



Ahmet Ali Süzen

Isparta University of Applied Sciences University,
ahmetsuzen@isparta.edu.tr, Isparta-Turkey

DOI	http://dx.doi.org/10.12739/NWSA.2019.14.3.1A0436
ORCID ID	0000-0002-5871-1652
CORRESPONDING AUTHOR	Ahmet Ali Süzen

LSTM DERİN SİNİR AĞLARI İLE ÜNİVERSİTE GİRİŞ SINAVINDAKİ MATEMATİK SORU SAYILARININ KONULARA GÖRE TAHMİNİ

ÖZ

Bu çalışmada Long Short-Term Memory (LSTM) derin sinir ağı (DSA) ile üniversite giriş sınavındaki matematik testinin soru sayılarının tahmin edilmesi için bir model önerilmiştir. Modelin veri kümesi 1981-2018 yıllarına ait sınavların matematik testinin 16 farklı konuya göre ayrılmış 931 soru sayısı verisinden oluşmaktadır. Veri kümesi %80'ı modelin eğitilmesi, %20'ü testi için ayrılmıştır. LSTM modelde zaman serisi tahmin problemlerinde yüksek doğruluk sağlanması için hiper parametreleri belirlenmiştir. Her konu gruba ait soru sayıları zaman serisi modelde ayrı ayrı eğitilmiştir. Çalışma sonucunda eğitimde ortalama %98.42, testte ortalama %96.82 doğruluk elde edilmiştir. Kullanılan DSA algoritmasının başarısının ölçülmesi için veri kümesi makine öğrenme algoritmalarında test edilerek kıyaslanmıştır. Bunun sonucunda LSTM DSA, en yüksek başarıyı sağlamıştır. Çalışma sonucu olarak modelden elde edilen doğruluğun yüksek olması, ilerleyen çalışmalarda soru tahmin robotların geliştirilmesine imkân sağlayacaktır.

Anahtar Kelimeler: Derin Sinir Ağı, LSTM, Üniversite Giriş Sınavı, Zaman Serisi Model, Matematik

PREDICTION OF NUMBERS QUESTION MATHEMATICS IN THE UNIVERSITY ENTRANCE EXAM BY TOPICS WITH LSTM-BASED DEEP NEURAL NETWORK

ABSTRACT

In this study, we proposed a model for estimating the number of questions in the long short term memory (LSTM) deep neural network (DNN) and the mathematics test in the university entrance exam. The data set of the model consists of 931 questions divided according to 16 subjects of the mathematics test for the years 1981-2018. The data set is divided into 80% for the training of the model and 20% for the test. Hypercritical parameters have been determined to provide high accuracy in time series estimation problems in the LSTM model. The number of questions for each subject group has been trained one by one in the time series model. As a result of the study, the average accuracy was 98.42% and the average accuracy was 96.82% in the test. The data set was compared with machine learning algorithms to measure the accuracy of the DNN algorithm used and LSTM DSA achieved the highest performance. As a result of study, the future studies will provide the development of robots to predict because of the high accuracy of the model.

Keywords: Deep Neural Network, LSTM, Prediction, Time Series Model, University Entrance Exam, Maths

How to Cite:

Süzen, A.A., (2019). LSTM Derin Sinir Ağları İle Üniversite Giriş Sınavındaki Matematik Soru Sayılarının Konulara Göre Tahmini, **Engineering Sciences (NWSAENS)**, 14(3):112-118, DOI: 10.12739/NWSA.2019.14.3.1A0436.



