Ph.D. Thesis, Rutgers University, New Jersey, USA, 2000.
- [14] C. David, Lexical acquisition in the core language engine. Fourth Conference of the European Chapter of the Association for Computational Linguistics, 1989.
- [15] J. Karen Sparc, Natural language processing: a historical review. Linguistica Computazionale, Springer, Dordrecht, 1994.
- [16] K. Nigam, M. Andrew, T. Sebastian, and M. Tom, Learning to classify text from labeled and unlabeled documents. Proceedings of the Fifteenth National/Tenth Conference on Artificial Intelligence/Innovative Applications of Artificial Intelligence, pp. 792-799, 1998.

- [17] W. Casey, H. Ben, C. Grace Y, and E. Gerard, Using the web for language independent spellchecking and autocorrection. Conference on Empirical Methods in Natural Language Processing, pp. 890-899, Singapore, 2009.
- [18] W. Xiong, L. Wu, F. Alleva, J. Droppo, X. Huang, and A. Stolcke, The microsoft 2017 conversational speech recognition system. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 5934-5938, 2018. <https://doi.org/10.1109/ICASSP.2018.8461870>.
- [19] W. Xiong et al., Toward human parity in conversational speech recognition. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 25(12), 2410-2423, 2017. <https://doi.org/10.1109/TASLP.2017.2756440>.
- [20] M. T. Qadri and M. Asif, Automatic number plate recognition system for vehicle identification using optical character recognition, in 2009 International Conference on Education Technology and Computer, pp. 335-338, 2009. <https://doi.org/10.1109/ICETC.2009.54>.
- [21] H. Han et al., Faster Re-translation Using Non-Autoregressive Model For Simultaneous Neural Machine Translation. arXiv preprint arXiv:2012.14681, 2020.
- [22] G. Alfio, B. Or, P. Siddharth, and M. Kathlees, Semantic technologies in IBM Watson. Fourth Workshop on Teaching NLP and CL, pp. 85-92, Sofia, Bulgaria, 2013.
- [23] I. Aduriz, M. Urkia, I. Alegria, X. Artola, N. Ezeiza, and K. Sarasola, A spelling corrector for Basque based on morphology. Literary and Linguistic Computing, 12 (1), 31-38, 1997. <https://doi.org/10.1093/lilc/12.1.31>.
- [24] D. Simla, Bulanık mantık ve yapay sinir ağları ile Türkçe yazım denetleyicisi. Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2005.
- [25] T. Katrin, W. Joachim, and H. Udo, Sentence and token splitting based on conditional random fields. 10th Conference of the Pacific Association for Computational Linguistics, p.57, Melbourne, Australia, 2007.
- [26] R. Ricardo, O. Hugo Gonçalves, and G. Paulo, NLPPort: A Pipeline for Portuguese NLP. 7th Symposium on Languages, Applications and Technologies, Portugal, 2018.
- [27] P. McNamee and J. Mayfield, Character n-gram tokenization for European language text retrieval. Information retrieval, 7(1), 73-97, 2004. <https://doi.org/10.1023/B:INRT.0000009441.78971.be>.
- [28] A. Voutilainen, Part-of-speech tagging. The Oxford handbook of computational linguistics, Oxford, 2003.
- [29] T. Kristina, K. Dan, M. Christopher D, and S. Yoram, Feature-rich part-of-speech tagging with a cyclic dependency network. Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics, pp. 252-259, 2003.
- [30] J. Anjali Ganesh, A comparative study of stemming algorithms. International Journal of Computer Applications in Technology, 2 (6), 1930-1938, 2011.
- [31] Z. A. Güven and M. O. Unalır, Önerilen varlık ismi tanıma yöntemi ile soru cevaplamada bert modelinin iyileştirilmesi. 6th International Conference on Computer Science and Engineering, 2021.
- [32] B. Mohit, Theory and Applications of Natural Language Processing. Springer, 2014. https://doi.org/10.1007/978-3-642-45358-8_7.
