



VOLUME: 1 (2018)

ISSUE: 2



Journal of Investigation on Engineering & Technology

<http://dergipark.gov.tr/jiet>



PUBLISHER:

Yayıncı

JIET Founding Committee

JIET FOUNDING COMMITTEE:

JIET Kurucu Kurul

Dr. Canan AKSOY
Dr. Emin TUĞCU
Dr. Erol İSKENDER
Dr. Hamdi Tolga KAHRAMAN
Dr. Hasan Tahsin ÖZTÜRK

EDITOR IN CHIEF:

Baş Editör

Dr. Hasan Tahsin ÖZTÜRK

EDITORS:

Editörler

Dr. Canan AKSOY
Dr. Emin TUĞCU
Dr. Erol İSKENDER
Dr. Hamdi Tolga KAHRAMAN

EDITORIAL BOARD:

Yayın Kurulu

Dr. Adem DOĞANGÜN (Uludağ University)
Dr. Umut TOPAL (Karadeniz Technical University)
Dr. Zeki KARACA (Ondokuz Mayıs University)
Dr. Tayfun DEDE (Karadeniz Technical University)
Dr. Egemen ARAS (Bursa Technical University)
Dr. Nurcan ÖZTÜRK (Karadeniz Technical University)
Dr. Ümit ÇALIK (Karadeniz Technical University)
Dr. Erdem TÜRKELİ (Ordu University)
Dr. Erdoğan DOĞDU (Çankaya University)
Dr. Şeref SAĞIROĞLU (Gazi University)
Dr. Güngör BAL (Gazi University)
Dr. M. Ali AKCAYOL (Gazi University)
Dr. Recep DEMİRCİ (Gazi University)
Dr. Tuncay YİĞİT (Süleyman Demirel University)
Dr. Ercan Nurcan YILMAZ (Gazi University)
Dr. Cemal YILMAZ (Gazi University)
Dr. Uğur GÜVENÇ (Düzce University)
Dr. Yusuf SÖNMEZ (Gazi University)
Dr. Eyüp GEDİKLİ (Karadeniz Technical University)

Product Information

Ürün Bilgisi

Volume **1** **Issue** **2** **December/2018**
Cilt *Sayı* *Aralık/2018*

Publisher **JJET Founding Committee**
Yayıncı *JJET Kurucu Kurulu*

Web Page **http://dergipark.gov.tr/jiet**
Web Sayfası

Date of Publication **December/2018**
Basım Tarihi *Aralık/2018*

Language **English/Turkish**
Yayın Dili *İngilizce/Türkçe*

Frequency **Published twice in a year**
Yayın Aralığı *Yılda iki kez yayınlanır*

Type of Publication **Periodical**
Yayın Türü *Sürelî yayın*

e-ISSN Number
e-ISSN Numarası

Yazışma Adresi

*Karadeniz Teknik Üniversitesi
Teknoloji Fakültesi
İnşaat Mühendisliği Bölümü
Çamlı M. Hacı Mehmet Baheddin Ulusoy
Cad. No:144 61830 Of / TRABZON
Telefon: +90 462 377 84 07
E-posta: jiet@ktu.edu.tr*

Makale gönderimi dergipark üzerinden yapılmaktadır. Tüm yayınlanan makalelere <http://dergipark.gov.tr/jiet> adresinden ulaşılabilir.

Correspondence Address

*Karadeniz Technical University
Faculty of Technology
Department of Civil Engineering
Çamlı M. Hacı Mehmet Baheddin Ulusoy
St. No:144 61830 Of / TRABZON
Phone: +90 462 377 84 07
E-mail: jiet@ktu.edu.tr*

Paper submission is done via dergipark. All published papers are available at <http://dergipark.gov.tr/jiet>.



