




Automated question generation and question answering from Turkish texts

Fatih Çağatay AKYÖN^{1,2,*}, Devrim ÇAVUŞOĞLU^{1,3}, Cemil CENGİZ¹

Sinan Onur ALTINUÇ^{1,2}, Alptekin TEMİZEL²

¹OBSS AI, Ankara, Turkey

²Graduate School of Informatics, METU, Ankara, Turkey

³Computer Engineering, METU, Ankara, Turkey

Received: 12.11.2021

Accepted/Published Online: 09.05.2022

Final Version: 22.07.2022

Abstract: While exam-style questions are a fundamental educational tool serving a variety of purposes, manual construction of questions is a complex process that requires training, experience and resources. Automatic question generation (QG) techniques can be utilized to satisfy the need for a continuous supply of new questions by streamlining their generation. However, compared to automatic question answering (QA), QG is a more challenging task. In this work, we fine-tune a multilingual T5 (mT5) transformer in a multitask setting for QA, QG and answer extraction tasks using Turkish QA datasets. To the best of our knowledge, this is the first academic work that performs automated text-to-text question generation from Turkish texts. Experimental evaluations show that the proposed multitask setting achieves state-of-the-art Turkish question answering and question generation performance on TQuADv1, TQuADv2 datasets and XQuAD Turkish split. The source code and the pretrained models are available at <https://github.com/obss/turkish-question-generation>.

Key words: Turkish, question answering, question generation, answer extraction, multitask, transformer

1. Introduction

Question generation (QG) is the task of generating questions from a given context and, optionally, some answers. The research on QG has been developing exponentially with the task getting more popular in education [1, 2], commercial applications such as chatbots and dialogue systems [3, 4] and healthcare [5].

Early works in QG were based mainly on human-designed sophisticated syntactic rules to transform a declarative sentence into the corresponding question. These tasks mainly relied on handcrafted feature extraction from documents. A method for generating multiple-choice tests from instructional documents (e.g., textbooks or encyclopedias) was proposed in [6]. In this work, domain-specific terms were extracted using the term frequency approach, and the sentences including the retrieved terms were transformed into questions using the parsed syntactic information of the sentence. In [7], the input text is first simplified with a set of transformations to produce multiple declarative sentences. Then, a declarative sentence is transformed into a set of possible questions by syntactic and lexical transformations. However, being based on rule-based transformations, these methods are not applicable to other languages and question styles. A preliminary work provides an implementation plan for rule-based question generation from Turkish texts using syntactic (constituent or dependency) parsing and semantic role labeling systems [8]. In the QG part, manually generated

*Correspondence: fatih.akyon@metu.edu.tr

templates and rules are used. However, the proposed method is not fully automated considering the manual selection of templates and its rule-based nature. Moreover, the paper does not provide sufficient technical details and no follow-up paper giving the details of the planned implementation is available.

Recently, many neural networks based techniques have been proposed for QG. An encoder-decoder architecture of an LSTM-based Seq2Seq model is adopted in [9]. Both the input sentence and the paragraph containing the sentence are encoded via separate bidirectional LSTMs [10] and then concatenated. This representation is then fed into the decoder, which is a left-to-right LSTM, to generate the question. The decoder learns to use the information in more relevant parts of the encoded input representation via an attention layer. Later models included target answer in the input to avoid questions that are too short and/or broadly targeted, such as “What is mentioned?”. Some models have achieved that by either treating the answer’s position as an extra input feature [11, 12] or by encoding the answer using a separate network [13, 14]. Moreover, position embeddings have been used to give more attention to the answer words closer to context words. Some utilized additional decoders to predict the question words (when, how, why, etc.) before generating the question [15]. LSTM-based Seq2seq models struggle to capture the paragraph-level context that is needed to generate high quality questions. Seq2Seq model was extended with answer tagging, maxout pointer mechanism and a gated self-attention encoder [12]. A multistage attention to link long document context with targeted answer is used in [16].

Transformer based models have been dominating the NLP research in tandem with QG research lately. These models are capable of capturing longer and comprehensive contexts more effectively than their predecessors, mainly LSTM-based Seq2Seq based models. Named entity recognition (NER) is used in [17], as a (preprocessing) task before the application of a transformer based model. In the work, they first extract a variety of named entities from the input text and then replace these entities with named entity tags for better generalization. Superior performances have been reported by applications of QG task that were proposed by those using a large transformer based language model (LM). A pretrained BERTurk for QG was adopted in [18] and three models were proposed using BERTurk for QG, sequential question generation with BERTurk using the previous decoded results, and finally highlighting the answer in the context which yielded a performance improvement. A pretrained GPT-2 for QG is used in [19] in a straightforward way by preparing inputs in a particular format. The model is evaluated in several ways such as context-copying, failures on constructing questions, robustness and answer-awareness.

An example question generation project using transformers in a specific framework is available¹ but its sentence tokenization pipeline is specific to English language, presents the results on an English dataset, emphasizes limited input types (highlight and prepend) and does not have a peer reviewed publication.

Moreover, there is a publicly shared work based on fine-tuning mT5-small model [20] on Turkish dataset for question generation task². However its sentence tokenization pipeline is not adapted to Turkish language, it is not clear whether the validation set is included in the training, does not present any evaluation results, emphasizes limited input types (only highlight) and does not have a peer reviewed publication.

In this work, in order to fully automate the question generation process from Turkish texts using a single model, we propose a multitask fine-tuning of mT5 model [20]. To the best of our knowledge, this is

¹question_generation (2020). Neural question generation using transformers [online]. Website https://github.com/patilsuraj/question_generation [accessed 04 07 2021].

²multitask-question-generation (2021). Turkish Multitask MT5 [online]. Website <https://github.com/ozcangundes/multitask-question-generation> [accessed 04 07 2021]

the first comprehensive academic work that performs automated text-to-text question generation from Turkish texts. The main contributions can be summarized as the adaptation of a sentence tokenization pipeline for the highlight input format and benchmarking of the mT5 model for Turkish question generating and answering on the TQuADv1, TQuADv2 and XQuAD datasets in multitask and single-task settings with different input formats (highlight/prepend/both).

