



JISTA

*Journal of Intelligent Systems: Theory
and Applications*

MARCH 2020

ISSN: 2651-3927



VOL 3 NO 1

ARTIFICIAL INTELLIGENT > MACHINE LEARNING > MULTI-AGENTS

WWW.JISTA.INFO



Journal of Intelligent Systems: Theory and Applications

Volume: 3 Issue: 1

Editorial Boards

Honorary Editors

Zekai Şen, zsen@itu.edu.tr, Istanbul Technical University, Turkey

Burhan Turksen, bturksen@etu.edu.tr, TOBB ETU, Turkey

Editor-In-Chief

Harun Taşkın, taskin@sakarya.edu.tr, Sakarya University, Turkey

Associate of Editor-In-Chief

Özer Uygun, ouygun@sakarya.edu.tr, Sakarya University, Turkey

Editors

Alper Kiraz, kiraz@sakarya.edu.tr, Sakarya University, Turkey

M. Fatih Adak, fatihadak@sakarya.edu.tr, Sakarya University, Turkey

Fuat Şimşir, fuatsimsir@karabuk.edu.tr, Karabük University, Turkey

Zafer Albayrak, zalbayrak@karabuk.edu.tr, Karabük University, Turkey

Editorial Advisory Board

Ali Allahverdi, ali.allahverdi@ku.edu.kw, Kuwait University, Kuwait

Andrew Kusiak, andrew-kusiak@uiowa.edu, The University Of Iowa, United States of America

Ayhan Demiriz, ademiriz@sakarya.edu.tr, Gebze Technical University, Turkey

Barış Yüce, b.yuce@exeter.ac.uk, Exeter University, United Kingdom

Cemalettin Kubat, kubat@sakarya.edu.tr, Sakarya University, Turkey

Cemil Öz, coz@sakarya.edu.tr, Sakarya University, Turkey

Dervis Karaboga, karaboga@erciyes.edu.tr, Erciyes University, Turkey

Ebubekir Koç, ekoc@fsm.edu.tr, Fatih Sultan Mehmet University, Turkey

Eldaw E. Eldukhri, eeldukhri@ksu.edu.sa, King Saud University, College Of Engineering Al-Muzahmia Branch, Saudi Arabia, United Kingdom

Ercan Öztemel, eoztemel@marmara.edu.tr, Marmara University, Turkey

Güneş Gençyılmaz, gunesgençyilmaz@aydin.edu.tr, Turkey

Hamid Arabnia, hra@cs.uga.edu, University Of Georgia, United States of America

Lyes Benyoucef, lyes.benyoucef@Isis.org, Aix-Marseille University, Marseille, France

Maged Dessouky, maged@rcf.usc.edu, University Of Southern California, Los Angeles, United States of America

Mehmet Emin Aydın, mehmet.aydin@beds.ac.uk, United Kingdom

Mehmet Recep Bozkurt, mbozkurt@sakarya.edu.tr, Sakarya University, Turkey

Mehmet Savsar, mehmet.savsar@ku.edu.kw, Kuwait University, Kuwait

Mohamed Dessouky, dessouky@usc.edu, University Of Southern California, Los Angeles, United States of America

M.H. Fazel Zarandi, zarandi@aut.ac.ir, Amerikabir University Of Technology, Iran

Türkay Dereli, dereli@gantep.edu.tr, Gaziantep University, Turkey

Witold Pedrycz, pedrycz@ee.ualberta.ca, University Of Alberta, Canada

Yılmaz Uyarođlu, uyaroglu@sakarya.edu.tr, Sakarya University, Turkey




Journal of Intelligent Systems: Theory and Applications

Volume: 3 Issue: 1

Contents

Research Articles

- | | |
|---|------|
| Assessment of Mutation Susceptibility in DNA Sequences with Word Vectors
<i>Alper Yilmaz</i> | 1-6 |
| Makine Seçim Probleminin Bulanık VIKOR Yöntemiyle İncelenmesi
<i>Rümeysa Faydalı, Enes Furkan Erkan</i> | 7-12 |



Assessment of Mutation Susceptibility in DNA Sequences with Word Vectors

Alper Yilmaz¹ 

¹Yildiz Technical University, Faculty of Chemical and Metallurgical Engineering, Department of Bioengineering, Istanbul/ Turkey

Abstract

With the advent of natural language processing (NLP) techniques empowered with deep learning approaches, more detailed relationships between words have been unraveled. Word2Vec is quite robust in discovering contextual and semantic relationships. Genome being a long text, is subject to similar studies to unravel yet to be discovered relationships between DNA k-mers. Dna2vec applies Word2Vec approach to whole genome so that DNA k-mers are represented as vectors. The cosine similarity queries on DNA vectors reveal unusual relationships between DNA k-mers.

In this study, we examined DNA sequence based prediction of mutation susceptibility. Initially, we generated word vectors for human and mouse genome via dna2vec. On the other hand, we retrieved coordinates of common and all mutations from dbSNP. For each coordinate, we extracted 8 nucleotide k-mers intersecting mutations and results are aggregated such a way that number of mutations for each 8-mer has been tabulated. These results are incorporated with dna2vec cosine similarity data. Our results showed that for a given k-mer, k-mers with highest cosine similarity coincide with highest mutation count k-mer. In other words, the neighbor with the highest cosine similarity for a k-mer was also seen to be the neighbor overlapping the mutation count. As a result of our studies, human and mouse, dna2vec vs. mutation overlap is 80% and 70%, respectively. In conclusion, dna2vec and other word embedding approaches can be used to reveal mutation or variation characteristics of genomes without sequencing or experimental data, solely using the genome sequence itself. This might pave the way for understanding the underlying mechanism or dynamics of mutations in genomes.

Keywords: mutation, word2vec, dna2vec, k-mer, cosine-similarity.

DNA Dizilerinde Kelime Vektörleri ile Mutasyon Yatkinlığının Değerlendirilmesi

Öz

Derin öğrenme yaklaşımları ile güçlendirilen doğal dil işleme (NLP) tekniklerinin ortaya çıkmasıyla, kelimeler arasındaki daha ayrıntılı ilişkiler ortaya çıkarılmıştır. Bu açıdan word2vec yöntemi bağlamsal ve anlamsal ilişkileri keşfetme konusunda oldukça gelişmiştir. Uzun bir metin olan genom, DNA k-merleri arasındaki ilişkileri henüz keşfedememiş olan benzer çalışmalara tabidir. Dna2vec, DNA k-merlerinin vektör olarak gösterilmesi için tüm genoma word2vec yaklaşımını uygular. DNA vektörleri üzerindeki kosinüs benzerlik sorguları DNA k-merleri arasında olağandışı ilişkiler ortaya koymaktadır.