CONTENTS

İçindekiler



Research Papers

(Araştırma Makaleleri)

Pages

Sayfalar

Artificial Neural Network-Based New Methodology for Modeling of Asphalt Mixtures and Comparison with IKE Method 1-13

Erol İSKENDER, Atakan AKSOY, Şükrü ÖZŞAHİN, Hamdi Tolga KAHRAMAN, Semih Dinçer KONAK

Development of Programming Learning Environment with Compiler Techniques 14-18

Sefa ARAS, Eyüp GEDİKLİ

Farklı Kür Koşullarının Kolemanit İkameli Betonların Dayanımına Etkisi 19-23

The Effect of Different Curing Conditions on Strength of Concrete Substituted Colemanite

Tuba KÜTÜK SERT, Cuma KARA

Beton Basınç Dayanımının JAYA ve Öğretme-Öğrenme Tabanlı Optimizasyon (TLBO) Algoritmalarıyla Modellenmesi 24-29

Modelling Compressive Strength of Concrete via Teaching-Learning Based Optimization and JAYA Algorithms

Hasan Tahsin ÖZTÜRK

Review Papers

Derleme Makaleler

Betonarme Binalarda Hasar Tespiti ve Hasar Belirleme Yöntemleri 30-36

Damage Detection and Damage Determination Methods in Reinforced Concrete Buildings

Yusuf YANIK, Gonca KAMBER YILMAZ, Temel TÜRKER

Artificial Neural Network-Based New Methodology for Modeling of Asphalt Mixtures and Comparison with IKE Method

Erol İSKENDER^{*1}, Atakan AKSOY^{1a}, Şükrü ÖZŞAHİN^{2b}, Hamdi Tolga KAHRAMAN^{3c}, Semih Dinçer KONAK^{4d}

¹Karadeniz Technical University, Faculty of Technology, Department of Civil Engineering, 61830, Trabzon

²Karadeniz Technical University, Faculty of Engineering, Department of Civil Engineering, 61080, Trabzon

³Karadeniz Technical University, Faculty of Engineering, Department of Industrial Engineering, 61080, Trabzon

⁴Karadeniz Technical University, Faculty of Technology, Department of Software Engineering, 61830, Trabzon

⁵Ministry of Environment and Urban Planning, General Directorate of Professional Services, 06510, Ankara

(Alınış / Received: 20.11.2018, Kabul / Accepted: 17.12.2018, Online Yayınlanma / Published Online: 31.12.2018)

Keywords

Intuitive k-nearest
neighbor estimator (IKE)
Artificial neural networks
(ANN)
Asphalt mixtures
Marshall stability test

Abstract: Artificial Neural Networks (ANNs) are the most adopted approach in modeling of engineering problems. In this paper, we have developed ANN-based a novel modeling approach for asphalt mixtures. The Flow, Stability and MQ of the mixtures have been modeled and predicted by the introduced ANN-based approach. The legibility, comprehensibility, consistency, estimation performance, standard deviation etc. of the presented approach has been compared the literature. The experimental studies have shown that the proposed approach provides robustness, stability and a high accuracy ratio for estimation the Flow, Stability and MQ. While this paper has presented a novel approach to modeling the asphalt mixtures, it has also verified the results of literature. Thus, powerful, efficient and alternative approaches were presented to the literature for modeling the asphalt mixtures.

1. Introduction

The major properties to be incorporated in bituminous paving mixtures are stability, durability, flexibility and skid resistance (in the case of wearing surface). Traditional mix design methods are established to determine the optimum asphalt content that would perform satisfactorily, particularly with respect to stability and durability. There are many mix design methods used throughout the world e.g. Marshall mix design method, Hubbard-field mix design method, Hveem mix design method, Asphalt Institute Triaxial method of mix design, etc. Out of these only two are widely accepted, namely Marshall Mix design method and Hveem mix design method [1]. Marshall mixture design procedure (ASTM D 1559) is used for designing the asphalt concrete mixes in Turkey. Two properties are determined from the Marshall test [2]. These are:

(a) The maximum load the specimen will carry before failure, which is known as the Marshall stability.

(b) The amount of deformation of the specimen before failure occurred, which is known as the Marshall flow.

Stability of asphalt concrete determines the performance of the highway pavement. Low stability in asphalt concrete may lead to various types of distress in asphalt pavements. Cracking, especially fatigue cracking, due to repeated loading has been recognized as an important distress problem in asphalt concrete pavements. The stability of asphalt concrete pavements depends on the stiffness of the mix, bitumen content, softening point of bitumen, viscosity of asphalt cement, grading of aggregate, construction practice, traffic, and climate conditions [3].