The model we explored, mT5, is a variant of T5 [21], which is a flexible transformer model used in sequence-to-sequence NLP tasks. T5 is an encoder-decoder style language model whose architecture closely follows the original Transformer [22]. It is pretrained on “span-corruption” objective, a special type of masked language modeling. In this scheme, consecutive input token spans are replaced with a mask token and the model is asked to reconstruct the original tokens in the spans as training objective. During fine-tuning, various distinct NLP tasks such as classification and generation are formulated in common text-to-text format in multitask learning setting. The main difference of mT5 is that it was trained on mC4 dataset, comprising natural text in 101 languages collected from the public Common Crawl web scrape. Being trained on multiple tasks and multiple languages, it can readily be fine-tuned on QA, QG and answer extraction tasks in Turkish language after converting the datasets to the common text-to-text format. As shown in Figure (top), QA task uses context and question pair as input and answer as target, QG uses answer highlighted context as input and question as target, answer extraction uses sentence highlighted context as input and answer list with separator as target. This approach does not require an external answer extraction model or human effort to label the answers since the same model is used to extract the answers (corresponding to one of the potential questions) from the context as shown in Figure (bottom).




Figure. Multitask fine-tuning of the multilingual pretrained mT5 model (top). The same fine-tuned model is then used for both answer extraction and question generating task (bottom).

2. Proposed approach

To convey a fully automated question generation pipeline, we assume that answer may not be given in the generation phase, and thus we also train the model to find answer a (corresponding to one of the potential questions) which is a span in the given context c . The task is formulated as in Eq. 1 where q denotes the question targeting the answer a and c' is the context c with highlighted tokens for sentences containing answers.

$$P(q, a|c) = P(a|c') \cdot P(q|a, c) \quad (1)$$

Answer extraction task is formulated as $P(a|c')$ where *context* and *answer* pairs are used from $\{\textit{context}, \textit{question}, \textit{answer}\}$ triplets from SQuAD style dataset. Context c is first preprocessed to highlight the target answers, and the preprocessed context c' is used as an input and answers are used as in training.

Question generation task is formulated as $P(q|a, c)$ where $\{\textit{answer}, \textit{context}\}$ pairs are used as input and, in training, *question* for the given answer is used as the target. If an answer is provided with the context, the answer extraction step is skipped, otherwise answer extraction is done before question generation.

When providing the inputs to text-to-text transformer, different parts of the input c , a , q are separated by a separator. In both single-task and multitask QG setting, we apply three different input format styling: *prepend*, *highlight* and *both*. In *prepend* format, we prepend the base input text with a task specific prefix as in T5 [21]. For example, for QG task we prepend the base input format with “*generate question* : ” prefix. In *highlight* format, we wrap the answer text in the context with a special $\langle hl \rangle$ (*highlight*) token similar to [20]. The *both* input format contains both *prepend* and *highlight* input formats.

In the single-task setting, we modify each sample to train separate models for QA and QG tasks. In generation phase, QA task requires a context and a question and QG task requires a context and an answer as input. In the multitask setting, we train the model to perform answer extraction, question generation and question answering tasks simultaneously. For answer extraction task, we put highlight tokens at the start and end of the sentence that contains the answer to be extracted. For the question generation, the answer of the question to be generated is highlighted [20]. Moreover, we prepend “*question*”, “*context*”, “*generate question*”, “*extract answer*” tokens before each sample to help the model distinguish one task from other. In Figure, the input and target formats of the model during fine-tuning is presented.

In single-task setting, for QG generation task, the answer always needs to be provided along with the context, whereas in multitask setting the answer is not strictly required to be given.

We adopt the answer-aware question generation methodology [15], where the model requires both the context and answer to generate questions. Use of the same model for automatic answer extraction in the multitask setting eliminates the need for manual highlighting of the answer and enables end-to-end question generation from raw text.

Adapting the current schema to another language involves putting highlight tokens between sentences, however, this might not be straightforward due to the language dependent nature of the sentence tokenization part. We needed to carefully design a proper sentence tokenization by manually handling edge cases mostly caused by abbreviations to mark the end of a sentence correctly in a Turkish text. There are wide options for sentence tokenization approaches for English text; however, there is no directly available sentence tokenization tool for Turkish text. We adapted an open-source tool TrTokenizer package³ for a sentence tokenization step

³TrTokenizer (2020). Sentence and word tokenizers for the Turkish language [online]. <https://github.com/apdullahayik/TrTokenizer> [accessed 24 08 2021]

as the base tool and adapted it by enhancing the edge cases. These edge cases such as “Ar. Gör.”, “(d. 998 - ö. 1068)”, “Ömer b. Abdülazîz”, etc. are then handled by regular expression based operations. The adapted Turkish sentence tokenization based answer highlighting, together with extended edge cases, have been provided publicly in the project repository.

3. Experimental setup and results

We first fine-tune BERTurk [23] and mT5 models on TQuADv2 training split to have the base models. Then F1 and EM scores are calculated on TQuADv2 validation split and XQuAD Turkish split for experimental evaluation. All the experiments have been performed on Nvidia A100 GPU with 80 GB VRAM using Transformers Trainer [24] on Pytorch [25] backbone.

For the evaluation of QA task performance, widely accepted F1 and exact match (EM) scores [26] are calculated. Although there is no widely accepted automatic evaluation metric for measuring the QG performance [27], most of the previous works used the classical metrics such as BLEU [28], METEOR [29] and ROUGE [30]. METEOR applies stemming and synonym matching (in English). Hence, it has been excluded in our experiments as these processes are not applicable to Turkish. We reported BLEU-1, BLEU-2 and ROUGE-L metrics for evaluating the QG task performance.

3.1. Datasets

TQuAD⁴ (TQuADv1) is a Turkish QA dataset on Turkish & Islamic Science History that was published within the scope of Teknofest 2018 Artificial Intelligence competition. TQuADv2 dataset [31] extended the number of question-answer pairs along with the number of subjects by adding additional paragraphs and question-answer pairs to TQuADv1, i.e. $TQuADv1 \subset TQuADv2$. Both of these datasets have the same structure with SQuAD [26].

XQuAD [32] is a multilingual QA dataset in Arabic, Chinese, German, Greek, Hindi, Russian, Spanish, Thai, Turkish and Vietnamese languages. It consists of samples professionally translated from the SQuAD 1.1 validation set. The Turkish split of the XQuAD, namely XQuAD.tr, is used to evaluate the fine-tuned models, for brevity we denote it as XQuAD in the remainder of this paper.

The details of these datasets are provided in Table 1, training sets are used for training the models and hyperparameter tuning, validation set is used for performance evaluation only. Some examples are presented in Appendix A.

Table 1. Details for datasets used in the proposed work.