1. GİRİŞ (INTRODUCTION)

Eğitim, bireyin nasıl bir yaşamı olacağını belirleyen etmenlerin en başında gelir [1]. Ülkemizde örgün eğitim kurumları okul öncesi, ilkokul, ortaokul, lise ve yükseköğretim (üniversite) olarak kademelenmektedir. Bu kademeler arası geçişler (ortaokul-lise ve lise-üniversite arasında) merkezi sınavlar aracılığıyla gerçekleştirilmektedir [2]. İlk kez 1974 ve 1975 yılında yükseköğretime öğrenci seçmek için yapılan Öğrenci Seçme ve Yerleştirme Sınavı, bugüne kadar farklı formatlarda uygulanmıştır [3]. 2017 yılında üniversiteye giriş sistemine son şekil verilmiştir. Bu çerçevede, 2018 yılında yapılacak sınavın adı "Yükseköğretim Kurumları Sınavı (YKS)" olarak belirlenmiştir [4]. Yükseköğretimde arz ve talep açısından son yıllarda önemli gelişmeler sağlanmıştır. ÖSYS'ye başvuran aday sayısı 2006 yılında 1 milyon 600 bin iken, 2017 yılında 2 milyon 200 bine, 2018 yılında ise 2 milyon 380 bine yükselmiştir. Ayrıca son 10 yılda yükseköğretimde toplam öğrenci sayısı ciddi bir artışla 2 milyon 485 binden 7 milyon 560 bine yükselmiştir [5]. 1970'li yıllardan bu yana yapılan sınavlar ile sınav sonucu, doğru/yanlış sayısı, puan, soru sayısı, sınav ortalaması vb. gibi birçok veri oluştu. Verilerin işlenecek düzeye gelmesi veriler üzerinden belirli çıkarımların yapılmasının önünü açmıştır.

Veri kümeleri, öznitelikler veya birden fazla bağlantılı değişken içeren gözlemlerden oluşmaktadır [6]. Veri kümelerinden çıkarım, sınıflandırma ve tahmin işlemleri yapay sinir ağları ile yapılmaktadır. Yapay sinir ağları 1943 yılından bu yana nesne tanıma [7], konuşma tanıma, el yazısı tanıma [8], gerçek zamanlı dil çeviri [9] ve robotik [10] gibi uygulamalarda kullanılmaktadır. Özellikle yüksek veri kümesi ve yüksek performanslı sistemlerin sağlanması ile derin sinir ağları tercih edilmeye başlandı. Derin sinir ağları (DSA) en basit tanımı ile geleneksel sinir ağlarının genişletilmesi ile oluşturulmuş makine öğrenme teknikleridir. DSA yapılarını makine öğrenme tekniklerinden ayıran unsur, DSA'ların özellik çıkarım adımlarına ihtiyaç duymamasıdır. Bunun sonucunda DSA daha fazla katman ve nöron sayısı ile karmaşık ve doğrusal olmayan özelliklerin öğrenilmesini sağlar [11]. DSA modeli geliştirilirken tercih edilen sinir ağı mimarileri aşağıda listelenmiştir [12].

- Konvolüsyonel Sinir Ağı (Convolution Neural Network-CNN)
- Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN)
- Uzun Kısa Vadeli Bellek Ağları (Long Short Term Memory-LSTM)
- Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machines-RBM)
- Oto-Kodlayıcılar (Autoencoders-AE)
- Derin veya Yığılılı Oto-Kodlayıcılar (Deep/Stacked Autoencoder-DAE)

DSA'nın eğitim alanındaki çalışmaları soru- cevap [14 ve 16], cümle kurma [17] ve ses tanıma [13] konularında toparlanmıştır. Literatürdeki çalışmaların geneli soru-cevap uygulamalarıdır. Cheng ve arkadaşları çocukların yabancı dil eğitimindeki konuşma akustiklerinin tanımlanması üzerine bir DSA geliştirmiştir [13]. Xiong ve arkadaşlar görsel üzerinden soru soran bir CNN DSA modeli üzerinde çalışmış ve %60,4 ortalama başarı sağlamıştır [14]. Liu ve arkadaşları Çin k12 akıllı eğitim modeli için bilgi tabanlı 9.000'den fazla soruya cevap sunan ve %70 başarı sağlayan asistan geliştirmişlerdir [15]. Yin ve arkadaşları LSTM algoritması ile QuesNet isimli test sorusu hazırlama modeli üzerinde çalışmışlardır [16]. Yapılan literatür taramasında, çalışmada önerilen soru sayısı tahmin modeli ile ilgili benzer çalışmaya rastlanmamıştır. Çalışmanın DSA'nın eğitim alanındaki çalışmalarına farklılık sunacağı öngörülmektedir.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Bu çalışmada üniversitesi giriş sınavı verileri kullanılarak gelecek sınavlarda çıkacak soru sayısının tahmin edilmesini sağlayan DNN modeli geliştirilmiştir. Modelin veri kümesini DSA modelinin veri kümesi 1981-2018 yıllarına ait sınavların verilerinde oluşturulmuştur. Modelin eğitimi sonunda doğruluğunun test edilmesi için veri kümesindeki son dört yıla ait soru sayıları kullanılmıştır. Önerilen model, eğitim ve test sonucunda ortalama %96.82 başarımla sağlanmıştır. Aynı veri kümesi geleneksel makine öğrenme algoritmaları ile test edilmiş ve önerilen LSTM DNN modeli en yüksek başarımla sağlamıştır. Çalışmanın gelecek modelinde soru tahmin işlemleri zaman serisi üzerinde yapılması planlanan sınavlara yönelik uygulanacaktır. Aynı zamanda modelin, soru tahmin robotlarının veya sistemlerin geliştirilmesine katkı vermesi hedeflenmektedir. Çalışmanın bundan sonraki bölümünde tahmin modelinin geliştirildiği derin öğrenme algoritması olan LSTM hakkında bilgilere yer verilmiştir. Üçüncü bölümünde ise modelin geliştirilme süreci olan veri ön işleme, tahmin modelinin eğitimi ve tahminlerin değerlendirilmesi işlenmiştir. Son olarak Bölüm 4’de geliştirilen modelin sonuçları ve çalışmanın geleceği hakkında önerilerde bulunulmuştur.