Flow is the ability of an HMA pavement to adjust to gradual settlements and movements in the subgrade without cracking. The flow may be regarded as an opposite property to the stability, determining the reversible behavior of the wearing course under traffic loads and affecting plastic and elastic properties of the asphalt concrete [4, 5].

The ratio of the Marshall stability to Marshall flow is termed the Marshall Quotient (MQ) and is an indication of stiffness of the mix and the resistance against the deformation of the asphalt concrete. MQ

*İlgili yazar: eroliskender@gmail.com ORCID: 0000-0001-7934-839X

^a ORCID: 0000-0001-5232-6465

^b ORCID: 0000-0001-8216-0048

^c ORCID: 0000-0001-9985-6324

^d ORCID: 0000-0002-5452-4606

values are calculated to evaluate the resistance of the deformation of the modified specimens. A higher value of MQ indicates a stiffer mixture and, hence, indicates that the mixture is likely more resistant [4-9].

The testing procedure in order to determine the Marshall stability, Marshall flow, and MQ is very time consuming and needs skilled workmanship. Due to this, if these values can be obtained for a standard mix by the help of another method as computer-aided data mining approaches, prepared specimens can be used for other mechanic test method.

Several alternative computer-aided data mining approaches have recently been developed. An instance is pattern recognition systems. These systems learn adaptively from experience and extract various discriminators. Artificial neural networks (ANNs) are one of the most widely used pattern recognition methods [10]. Detailed information about the applications of artificial neural networks in pavement engineering area can be found in the literature [11-18]. The relevant literature is summarized in detail [19]. It doesn't need for present the studies engaged in paper again and again.

Genetic programming (GP) is another alternative approach for the analysis of the rutting potential [20, 21]. GP may generally be defined as a supervised machine learning technique that searches a program space instead of a data space. Many researchers have employed GP and its variants to find out any complex relationships between the experimental data [22-25].

Recently, Aksoy et al. [26] introduced a novel approach for modeling stability test data. In the proposed model, the Intuitive k-Nearest Neighbor Estimator (IKE) based on genetic algorithm and k-nearest neighbor algorithm was used for understanding Marshall Parameters. The stability, flow and MQ values were interrogated with measured and predicted values. Using the genetic approach, the flow number, stability and MQ can accurately be estimated without carrying out sophisticated and time-consuming laboratory tests with any other testing equipment. Weighted features have a primary role in the value estimation of target parameters. Moreover, the proposed model successfully explores the effects of different features on the target parameters and predicts the real values of the parameters with a high accuracy rate. According to the experimental results, applying of IKE provides a high accuracy for the asphalt mixtures problem [26]. The IKE algorithm has been also applied to weight the parameters of synchronous motor and predict the excitation current of it. Please see the reference studies for detailed information about the IKE algorithm [26, 27].

Although the IKE model has been used in asphalt pavements area, it has not been compared the most frequently used model such as artificial neural networks (ANNs). The purpose of this study is to compare the performances of IKE and ANN for Marshall Test parameters and the MQ approach. Moreover, validity of IKE is researched on new samples prepared in laboratory at same parameters.

2. Materials and Method

2.1. Mixture design

Used aggregate combination was obtained from the Catak rock quarry in Trabzon province. Various engineering properties of coarse and fine aggregate were given in Table 1 and Table 2 and the gradation curve is shown in Figure 1. Asphalt cement with 50-70 penetration grades was used. Test results for bituminous binder supplied from Kirikkale oil refinery are given in Table 3. Design parameters were obtained with the ASTM D1559 Marshall method and optimum mixture parameters were presented in Table 4.

It was studied with 126 briquettes produced in the laboratory with the optimum asphalt cement content. 63 samples prepared with same parameters previously had been used IKE algorithm. Seven groups with nine samples had been created depending upon compaction energies. Seven samples had been used in the IKE for the training set and two samples had been used for the test set from each group [26].

