

Türkçe Dil Modellerinin Performans Karşılaştırması

Performance Comparison of Turkish Language Models

Eren Dogan*, M. Egemen Uzun*, Atahan Uz*

H. Emre Seyrek*, Ahmed Zeer*, Ezgi Sevi*

H. Toprak Kesgin*, M. Kaan Yuce*, M. Fatih Amasyalı*

*Cosmos AI Research Group, Department of Computer Engineering, Yıldız Technical University, Istanbul, Turkey

Özetçe —Dil modellerinin neredeyse her türlü görevi yerine getirmede sağladıkları gelişmeler, sadece araştırmacıların değil toplumun da ilgisi çekmiş ve artık birer ürün haline gelmelerini sağlamıştır. Ticari olarak çok başarılı dil modelleri bulunmaktadır. Ancak kullanıcılar maliyet, veri gizliliği ya da regülasyonlar sebebiyle açık kaynaklı dil modellerini tercih edebilmektedir. Ancak sayıları her geçen gün artan bu modellerin Türkçe için performansları konusunda kapsamlı bir karşılaştırma bulunmamaktadır. Bu çalışmada literatürdeki bu boşluğun kapatılması hedeflenmiştir. Seçilen 7 dil modelinin bağlamda öğrenme ve soru cevaplama kabiliyetlerine göre karşılaştırması yapılmıştır. Bu kapsamda bağlamda öğrenme ve soru cevaplama için Türkçe veri kümeleri hazırlanmış, hem otomatik hem de insan değerlendirmesi yapılmıştır. Elde edilen sonuçlar soru cevaplama için çok dilli modellerin Türkçeye uyarlanmasında talimat veri kümeleriyle eğitimden önce ön eğitime devam etmenin daha başarılı olduğunu ve bağlamda öğrenme kabiliyeti ile soru cevaplama kabiliyetinin çok ilişkili olmadığını göstermektedir.

Anahtar Kelimeler—yapay zeka, doğal dil işleme, büyük dil modelleri, üretici modeller, bağlamda öğrenme, insan değerlendirmesi

Abstract—The developments that language models have provided in fulfilling almost all kinds of tasks have attracted the attention of not only researchers but also the society and have enabled them to become products. There are commercially successful language models available. However, users may prefer open-source language models due to cost, data privacy, or regulations. Yet, despite the increasing number of these models, there is no comprehensive comparison of their performance for Turkish. This study aims to fill this gap in the literature. A comparison is made among seven selected language models based on their contextual learning and question-answering abilities. Turkish datasets for contextual learning and question-answering were prepared, and both automatic and human evaluations were conducted. The results show that for question-answering, continuing pretraining before fine-tuning with instructional datasets is more successful in adapting multilingual models to Turkish and that in-context learning performances do not much related to question-answering performances.

Keywords—artificial intelligence, natural language processing, large language models, generative models, in context learning, human evaluation

I. GİRİŞ

Günümüzde Türkçe dahil birçok dil için oldukça başarılı ticari dil modelleri bulunmaktadır. Ancak, bu dil modellerini

etkin bir şekilde kullanmak çeşitli sebeplerden (maliyet, güvenlik vb.) dolayı tercih edilmemektedir. Bu nedenle, akademide ve sektördeki birçok araştırmacı, açık kaynaklı dil modellerine yönelmektedir. Ancak, herkesin erişimine açık olan bu dil modellerinin Türkçe'deki yeterliliklerine yönelik yeterli bir analiz bulunmamaktadır. Bu çalışmada, literatürdeki boşluğun kapatılması hedeflenmiştir. Bu kapsamda seçilen açık kaynaklı Türkçe dil modellerinin farklı karşılaştırma ölçütlerine göre performansları incelenmiştir.