Bu çalışmada, mutasyon duyarlılığının DNA dizisi temelli tahmini incelendi. Başlangıçta, insan ve fare genomu için dna2vec yoluyla sözcük vektörleri üretildi. Diğer yandan, ortak ve tüm mutasyonların koordinatlarını dbSNP'den alındı. Her koordinat için, kesişen mutasyonlar halinde 8 nükleotidlik k-merler çıkarıldı ve sonuçlar toplandı. Bu sonuçlar dna2vec kosinüs benzerlik verileri ile birleştirildi. Sonuçlarımız, belirli bir k-mer için, en yüksek kosinüs benzerliğine sahip k-merlerin en yüksek mutasyon sayısına sahip k-merler ile çakıştığını göstermiştir. Başka bir deyişle, bir k-mer için kosinüs benzerliği en yüksek komşunun, mutasyon sayısıyla çakışan komşu olduğu da görülmüştür. Çalışmalarımız sonucunda insanda ve farede, k-mer kosinüs benzerliği ve mutasyon örtüşmesinin oranları sırasıyla %80 ve %70 olduğu görülmüştür. Bu çalışmalar sonucunda dna2vec ve diğer kelime gömme yaklaşımları, sadece genom dizisinin kendisi kullanılarak, dizileme veya deney verileri olmadan genomların mutasyon veya varyasyon

* Corresponding Author.
E-mail: alyilmaz@yildiz.edu.tr

Received : 17 Jan 2020
Revision : 22 Jan 2020
Accepted : 07 Feb 2020

özelliklerini ortaya çıkarmak için kullanılabilir olduğu gösterilmiştir. Bu durum, genomlardaki mutasyonların altında yatan mekanizmayı veya dinamikleri anlamının yolunu açabilir.

Anahtar kelimeler: mutasyon, word2vec, dna2vec, k-mer, kosinüs benzerliği.

1. Introduction

Underlying problem of language modeling is that dimensionality. Most known and used technique to solve this problem is word2vec, word embedding method (Mikolov *et al.* 2013).

This method includes two models; Continuous Bag of Words (CBOW) and Skip Gram. These models converts word in the corpus into vectors. Purpose of these models is to determine contextually similar words. In line with this objective, they utilize “context window”. All words within n units from a target word in context window belong to context of that target word. This architecture based on context window can predict either target or the context. A shallow neural network is used for training of words in these architectures. Output of this neural network gives the semantic or syntactic relation among words. Word vectors can be added or subtracted in order to reveal or extend relationships between words, as shown below:

$$\text{vec}(\text{king}) - \text{vec}(\text{man}) + \text{vec}(\text{woman}) \approx \text{vec}(\text{queen})$$

(Mikolov *et al.* 2013)

Moreover, word2vec can capture word relations such as past-tense, ownership, language spoken in the country or the capital of country information (Levy and Goldberg, 2014). For many machine learning algorithms, an input of fixed-length vector is required. Word2vec generates fixed-length embedding for words which can be later used as input to subsequent machine learning applications. Thus, word2vec has been used in studies in different areas such as document representations for classification of documents and sentiment analysis (Le and Mikolov, 2014; Kusner *et al.* 2015; Chen, 2017), network detection to predict the link between the edges and nodes (Perozzi *et al.* 2014; Chen and Lawrence Zitnick, 2015), image caption generation (Pedersoli *et al.* 2017; Kiros *et al.* 2014), identification of public user tendency such as political preference or occupational class (Preoțiuc-Pietro *et al.* 2015; Yang *et al.* 2018; Preoțiuc-Pietro *et al.* 2017), limited contextual information transformation (Dos Santos and Gatti, 2014; De Boom *et al.* 2015), image annotation to provide computer vision and pattern recognition (Uricchio *et al.* 2017), using biomedical literature to predict drug interactions and capturing medical semantic similarities (Wang *et al.* 2018; Zhao *et al.* 2016), emotion detection (Abdul-Mageed and

Ungar, 2017; Eisner *et al.* 2016), improving word similarity detection (Schwartz *et al.* 2015; Faruqui *et al.* 2016) and polysemy detection (Arora *et al.* 2018; Jauhar *et al.* 2015) and removing gender bias in embeddings (Bolukbasi *et al.* 2016). The applications of word2vec can extend to domains far from computer science such as urban planning (Yao *et al.* 2017). Word2vec has been calculated for Turkic languages (Akın and Akın, 2007) as well.

The human genome consisting of 3 billion letters can be considered as a long string and thus subject to word embedding studies. This long string can be divided into constant or variable-length k-mers to produce words. In order to reveal semantic and syntactic relationships between the k-mers in human genome, the dna2vec study was carried out by using word2vec method (Ng, 2017).

Dna2Vec method, using variable-length k-mers training in two-layer neural network, demonstrated correlation between Needleman-Wunsch alignment score and dna2vec cosine similarity of k-mers. Needleman-Wunsch algorithm (Needleman *et al.* 1970) measures sequence similarity between to k-mers by global alignment approach. In addition, summing dna2vec embedding vectors for two k-mers is equivalent to concatenated k-mer. For example;

$$\text{vec}(\text{AAC}) + \text{vec}(\text{TCT}) \approx \text{vec}(\text{AACTCT})$$

or

$$\text{vec}(\text{AAC}) + \text{vec}(\text{TCT}) \approx \text{vec}(\text{TCTAAC})$$

In this study, we investigated relation between mutation dynamic and vector embeddings. Mutation is change of a letter in the genome, usually causing adverse effects in gene products resulting in diseases. There are no algorithms for predicting mutations and only technique to detect mutations is experimentally sequencing the DNA. In order find a technique to predict mutations, millions of known mutations and their affected words were compared with dna2vec vector embeddings. Our results show there is correlation with vector embedding and mutation count per k-mer suggesting vector embeddings have potential to predict mutations in genome.

2. Methods

2.1. Data Retrieval and dna2vec Script

Human genome hg38 and mouse genome mm10 downloaded from NCBI, common SNPs for human and mouse are downloaded from dbSNP ([dbSNP link](#)). Human dna2vec model was retrieved from dna2vec repository ([GitHub link](#)). Python scripts from dna2vec study are used to generate human and mouse dna2vec models (Ng, 2017). Human genome results were compared with results from mouse genome in order to show that our findings hold true for any organism. Also, mouse genome has comprehensive mutation data available.

2.2. Counting mutation per k-mer

We collected sliding window 8-mer around each mutation for nearly 35 million mutations in human and 73 million mutations in mouse. Then we counted occurrence of all k-mers and mutation pairs. Each pair contain coordinate and type of mutation in the k-mer.

2.3. Integration mutation and dna2vec data

For all 65,536 8-mers we generated 24 neighbors with hamming one distance for each coordinate of the k-mer. For a particular k-mer and its neighbor, we extracted mutation count and dna2vec cosine similarity.

2.4. Calculating correlation between mutations and cosine similarity

Using the data generated in previous step for each mutation in every coordinate for all the words we compared number of mutations and cosine similarity and prepared the confusion matrix.

3. Results

3.1. dna2vec Properties

As previously shown addition and subtraction vector embeddings correspond to concatenation and subtraction events in k-mers. Concatenation of a k-mer to another k-mer from right or from left generates two strings with comparable embeddings. (Figure 1A). Similarly, subtracting and then concatenating is applicable to embeddings (Figure 1B).