Name	Training set		Validation set	
	Paragraphs	QA-pairs	Paragraphs	QA-pairs
TQuADv1	2232	8308	275	892
TQuADv2	2400	14224	301	1330
XQuAD	-	-	240	1190

⁴turkish-nlp-qa-dataset (2019). Turkish NLP Q&A Dataset [online]. Website <https://github.com/TQuad/turkish-nlp-qa-dataset> [accessed 04.07.2021]

3.2. Hyperparameter tuning

We experimentally evaluated mT5 [20] against BERTurk [23] and, to have a fair comparison, we performed hyperparameter tuning. For both models, we used grid-search to select the best optimizer type (Adafactor, AdamW), initial learning rate ($1e-3$, $1e-4$, $1e-5$) and number of training epochs (1, 3, 5, 8, 10, 15, 20). BERTurk-base language model [23] has been fine-tuned for QA task on TQuADv2 training split, F1 and EM scores have been calculated on TQuADv2 validation split and XQuAD Turkish split. We selected the set of parameters which attain the overall best scores in all metrics: *AdamW* optimizer with a learning rate of $1e-4$ and number of epochs for BERTurk. Similarly, mT5-small language model [23] has been fine-tuned in a multitask setting on TQuADv2 training split. Then F1, EM scores for QA samples and BLEU, ROUGE scores for QG samples have been calculated on TQuADv2 validation split and XQuAD Turkish split. QA and QG results of the best performing combination can be seen in Tables 2 and 3. We selected the set of parameters which attain the overall best scores in all metrics: *AdamW* optimizer with a learning rate of $1e-3$ and 15 epochs. For the remainder of the experiments, these fine-tuned BERTurk and mT5 models with the determined set of parameters have been used.

Table 2. QA scores of the best performing hyperparameter combination for BERTurk and mT5-small using AdamW as optimizer.

Model	Num. Epochs	Initial lr	TQuADv2-val	TQuADv2-val	XQuAD	XQuAD
			F1	EM	F1	EM
BERTurk	3	$1e-4$	67.1	50.5	53.0	37.4
mT5-small	15	$1e-3$	64.8	49.3	48.2	31.1

Table 3. QG scores of the best performing hyperparameter combination for mT5-small: AdamW with initial learning rate of $1e-3$ and 15 epochs.

TQuADv2-val	TQuADv2-val	TQuADv2-val	XQuAD	XQuAD	XQuAD
BLEU-1	BLEU-2	ROUGE-L	BLEU-1	BLEU-2	ROUGE-L
39.3	32.8	45.6	21.3	14.0	28.5

3.3. Experimental evaluation

According to the TQuADv2 fine-tuning results in Table 4, the proposed mT5 settings outperform the BERTurk in QA task and multitask setting further increases the QA performance.

To evaluate the question generation performance of the proposed single and multitask settings, we fine-tuned mT5 model on TQuADv2 training split in both settings. Three different input formats explained in Section 2 are used and BLEU-1, ROUGE-L scores are calculated on TQuADv2 validation split and XQuAD Turkish split. According to TQuADv2 fine-tuning results in Table 5, *highlight* format increases the BLEU-1 scores by up to 1.6 points and ROUGE-L scores by up to 1.7 points compared to *prepend* format in single-task setting. Moreover, *highlight* format increases the BLEU-1 scores by up to 1.2 and ROUGE-L scores by up to 0.8 points compared to *prepend* format in multitask setting. Moreover, combining both techniques increases BLEU-1 scores by up to 2.9 points and ROUGE-L scores by up to 3.8 points compared to *prepend* format.

Additional experiments have been conducted to evaluate the overall performance of the larger mT5 variants, mT5-base and mT5-large in comparison to BERTurk. QA and QG evaluation results for fine-tuned TQuADv1 and TQuADv2 are provided in Tables 6 and 7 respectively. According to the QA results in Tables 6, all mT5 variants outperform BERTurk for smaller dataset sizes, BERTurk may outperform mT5-small for larger dataset sizes. This indicates that mT5 models are always preferable when the data is scarce whereas regular single-task training may also be used in place of the mT5-small variant when sufficient data is available. A comparative performance evaluation of mT5 variants shows that increasing the model size improves the performance significantly for both datasets, especially when switching from mT5-small to mT5-base. While using an even bigger model, mT5-large, improves the performance, it has a relatively more modest effect. Nevertheless, this trend of obtaining better scores by increasing the model capacity is consistent with the previous works on other transformer based models. Comparison of the results for different versions of the TQuAD datasets in Table 6 and 7 show that, although the TQuADv1 validation scores are higher than TQuADv2 validation scores, the models trained on the TQuADv2 train set are able to generalize better as indicated by the XQuAD Turkish split results. This can be attributed to the larger size and better quality of the TQuADv2 dataset.

Table 4. BERTurk-base and mT5-base QA evaluation results for TQuADv2 fine-tuning.

Setting	TQuADv2-val	TQuADv2-val	XQuAD	XQuAD
	F1	EM	F1	EM
BERTurk	67.1	50.5	53.0	37.4
Single-task mT5	71.6	55.1	60.7	40.2
Multitask mT5	71.5	56.2	61.1	43.3

Table 5. mT5-base QG evaluation results for single-task (ST) and multitask (MT) for TQuADv2 fine-tuning.

Setting	TQuADv2-val	TQuADv2-val	XQuAD	XQuAD
	BLEU-1	ROUGE-L	BLEU-1	ROUGE-L
MT-Both mT5	47.6	53.9	27.9	35.8
MT-Highlight mT5	45.9	52.5	26.2	34.8
MT-Prepend mT5	45.5	52.6	25.0	34.0
ST-Both mT5	46.1	52.6	26.2	34.1
ST-Highlight mT5	45.2	52.4	25.8	33.5
ST-Prepend mT5	43.6	50.8	23.4	31.8

For qualitative evaluation, some model outputs from different paragraphs are provided in Appendix B illustrating consistent and inconsistent (that lacks coherence, not addressing the input answer, etc.) generations.

4. Conclusion

By combining the proposed answer extraction and answer-aware QG modules, it is possible to fully automate the QG task without any manual answer extraction labor. Automated evaluation metrics on TQuAD validation set show that the model is capable of generating meaningful question-answer pairs from the context after fine-tuning. Moreover, results show that the proposed multitask approach has better performance on QA, answer

Table 6. TQuADv1 and TQuADv2 fine-tuning QA evaluation results for multitask mT5 variants and BERTurk. MT-Both means, mT5 model is fine-tuned with *Both* input formats and in a multitask setting.