3. LONG SHORT-TERM MEMORY (LSTM)

LSTM derin öğrenme algoritması, 1997’de Hochreiter ve Schmidhuber tarafından RNN mimarisinin dezavantajlarını yok etmek için ortaya atılan bir tekrarlayan sinir ağı olarak bilinmektedir [18]. LSTM, hafıza geçişli mekanizması ile uzun vadeli bağımlılıkları öğrenebildiği için sıralı veya zaman serisi problemlerde önerilmektedir [19]. Temel LSTM mimarisi giriş (Denklem 1), çıkış (Denklem 4), unut kapıları (Denklem 2) ve hafıza hücrelerinden (Denklem 3) oluşmaktadır [20]. Sinir ağının kapı ve hücrelerine ait işlem fonksiyonları aşağıda verilmiştir.

$$i_t = \sigma (W_{xi} x_t + W_{hi} h_{t-1} + W_{ci} c_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma (W_{xf} x_t + W_{hf} h_{t-1} + W_{cf} c_{t-1} + b_f) \quad (2)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh (W_{xc} x_t + W_{hc} h_{t-1} + b_c) \quad (3)$$

$$o_t = \sigma (W_{xo} x_t + W_{ho} h_{t-1} + W_{co} c_t + b_o) \quad (4)$$

$$h_t = o_t \odot h(c_t) \quad (5)$$

i , o , f , c , W terimleri sırasıyla giriş kapısı, çıkış kapısı, unut kapısı, hücre aktivasyon vektörünü, ağırlık matrisini ifade etmektedir. LSTM yapılarının formülünde kullanılan \odot , iki vektör veya metriğin skaler çarpımını gösterir. Son olarak $\sigma(x)$ standart bir sigmoid fonksiyonunun tanımlanması Denklem 6’da gösterilmiştir.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

LSTM zaman serisi tahminlerde sık kullanılan bir derin sinir ağı algoritmasıdır. İlk olarak kaotik zaman serisi tahmininde kullanılmıştır [21]. Aynı zamanda konuşma [22], metin işleme [23], müzik [24] ve sınıflandırma [25] uygulamalarında LSTM mimarileri kullanılmış ve başarılı sonuçlar alınmıştır.

4. MODELİN GELİŞTİRİLMESİ (MODEL DEVELOPMENT)

4.1. Verilerin Hazırlanması (Preparation of Data)

Tahmin modelinin eğitilmesi ve testinde 1981 ile 2018 yıllarına arasındaki üniversite giriş sınavının matematik testine ait soru sayıları kullanılmıştır. Veri kümesi 16 farklı konu başlığı ve toplamda 931 veriden oluşmaktadır. Eğitim verisi %80 (s_n), test verisi %20 (t_n) olarak belirlenmiştir. Veri setindeki veriler modelin eğitimine girmeden Denklem 7’de gösterildiği gibi formüle edilen MinMaxScalar ile normalize edilmiştir [26].

$$V_{s=} = \frac{V - X_{min}}{X_{max} - X_{min}} (Y_{Max} - Y_{Min}) + Y_{min} \quad (7)$$

Burada V_s Ölçeklenmiş veriyi, $[X_{\min}-X_{\max}]$ ilk aralığı, $[Y_{\min}-Y_{\max}]$ yeni aralığı temsil etmektedir.