Dil modellerinin karşılaştırılması üzerine farklı kaynaklar bulunmaktadır. Bağlamda öğrenme dil modellerini karşılaştırmak için sıklıkla kullanılan bir ölçüttür [1]. Buna ek olarak, soru cevaplama da her türlü metinsel görevi ortak bir formatta ele almaya imkan verdiği ve kullanıcı etkileşimine çok uygun olduğu için karşılaştırmalarda kullanılan bir diğer ölçüttür. Bu ölçütleri kullanan LLM Leaderboard [1] ve Chat Arena [2] gibi kıyaslama platformları araştırmacıları yönlendirmede çok etkili olmaktadır. Ancak Türkçe diline özgü değildir. Benzer şekilde çok fazla sayıda kabiliyeti test etmek için hazırlanmış BigBench [3], Big Glue [4], AGI Eval [5] gibi değerlendirme veri setleri de Türkçe odaklı değildir.

Bu eksiklerin azaltılması için yapılan araştırmada Türkçe dil modellerinin karşılaştırılması adına üç temel çıktı sunulmaktadır: 1) Bağlamda öğrenme veri kümeleri, 2) Soru cevaplama veri kümeleri, 3) Modellerin hem otomatik hem de oylama usulü karşılaştırma sonuçları. Bu çıktılarla, henüz başlangıç aşamalarında olan açık kaynaklı Türkçe dil modeli araştırmalarına katkı sağlanması hedeflenmiştir.

II. KARŞILAŞTIRILAN DİL MODELLERİ

A. Karşılaştırılan Dil Modellerinin Seçimi

Çalışmada performans karşılaştırılmasına tabi tutulan modeller, araştırmanın belirtilen amacına yönelik olması için belirli ölçütlere göre seçilmiştir. Seçilen modeller 51.0 GB sistem RAM'i, 15.0 GB T4 GPU ve 166.8 GB Disk kapasiteli donanımlara sahip bir sanal makinede test edilmiştir. Yalnızca belirtilen donanımlara sahip sanal makinenin çalıştırabildiği modeller kıyaslamaya dahil edilmiştir.

Seçilecek modellerde GPT tabanlı bir yapıda, büyüklük olarak 1,5 ve 7,5 milyar parametre aralığında ve açık kaynaklı olma şartı aranmıştır. Karşılaştırılacak bütün modeller Türkçe performanslarına göre kıyaslanacakları için ilk olarak Türkçe metin anlama ve çıktı üretebilme kabiliyetleri olan

modeller değerlendirmeye alınmıştır. Değerlendirmeye alınan modeller arasında, kullanıcı tarafından verilen talimatı yerine getirebilme, verilen soruya karşı bir cevap çıktısı üretme, eksik verilen cümlelerin devamını getirebilme gibi çoklu metin dil kabiliyetlerini yerine getirebilme şartına bakılmıştır. Bu görevlerde bozuk ve anlamsız çıktı üreterek bariz şekilde başarısız ve yetersiz olarak ayırt edilebilen modeller karşılaştırmaya dahil edilmemiştir. Bu kapsamda, Türkçe Bert modelleri [6], [7] ve TURNA [8] GPT tabanlı olmadıkları ve MASK tabanlı oldukları için; Main ise sürümünün açık kaynaklı olmaması nedeniyle bu karşılaştırmaya dahil edilmemiştir.

B. Seçilen Modeller

Performansları karşılaştırılan dil modelleri Tablo I'de verilmiştir.