Table 1. Properties of the used aggregate

Properties	Test Method	Value
L.A. Abrasion (%)	ASTM C-131	12.4
Flakiness (%)	BS 812 (Part 105)	14.3
Stripping resistance (%)	ASTM D-1664	30-35
Water absorption (%)	ASTM C-127	0.8
Soundness in NaSO ₄ (%)	ASTM C-88	1.1
Polished stone value	BS 812 (Part 114)	0.60
Plasticity index for sandy aggregate	TS 1900	non-plastic

Table 2. Aggregate specific gravities (g/cm³)

Grain-size fraction	Apparent specific gravity	Bulk specific gravity
Coarse aggregate	2.782	2.723
Fine Aggregate	2.800	2.703
Filler aggregate	2.885	-
Aggregate mixture	2.795	2.705

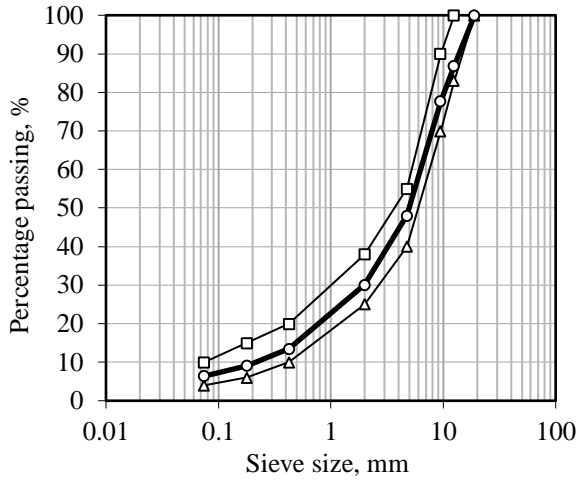


Figure 1. Aggregate distribution on gradation chart

In this research, 63 samples else produced with same parameters in addition to first paper. Also ANN was applied to samples apart from IKE. Same training set (49 samples) was used. Remained 77 Marshall briquettes were used for test set. Weights of IKE model were not changed and validity of model was investigated on new samples that are not introduced model before. Results of ANN which is the most used program in literature with results of IKE were compared. Properties of the samples used in the experimental stages are illustrated in Tables A1 and Table A2. Table A1 shows the training set sample properties while Table A2 gives test set properties.

Table 3. The results of tests performed on asphalt cement (AC 50-70)

Properties	Test Method	Unit	Value
Specific gravity (25°C)	ASTM D-70	gr/cm ³	1.027
Softening point (°C)	ASTM D36-76	°C	52
Flash point (Cleveland)	ASTM D-92	°C	210
Penetration (25°C)	ASTM D-5	0.1mm	65
Ductility (25°C)	ASTM D-113	cm	100+

Table 4. Marshall Design test results

Design parameters	Values	Board in Turkey	
		Min.	Max.
Bulk specific gravity, Gmb	2.438	-	-
Marshall stability, kg	1570	900	-
Air voids, Pa, %	4	3	5
Void filled with asphalt, Vf, %	71.5	75	85
Flow, F, 1/100 in.	3.3	2	4
Filler/bitumen	1.22	-	1.5
Asphalt cement, Wa	5.25		

2.2. The Intuitive k-nearest neighbor estimator (IKE method)

The IKE is an instance-based heuristic searching and prediction algorithm. It consists of genetic algorithm-based weight-tuning unit, similarity measurement unit and nearest-neighbor-based estimation unit. It heuristically explores the effectiveness and importance of input parameters/features on output parameters/target values of a problem. This process is called weighting. It is very useful for modeling the parameters of system and reveals the hidden states. Weighting of input parameters of a problem also improves the classification and prediction performance of nearest-neighbor-based algorithms. Flow chart of IKE algorithm was given in Figure 2.