3.2 Mutation counts

We applied sliding window technique to the genome and we counted each mutation in every coordinate for all 8-mers. Figure 2 illustrates technique and genome-wide results for k-mers of interest. Mutation counts for both human and mouse genomes were calculated.




Figure 1. Schematic representation of concatenation and subtraction event in context of dna2vec embeddings.

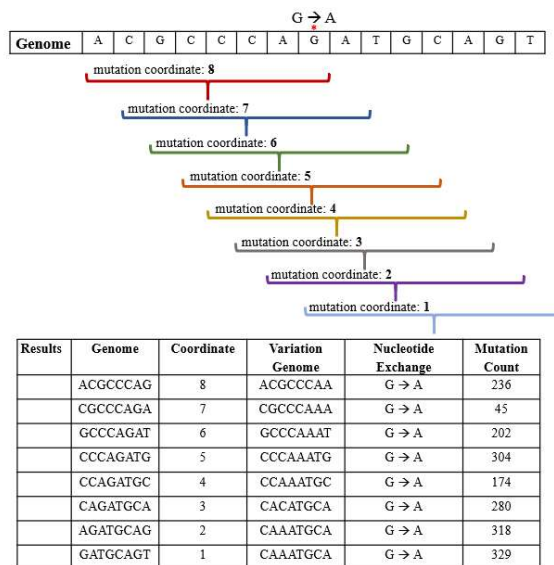


Figure 2: Mutation count for each sliding window k-mer overlapping a mutation. Top part depicts k-mers overlapping a mutation and coordinate of mutation in each k-mer. Bottom is generated after extracting and counting k-mers over all mutations.

3.3 Mutation counts vs. vector similarity

In order to quantify relationship between vector embeddings and mutation counts we used ranking of mutation counts and cosine similarity per coordinate. So, for a k-mer, all possible mutations at a particular coordinate were ranked according to mutation counts (rank 1 is the highest count). Similarly, for a particular

k-mer cosine similarity of all possible words generated by changing one letter (i.e. mutation) has been calculated and ranked (highest similarity is ranked 1). Only after, we calculated correlation between mutation occurrence and cosine similarity. We found that 80% of human mutations and 70% of mouse mutations have overlapping top rank with cosine similarity. Table 1 lists k-mers carrying mutations with highest mutation count and highest cosine similarity.

Table 1: Mutation counts and cosine similarity values. For the k-mer TGAGCACT, each possible neighbor with hamming distance one has been listed and for each neighbor, mutation count and cosine similarity has been calculated. The numbers in parenthesis indicate ranking of mutation within given coordinate.

	Conversion	Mutation	Cosine
	n	Count	Similarity
T	T → A	50 (3)	0.6481 (1)
	T → G	90 (2)	0.6410 (2)
	T → C	277 (1)	0.5936 (3)
G	G → T	52 (3)	0.6190 (1)
	G → A	343 (1)	0.5888 (2)
	G → C	106 (2)	0.5191 (3)
A	A → G	162 (1)	0.5550 (1)
	A → C	45 (2)	0.5400 (2)
	A → T	33 (3)	0.5215 (3)
G	G → A	452 (1)	0.5696 (1)
	G → T	69 (3)	0.5490 (2)
	G → C	82 (2)	0.5370 (3)
C	C → T	301 (1)	0.6268 (1)
	C → G	66 (3)	0.5402 (2)
	C → A	109 (2)	0.5014 (3)
A	A → G	293 (1)	0.6137 (1)
	A → T	69 (3)	0.6101 (2)
	A → C	127 (2)	0.5726 (3)
C	C → T	379 (1)	0.6706 (1)
	C → G	135 (2)	0.6256 (2)
	C → A	75 (3)	0.6208 (3)
T	C → T	283 (1)	0.7887 (1)
	C → G	68 (2)	0.7461 (2)
	C → A	50 (3)	0.7352 (3)

Figure 3 illustrates overlap of mutation count and cosine similarity rankings per coordinate for a particular 8-mer. For the first coordinate of the k-mer TGAGCACT, T → C mutation has the highest ranking compared to T → G and T → A mutations. On the other hand, word generated by T → A change has the highest cosine similarity ranking when compared to words generated by T → G and T → C changes. When all coordinates are examined, at 6 out of 8 coordinates, top ranks for mutation and cosine similarity overlaps.



Figure 3: Relation between the mutation count and cosine similarity. Letters above and below indicate ranking of mutation counts and cosine similarity, respectively, in decreasing order.

3.4 Confusion Matrix

We prepared the confusion matrix for both human and mouse (Table 2, Table 3) in order to assess predictive power of cosine similarity to predict experimental mutations. Ranking order per coordinate has been considered as features to be compared. The confusion matrix show that accuracy values are 0.7974 and 0.8322 for mouse and human, respectively.

Table 2: Confusion matrix for mouse

Prediction (Cosine Similarity)	Reference (Mutation Rank)		
	1	2	3
1	7174	123	2
2	1182	328	33
3	428	165	105

Summary of Statistics			
	Class: 1	Class: 2	Class: 3
Sensitivity	0.8167	0.5325	0.7500
Specificity	0.8347	0.8639	0.9369
Accuracy	0.7974		

4. Conclusions

dna2vec has been previously shown to exhibit concatenation and similarity properties for k-mer vectors. Our study showed that dna2vec can also reveal mutation susceptibility of k-mers. Our findings suggest that by using dna2vec, mutation susceptibility of k-mers can be predicted by processing the genome sequence alone even if no experimental result is available.

Table 3: Confusion matrix for human

Prediction (Cosine Similarity)	Reference (Mutation Rank)		
	1	2	3
1	2073	16	0
2	307	33	4
3	64	35	6

Summary of Statistics

	Class: 1	Class: 2	Class: 3
Sensitivity	0.8482	0.39286	0.600000
Specificity	0.8298	0.87327	0.960839
Accuracy	0.8322		

This indicates that mutation susceptibility information is inherent and embedded within genome sequence and dna2vec can unlock it. With our approach, genomes of numerous organisms can be analyzed for mutation susceptibility, paving the way to comparison mutation dynamics or mechanisms among different organism without experimental mutation data. Moreover, dna2vec has potential to unveil the traces of yet undiscovered biological mechanisms effecting k-mers in genome. Finally, dna2vec opens up the genome to various applications of artificial intelligence by converting DNA sequences into fixed length, transformed embeddings.

Acknowledgment

Code and data used in this study are available at https://github.com/alpervilmaz/dna2vec_snp

References

Abdul-Mageed, M., & Ungar, L. (2017, July). Emonet: Fine-grained emotion detection with gated recurrent neural networks. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* (pp. 718-728).

Akin, A. A., & Akin, M. D. (2007). Zemberek, an open source nlp framework for turkic languages. *Structure*, 10, 1-5.

Arora, S., Li, Y., Liang, Y., Ma, T., & Risteski, A. (2018). Linear algebraic structure of word senses, with applications to polysemy. *Transactions of the Association for Computational Linguistics*, 6, 483-495.

Bolukbasi, T., Chang, K. W., Zou, J. Y., Saligrama, V., & Kalai, A. T. (2016). Man is to computer programmer as woman is to homemaker? debiasing word embeddings. In *Advances in neural information processing systems* (pp. 4349-4357).