TABLO I: KARŞILAŞTIRILAN DİL MODELLERİ

Model	Parametre Sayısı	Yayınlanma Tarihi	TR Fine-Tuned	Base Model	Açıklamalar
Mistral-7B-Instruct-v0.2-turkish [9]	7.24 Milyar	05/01/2024	✓	Mistral-7B-Instruct-v0.2	SFT Training ve Freeze yöntemleri kullanılarak alpaca-gpt4-tr talimatlarına göre finetune edilmiş bir versiyondur.
Llama-2-7b-chat-turkish-instructions [10]	6.74 Milyar	11/08/2023	✓	Llama-2-7B-chat	Türkçe talimatlar veri kümesinde finetune edilmiş bir versiyondur.
Trendyol-LLM-7b-chat-v0.1 [11]	6.84 Milyar	07/02/2024	✓	Trendyol-LLM-7b-base-v0.1	Base modeli temel alınarak 180 binlik Türkçe talimat veri seti üzerinde LoRa kullanılarak finetune edilmiş bir versiyondur.
Trendyol-LLM-7b-base-v0.1 [12]	6.84 Milyar	07/02/2024	✓	Llama-2-7B	Optimize edilmiş bir transformer mimarisi kullanan autoregressive dil modelidir. LoRa kullanılarak 10 milyar token üzerinde finetune edilmiştir.
mGPT [13]	1.3 Milyar	15/04/2022	—	—	Wikipedia ve C4 Corpus kullanılarak 25 dil ailesinden dilbilimsel olarak çeşitli 61 dilde pretrain edilmiş bir multilingual dil modelidir.
Deepseek-llm-7b-chat [14]	7.0 Milyar	29/11/2023	—	deepseek-llm-7b-base	Base model kullanılarak Talimat veri kümesinde finetune edilmiş multilingual bir dil modelidir.
open chat_3.5 [15]	7.0 Milyar	20/09/2023	—	Mistral-7B-v0.1	Pekiştirmeli öğrenmeden ilham alan C-RLFT tekniği ile finetune edilmiş , multilingual bir dil modelidir.

III. KARŞILAŞTIRMA VERİ KÜMELERİ

Soru cevaplama çok farklı görevler için ortak bir format sağlamaktadır. Bu sebeple dil modellerinin karşılaştırılmasında en yaygın olarak kullanılan yöntemlerdendir. Seçilmiş talimat

veri kümesi, çok farklı alanlardan soru içermektedir. Bu şekilde, her bir modelin bu sorulardaki cevaplarını hem otomatik değerlendirmelerle hem de oylama yolu ile karşılaştırılmaktadır. Model, aynı veri kümesiyle eğitilmediği sürece çıktılarının cevaplarla örtüşmesi her zaman söz konusu değildir. Soru-cevap kümesinden örnekler Tablo II'de verilmiştir.

TABLO II: SORU-CEVAP KÜMESİ ÖRNEĞİ

Soru	Cevap
Bir elma ağacında 10 elma var. Bir rüzgar esiyor ve ağaçtan 2 elma düşüyor. Kaç elma ağaçta kalmış olur?	Ağaçta 8 elma kalmış olur.
Saç bakımı için üç basit yöntemi açıklayın.	Düzenli kesim, doğal ürünlerle nazik temizlik, derin nemlendirme tedavileri.
Sosyal ilişkileri geliştirmek ve yeni arkadaşlar edinmek için stratejiler sun.	İlgili alanlarına uygun etkinliklere katıl, güler yüzlü iletişim kur, aktif dinleme pratiği yap, sosyal medyayı etkili kullan ve inisiyatif al.

Bağlamda öğrenme veri kümelerinde modelin eğitilmeden sadece örnekler göstererek cevaplama kabiliyeti ölçülmüştür. Veri kümesinden örnekler Tablo III'de verilmiştir.

TABLO III: BAĞLAMDA ÖĞRENME VERİ KÜMESİ ÖRNEĞİ

Soru	Seçenekler	Cevap
Güneş sistemindeki hangi gezegen en uzun yıla sahiptir?	"Güneş'e en yakın gezegen.", "En uzun güne sahip gezegen.", "En çok uydusu olan gezegen.", "Güneş'e en uzak gezegen."	Güneş'e en uzak gezegen.
Singapur'da sakız çiğnemek yasa dışı mı?	"Hayır, Singapur'da yalnızca sakız ithal etmek ve satmak yasa dışıdır.", "Evet, Singapur'da sakız çiğnemek yasaktır."	Hayır, Singapur'da yalnızca sakız ithal etmek ve satmak yasa dışıdır.