3.2. LSTM Model (LSTM Model)

Konulara ait geçmiş soru sayıları $x=(x_1, x_2, x_3, \dots, x_t)$ şeklinde girdi kabul edilmiştir. Sonrasında LSTM içerisinde $h=(h_1, h_2, h_3, \dots, h_t)$ gizli vektör dizisi hesaplanır ve çıkışta konuya ait soru sayısı tahmini $y=(y_1, y_2, y_3, \dots, y_t)$ dizisi ile alınır. Bu süreç Denklem 8 ve 9'a göre tekrarlanır.

$$h_t = \Theta(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (8)$$

$$y_t = W_{hy}h_t + b_y \quad (9)$$

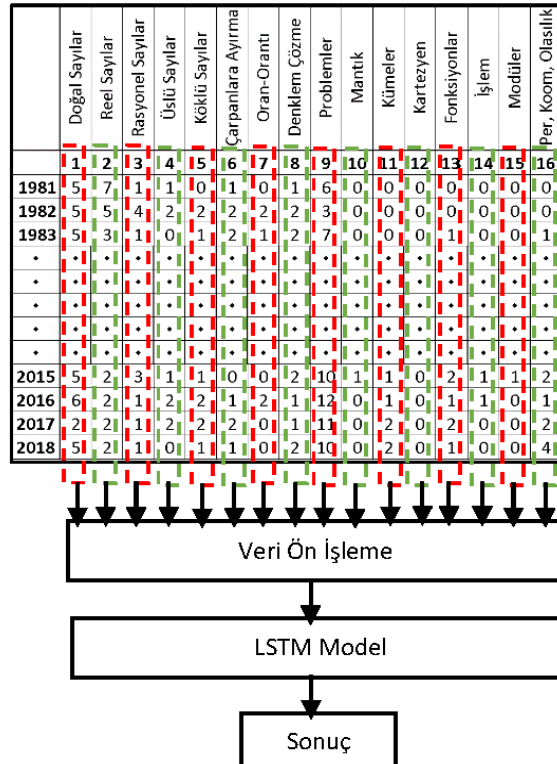
Dört katmanlı LSTM modelde öğrenme hızı $\alpha=0.001$, seyreltme oranı dropout=0.5 ve eğitim sayısı epoch=100 olarak belirlenmiştir. Modelin tahmin doğruluğunu ölçmek için ortalama kare hata (MSE-Mean Square Error) kullanılmıştır. Denklem 10'da gösterilen p_i tahmin verisini, y_i ölçülen veriyi temsil etmektedir.

$$e = \frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2 \quad (10)$$

Model, Spyder IDE'si üzerinde Python dili ile tensorflow kütüphanesi kullanılarak geliştirilmiştir. Ayrıca modelin eğitimi ve testi Windows 10 Pro işletim sistemi üzerinde Intel I7 2.9 GHZ işlemci, 12 GB RAM ve NVIDIA 940MX grafik kartına sahip donanım ile yapılmıştır.

4.3. Modelin Değerlendirilmesi (Evaluation of Model)

Şekil 1'de blok görüntüsü verilen LSTM tabanlı soru sayısı tahmin modelinde 1981-2018 arası veriler her konu türüne göre ayrı ayrı eğitim ve test uygulanmıştır.



Şekil 1. Modelin blok diyagramı
(Figure 1. Block diagram of model)

Modelin eğitimi 16 farklı girdi değerine göre eğitimde ortalama %98.42 ve testte ise %96.82'lik bir doğruluk performansı elde

edilmiştir. Tablo 1’de her konuya ait tahmin başarı performansları gösterilmiştir. Buna göre konudaki soru sayısının ve çeşitliliğin az olduğu girdilerde başarınının daha yüksek olduğu görülmektedir.