Chen, M. (2017). Efficient vector representation for documents through corruption. *arXiv preprint arXiv:1707.02377*.

Chen, X., & Lawrence Zitnick, C. (2015). Mind's eye: A recurrent visual representation for image caption generation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2422-2431).

De Boom, C., Van Canneyt, S., Bohez, S., Demeester, T., & Dhoedt, B. (2015, November). Learning semantic similarity for very short texts. In *2015 IEEE International Conference on Data Mining Workshop (ICDMW)* (pp. 1229-1234). IEEE.

Dos Santos, C., & Gatti, M. (2014, August). Deep convolutional neural networks for sentiment analysis of short texts. In *Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics: Technical Papers* (pp. 69-78).

Eisner, B., Rocktäschel, T., Augenstein, I., Bošnjak, M., & Riedel, S. (2016). emoji2vec: Learning emoji representations from their description. *arXiv preprint arXiv:1609.08359*.

Faruqui, M., Tsvetkov, Y., Rastogi, P., & Dyer, C. (2016). Problems with evaluation of word embeddings using word similarity tasks. *arXiv preprint arXiv:1605.02276*.

Gladkova, A., Drozd, A., & Matsuoka, S. (2016, June). Analogy-based detection of morphological and semantic relations with word embeddings: what works and what doesn't. In *Proceedings of the NAACL Student Research Workshop* (pp. 8-15).

Jauhar, S. K., Dyer, C., & Hovy, E. (2015). Ontologically grounded multi-sense representation learning for semantic vector space models. In *Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies* (pp. 683-693).

Kiros, R., Salakhutdinov, R., & Zemel, R. S. (2014). Unifying visual-semantic embeddings with multimodal neural language models. *arXiv preprint arXiv:1411.2539*.

Kusner, M., Sun, Y., Kolkin, N., & Weinberger, K. (2015, June). From word embeddings to document distances. In *International conference on machine learning* (pp. 957-966).

Le, Q., & Mikolov, T. (2014, January). Distributed representations of sentences and documents. In *International conference on machine learning* (pp. 1188-1196).

Levy, O., & Goldberg, Y. (2014, June). Linguistic regularities in sparse and explicit word representations. In *Proceedings of the eighteenth conference on computational natural language learning* (pp. 171-180).

Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.

Mikolov, T., Yih, W. T., & Zweig, G. (2013, June). Linguistic regularities in continuous space word representations. In *Proceedings of the 2013 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies* (pp. 746-751).

- Needleman, S. B., & Wunsch, C. D. (1970). *A general method applicable to the search for similarities in the amino acid sequence of two proteins*. *Journal of Molecular Biology*, 48(3), 443–453. doi:10.1016/0022-2836(70)90057-4
- Ng, P. (2017). dna2vec: Consistent vector representations of variable-length k-mers. arXiv preprint arXiv:1701.06279. 45
- Pedersoli, M., Lucas, T., Schmid, C., & Verbeek, J. (2017). Areas of attention for image captioning. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 1242-1250).
- Perozzi, B., Al-Rfou, R., & Skiena, S. (2014, August). Deepwalk: Online learning of social representations. In *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 701-710). ACM.
- Preoțiuc-Pietro, D., Lampos, V., & Aletas, N. (2015, July). An analysis of the user occupational class through Twitter content. In *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)* (pp. 1754-1764).
- Preoțiuc-Pietro, D., Liu, Y., Hopkins, D., & Ungar, L. (2017, July). Beyond binary labels: political ideology prediction of twitter users. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* (pp. 729-740).
- Schwartz, R., Reichart, R., & Rappoport, A. (2015, July). Symmetric pattern based word embeddings for improved word similarity prediction. In *Proceedings of the nineteenth conference on computational natural language learning* (pp. 258-267).
- Sienčnik, S. K. (2015, May). Adapting word2vec to named entity recognition. In *Proceedings of the 20th nordic conference of computational linguistics, nodalida 2015, may 11-13, 2015, vilnius, lithuania* (No. 109, pp. 239-243). Linköping University Electronic Press.
- Uricchio, T., Ballan, L., Seidenari, L., & Del Bimbo, A. (2017). Automatic image annotation via label transfer in the semantic space. *Pattern Recognition*, 71, 144-157.
- Wang, Y., Liu, S., Afzal, N., Rastegar-Mojarad, M., Wang, L., Shen, F., ... & Liu, H. (2018). A comparison of word embeddings for the biomedical natural language processing. *Journal of biomedical informatics*, 87, 12-20.
- Yang, X., Macdonald, C., & Ounis, I. (2018). Using word embeddings in twitter election classification. *Information Retrieval Journal*, 21(2-3), 183-207.
- Yao, Y., Li, X., Liu, X., Liu, P., Liang, Z., Zhang, J., & Mai, K. (2017). Sensing spatial distribution of urban land use by integrating points-of-interest and Google Word2Vec model. *International Journal of Geographical Information Science*, 31(4), 825-848.
- Zhao, Z., Yang, Z., Luo, L., Lin, H., & Wang, J. (2016). Drug drug interaction extraction from biomedical literature using syntax convolutional neural network. *Bioinformatics*, 32(22), 3444-3453.



Makine Seçim Probleminin Bulanık VIKOR Yöntemiyle İncelenmesi

Rümeysa Faydalı¹, Enes Furkan Erkan^{2*}

^{1,2}Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü

rumeysa.faydali, eneserkan@ogr.sakarya.edu.tr

Öz

Firmalar için üretim, hedeflerini gerçekleştirmede büyük bir öneme sahip olan işletme fonksiyonudur. İnsan, malzeme ve makineden oluşan sistemi başarılı yöneten işletmeler üretim sistemlerini kolaylıkla iyileştirebilir. Üretim faktörlerinin uyumlu olması ve işletme hedeflerine uygun bir şekilde planlanmış olması uzun ömürlü yaşam döngüsü için hayati önem taşımaktadır. Hedeflere uygun karar alınabilmesi için karar vericilerin çok sayıda kriteri değerlendirmesi gerekmektedir. En uygun kararların alınabilmesi, işletmelerde verimlilik ve başarının artması demektir. Makine seçimi de firmalar için üretimdeki verimliliği arttırmada çözülmesi gereken bir karar verme problemidir. Firmalar bu sebeple makine seçim değerlendirmesini detaylıca ele almalı ve çözmeye çalışmalıdır. Bulanık VIKOR yöntemi bir çok kriterli karar verme yöntemidir ve maksimum grup faydasını ve minimum bireysel pişmanlığı tespit edip, uzlaştırıcı bir çözüm oluşturur. Uygulamada bulanık VIKOR yöntemi kullanılarak bir tekstil firmasının yeni bir makine seçim problemi ele alınmıştır. Bu süreçte dört alternatif, beş karar verici tarafından yedi kritere göre değerlendirilip hesaplanan sonuçlara göre sıralanmıştır. Uygulama ile bulanık VIKOR yönteminin yeni bir makine seçiminde etkin bir yöntem olarak kullanılabilmesi sonucuna ulaşılmıştır.