Bağlamda öğrenme performanslarının ölçümünde ARC [16], HellaSwag [17], TruthfulQA [18], MMLU [19] veri setleri yaygın olarak kullanılmaktadır. Bu veri setleri ile ilgili bilgiler Tablo IV'de verilmiştir. Veri setlerinin İngilizce olmasından dolayı her veri kümesinden örnekleme yapıp Türkçeye çevrilmiştir.

Soru cevaplama veri kümesi ise açık kaynak olan bir Türkçe veri kümesinden [20] düzgün ve anlamlı 1000 tane örnek ayıklanarak oluşturulmuştur. Bu veri kümesinin modellerin eğitiminde kullanılmış olma ihtimali yüzünden ayrıca, 300 tane yeni soru-cevap ikilisi hazırlanıp bir veri kümesi daha oluşturulmuştur. Oluşturulan veri kümeleri, araştırmacılarla paylaşılacaktır.

TABLO IV: BAĞLAMDA ÖĞRENME VERİ KÜMELERİ

İsmi/Türü	Test	Train	Validation	dev	Shot NO.	Seçmeli
ARC	400	812	—	—	25	Evet
HellaSwag	—	891	641	—	10	Hayır
TruthfulQA	—	—	635	—	0	Evet
MMLU	662	—	—	30	5	Evet

IV. KARŞILAŞTIRMA ÖLÇÜTLERİ

Bu çalışmada, Türkçe dil modellerinin performanslarının kapsamlı bir şekilde değerlendirilmesi amacıyla üç farklı ölçüt kullanılmıştır. Bu ölçütler, modellerin Türkçe dilini ne kadar iyi anladıklarını ve dili kullanma becerilerini ölçmek

için özenle seçilmiştir. Aşağıda, her bir ölçütün detayları ve değerlendirme sürecindeki rolü açıklanmaktadır.

A. Bağlamda Öğrenme

Bağlamda öğrenme kısmında, dil modellerinin bağlamı nasıl anladıklarını ve bu bağlam içerisinde ne kadar doğru ve uygun cevap verebildikleri değerlendirilmiştir. Bağlamda öğrenme, modellere sınırlı sayıda örnek sunarak yeni görevlerde nasıl performans gösterdiklerini görmeyi amaçlar. Bu yaklaşım, modellerin az örnekle hızlı bir şekilde öğrenme ve adaptasyon yeteneklerini ortaya koymaktadır.

ARC, HellaSwag ve MMLU veri kümeleri üzerinde yapılan testlerde, modellerin normalize edilmiş doğruluk oranları (acc_norm) ölçülmüştür. TruthfulQA veri kümesinde ise yapılan testte, modellerin ürettiği cevapların doğruluğunu ve güvenilirliğini ölçmek için Çoklu Doğruluk (mc2) metriği kullanılmıştır. Bu metrikler, modellerin verilen sorulara ne kadar doğru ve bağlamla uyumlu cevaplar verebildiklerini değerlendirmek için kullanılmıştır.

Bu dört veri kümesi üzerinde yapılan performans testleri, Türkçe dil modellerinin bağlamda öğrenme yeteneklerinin kapsamlı bir şekilde değerlendirilmesine olanak tanımıştır. Bu testler sayesinde, her bir modelin farklı türdeki sorulara ve senaryolara nasıl tepki verdiği, hangi alanlarda güçlü olduğu ve hangi alanlarda geliştirilmesi gerektiği gibi konularda değerli bilgiler elde edilmiştir.

B. Soru Cevaplamada Otomatik Değerlendirme

Bu bölümde, Türkçe dil modellerinin soru cevaplama becerilerinin otomatik değerlendirme yöntemleriyle nasıl ölçüldüğü açıklanmaktadır. Araştırmada, [20] veri setinden alınan 1000 örnekle ve yeni hazırladığımız 300 örnekle oluşturulan iki veri seti kullanılmıştır. Bu kümeler, soru ve cevap çiftlerinden oluşmaktadır. Bu veri kümelerindeki sorular kullanılarak modellerin bu sorulara karşılık ürettiği cevaplar alınmıştır. Elde edilen model cevapları, belirlenen referans cevaplar ile karşılaştırılmış ve analiz edilmiştir. Analizde, ROUGE-1, ROUGE-2 ve ROUGE-L metrikleri kullanılarak, modellerin ürettikleri cevapların referans cevaplarla ne derece uyumlu olduğu ölçülmüştür. Bu değerlendirme yöntemleri sayesinde, modellerin cevaplarının doğruluğu ve dilbilgisi açısından kalitesi detaylı bir şekilde incelenmiştir.