TQuADv1 fine-tuning results

Setting	TQuADv1-val	TQuADv1-val	XQuAD	XQuAD
	F1	EM	F1	EM
BERTurk-base	62.5	45.2	42.9	26.6
MT-Both mT5-small	63.8	48.5	43.5	27.0
MT-Both mT5-base	72.1	55.8	54.6	35.9
MT-Both mT5-large	74.7	59.6	62.1	42.9

TQuADv2 fine-tuning results

Setting	TQuADv2-val	TQuADv2-val	XQuAD	XQuAD
	F1	EM	F1	EM
BERTurk-base	67.1	50.5	53.0	37.4
MT-Both mT5-small	65.0	49.3	48.8	32.9
MT-Both mT5-base	71.5	56.2	61.1	43.3
MT-Both mT5-large	73.3	58.4	65.0	46.7

Table 7. TQuADv1 and TQuADv2 fine-tuning QG evaluation results for multitask mT5 variants. MT-Both means, mT5 model is fine-tuned with 'Both' input format and in a multitask setting.

TQuADv1 fine-tuning results

Setting	TQuADv1-val	TQuADv1-val	TQuADv1	XQuAD	XQuAD	XQuAD
	BLEU-1	BLEU-2	ROUGE-L	BLEU-1	BLEU-2	ROUGE-L
MT-Both mT5-small	37.3	30.1	44.3	19.8	12.7	26.3
MT-Both mT5-base	48.4	41.7	53.6	21.6	14.1	28.3
MT-Both mT5-large	49.8	43.2	55.2	24.9	16.3	30.2

TQuADv2 fine-tuning results

Setting	TQuADv2-val	TQuADv2-val	TQuADv2	XQuAD	XQuAD	XQuAD
	BLEU-1	BLEU-2	ROUGE-L	BLEU-1	BLEU-2	ROUGE-L
MT-Both mT5-small	39.6	32.9	46.5	21.1	13.8	28.4
MT-Both mT5-base	47.6	41.2	53.9	27.9	20.9	35.8
MT-Both mT5-large	49.1	42.7	54.3	29.3	21.9	37.5

extraction and QG compared to single-task setting. By combining the *prepend* and *highlight* input formats, QG performance of an mT5 model can be boosted up to 10%.

In the future, further experiments with the multitask model on the other QG tasks such as multiple choice, true/false, yes/no will be examined and effect of multilingual knowledge in mT5 will be analysed. In addition, human evaluations could be done to provide further insight about the performances of the methods.

References

- [1] Kurdi G, Leo J, Parsia B, Sattler U, Al-Emari S. A systematic review of automatic question generation for educational purposes. *International Journal of Artificial Intelligence in Education* 2020; 30 (1): 121–204. doi:

10.1007/s40593-019-00186-y.

- [2] Lee CH, Chen TY, Chen LP, Yang PC, Tsai RTH. Automatic question generation from children's stories for companion chatbot. In: 2018 IEEE International Conference on Information Reuse and Integration (IRI); 2018. pp. 491–494.
- [3] Laban P, Canny J, Hearst MA. What's the latest? a question-driven news chatbot. In: Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics: System Demonstrations; Online; Association for Computational Linguistics; 2020. pp. 380–387.
- [4] Sreelakshmi A, Abhinaya S, Nair A, Nirmala SJ. A question answering and quiz generation chatbot for education. In: 2019 Grace Hopper Celebration India (GHCI); 2019. pp. 1–6.
- [5] Yue X, Zhang XF, Yao Z, Lin S, Sun H. CliniQG4QA: Generating diverse questions for domain adaptation of clinical question answering. In: 2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM); 2021. pp. 580–587.
- [6] Mitkov R. Computer-aided generation of multiple-choice tests. In: HLT-NAACL 03 workshop on Building educational applications using natural language processing; 2003. pp. 17–22.
- [7] Heilman M, Smith NA. Good question! statistical ranking for question generation. In: Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics; 2010. pp. 609–617.
- [8] Soleymanzadeh K. Domain specific automatic question generation from text. In: ACL 2017, Student Research Workshop; 2017. pp. 82–88.
- [9] Du X, Shao J, Cardie C. Learning to ask: Neural question generation for reading comprehension. In: 55th Annual Meeting of the Association for Computational Linguistics; 2017. pp. 1342–1352.
- [10] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural computation* 1997; 9 (8): 1735–1780. doi: 10.1162/neco.1997.9.8.1735
- [11] Zhou Q, Yang N, Wei F, Tan C, Bao H et al. Neural question generation from text: A preliminary study. In: National CCF Conference on Natural Language Processing and Chinese Computing; 2017. pp. 662–671.
- [12] Zhao Y, Ni X, Ding Y, Ke Q. Paragraph-level neural question generation with maxout pointer and gated self-attention networks. In: 2018 Conference on Empirical Methods in Natural Language Processing; 2018. pp. 3901–3910.
- [13] Duan N, Tang D, Chen P, Zhou M. Question generation for question answering. In: 2017 Conference on Empirical Methods in Natural Language Processing; 2017. pp. 866–874.
- [14] Kim Y, Lee H, Shin J, Jung K. Improving neural question generation using answer separation. In: AAAI Conference on Artificial Intelligence; 2019. pp. 6602–6609.
- [15] Sun X, Liu J, Lyu Y, He W, Ma Y et al. Answer-focused and position-aware neural question generation. In: 2018 Conference on Empirical Methods in Natural Language Processing; Brussels, Belgium; Association for Computational Linguistics; 2018. pp. 3930–3939.
- [16] Tuan LA, Shah D, Barzilay R. Capturing greater context for question generation. In: AAAI Conference on Artificial Intelligence; 2020. pp. 9065–9072.
- [17] Kriangchaivech K, Wangperawong A. Question generation by transformers. *CoRR* 2019; abs/1909.05017. doi: 10.48550/arXiv.1909.05017
- [18] Chan YH, Fan YC. A recurrent BERT-based model for question generation. In: 2nd Workshop on Machine Reading for Question Answering; 2019. pp. 154–162.
- [19] Lopez LE, Cruz DK, Cruz JCB, Cheng C. Transformer-based end-to-end question generation. *CoRR* 2020; abs/2005.01107.