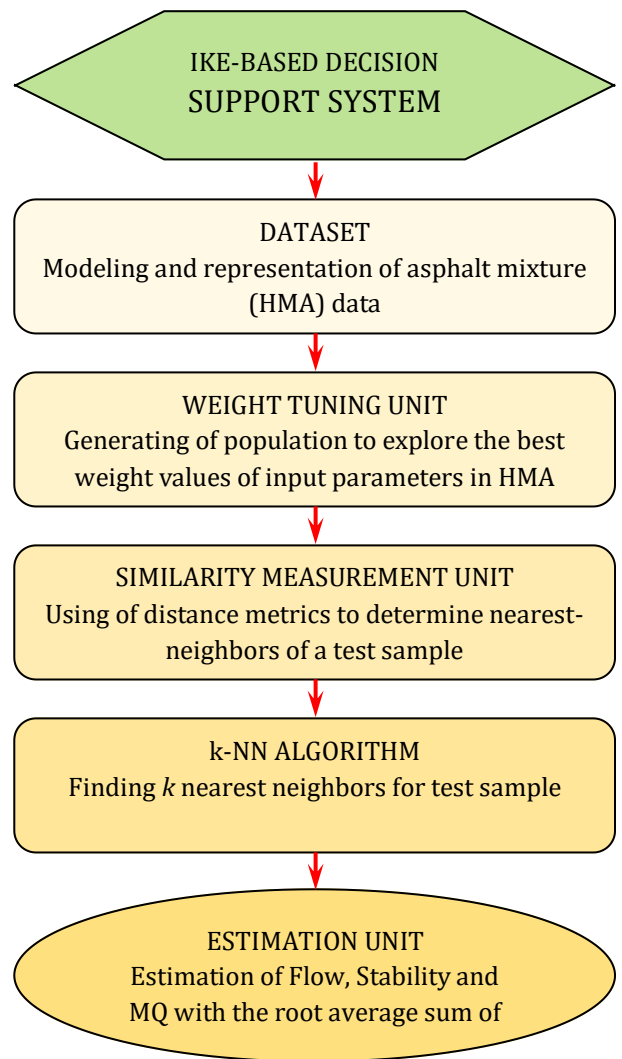


Figure 2. Steps for weighting the parameters of asphalt mixtures and predicting the flow, stability and MQ in IKE algorithm [26, 27]

- Dataset: In the IKE algorithm as is the case with most instance-based algorithms, a training and

test dataset is prepared. The datasets are used to represent a sample space of observations belong to a problem, to model the relationships between the features and target values of the instances and to verify the training achievement of algorithm. In the previous study, we used 49 sample observations to create the training dataset and 14 sample observations to create the test dataset for asphalt mixture problem.

- **Weight-tuning unit:** It heuristically searches the optimal weight values of each input parameter or feature on the target parameter(s) of observation belong to a problem. The weighting of features changes the results of distance measurements among the observations. Depending on these changes the nearest neighbors of a test observation can be changed. Consequently, in the nearest neighbor-based approaches the decision of algorithms also changes. According to the literature [28-30], the usage of weighted features in the distance metrics improves the similarity measurements and the performance of nearest neighbor-based algorithms. The optimal weight values are explored by the heuristic methods. One of the popular heuristic searching methods is the GA. In the previous study, we used the GA-based weighting method and explored the best weight values of features for the "Flow", "Stability" and "MQ" in asphalt mixtures. Please see the reference study for detailed information about the weight-tuning method and the optimal weight values of features in asphalt mixtures [26].
- **Similarity measurement unit:** It is used to measure the distances among a test observation and training (sample) observations. It creates n -dimensional (n is the number of training observations) distance array. The array is used to determine the nearest neighbors of test observation in the k-NN algorithm.
- **k-NN algorithm:** It determines the nearest neighbors of test observation(s) depending on the distance measurements.
- **Estimation unit:** It estimates the values of Flow, Stability and MQ for test observation depending on the k -nearest neighbors of it. The *root average sum of squares* method was used to estimate the target values in the previous study. Please see the previous study for more information [26].

2.3. Artificial neural network model

Engineering community is always looking for higher accuracy, speed and reliability while evaluating any engineering process. Neural networks have emerged as successful computational tools for studying a majority of pavement engineering problems [12]. Increasingly, modern pattern recognition techniques such as neural network are being considered to develop models from data to their ability to learn and

recognize trends in the data pattern [31].

Artificial neural networks (ANNs) are proposed on the research about modern neurobiology and human information processing by cognitive science, and they can achieve a variety of complex information processing functions by simulation of the neurons in the network structure and characteristics. ANN has the capability of establishing a functional relationship between two data spaces during a learning process and reproduce/generalize these data during a recall process. In other words, in one of their basic applications and after successful training, they can provide the correlating mathematical relationship between multi-dimensional input/output data sets [32].