Tablo 1. 16 farklı eğitim ve teste ait doğruluk performansı
(Table 1. Performance accuracy for 16 different training and testing)

Açıklama	Eğitim	Test
Doğal Sayılar	96.8	95.1
Reel Sayılar	97.4	95.7
Rasyonel Sayılar	97.7	95.9
Üslü Sayılar	98.1	96.4
Köklü Sayılar	98	96.9
Çarpanlara Ayırma	96.8	92.85
Oran-Orantı	99.02	97.1
Denklem Çözme	97.3	97.2
Problemler	96.8	94.1
Mantık	98	97
Kümeler	99.1	98.3
Kartezyen	99.3	98.7
Fonksiyonlar	99.7	98.1
İşlem	99.7	98.9
Modüler	99.6	99
Per, Koom, Olasılık	99.8	97.9
Ortalama	98.42	96.82

Tablo 2’de modelin tüm eğitim ve test işlemleri sonucunda ortaya çıkan MSE değeri ve doğruluk performansı verilmiştir.

Tablo 2. Eğitim ve testin ortalama hata ve doğruluk performansları
(Table 2. Average error and accuracy performances of training and testing)

	MSE	Accuracy
Eğitim	0.0075	98.42
Test	0.0102	96.82

Önerilen LSTM modelin kullanılan veri kümesindeki doğruluğunun başarısını ölçmek için aynı veri kümesi farklı öğrenme ve tahmin algoritmaları ile test edilmiştir. Bu model için karar ağacı regresyonu, lojistik regresyon, poisson regresyonu ve çok katmanlı algılayıcı (MLP) kullanılmıştır. Algoritmalar önerilen modelin eğitildiği donanım üzerinde test edilmiştir. Karşılaştırma sonucu olarak Tablo 3 incelendiğinde önerilen LSTM modelin bu veri kümesi üzerinde en yüksek başarıyı verdiği görülmüştür.

Tablo 3. Diğer yöntemlerle elde edilen sonuçlar
(Table 3. Results obtained by other methods)

Algoritma	Doğruluk
Karar Ağacı Regresyonu	73.20
Lojistik Regresyon	89.54
Poisson Regresyonu	82.60
MLP	86.82
LSTM	96.82

5. SONUÇ (CONCLUSION)

Bu çalışmada LSTM derin öğrenme algoritması kullanılarak üniversite giriş sınavının matematik testindeki soruların konu bazlı tahmini gerçekleştirilmiştir. 1981-2018 yılları arasında yapılan

sınavlara ait veriler kullanılarak zaman serisi bir LSTM modeli geliştirilmiş ve eğitilmiştir. Model eğitimde %98.42, teste %96.82 başarı sağlamıştır. Elde edilen sonuçlar aynı veri kümesi üzerinde farklı algoritmalar ile kıyaslanmıştır. Sonuç olarak LSTM derin öğrenme algoritmalarının zaman serisi tahminlerde en yüksek başarıyı verdiği görülmüştür. Önerilen LSTM modelin gelecek çalışmada veri kümesi 1981 öncesi ve 2018 sonrası elde edilen veriler ile çoğaltılacaktır. Veri sayısının artması ile model tekrar teste alınacak ve başarı oranının artışı izlenecektir. Verinin çoğaltılması ile modelin başarı oranı artması ile beraber ilerleyen sınavlar için konulara göre soru sayısı tahmin robotu geliştirilecek ve *github* üzerinden paylaşılacaktır.

KAYNAKLAR (REFERENCES)