- [20] Xue L, Constant N, Roberts A, Kale M, Al-Rfou R et al. mt5: A massively multilingual pre-trained text-to-text transformer. CoRR 2020; abs/2010.11934. doi: 10.18653/v1/2021.naacl-main.41
- [21] Raffel C, Shazeer N, Roberts A, Lee K, Narang S et al. Exploring the limits of transfer learning with a unified text-to-text transformer. Journal of Machine Learning Research 2020; 21: 1–67. doi: 10.48550/arXiv.1910.10683
- [22] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN et al. Attention is all you need. Advances in neural information processing systems 2017; 30. doi: 10.48550/arXiv.1706.03762
- [23] Schweter S. BERTurk - BERT models for turkish 2020. doi: 10.5281/zenodo.3770924
- [24] Wolf T, Debut L, Sanh V, Chaumond J, Delangue C et al. Transformers: State-of-the-art natural language processing. In: 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations; 2020. pp. 38–45.
- [25] Paszke A, Gross S, Massa F, Lerer A, Bradbury J et al. Pytorch: An imperative style, high-performance deep learning library. Advances in neural information processing systems 2019; 32. doi: 10.48550/arXiv.1912.01703
- [26] Rajpurkar P, Zhang J, Lopyrev K, Liang P. Squad: 100, 000+ questions for machine comprehension of text. In: EMNLP; 2016.
- [27] Amidei J, Piwek P, Willis A. Evaluation methodologies in automatic question generation 2013-2018. In: 11th International Natural Language Generation Conference; 2018. pp. 307–317.
- [28] Papineni K, Roukos S, Ward T, Zhu WJ. BLEU: a method for automatic evaluation of machine translation. In: 40th annual meeting of the Association for Computational Linguistics; 2002. pp. 311–318.
- [29] Banerjee S, Lavie A. METEOR: An automatic metric for MT evaluation with improved correlation with human judgments. In: ACL workshop on intrinsic and extrinsic evaluation measures for machine translation and/or summarization; 2005. pp. 65–72.
- [30] Lin CY. ROUGE: A package for automatic evaluation of summaries. In: Text summarization branches out; 2004. pp. 74–81.
- [31] Soygazi F, Çiftçi O, Kök U, Cengiz S. THQuAD: Turkish historic question answering dataset for reading comprehension. In: 2021 6th International Conference on Computer Science and Engineering (UBMK); 2021. pp. 215–220.
- [32] Artetxe M, Ruder S, Yogatama D. On the cross-lingual transferability of monolingual representations. CoRR 2019; abs/1910.11856. doi: 10.48550/arXiv.1910.11856

Appendices

A. Samples from Datasets

Here we provide some samples from datasets for visual inspection. For TQuADv1 (Table 8) and TQuADv2 (Table 9), samples are shown from both training and validation sets, and for XQuAD (Table 10), samples are shown with tag of validation set only as XQuAD is considered a validation set by itself as a whole. The answers are highlighted within the context with green background for ease of reading.

Table 8. Some samples drawn from TQuADv1.

Split	Sample	TQuADv1
Train	context	Constantinus'un yaptığı etkiye gelince, Schipperges şu görüştedir: Avrupa tıbbına bir stratejik etkide bulunamamıştır. Constantinus'un külliyatı Salerno için çok önemli olsa da, Avrupa'daki diğer okullara sadece hazırlayıcı etkide bulunmuştur. Bu yargılamasında Schipperges, tip kitapları resepsiyonunun ilk dalgasını, İber Yarımadası üzerinden gerçekleşen ikinci dalga ile karşılaştırdığı açıdan haklı olabilir, şu kadar var ki, hazırlayıcı etkinin önemi küçümsenemez. Üstelik yalnızca bir tanesi müstesna olmak üzere, onun yaklaşık yirmi eserin çevirisi daha iyi çevirilerle yerlerini kaybetmiş değil, bilakis onlar yüzlerce yıl Constantinus'un kendi eserleriymiş gibi elden ele dolaşmıştır. Constantinus'un Latince'ye aktardığı eserlerle ilişkisi sözkonusu olduğunda Schipperges onu aşırı olarak nitelenmekten kaçınmaktadır. Ona göre, Constantinus'un çalışmaları alışıldık terim "resepsiyon" ile nitelendirilemez, onun yaptığı daha çok başlangıçtan beri, belirli bir organik amaç için yabancı bilgi malzemesinin bilinçli bir koadunasyonu (bir öğretinin geniş bir kitle için yorumlanması/ şerhi) ve adaptasyon formunda işlenmesi olarak nitelendirilebilir. Bu faaliyet için asimilasyon/ özümseme daha doğru bir ifadedir ⁶⁸ . Ama ben şahsen, Schipperges'in Constantinus'un Latince'ye aktardığı eserlerle olan ilişkisinin tarzına ve şekline yönelik yaptığı bu nitelenmelerde isabetli davrandığına inanmıyorum. Bence Constantinus'un çevirilerinde söz konusu olan husus, kendine has bir resepsiyon tarzıdır. Constantinus'un, çevirdiği eserlerin gerçek yazarlarının isimlerini saklamaya asla hakkı yoktu. Bu durum karşısında onun neden böyle davrandığı sorusunu cevaplandırmak gerekir. 1930 yılında buna ilişkin olarak Hermann Lehmann şöyle demektedir: Constantinus'un bu davranışıyla Salerno'daki yüksek okulun gözündeki üstünlüğünü yüceltmek istemiş olacağından başka bir şey düşünemiyorum. Ben daha farklı bir açıklamaya varıyorum. Buna göre, Constantinus'un kendisine esas aldığı eserlerle olan bu aşırı ilişki birden çok faktörle izah edilebilir:
	question answer	Schippinges'e göre Constantinus'un çalışmaları hangi terim ile nitelendirilemez? alışıldık terim "resepsiyon" ile
Train	context	İslam dünyasında bilimin 16. yüzyılda hala yüksek seviyede bulunduğunu gösteren çok ilginç bir örneği deskriptif coğrafya ekolünden verebiliriz. Bize bu örneği, Avrupa'da Afrikalı Leo (Leo Africanus) olarak tanınan el-hasan b. Muhammed el-Vezzan (doğumu yaklaşık 888/1483)'dir. Fas (Fez) şehrinde büyümüş ve eğitimini almış olan Granada doğumlu bu bilgin, diplomatik hizmetler yoluyla, özellikle kuzey Afrika'da olmak üzere birçok İslam ülkesini tanıyıp bir yazar olarak coğrafya ve kartografya ile ilgileniyordu. İstanbul'dan dönüş yolculuğunda Sicilyalı korsanların eline esir düşmüş, ilk olarak Napoli'ye daha sonra Roma'ya satılıp Papa X. Leo tarafından 6.1.1520 yılında bizzat Papa'nın adıyla Giovanni Leo olarak vaftiz edilmişti. İtalya'daki ikametı sırasında İtalyanca öğrendi ve Arapça öğretti. Yazar olarak faaliyetlerini Roma ve Bologna'da devam ettirdi. Afrika coğrafyası dışında kuzey Afrikalı 30 bilginin biyografilerini içeren diğer eser derledi. Afrika kitabını esaretinin 6. yılı olan 1526'da İtalyan dilinde tamamladı. 935/1529 yılında Tunus'a döndü ve orada Müslüman olarak öldü.
	question answer	el-Hasan b. Muhammed el-Vezzan isimli bilgin avrupa'da nasıl tanınmaktadır ? Afrikalı Leo
Val	context	Pardus için mevcut işletim sistemleri, başta Linux olmak üzere incelendi, açık kaynak yazılım metodolojisi (yöntem bilimi) ve felsefesi ayrıntılı olarak çalışıldı. Bu incelemeler sonrasında, 2003 yılı sonbaharında, Linux temelli, açık kaynaklı, olabildiğince GPL lisanslama yöntemini kullanan bir işletim sistemi dağıtımı oluşturulmasına karar verildi. Pardus Projesi'nin hayata geçmesi, 2004 yılı başında teknik ekibin çekirdeğinin oluşturulmasıyla başladı. Bu aşamada Türkiye'nin Linux geçmişi, mevcut ve planlanan dağıtımlar, açık kaynak ve Linux camiası ve girişimleri de göz önüne alınarak, var olan bilgi birikimi ve deneyimden en üst düzeyde yararlanmanın yolları arandı. Sonuçta ulusal işletim sistemi geliştirilmesinde görev alması en uygun kişiler Türkiye'nin dört bir yanından seçilerek TÜBİTAK/UEKAE bünyesinde bir araya geldiler.
	question answer	Pardus'un 2004 yılı başlarında hayata geçirilen projelerinde çalışacak en uygun kişiler hangi kuruluşun çatısı altında toplanmışlardır? TÜBİTAK/UEKAE