Their inherited abilities such as nonlinear learning and noise tolerance make them particularly useful in situations where the problem is likely to change. ANN are especially useful at solving problems that cannot be clearly represented with a procedure, i.e. expressed as a series of steps, such as recognizing patterns, classification, series prediction and data mining [33].

The development of artificial neural network (ANN) models significantly depends on the experimental results. In the present work, blows, sample height (mm), density (g/cm^3), void (%), VMA (%), and VFA (%) were considered as the prime processing variables. The proposed ANN model was designed by software developed using the MATLAB Neural Network Toolbox. The data were obtained from previous study [26] and new samples were produced in laboratory. Among these data, 49 samples were selected for ANN training process, while the remaining 77 samples were used to verify the generalization capability of ANN. The data sets used in the prediction model are shown in Tables A1 and A2.

The ANN models, which have different network structures and parameters were constituted, and ANNs training processes were performed with MATLAB package software to determine weight and bias values and to minimize the mean square error. In order to determine the performance of networks, the models were tested using a set of data (namely test data) containing input-output pairs which were not utilized for training processes. Thus the most sensitive (appropriate) ANN result was targeted.

The obtained predicted values as a result of the testing process were compared with the real (measured) values. The model providing the best prediction values with respect to the root mean-square error (RMSE) ratio, calculated with Eq. 1, and the mean absolute percentage error (MAPE) ratio,

calculated with Eq.2, was chosen as the prediction model.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \dots \dots \dots \text{Eq. 1}$$

$$MAPE = \frac{1}{N} \left(\sum_{i=1}^N \left[\left| \frac{t_i - td_i}{t_i} \right| \right] \right) \times 100 \dots \dots \dots \text{Eq. 2}$$

In Eqs. 1 and 2, t_i is the actual output values, td_i is the neural network predicted values, and N is the number of objects. In Tables A1 and A2, the values calculated by utilizing this prediction model for the training and test data, real values, and predicted values are indicated.

Figures 3 and 4 show the ANN models containing 1 input layer, 2 hidden layers and 1 output layer. The selected ANN model represents the prediction model that produced the closest values to the measured values for the flow and stability. The blows, sample height (mm), density (g/cm³), void (%), VMA (%), and VFA (%) were used as the input variables, while the flow and stability values were used as the output variables in the ANN models. The processing element numbers (neurons) of the two hidden layers were chosen as 4 and 3 for the flow model in Figure 3, and 4 and 4 for the stability model in Figure 4 respectively.




Figure 3. The ANN architecture selected as the prediction model for the flow




Figure 4. The ANN architecture selected as the prediction model for the stability

A feed forward and back propagation multilayer ANN was used for solving problems, and the network training and testing was carried out using the MATLAB software package. In this study, the hyperbolic tangent sigmoid function (tansig) and the linear transfer function (purelin) were used as the activation transfer functions, the levenberg-marquardt algorithm (trainlm) was used as the training algorithm, the gradient descent with a momentum back propagation algorithm (traingdm) was used as the learning rule, and the mean square error (MSE) was used as the performance function. The mean square error (MSE) was calculated using Eq. 3.

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2 \dots \dots \dots \text{Eq. 3}$$

Where, t_i is the actual output (targeted values), td_i is the neural network output (predicted values), and N is the total number of training patterns.

To ensure an equal contribution of each parameter in the model, the training and test datasets were normalized (-1, 1 range) due to the use of the hyperbolic tangent sigmoid function in the model and network, which allowed the data to be translated into the original value, with a reverse normalizing process for the interpretation of the results. The normalization (scaling) operations were carried out using Eq. 4.

$$X_{norm} = 2 \times \frac{X - X_{min}}{X_{max} - X_{min}} \dots \dots \dots \text{Eq. 4}$$

In this equation, X_{norm} is the normalized value of a variable X (real value of the variable), and X_{max} and X_{min} are the maximum and minimum values of X , respectively.

It was decided that the 0.001 targeted MSE values would be sufficient for the training of the artificial neural networks. When MSE of ANN training process reached 0.001, the training was terminated and change of flow and stability were modeled with obtained network parameters.