Anahtar kelimeler: Bulanık Mantık, Bulanık VIKOR, Makine Seçimi.

A Fuzzy VIKOR Method for Machine Selection

Abstract

For companies, production is a business function. Human, material and machine creates production system. The use of decision-makers is very important in order to make decisions in accordance with their objectives. For this reason, companies should consider machine selection. The Fuzzy VIKOR method is a multi-criteria decision-making method and a conciliatory analysis of finding maximum group benefit and minimum regret. In practice VIKOR method design a textile company to address the problem of selecting a new machine. In this process, five experts were evaluated according to the first seven criteria and four alternatives were ranked according to the calculated results. The VIKOR method is used as an effective method for selecting a new machine.

Keywords: Fuzzy Logic, Fuzzy VIKOR, Machine Selection.

1. Giriş

Günümüz şartlarında rekabet eden üretim işletmelerinin öncelikli amacı etkin kaynak kullanımı ile hizmet veya mal üretip sürdürülebilirliği oluşturmaktır. İşletmeler için kaynak kullanımını etkin hale getirmek ve rekabet avantajı sağlamak için en önemli noktalardan biri makine seçimi konusudur. Doğru makine seçimi

verimliliği, üretimin kalitesini, maliyeti ve birçok önemli fonksiyonu doğrudan etkilediği için oldukça önemli bir konudur. Bu yüzden karar verme sürecinde yönetsel bir işleyişe ihtiyaç duyulduğundan bir yatırım problemi olarak da ele alınmalıdır.

Makine seçimi problemi, verimliliği, üretimin performansını etkileyen bir karar ve aynı zamanda uzmanlık gerektiren oldukça önemli bir süreçtir.

* Sorumlu yazar: Enes Furkan Erkan
E-posta adresi: eneserkan@sakarya.edu.tr

Alındı : 20 Oca 2020
Revizyon : 04 Şub 2020
Kabul : 15 Şub 2020

(Arslan, 2004). Bu sebeple doğru ve en olası makine seçimi firmayı verimlilik artışıyla beraber başarıya götürür (Önüt, 2008). Makine seçim probleminde kriterlere göre alternatiflerin değerlendirilmesi söz konusu olduğundan çok kriterli karar verme (ÇKKV) problemi olarak ele alınabilir.

Makine seçim problemlerinde, çok kriterli karar verme yöntemlerinden en sık kullanılanlar arasında analitik hiyerarşi sürecinin yer aldığı görülmektedir. (Tabucanon vd., 1994; Lin ve Yang, 1996; Yurdakul, 2004) yaptıkları çalışmalarda çeşitli kriterler kullanarak alternatifler arasında analitik hiyerarşi süreci ile seçim yapmışlardır. Ayrıca birçok yöntem ile makine seçim problemi çalışılmıştır.

Uygulamada, makine seçim probleminde Bulanık VIKOR yönteminin kullanılması ile çözüm geliştirilmesi amaçlanmıştır. Makine seçim uygulamalarında birçok çok kriterli karar verme yöntemi kullanılmaktadır. Bulanık VIKOR yöntemi, makine seçimi için de çeşitli problemlerdeki alternatiflerin seçimi için sıklıkla kullanılmaktadır.

Anlaşılabilir olma ve hesaplama konusunda sağladığı kolaylıklar ve Excel programında çözümün mümkün olması, Bulanık VIKOR yöntemini literatürde sıklıkla kullanılan yöntemlerden biri haline getirmiştir.


2. Yöntem

Geleneksel küme yaklaşımında karar vericilerin tercihlerini, düşüncelerini ifade etmede belirsiz kalması bu yöntemle çözümü zorlaştırabilmektedir. (Zadeh,1965) belirsizlik durumunu yok etmek için bulanık küme teorisini bulmuştur. Bulanık küme teorisine, tercihlerdeki belirsizlik, muğlaklık durumunu çözmeyi ve karar verme sürecinde dilsel değişkenleri kullanmayı amaçlamıştır. Bulanık çok kriterli karar verme teknikleri, kalitatif ya da eksik bilgiyi gidermede kullanılır (Opricovic, 2011). Bulanık VIKOR yöntemi de bu tekniklerden biridir. Bulanık VIKOR ile dilsel değişkenler kolaylıkla bulanık sayılara çevrilebilir. Üçgen üyelik fonksiyonları hesaplamalardaki kolaylık ve çözüme daha kolay ulaşabilme adına uygulamalarda sıklıkla kullanılmaktadır. Üçgen üyelik fonksiyonu bu uygulamada da kullanılmıştır.

Teoride kesin yargılar yerine doğal dilde kullanılan ifadeleri içeren dilsel değişkenler kullanılmaktadır. (Çakır ve Canbolat, 2008). Çözümleme için dilsel değişkenler bulanık sayılara dönüştürülmelidir. Bulanık sayı da özel bir bulanık kümedir. ($\tilde{A} = X \in R \mid \mu_{\tilde{A}}(x)$) Burada x , reel doğru üstündeki $R1 = -\infty < x < \infty$ değerlerdir ve üyelik fonksiyonu $\mu_{\tilde{A}}(x)$ ise $[0,1]$ aralığındadır.

Bulanık üyelik fonksiyonları farklı türlerde olabilmektedir. Bu çalışmada ise üçgen bulanık

sayılar kullanılarak çözüme gidilmiştir.



Şekil 1. Üçgen Bulanık Sayının Üyelik Fonksiyonu

Burada l , \tilde{M} bulanık sayısının alt değeri ve u , \tilde{M} bulanık sayısının üst değeridir, m ise orta değerdir. (Seçme vd., 2009):

Çok kriterli karar verme tekniklerinde gerçek değerler kullanılarak kriter ağırlıkları belirlenir ve değerlendirme bu şekilde yapılır. Gerçek hayatta ise bu her zaman böyle olmamaktadır. Kesin yargılar kullanmak her zaman mümkün olmadığı gibi ifadeler muğlak olabilmektedir. Sorunu yok etmek için Zadeh (1965) bulanık mantığı ortaya koymuştur. Bu mantıkta kesin olmayan yargıları dilsel değişkenler yardımıyla ifade edebilmek mümkün olmuştur. Bulanık mantık, çok kriterli karar verme tekniklerinde sıklıkla kullanılmaya başlanmıştır. VIKOR yöntemi de bunlardan biridir. Bulanık VIKOR yönteminin uygulama aşamaları aşağıdaki gibidir. (Chen ve Wang, 2009; Moeinzadeh ve Hajfathaliha, 2009)

Adım 1. İlk olarak karar vericiler belirlenir. Karar verici grup tarafından değerlendirme kriterleri ve alternatifler belirlenir. Karar verici sayısı n , alternatif sayısı m ve kriter sayısı k olarak kabul edilir.

Adım 2. Daha sonra dilsel değişkenler ve bu değişkenler için bulanık sayılar belirlenir. Dilsel değişkenler ve bulanık sayı karşılıkları Tablo 1'deki gibidir.