Table 9. Some samples drawn from TQuADv2.

Split	Sample	TQuADv2
Train	context	Hünkâr İskeleye Antlaşması ile iki devlet arasında oluşan ittifakın hâtırısı olmak üzere Rus askerlerinin ordugâh kurdukları yere bir ant dikilmiştir (zamanında yapılmış gravürü için bk. Kutluoğlu, rs. nr. 7, 8). Amtın iki cephesinde Türkçe ve Rusça olmak üzere iki devlet arasındaki dostluğu tebci eden mısralar, İstanbul halkının bu gelişme karşısında duyduğu infiali aksettirmektedir. Muhafazakâr çevrelerin Rusya'ya karşı duymakta olduğu nefret ve özellikle II. Mahmud aleyhine sarfettikleri sözler, Avusturya elçisi Baron von Stürmer'in raporlarında görülen ve padişahı "sarhoş, çılgın, gâvur" olarak niteleyen kayıtlarla da sabittir. Rus ittifakına karşı duyulan bu infialin arkasında, Mehmed Ali Paşa'nın bütün Avrupa'da pek etkili olan ve büyük para gücü ile devreye sokup başarı ile yürüttüğü propaganda faaliyetlerinin olduğu açıktır.
	question	Hünkâr İskeleye Antlaşması ile iki devlet arasında oluşan ittifakın hâtırısı olmak üzere nereye bir ant dikilmiştir ?
	answer	Rus askerlerinin ordugâh kurdukları yere
Train	context	Ferhat Paşa Antlaşması, III. Murat döneminde, 21 Mart 1590 tarihinde, Osmanlı Devleti'yle Safevi Devleti arasında imzalanmış bir barış antlaşmasıdır. Ferhat Paşa Antlaşması, 1578-1590 tarihlerindeki Osmanlı-Safevi Savaşı'nı sona erdirmiştir. Ferhat Paşa Antlaşması duraklama döneminin ilk antlaşmasıdır. Ferhat Paşa Antlaşması İstanbul'da imzalanmıştır. Ferhat Paşa Antlaşması sonucunda Tebriz, Karabağ, Gürcistan, Dağistan ve Şirvan Osmanlılara bırakıldı. Ferhat Paşa Antlaşması ile Osmanlılar doğudaki en geniş sınırlarına ulaşmışlardır. Ferhat Paşa Antlaşması, III. Mehmet döneminde, Safeviler tarafından ihlal edilmiştir.
	question	Ferhat Paşa Antlaşması nerede imzalanmıştır?
	answer	İstanbul'da
Val	context	Mehmed Ali Paşa'nın karşı propagandasından ve genel bir infialden çekinen Bâbüâli'nin filonun Boğaz dışında Süzebolu açıklarında demir atması teklifleri ise etkisiz kaldı. Rus filosunun Boğaz'a gelmesi karşısında ne Fransa'nın Mehmed Ali Paşa yanlısı politikasında, ne de İngiltere'nin ısrarla sürdürmekte olduğu tesbit edilen ilgisiz tutumunda bütün diplomatik teşebbüslere rağmen herhangi bir değişiklik görmeyen Bâbüâli, başşehirin müdafaası için Rusya kara kuvvetlerinin de getirilmesine karar verdi (1833 Mart sonları). 5000 kişilik bir Rus kuvveti 5 Nisan'da İstanbul'a gelerek Beykoz'da karaya çıkıp Hünkâr İskeleye'nde karargâh kurdu. O sıralarda Mısır kuvvetleriyle anlaşmak üzere Kütahya'da görüşmeler sürdürülmekteydi. Nihayet Adana'nın da "muhassıllık" olarak İbrâhim Paşa'ya bırakılması, Mısır ve bütün Suriye vilâyetlerinin, diğer bir ifadeyle I. Selim'in 1516 Mercidâbık ve 1517 Ridâniye zaferleriyle ele geçen bütün yerlerin, Mehmed Ali Paşa'ya terkile varlan uzlaşma neticesinde Mısır meselesinin birinci safhası sona ermiş ve bu tevcihati ihtiva eden ferman 6 Mayıs'ta Mehmed Ali Paşa'ya gönderilerek iki taraf arasındaki ihtilâfa şimdilik son verilmişti. Mısır kuvvetlerinin Toroslar'ın öte taraflarına çekilmesi işi başlamış olmakla beraber Rus kara ve deniz kuvvetlerinde herhangi bir toparlanma gözlenmediği gibi, 5 Mayıs 1833'te çarın büyük yetkilerle yolladığı olağan üstü elçisi Aleksey Orlof'un (Alexej Orlov) İstanbul'a gelişi yapılan bu yardımın faturasının ağır olacağına işaret etmekteydi. Nitekim Orlof, iki devlet arasında 3 Ocak 1799'da yapılan antlaşmaya benzer bir savunma ittifakı teklif etmekte gecikmemiştir. Öte yandan Rusya'nın kara ve deniz kuvvetlerini geri çekmemesi İngiltere ve Fransa'nın donanma nümayişlerine yol açmaktaydı. Ortak harekât, Boğazlar'dan geçerek Rus kuvvetlerini geri çekilmeye zorlama teşebbüslerine kadar varan temayüller gösterdiyse de Rus ittifak teklifinin Bâbüâli tarafından reddine yeterli olmadı. İlk esasları Ahmed Fevzi Paşa ve Orlof arasında tesbit edilen görüşmelere daha sonra Serasker Hüseyin Paşa ve Reisülküttâb Âkif Efendi ile Rus elçisi Butenef de katıldı. İlk toplantı 26 Haziran'da Hüseyin Paşa'nın Emirgân'daki yalısında yapıldı ve 8 Temmuz'daki ikinci toplantıda antlaşma burada imzalandı. Antlaşmanın yapılmasından iki gün sonra Rus filosu ve sayıları 13 veya 15.000'e varan kara kuvvetleri Karadeniz'e çıkmak üzere Boğaz'dan hareket etti.
	question	8 Temmuz'daki ikinci toplantıda antlaşma nerede imzalandı ?
	answer	Hüseyin Paşa'nın Emirgân'daki yalısında