The amounts of error variation depending on iteration of the selected artificial neural networks are shown in Fig. 5, for flow (Fig. 5a), stability (Fig. 5b). The number of epochs after which the training models were stopped is 47 and 8.

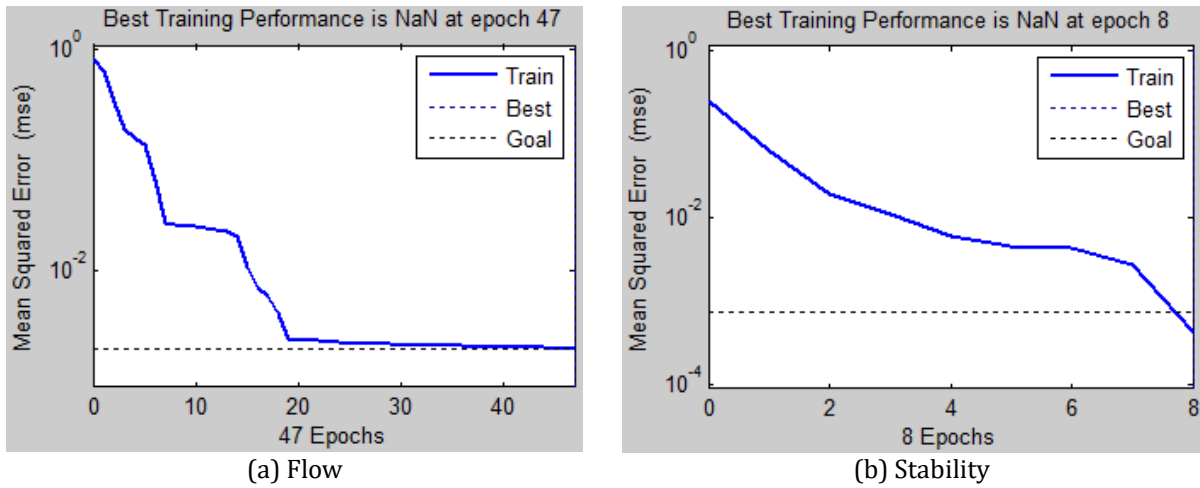


Figure 5. A plot of error variation depending on iteration of the ANN

3. Results and Evaluation

One of the most important properties of IKE model is that effect of input parameters on the target parameters can be determined. Modeling of data can be performed with classical system via this correspondence. From the point of repeatability of research, all details included used data were given clearly. Thus, opportunity of comparison with other models is created to researchers. Weighting effects of input parameters on the target for flow, stability and MQ are presented in Table 5.

It was seen that the compaction energy was the most effectual parameter on Marshall Quotient from Table 5. The other input parameters (sample height, density, air void, VMA, and VFA) were more effectual on stability values than MQ and flow. Air void level was found direct relation with flow according to IKE.

77 samples were used in both IKE and ANN model as test set. Real test results and predicted values form models were presented in Figure 6 - Figure 8. Both measured and predicted stability, flow and MQ values were observed in compatible with each others.

Table 5. Effects of input parameters on the target parameters for flow, stability and MQ [26]

	Degree of correspondence	Compaction energy	Sample height	Density	Air Void	VMA	VFA
Flow	1.53008	0.36826	0.04971	0.24003	0.64961	0.42475	0.00162
Stability	0.01542	0.54533	0.81421	0.98152	0.5802	0.90526	0.85213
Marshall quotient	0.00969	0.81859	0.57302	0.80202	0.45871	0.34327	0.19848