Adım 3. Belirlenen sonuçlar bir araya getirilir. Her kriter için aşağıdaki formülle bütünleştirilmiş ağırlık hesaplanır. Denklemden n karar verici sayısını ifade eder.

$$\tilde{W}_j = \frac{1}{n} \left[\sum_{e=1}^n \tilde{W}_j^e \right] \quad j = 1, 2, \dots, k \quad (1)$$

$$\tilde{x}_{ij} = \frac{1}{n} \left[\sum_{e=1}^n \tilde{x}_{ij}^e \right] \quad i = 1, 2, \dots, m \quad (2)$$

Adım 4. 3. Adım tamamlandıktan sonra alternatif ve kriterlere göre bulanık karar matrisi ve bulanık ağırlık matrisi oluşturulur.

$$D = \begin{bmatrix} \tilde{x}_{11} & \dots & \tilde{x}_{1n} \\ \vdots & \ddots & \vdots \\ \tilde{x}_{m1} & \dots & \tilde{x}_{mk} \end{bmatrix} \quad i = 1, 2, \dots, m; j = 1, 2, \dots, k \quad (3)$$

$$\widetilde{W} = [\widetilde{W}_1, \widetilde{W}_2, \dots, \widetilde{W}_k] \quad j = 1, 2, \dots, k \quad (4)$$

Adım 5. Bu adımda bulanık en iyi ve bulanık en kötü değerler aşağıdaki formüllerle belirlenir.

$$\widetilde{f}_j^* = \max_i \widetilde{x}_{ij}, \quad \widetilde{f}_j^- = \min_i \widetilde{x}_{ij} \quad (5)$$

Adım 6. \widetilde{S}_i^* ve \widetilde{R}_i^* değerleri hesaplanır. \widetilde{S}_i^* değeri, i. alternatifte her bir kriter değerinin bulanık en iyi değere uzaklığının toplamını verirken, \widetilde{R}_i^* ise j. kritere göre i. alternatifinin bulanık en kötü değere olan uzaklığının maksimumunu verir. Dolayısıyla \widetilde{S}_i ve \widetilde{R}_i değerleri i. alternatifin ortalama ve en kötü skorlarını göstermektedir.

$$\widetilde{S}_i = \sum_{j=1}^k \widetilde{W}_j (\widetilde{f}_j^* - \widetilde{x}_{ij}) / (\widetilde{f}_j^* - \widetilde{f}_j^-) \quad (6)$$

$$\widetilde{R}_i = \max_j [\widetilde{W}_j (\widetilde{f}_j^* - \widetilde{x}_{ij}) / (\widetilde{f}_j^* - \widetilde{f}_j^-)] \quad (7)$$

Adım 7. \widetilde{S}_i^* , \widetilde{S}_i^- , \widetilde{R}_i^* ve \widetilde{R}_i^- değerleri hesaplanır. \widetilde{S}_i^* maksimum çoğunluk kuralını ve \widetilde{R}_i^* ise farklı görüşte olanların bireysel pişmanlıklarının minimumunu verir.

$$\widetilde{S}_i^* = \min_i \widetilde{S}_i, \quad \widetilde{S}_i^- = \max_i \widetilde{S}_i \quad (8)$$

$$\widetilde{R}_i^* = \min_i \widetilde{R}_i, \quad \widetilde{R}_i^- = \max_i \widetilde{R}_i \quad (9)$$

Bu hesaplamalardan sonra \widetilde{Q}_i indeksi elde edilir. \widetilde{Q}_i indeksi, \widetilde{S}_i^* , \widetilde{S}_i^- , \widetilde{R}_i^* ve \widetilde{R}_i^- değerlerinin birlikte değerlendirilmesiyle belirlenir. v ise stratejiler arasında maksimum grup faydasını sağlayanın ağırlığını belirtir. Çoğunluk için uzlaşmacı olmak üzere $v \approx 0.5$ alınabilir. (Opricovic, 2011)

$$\widetilde{Q}_i = \frac{v(\widetilde{S}_i^* - \widetilde{S}_i^-)}{\widetilde{S}_i^* - \widetilde{S}_i^-} + (1 - v)(\widetilde{R}_i^- - \widetilde{R}_i^*) / (\widetilde{R}_i^- - \widetilde{R}_i^*) \quad (10)$$

Adım 8. Bu adımda üçgensel bulanık sayı \widetilde{Q}_i durulaştırılarak Q_i indeksi elde edilir. Literatür çalışmalarında birçok farklı durulaştırma yöntemleri kullanılmaktadır. Formüle göre; u_i , üçgen bulanık

Tablo 1. Dilsel Değişkenler Ve Bulanık Sayı Karşılıkları

Kriter ağırlıkları için kullanılan değişkenler		Alternatiflerin derecelendirilmesi için kullanılan değişkenler	
Dilsel Değişkenler	Bulanık Sayı Karşılıkları	Dilsel Değişkenler	Bulanık Sayı Karşılıkları
(ÇD) Çok Düşük	(0, 0, 0.25)	(ÇK) Çok Kötü	(0, 0, 2.5)
(D) Düşük	(0, 0.25, 0.5)	(K) Kötü	(0, 2.5, 5)
(O) Orta	(0.25, 0.5, 0.75)	(İ) İyi	(2.5, 5, 7.5)
(Y) Yüksek	(0.5, 0.75, 1)	(İİ) Çok İyi	(5, 7.5, 10)
(ÇY) Çok Yüksek	(0.75, 1, 1)		

sayının üst değerini; m_i orta değerini ve l_i ise alt değerini ifade etmektedir.

$$BNP_i = \frac{[(u_i - l_i) + (m_i - l_i)]}{3} + l_i \quad \forall_i \quad (11)$$

Alternatifler Q_i indeksine göre sıralanır. En küçük Q_i indeksine sahip alternatif en iyi alternatiftir.

Adım 9. Bu adım uzlaştırıcı çözümün belirlenmesi aşamasıdır. Bu adımda, belirlenen en iyi alternatifin en iyi uzlaştırıcı çözüm olup olmadığına karar verilmesi gerekir. Bunu belirleyebilmek için ise aşağıdaki koşullar değerlendirilmelidir.

- **Kabul Edilebilir Avantaj Koşulu:** Bu koşulda en iyi ve ona en yakın olan alternatif arasında bir fark var mı sorusunun cevabını aranır. Aşağıdaki formül sağlanırsa (A') en iyi uzlaştırıcı çözümdür diyebiliriz. (A') değeri Q_i indeksi en küçük olan yani en iyi alternatif iken (A'') ise en iyi ikinci alternatiftir.

$$Q(A'') - Q(A') \geq DQ \quad (12)$$

$DQ = 1/(1-m)$; m alternatif sayısını ifade eder. ($m \leq 4$ ise $DQ = 0.25$ alınır.)