C. Soru Cevaplama İnsan Değerlendirmesi

Bu çalışmanın önemli bir aşaması, Türkçe dil modellerinin ürettiği cevapların insan değerlendirmesine tabi tutulmasıdır. Bu süreçte, dil modellerinin performansını objektif bir şekilde karşılaştırmak adına bir oylama arayüzü oluşturulmuştur.

Oylama süreci, dokuz farklı hakem tarafından gerçekleştirilmiştir. Her bir hakem, soru-cevap veri kümelerinden rastgele seçilen bir soru ile karşılaşmış ve bu soruya iki farklı model tarafından üretilen cevapları görmüştür. Hakemler, her iki cevabı da sorunun bağlamına, doğruluğuna ve mantıksal tutarlılığına göre değerlendirmişlerdir. Değerlendirme sırasında, hakemlerin objektif kalabilmesi için modellerin isimleri gizlenmiştir, böylece değerlendirmeler tamamen modelin ürettiği cevabın kalitesine dayanmıştır.

Bu insan değerlendirmesi süreci, modellerin sadece doğruluk oranlarına veya otomatik metriklerle ölçülen performanslarına göre değil, aynı zamanda insanların dil kullanımındaki nüansları ve incelikleri nasıl algıladıklarına dayanarak modellerin değerlendirilmesine olanak tanımıştır. Şekil 1’de oluşturulan oylama arayüzü verilmiştir.

Şekil 1: Oylama Uygulaması

Yapılan oylama sonucunda her model için **Elo** ve **WinPct** ismi verilen iki metrik ölçülmüştür.

Elo: Her modelin elo’su 1000 değerinden başlamıştır. Modeller arasındaki eşleşmelerde bir model tercih edilince ilgili model elo kazanmış, diğer model ise elo kaybetmiştir. Elo’su yüksek bir rakibe karşı kazanmak çok elo kazandırırken elo’su düşük bir rakibe karşı kazanmak az elo kazandırmaktadır.

WinPct: Her bir modelin, “daha iyi” veya “İkisi de iyi” olarak seçildiği maç sayısının modelin yaptığı toplam maç sayısına oranıdır. Modelin sorulara verdiği yanıtların yüzde kaç oranında tatmin edici bulunduğunu ölçer.

V. DENEYSEL SONUÇLAR

Yapılan oylama ve ölçümler sonucunda her bir model için Tablo V’deki sonuçlar elde edilmiştir. Mevcut veri kümesinden seçilen 1000 soru ve cevap üzerindeki ölçümler **X**, hakemler tarafından hazırlanan 300 soru ile yapılan oylama ve ölçümler **Y** ile gösterilmiştir. Tablo III’deki sonuçlara göre, oylama sonuçları ve Rouge metrikleri birbiriyle yüksek korelasyon göstermiştir. Bağlamda öğrenme veri kümelerindeki performanslarla soru cevaplama performansları arasında korelasyon genel olarak düşüktür.


Oylama 9 adet hakem tarafından yapılmış, toplam 1200 oy kullanılmıştır. Hakemlerin oy tercihlerinin korelasyonunun ortalaması 0.957, standart sapması 0.03’dir. Buradan soruların kişilerin subjektif yorumuna bağlı olmayan sorulardan hazırlandığı ve oylamanın doğru bir metodolojiyle gerçekleştirildiği görülmektedir. Metriklerin birbiriyle korelasyon matrisi Şekil 2’de verilmiştir.