Table 10. Some samples drawn from XQuAD.

Split	Sample	XQuAD
Val	context	Peyton Manning,iki farklı takımı birden fazla Super Bowls'a gitmesinde önderlik eden ilk kilit oyuncu oldu. Ayrıca, 39 yaşında bir Super Bowl'da oynayan en eski oyun kurucu oldu. Geçmiş rekor, Broncos'u 38 yaşında Super Bowl XXXIII'te galibiyete götüren ve şu anda Denver'in Futbol Operasyonları Başkan Yardımcısı ve Genel Müdür'ü olan John Elway'in ellerindeydi.
	question	Bir Super Bowl'da oynayan en yaşlı kilit oyuncu olma rekorunu daha önce kim elinde bulunduruyordu?
	answer	John Elway
Val	context	Polonya'daki bölgesel ayrılma temel birimi bir komündür (gmina). Bir şehir aynı zamanda bir komündür - ancak kent tüzüğü ile. Hem şehirler hem de komünler bir belediye başkanı tarafından yönetilmektedir - ancak komünlerde belediye başkanı vogt'tur (Lehçe'de wójt), ancak şehirlerde - burmistrz'dir. Bazı daha büyük şehirler, bölgedeki bölünmenin ikinci seviyesindeki birimler tarafından sahip olunan görev ve ayrıcalıklar gibi yetkileri elde ederler - ilçeler veya powiat'lar. Bu yetkilere örnek olarak bir otomobil tescili verilebilir: bir gmina otomobilleri kaydedemez, bu bir powiat'ın görevidir (yani bir kayıt numarası, bir arabamın gmina'ya değil, hangi powiat'a kaydedilmiş olduğuna bağlıdır). Bu durumda biz şehir, ilçe veya powiat grodzki hakkında konuşuyoruz. Bu şehirler örneğin Lublin, Krakov, Gdansk, Poznan'dır. Varşova'da, ilçelerinde ek olarak bazı powiat'ların yetkileri bulunmaktadır - daha önce belirtilen araba kaydı gibi. Örneğin, Wola ilçesinin kendi kanıtı vardır ve Ursynów bölgesi- kendi (ve Wola'nın otomobillerinin Ursynów'unkinden başka bir kayıt numarası) vardır. Ancak, örneğin Kraków'daki ilçelerde powiat hakları yoktur, bu nedenle Kraków'daki kayıt numaraları tüm ilçelerde aynı tiptedir.
	question	Polonya'daki bölgesel ayrımlardaki ikinci seviye nedir?
	answer	ilçeler veya powiat

B. Model Outputs

Here we provide some sample question generation results from TQuADv2 dataset for visual inspection. For sample consistent (Table 11) and inconsistent (Table 12) question generations, results are shown. The answers are highlighted within the context with green background for ease of reading.

Table 11. Some consistent question generation results from TQuADv2.