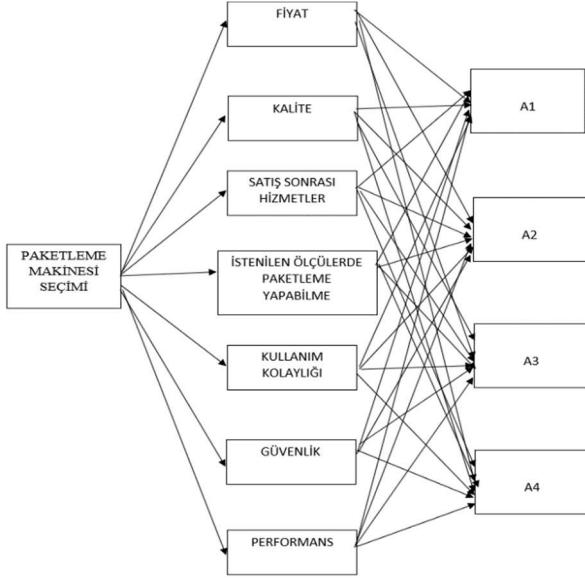
- **Kabul Edilebilir İstikrar Koşulu:** En iyi alternatif yani (A'), aynı zamanda S veya R değerlerinin sıralamasında da en iyi alternatif olmalıdır.

Eğer $Q(A^m) - Q(A') < DQ$ ise ve 1. koşul sağlanıyorsa (A^m) ve (A') alternatifleri benzer çözümlerdir diyebiliriz. Yani (A') alternatifi bir üstünlüğe sahip olmamıştır. 2. koşul sağlanmazsa, karar vermede istikrar yoktur demektir. Bu sebeple (A') ve (A'') uzlaştırıcı çözümleri aynıdır.

Adım 10. Q değeri en küçük olan alternatifi sıralamada en iyi alternatif olarak seçilebilir.

3. Uygulama

Çalışmada bir tekstil firmasının makine seçimi bulanık VIKOR yöntemi kullanılarak incelenmiştir. Sürecin hiyerarşik şekli aşağıdaki gibidir:



Şekil 2. Makine Seçiminin Hiyerarşik Yapısı

Uygulama bir tekstil firmasının kalite kontrol ve son işlem bölümünde kullanılmak istenen bir paketleme makinesinin seçimi sürecinde uygulanmıştır. Bu tekstil firmasında elastik ve mefruşat olmak üzere ürünler iki gruba ayrılmaktadır. Kalite kontrol aşamasında %100 kontrolü yapılan kumaşlar aynı zamanda rulolara sarılıp daha sonra paketlenmektedir. Firma elastik kumaşların kalite kontrolünün yapıldığı 5 makineden çıkan ürünler için paketleme işlemini bir makine yardımıyla yapmak istemektedir. Makine seçiminde dört alternatif arasından en doğru tercihi yapmayı hedeflemektedirler. Bu sebeple, alanında uzman kişilerden oluşan bir ekip kurulmuş ve sürece yönelik değerlendirme kriterleri belirlenmiştir. Uygulamanın adımları aşağıdaki şekildedir:

Adım 1: İlk adımda karar verici grubu oluşturulur. Çalışmada bir kalite güvence müdürü, kalite kontrol

müdür yardımcısı, fabrika genel müdür yardımcısı, mekatronik mühendisi ve kalite kontrol mühendisi olmak üzere alanında uzman 5 kişiden oluşan bir ekip kurulmuş ve 4 alternatife yönelik değerlendirme yapılmıştır. Literatür araştırması ve karar vericilerin görüşleri doğrultusunda Tablo 2’de gösterilen karar kriterleri belirlenmiştir.

Tablo 2. Karar Kriterleri

Kriterler	
K1	Fiyat
K2	Kalite
K3	Satış Sonrası Hizmetler
K4	İstenilen Ölçüde Paketleme Yapabilirliği
K5	Kullanım Kolaylığı
K6	Güvenlik
K7	Performans

Adım 2: Daha sonra kriterlerin ve alternatiflerin karar vericiler tarafından değerlendirilebilmesi için dilsel değişkenler belirlenmelidir. Uygulamada kullanılan dilsel değişkenler ve onların bulanık sayı karşılıkları Tablo 1’deki gibidir.

Adım 3: Bu adımda karar vericilerin belirlediği dilsel değişkenler bulanık sayı karşılıklarına çevrilmiş, daha sonra 3. ve 6. denklemler yardımıyla karar vericilerin tercih ve görüşleri bir araya getirilmiştir. Bu işlemler sonucunda Tablo 3’teki gibi bütünleştirilmiş ağırlıklar oluşturulmuştur.

Tablo 3. Kriterler için Bütünleştirilmiş Bulanık Ağırlık Matrisi

KRİTER	KRİTERLER		
	L	M	U
K1	0,6	0,85	1
K2	0,5	0,75	0,95
K3	0,55	0,8	0,95
K4	0,55	0,8	0,95
K5	0,35	0,6	0,8
K6	0,6	0,85	1
K7	0,55	0,8	0,95

Tablo 4. Alternatifler İçin Bulanık Karar Matrisi

	A1			A2			A3			A4		
	l	m	u	l	m	u	l	m	u	l	m	u
K1	3,5	6	8,5	4	6,5	8,5	6,5	9	10	4,5	7	9,5
K2	2	4,5	7	1	3,5	6	6,5	9	10	6,5	9	10
K3	6	8,5	10	5,5	8	9,5	3	5,5	8	3,5	6	8,5
K4	5	7,5	9	6	8,5	10	2	4,5	7	1,5	4	6,5
K5	5,5	8	9,5	2,5	5	7,5	2	4,5	7	5	7,5	10
K6	3,5	6	8,5	6	8,5	10	5,5	8	9,5	1	3,5	6
K7	5,5	8	10	3,5	6	8,5	5,5	8	10	6	8,5	10

Adım 5: Bulanık karar matrisi değerlendirilerek 7. denklem aracılığıyla kriterler için bulanık en iyi ve bulanık en kötü sonuçlar Tablo 5'teki gibi bulunmuştur.

Tablo 5. Bulanık En iyi ve Bulanık En Kötü Değerler

	F(*)			F(-)		
	l	m	u	l	m	u
K1	6,5	9	10	3,5	6	8,5
K2	6,5	9	10	1	3,5	6
K3	6	8,5	10	3	5,5	8
K4	6	8,5	10	1,5	4	6,5
K5	5,5	8	10	2	4,5	7
K6	6	8,5	10	1	3,5	6
K7	6	8,5	10	3,5	6	8,5

Adım 6: Alternatiflerin \tilde{S}_i ve \tilde{R}_i değerleri Tablo 6'daki gibi belirlenmiştir.

Tablo 6. \tilde{S}_i ve \tilde{R}_i Değerleri

	\tilde{S}_i			\tilde{R}_i		
	l	m	u	l	m	u
A1	1,541	2,226	2,492	0,600	0,850	1,000
A2	1,942	2,906	3,804	0,550	0,800	1,000
A3	1,559	2,356	2,689	0,550	0,800	0,950
A4	2,058	2,969	2,996	0,600	0,850	1,000

Adım 7: Tablo 6'daki değerlere göre 10 ve 11. denklemler yardımıyla \tilde{S}_i^* , \tilde{S}_i^- , \tilde{R}_i^* ve \tilde{R}_i^- değerleri Tablo 7'deki gibi hesaplanmıştır.