- [33] P.-H. Chen, Essential Elements of Natural Language Processing: What the Radiologist Should Know. Academic Radiology, 27 (1), 6-12, 2020. <https://doi.org/10.1016/j.acra.2019.08.010>.
- [34] J. K. and J. R., Stop-Word Removal Algorithm and its Implementation for Sanskrit Language. International Journal of Computer Applications, 150 (2), 15-17, 2016. <https://doi.org/10.5120/ijca2016911462>.
- [35] E. S. Akgül, C. Ertano, and B. Diri, Sentiment analysis with Twitter. Pamukkale University Journal of Engineering Sciences, 22 (2), 106-110, 2016. <https://doi.org/10.5505/pajes.2015.37268>.
- [36] M. Abdel-Nasser and K. Mahmoud, Accurate photovoltaic power forecasting models using deep LSTM-RNN. Neural Computing and Applications, 31 (7), 2727-2740, 2019. <https://doi.org/10.1007/s00521-017-3225-z>.
- [37] A. Sherstinsky, Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. Physica D: Nonlinear Phenomena, 404, 132306, 2020. <https://doi.org/10.1016/j.physd.2019.132306>.
- [38] A. C. Mendes and C. Antunes, Pattern mining with natural language processing: An exploratory approach. International Workshop on Machine Learning and Data Mining in Pattern Recognition, Berlin, Germany, 2009. https://doi.org/10.1007/978-3-642-03070-3_20.
- [39] A. H. Miller et al., ParlAI: A Dialog Research Software Platform. arXiv preprint arXiv:1705.06476, 2017.
- [40] M. Ott et al., fairseq: A Fast, Extensible Toolkit for Sequence Modeling. arXiv preprint arXiv:1904.01038, 2019.
- [41] M. Gardner et al., AllenNLP: A Deep Semantic Natural Language Processing Platform. arXiv preprint arXiv:1803.07640, 2018.
- [42] V. Zhong, C. Xiong, and R. Socher, Seq2SQL: Generating Structured Queries from Natural Language using Reinforcement Learning. arXiv preprint arXiv:1709.00103, 2017.
- [43] Y. Cai and X. Wan, IGSQ: Database Schema Interaction Graph Based Neural Model for Context-Dependent Text-to-SQL Generation. arXiv preprint arXiv:2011.05744, 2020.
- [44] G. Tur, D. Hakkani-Tur, and L. Heck, What is left to be understood in ATIS?. 2010 IEEE Spoken Language Technology Workshop, pp. 19-24, 2010. <https://doi.org/10.1109/SLT.2010.5700816>.

- [45] T. Yu, Z. Li, Z. Zhang, R. Zhang, and D. Radev, TypeSQL: Knowledge-based Type-Aware Neural Text-to-SQL Generation. arXiv preprint arXiv:1804.09769, 2018.
- [46] B. Wang, R. Shin, X. Liu, O. Polozov, and M. Richardson, RAT-SQL: Relation-Aware Schema Encoding and Linking for Text-to-SQL Parsers. arXiv preprint arXiv:1911.04942, 2019.
- [47] A. T. Nguyen, M. H. Dao, and D. Q. Nguyen, A Pilot Study of Text-to-SQL Semantic Parsing for Vietnamese. arXiv preprint arXiv:2010.01891, 2020.
- [48] T. Shi, K. Tatwawadi, K. Chakrabarti, Y. Mao, O. Polozov, and W. Chen, IncSQL: Training Incremental Text-to-SQL Parsers with Non-Deterministic Oracles. arXiv preprint arXiv:1809.05054, 2018.
- [49] J. M. Zelle and R. J. Mooney, Learning to parse database queries using inductive logic programming. Proceedings of the national conference on artificial intelligence, pp. 1050-1055, Oregon, USA, 1996.
- [50] A. Aghajanyan et al., Conversational Semantic Parsing. arXiv preprint arXiv:2009.13655, 2020.