Split	Type	Text
Val	<p>context</p> <p>generated question</p> <p>gold question</p> <p>gold answer</p>	<p>Turkcell , Türkiye merkezli teknolojik iletişim operatör şirketidir. GSM, 2G , 3G , 4G ve 4.5G operatörüdür. GSM 900, UMTS2100, LTE800, LTE900, LTE1800, LTE2100, LTE2600 teknolojilerini kullanarak hizmet vermektedir. Kurulduğu günden bu yana, lisans bedeli de dahil olmak üzere, yurt içerisinde, Turkcell ileriye dönük hedeflerinde 18 milyar Lira yatırım yapmayı hedeflemiştir ve yüzbinlerce Türk vatandaşına iş istihdamı sağlamıştır.</p> <p>Turkcell hangi frekanslar üzerinden hizmet vermektedir?</p> <p>Turkcell hangi frekanslar üzerinden hizmet vermektedir?</p> <p>GSM 900, UMTS2100, LTE800, LTE900, LTE1800, LTE2100, LTE2600</p>
Val	<p>context</p> <p>generated question</p> <p>gold question</p> <p>gold answer</p>	<p>Turkcell 11 Temmuz 2000 yılından itibaren İstanbul borsasında hisselerini satışa çıkardığından beri New York Borsası'nda listelenen ilk Türk şirketi olmuştur. Turkcell'in hissedar yapısı aşağıdaki gibidir: %51 Turkcell Holding A.Ş'ye ait, %0.05 Çukurova Holding A.Ş'ye, %13.07 Sonera Holding B.V'ye, %1,18 MV Holding A.Ş'ye aittir ve serbest payda ise %34,7 dir. 2011'in Aralık ayında Sonera Holding ve Çukurova Grubu doğrudan ve dolaylı olarak sırasıyla Turkcell'in hisse senedinin yaklaşık %37.1 ve %13.8'ini sahiplendiler. Çukurova Grubu 2005 yılının mart ayında TeliaSonera'ya hissesinin büyük bir kısmını sattı. O zamandan beri bu iki firma anlaşıp anlaşamama konusunda tartışıyorlar. 2009 yılının Ağustos ayında Uluslararası Ticaret Odası Çukurova'nın Turkcell Holding içindeki kalan tüm hisselerini TeliaSonera'ya dağıtmasının gerektiği durumunda bir hüküm yayınladı.</p> <p>Turkcell hisselerini İstanbul borsasında hangi tarih itibariyle satışa çıkarmıştır?</p> <p>Turkcell hisselerini İstanbul borsasında hangi tarih itibariyle satışa çıkarmıştır?</p> <p>11 Temmuz 2000</p>
Val	<p>context</p> <p>generated question</p> <p>gold question</p> <p>gold answer</p>	<p>Kemaleddin ibn Yunus ya da Musa ibn Yunus (doğum yılı ve yeri: 1156 Musul - ölüm yılı ve yeri: 1241 Musul).Astronom, matematikçi ve İslam bilgini.Tam adı Musa bin Yunus bin Muhammed bin Men'a'dır, Künyesi ise Ebu'l-Feth'tir, lakabı Kemaleddin olup ayrıca İbn-i Yunus ve Mewsili diye de bilinir.İlk eğitimini babası Şeyh Yunus Rızauddin'in yanında fıkah ve hadis ilimleri öğrendi, ardından Bağdat'taki Nizamiye Medreseleri'nde okumaya devam etti. Burada Şerafeddin el-Tusi'den matematik derslerini aldı, ardından Batlamyus'un Almagest adlı eserini de öğrenir. Ardından Musul'a döndü, Emir Zeyneddin Camii'nde dersler verdi. İlim öğretmeye elverişli olarak inşa edilen bu cami Kemaliyye Medresesi olarak anıldı. Kısa zamanda şöhreti etrafa yayılan Musa Kemaleddin ibn Yunus pek çok çevreden gelen talebelere ilim öğretti.</p> <p>Musa Kemaleddin ayrıca hangi isimlerle bilinir?</p> <p>Kemaleddin ibn Yunus lakabı dışında hangi isimlerle bilinir?</p> <p>İbn-i Yunus ve Mewsili</p>

Table 12. Some inconsistent question generation results from TQuADv2.

Split	Type	Text
Val	context	Şark meselesi temel hatlarıyla iki önemli süreçten oluşmaktadır. Bunlardan birincisi '1071-1683' yılları arasındaki Şark Meselesi'dir. Bu tarihler arasında Avrupa, Türklere karşı savunmaya geçmiş, Türkler ise fetihlere hız kazandırarak akıncılarını Avrupa topraklarına göndermiştir. Bu ilk süreç olan Şark Meselesinde temel amaç Türkleri Anadolu'ya sokmamak, Türklerin Anadolu'daki ilerleyişini durdurmak ve Türklerin Rumeli'ye girişini engellemektir. İstanbul'un Türkler tarafından fethini engellemek isteyen Avrupa devletleri, Türklerin Balkanlar üzerinden Avrupa içlerine doğru ilerleyişine engel olmak için birçok politikalar izlemişler ve bu politikalarda Şark Meselesinin ilk planlı durdurma safhasını oluşturmaktadır.
	generated question	Şark Meselesi'nin temel hatlarıyla iki önemli süreçten biri ne zamandır?
	gold question gold answer	Şark meselesi temel hatlarıyla iki önemli süreçten oluşmaktadır. Bunlardan birincisi nedir? '1071-1683' yılları arasındaki Şark Meselesi'dir.
Val	context	Maksimum Güç Noktası İzleyicisi (MPPT): Panellerden gelen enerjivi düzenleyerek sürekli en yüksek güç üretimini sağlayan bir cihazdır. Bunu yapmak için akımı değiştirmektedir. Burada çıkan akım ile batarya şarj edilmektedir. Yarış sırasında en yüksek 15A şarj değeri görülmüştür. Bu cihaz sayesinde akülerimizi daha kısa sürede şarj edecek akımı seçebiliyoruz.
	generated question	Maximum Güç Noktası İzleyicisi akülerimizi daha kısa sürede şarj edecek hangi akımı değiştirmektedir?
	gold question gold answer	Yarış sırasında ulaşılan en yüksek şarj değeri kaç amperdir? 15A
Val	context	EK 33. Madde 1. paragraf: Ulusal egemenlik kapsamındaki uydu yörünge pozisyonlarının hakları, yönetimi ve işletme yetkisine sahip olmak ve bununla ilgili yükümlülükleri yerine getirmek, adına kayıtlı ve diğer operatörlere ait uyduları işletmeye vermek ya da verilmesini sağlamak, bu uyduları işletmek, ulusal ve yabancı operatörlere ait uydular üzerinden haberleşme ve iletim alt yapısını kurmak, işletmek ve ticari faaliyette bulunmak üzere, bu Kanun ile kuruluş ve tescile ilişkin hükümleri hariç olmak üzere 6762 sayılı Türk Ticaret Kanunu ve özel hukuk hükümlerine tâbi, Türksat Uydu Haberleşme ve İşletme Anonim Şirketi (Türksat A.Ş.) unvanı altında bir anonim şirket kurulmuştur.EK 33. Madde 3. paragraf: Türksat A.Ş.'nin hisselerinin tamamı Hazine Müsteşarlığına aittir. Ancak, Hazine Müsteşarlığının mülkiyet hakkı ile kâr payı hakkına hâlel gelmemek ve kamunun pay sahipliğinden kaynaklanan bütün mali hakları Hazine Müsteşarlığında kalmak kaydıyla, Hazine Müsteşarlığının Türksat A.Ş.'deki pay sahipliğine dayanan oy, yönetim, temsil, denetim gibi hak ve yetkileri Ulaştırma Bakanlığı tarafından kullanılır. 800 civarında televizyon ve radyo data yayını vardır. Şirket; televizyon ve radyo yayıncılığı, Kablo TV hizmeti, internet bağlantısı, veri transferi, VoIP gibi hizmetleri sunmaktadır.
	generated question	Türksat'ın kaç adet uydu yapısı vardır?
	gold question gold answer	Türksat A.Ş kaç adet televizyon ve radyo yayını vardır? 800 civarında