Tablo 7. \tilde{S}_i^* , \tilde{S}_i^- , \tilde{R}_i^* ve \tilde{R}_i^- değerleri

	l	m	u
S*	1,541	2,226	2,492
S-	2,058	2,969	3,804
R*	0,550	0,800	0,950
R-	0,600	0,850	1,000

Adım 8: Tablo 7'deki değerlere göre 12. denklem kullanılarak \tilde{Q}_i i değerleri belirlenmiştir. Denklemdeki v değeri genellikle 0.5 olarak kullanılmaktadır. Uygulamada da 0.5 olarak alınmıştır. Durulaştırma işlemi için ise 13. denklem kullanılmıştır ve sonuçlar Tablo 8'de verilmiştir. Elde edilen Q_i değerleriyle birlikte S_i ve R_i değerleri de Tablo 9'daki gibi sıralanmıştır.

Tablo 8. \tilde{Q}_i değerleri

Alter.	\tilde{Q}_i		
	n1	n2	n3
A1	0,500	0,500	0,500
A2	0,387	0,458	1,000
A3	0,017	0,087	0,075
A4	1,000	1,000	0,692

Tablo 9. \tilde{Q}_i , \tilde{S}_i ve \tilde{R}_i değerleri

	Q		S		R	
	İndeks	Sıra	İndeks	Sıra	İndeks	Sıra
A1	0,500	2	2,087	1	0,817	3
A2	0,667	3	2,884	4	0,783	2
A3	0,064	1	2,201	2	0,767	1
A4	0,897	4	2,674	3	0,817	4

Adım 9: Sonuca varılabilmesi son aşama olarak 2 koşulun sağlanıp sağlanmadığı kontrol edilir.

1.Koşul: Kabul edilebilir avantaj: Bu koşulda 14. Denklem göre $Q(A'') - Q(A') \geq 0.25$ şartı sağlanmalıdır. Uygulamaya göre elde edilen sonuç ; $Q(A'') - Q(A') = 0.500 - 0.064 = 0.436 \geq 0.25$ şeklindedir.

2.Koşul: Karar vermede kabul edilebilir istikrar: 2. koşula göre A' alternatifi S_i veya R_i sıralamasında da en iyi alternatif olmalıdır. Tablo 10'da Q_i , S_i ve R_i için alternatiflerin sıralaması verilmiştir. Tablodan görüldüğü üzere A3 alternatifi Q_i ve R_i sıralamasında en iyi alternatif olmuştur.

Tablo 10. Q_i , S_i ve R_i Değerlerine Göre Sıralanan Alternatifler

Q_i	A3 > A1 > A2 > A4
S_i	A1 > A3 > A4 > A2
R_i	A3 > A2 > A1 = A4

Yapılan değerlendirmede görüldüğü üzere A3 alternatifi kabul edilir avantaj ve kabul edilir istikrar koşullarını sağlamaktadır. Dolayısıyla A3 alternatifi en iyi sonucu veren uzlaşık çözümdür.

4. Sonuç

Uygun makine seçimi işletmelerde üretim planlamasının etkin ve verimli bir şekilde yapılmasını sağlar. Dolayısıyla makine seçimi önemli bir karar verme sürecine dayanır. Çalışmada karar vericiler için zor bir problem olan makine seçim problemi ele alınmıştır. Elastik ve mefruşat türünde kumaş üreten bir tekstil firmasına kalite kontrol ve son işlem departmanından kullanılmak üzere paketleme makinesi alımı amaçlanmıştır. Bunun için 4 alternatif belirlenmiştir. Ayrıca makine için 7 kriter belirlenmiştir. Bunlar; fiyat, kalite, satış sonrası hizmetler, istenilen ölçülerde paketleme yapabilme, kullanım kolaylığı, güvenlik, performanstır. Uygulamada bu karar verme problemini çözmek için çok kriterli karar verme teknikleri arasından Bulanık VIKOR seçilmiş ve çözümde kullanılmıştır. Karar vericiler, gerçek yaşam uygulamalarında belirsiz tercihler ve görüşler ifade edebilmektedir. Bu açıdan çalışmada sunulan bulanık çok kriterli karar verme yaklaşımı ile eksikliklerin giderilmesi mümkün kılınmıştır. 5 uzman görüşü dikkate alınarak yapılan hesaplamalar doğrultusunda

makine seçimi için seçilen kriterlerde en ideal sonucun A3 alternatifi olduğuna karar verilmiştir.

Gelecekteki çalışmalarda, farklı problemlere yönelik daha fazla kriter ve alternatiflerle de çözüme ulaşılabilir. Aynı zamanda farklı çok kriterli karar verme teknikleri ile Bulanık VIKOR yöntemi birleştirilerek uygulama yapılabilir. Bulanık VIKOR yöntemi proje seçimi, tesis yeri seçimi, tedarikçi seçimi, personel seçimi, farklı stratejik seçimler gibi çalışmalarda da çözüm yöntemi olarak kullanılabilir.

KAYNAKLAR

Arslan, MÇ., Çatay, B., Budak, E., (2004). A Decision Support System For Machine Tool Selection, *Journal of Manufacturing Technology Management*, 15(1), 101-109.

Chen, L.Y. ve Wang, T.C. (2009) “Optimizing partners’ choice in IS/IT Outsourcing Projects: The Strategic Decision of Fuzzy VIKOR” *International Journal of Production Economics*, 120:233-242.

Çakır, O., Canbolat, MS.. (2008) A web-based decision support system for multi-criteria inventory classification using fuzzy AHP methodology, *Expert Systems with Applications*, 35(3), 1367-1378.

Lin, Z.C. ve Yang, C.B. (1996) Evaluation of machine selection by the AHP method. *Journal of Materials Processing Technology*, 57: 253-258.

Moeinzadeh, P. ve Hajfathaliha, A. (2009) A Combined Fuzzy Decision Making Approach to Supply Chain Risk Assessment. *World Academy of Science, Engineering and Technology*, (60): 519-535.

Opricovic, S., (2011). Fuzzy VIKOR with an application to water resources planning, *Expert Systems with Applications*, 38(10), 12983-12990.

Önüt, S., Kara, SS., Efendigil, T. (2008). A Hybrid Fuzzy MCDM Approach To Machine Tool Selection, *Journal of Intelligent Manufacturing*, 19(4), 443–453.

Seçme, NY., Bayrakdaroğlu, A., Kahraman, C. (2009) Fuzzy performance evaluation in Turkish banking sector using analytic hierarchy process and TOPSIS, *Expert Systems with Applications*, 36(9), 11699-11709.

Tabucanon, M. T., Batanov, D. N. ve Verma, D. K. (1994) Intelligent Decision Support System (DSS) for the Selection Process of Alternative Machines for Flexible Manufacturing Systems (FMS). *Computers in Industry*, 25: 131-143.

Yurdakul, M. 2004. AHP as a Strategic Decision-Making Tool to Justify Machine Tool Selection. *Journal of Materials Processing Technology*, 146: 365-376.

Zadeh, L.A. (1965), *Fuzzy Sets. Information and Control* 8, 338-383.