Tüm ölçüm sonuçlarına bakılarak modellerin başarı sıralaması şu şekilde belirlenmiştir: 1-trendyol-chat, 2-openchat 3.5, 3-deepseek-chat, 4-trendyol-base, 5-llama, 6-mistral, 7-mGPT.

Bunun modellerin her koşuldaki performansını gösteren nihai bir sıralama olmadığına dikkat edilmelidir.

TABLE V: MODELLERİN DEĞERLENDİRİLMESİ

Metrik	mGPT	mistral	llama	trendyol base	deepseek chat	openchat	trendyol chat
X-Elo	592	836	893	983	1108	1129	1456
Y-Elo	612	753	933	924	1122	1304	1349
X-WinPct	4.13	24.57	22.29	39.66	53.12	73.07	90.48
Y-WinPct	3.65	11.73	19.19	23.89	49.56	77.62	75.41
arc_challenge	0.257	0.320	0.265	0.352	0.287	0.327	0.345
hellaswag	0.299	0.407	0.361	0.418	0.405	0.399	0.410
truthful_qa	0.411	0.532	0.449	0.444	0.475	0.475	0.489
mmu	0.256	0.476	0.334	0.323	0.391	0.471	0.380
Rouge-1_X	4.991	6.674	11.86	9.274	12.29	16.96	27.70
Rouge-2_X	0.224	0.622	2.317	1.646	2.430	5.093	9.890
Rouge-L_X	4.762	6.242	11.33	8.834	11.79	16.31	26.21
Rouge-1_Y	3.228	4.479	12.09	7.118	11.70	16.72	20.55
Rouge-2_Y	0.135	0.601	3.243	1.547	2.811	6.371	7.681
Rouge-L_Y	2.986	4.208	11.66	6.788	11.21	16.11	19.43



Şekil 2: Metriklerin Korelasyon Matrisi

VI. SONUÇ VE GELECEK ÇALIŞMALAR

Belirlenen modeller farklı ölçme yöntemleri ile değerlendirildiğinde birkaç bulguya rastlanmaktadır. Modellere ait rouge metriklerinin ve hakem oylamasının sonuçlarının birbiri ile oldukça benzer olduğu görülmektedir. Bu durum modellerin performansları arasındaki farkların büyük olmasından kaynaklanabileceği gibi aynı zamanda birbirine yakın performans gösteren modeller için de farklılık gösterebilir.

Birçok dili destekleyen modellerin Türkçe için talimat veri kümeleriyle eğitim işlemi öncesinde standart bir ön eğitime devam edilmesi gerektiği görülmektedir. Trendyol-chat modelinin, Trendyol-base modeline karşı oylama ve rouge skorlarına üstünlük sağlamasından bu sonuca varılmıştır. Openchat modelinde Türkçe özelinde bir eğitim yapılmamış, buna karşın model Trendyol-chat ile yakın sonuçlar elde etmiştir.

Türkçe talimat veri kümesinden derlenmiş 1000 girdili veri setinde Trendyol-chat diğer modellere karşı büyük bir başarı göstermiştir. Buna rağmen tarafımızca oluşturulan 300 örnekli veri setinde bu farkını koruyamadığı görülmektedir. Bunun sebebinin, bu veri setinin modelin fine-tune eğitiminde kullanılmış olması olarak düşünülmektedir.

Bağlamda öğrenme değerlendirmesinde Trendyol-base ve Trendyol-chat'in benzer başarı sergilemesi, bağlamda öğrenme

üzerinde talimat veri kümesiyle eğitim işleminin soru cevaplamadaki kadar etkili olmayabileceğini göstermektedir. Aynı zamanda deneylerde modellerin bağlamda öğrenme performansları ile soru cevaplama performanslarının ilişkili olmadığı ortaya konulmuştur.

Bu çalışmanın amacı, açık kaynaklı modeller arasında bir durum değerlendirmesi yapmak olup model seçiminde en büyük kriter olarak Türkçe cevap verme özelliği gözetilmiştir. Unutulmamalıdır ki sözü geçen mimarilerin farklı veri kümeleri ile eğitimleri sonucunda bu çalışmadan farklı sonuçlara ulaşmak mümkündür. Daha objektif bir sonuca ulaşabilmek için gelecek çalışmalarda daha büyük veri setleri ile benzer modellerde karmaşık senaryolar için detaylı durum değerlendirmeleri hedeflenmektedir.