- [1] Oral, I., Mcgivney, E J., (2014). Türkiye Eğitim Sisteminde Eşitlik ve Akademik Başarı. Eğitim Reformu Girişimi, İstanbul.
- [2] Baran, İ.N. ve Altun, T., (2014). 333 Dershanelerin Eğitim Sistemimizdeki Yeri Ve Önemi. Eğitim ve Öğretim Araştırmaları Dergisi, 3(2):2146-9199.
- [3] Zararsız, M.E., Ekici, B. ve Ulutaş, S., (2012). İlköğretimden Ortaöğretime Ortaöğretimden Yükseköğretime Geçiş Analizi. T.C. Millî Eğitim Bakanlığı.
- [4] Gürbüz Türk, O. ve Kıncal, R.Y., (2018). Türkiye’de Yükseköğretime Geçiş Sürecinin Analizi: Gelişmeler, Modeller ve Uygulamalar. Akdeniz Eğitim Araştırmaları Dergisi, 12(24):33-54.
- [5] Erdem, A.R., (2014). Yükseköğretime Geçişin Kritiği, Cumhuriyet'in Kuruluşundan Günümüze Eğitimde Kademeler Arası Geçiş ve Yeni Modeller. Uluslararası Kongresi, 851-864.
- [6] Khashei, M. ve Bijari, M., (2011). A Novel Hybridization of Artificial Neural Networks and Arima Models for Time Series Forecasting". Applied Soft Computing 11(2):2664-2675.
- [7] Szegedy, C., Toshev, A., and Erhan, D., (2013). Deep Neural Networks for Object Detection. In: Advances in Neural Information Processing Systems, pp:2553-2561.
- [8] Graves, A., (2012). Supervised Sequence Labelling with Recurrent Neural Networks. ISBN 9783642212703. URL <http://books.google.com/books>.
- [9] Akmeliawati, R., Ooi, M.P.L., and Kuang, Y.C., (2007). Real-time Malaysian Sign Language Translation Using Colour Segmentation and Neural Network. In: Instrumentation and Measurement Technology Conference Proceedings, 1(6).
- [10] King, S.Y. and Hwang, J.N., (1989). Neural Network Architectures for Robotic Applications Robotics and Automation, IEEE Transactions on 5(5):641-657.
- [11] Derakhshani, A. and Foruzan, A.H., (2019). Predicting the Principal Strong Ground Motion Parameters: A deep learning approach, Applied Soft Computing Journal, 80:192-201.
- [12] Şeker, A., Diri, B. ve Balık, H.H., (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, Gazi Mühendislik Bilimleri Dergisi, 3(3):47-64.
- [13] Cheng, J., Chen, X., and Metallinou, A., (2015). Deep Neural Network Acoustic Models for Spoken Assessment Applications. Speech Communication, 73:14-27.
- [14] Xiong, C., Merity, S., and Socher, R., (2016). Dynamic Memory Networks for Visual and Textual Question Answering. In International conference on machine learning, 2397-240.
- [15] Liu, Y., Xu, B., Yang, Y., Chung, T., and Zhang, P., (2019). Constructing a Hybrid Automatic Q&A System Integrating Knowledge



- Graph and Information Retrieval Technologies. In *Foundations and Trends in Smart Learning* (pp:67-76).
- [16] Yin, Y., Liu, Q., Huang, Z., Chen, E., Tong, W., Wang, S., and Su, Y., (2019). QuesNet: A Unified Representation for Heterogeneous Test Questions. arXiv preprint arXiv:1905.10949.
- [17] Hassan, A. and Mahmood, A., (2018). Convolutional Recurrent Deep Learning Model for Sentence Classification. *IEEE Access*, 6, 13949-13957.
- [18] Chakraborty, K., Mehrotra, K., Mohan, C.K., and Ranka, S., (1992). Forecasting The Behavior of Multivariate Time Series Using Neural Networks. *Neural Networks* 5(6):961-970.
- [19] Hochreiter, S. and Schmidhuber, J., (1997). Long Short-term Memory. *Neural Computation*, 9(8):1735-1780.
- [20] Ahmadi, N., Constandinou, T., and Bouganis, C., (2019). Decoding Hand Kinematics from Local Field Potentials Using Long Short-Term Memory (LSTM) Network. 9th International IEEE EMBS Conference on Neural Engineering (NER 2019), 1-5s.
- [21] Graves, A. and Schmidhuber, J., (2005). Framewise Phoneme Classification With Bidirectional LSTM and other Neural Network Architectures. *Neural Networks*, 18(5-6):602-610.
- [22] Graves, A., Mohamed, A., and Hinton, G., (2013). Speech Recognition with Deep Recurrent Neural Networks. In 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp:6645-6649.
- [23] Fernández, S., Graves, A., and Schmidhuber, J., (2007). An Application of Recurrent Neural Networks to Discriminative Keyword Spotting. In International Conference on Artificial Neural Networks, pp:220-229.
- [24] Samui, S., Chakrabarti, I., and Ghosh, S.K., (2018). Tensor-Train Long Short-Term Memory for Monaural Speech Enhancement. ArXiv Preprint ArXiv:1812.10095.
- [25] Raj, H., Weihong, Y., Banbhrani, S.K., and Dino, S.P., (2018). LSTM Based Short Message Service (SMS) Modeling for Spam Classification. In Proceedings of the 2018 International Conference on Machine Learning Technologies, 76-80.
- [26] Zang, C., (2017). Deep Learning in Multiple Multistep Time Series Prediction". arXiv preprint arXiv:1710.04373.