KAYNAKLAR

- [1] "Open llm leaderboard - a hugging face space by huggingfaceh4," 2024.
- [2] "Lmsys chatbot arena leaderboard - a hugging face space by lmsys," 2024.
- [3] A. Srivastava, A. Rastogi, A. Rao, A. A. M. Shoen, A. Abid, A. Fisch, A. R. Brown, A. Santoro, A. Gupta, A. Garriga-Alonso, *et al.*, "Beyond the imitation game: Quantifying and extrapolating the capabilities of language models," *arXiv preprint arXiv:2206.04615*, 2022.
- [4] A. Wang, A. Singh, J. Michael, F. Hill, O. Levy, and S. R. Bowman, "Glue: A multi-task benchmark and analysis platform for natural language understanding," *arXiv preprint arXiv:1804.07461*, 2018.
- [5] W. Zhong, R. Cui, Y. Guo, Y. Liang, S. Lu, Y. Wang, A. Saied, W. Chen, and N. Duan, "Agieval: A human-centric benchmark for evaluating foundation models," *arXiv preprint arXiv:2304.06364*, 2023.
- [6] "Github - stefan-it/turkish-bert: Turkish bert/distilbert, electra and convbert models," 2024.
- [7] H. T. Kesgin, M. K. Yuce, and M. F. Amasyali, "Developing and evaluating tiny to medium-sized turkish bert models," *arXiv preprint arXiv:2307.14134*, 2023.
- [8] G. Uludoğan, Z. Y. Balal, F. Akkurt, M. Türker, O. Güngör, and S. Üsküdarlı, "Turna: A turkish encoder-decoder language model for enhanced understanding and generation," *arXiv preprint arXiv:2401.14373*, 2024.
- [9] "malhajar/mistral-7b-instruct-v0.2-turkish · hugging face," 2024.
- [10] "mohammedbriman/llama-2-7b-chat-turkish-instructions · hugging face," 2024.
- [11] "Trendyol/trendyol-llm-7b-base-v0.1 · hugging face," 2024.
- [12] "Trendyol/trendyol-llm-7b-chat-v0.1 · hugging face," 2024.
- [13] O. Shliazhko, A. Fenogenova, M. Tikhonova, V. Mikhailov, A. Kozlova, and T. Shavrina, "mgpt: Few-shot learners go multilingual," *arXiv preprint arXiv:2204.07580*, 2022.
- [14] "deepseek-ai/deepseek-llm-7b-chat · hugging face," 2024.
- [15] G. Wang, S. Cheng, X. Zhan, X. Li, S. Song, and Y. Liu, "Openchat: Advancing open-source language models with mixed-quality data," *arXiv preprint arXiv:2309.11235*, 2023.
- [16] P. Clark, I. Cowhey, O. Etzioni, T. Khot, A. Sabharwal, C. Schoenick, and O. Tafjord, "Think you have solved question answering? try arc, the ai2 reasoning challenge," *arXiv preprint arXiv:1803.05457*, 2018.
- [17] R. Zellers, A. Holtzman, Y. Bisk, A. Farhadi, and Y. Choi, "Hellaswag: Can a machine really finish your sentence?," *arXiv preprint arXiv:1905.07830*, 2019.
- [18] S. Lin, J. Hilton, and O. Evans, "Truthfulqa: Measuring how models mimic human falsehoods," *arXiv preprint arXiv:2109.07958*, 2021.
- [19] D. Hendrycks, C. Burns, S. Basart, A. Zou, M. Mazeika, D. Song, and J. Steinhardt, "Measuring massive multitask language understanding," *arXiv preprint arXiv:2009.03300*, 2020.
- [20] "mervet/turkish_instructions · datasets at hugging face," 2024.