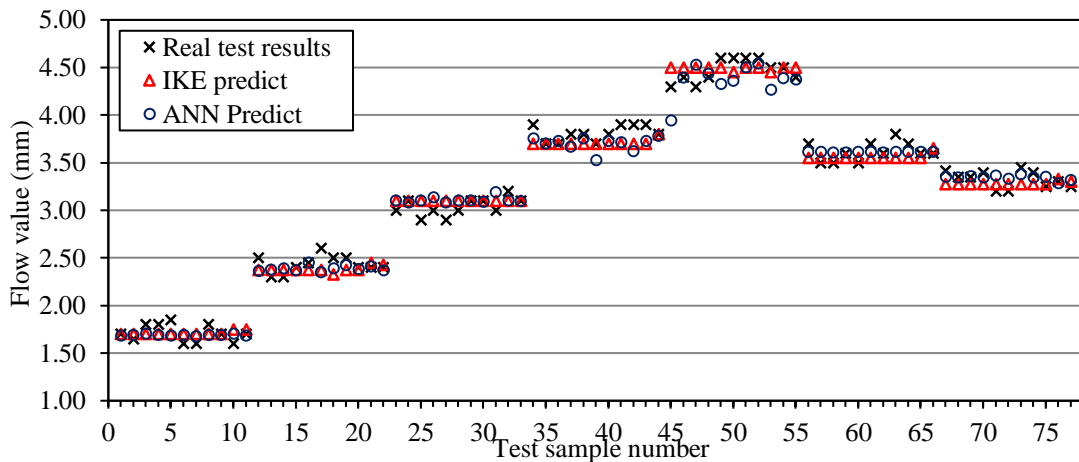


Figure 6. Comparison of predicted values of IKE and ANN with real flow values




Figure 7. Comparison of predicted values of IKE and ANN with real stability values

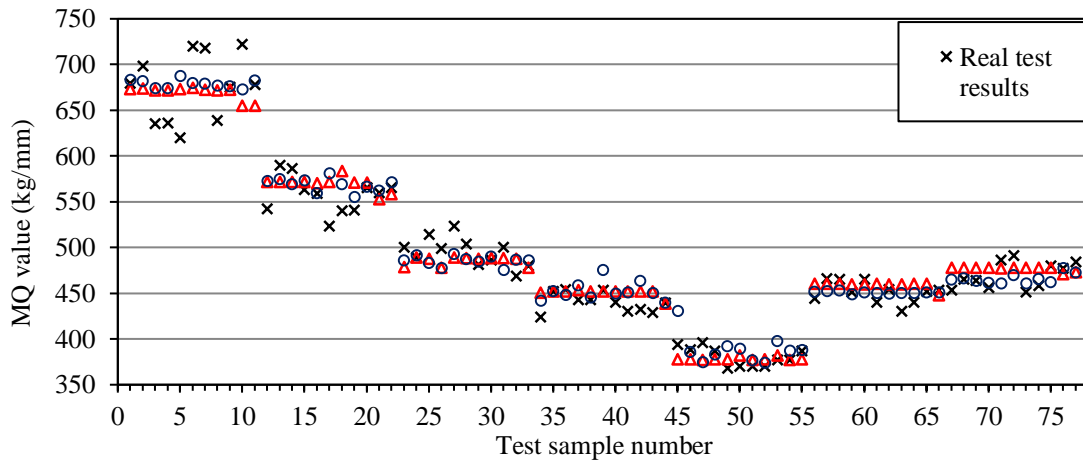


Figure 8. Comparison of predicted values of IKE and ANN with real MQ values

The coefficient of determination (R^2), the root mean squared error (RMSE), and mean absolute % error (MAPE) were calculated on the back of flow, stability, and MQ values were predicted. R^2 was used to provide a measure of the goodness of fit of the model. RMSE, a frequently-used measure of the differences between values predicted by a model and the values actually observed from the test. And MAPE was used to determine the error rate between real and predicted flow, stability and MQ values. MAPE and RMSE were calculated with Eq. 1, Eq. 2 and related data was shown in Table 6.

Table 6. Comparison parameters for IKE and ANN models

	IKE			ANN		
	Flow	Stability	MQ	Flow	Stability	MQ
MAPE	3.078	0.427	3.234	3.014	0.361	3.086
RMSE	0.113	7.993	21.53	0.122	6.7871	21.07
R^2	0.983	0.998	0.944	0.981	0.999	0.947

From the Table 6, it can be inferred that IKE and ANN approaches can be applied to Marshall test parameters. MAPE value of ANN model for specimens are 3.014, 0.361, and 3.086 for flow, stability and MQ respectively. These values lower than IKE ones. R^2 values are considerable close. These values indicate that the ANN is slightly effective to predict the flow, stability and MQ.

Comparison of error rate distribution of two models was illustrated in Figure 9 – Figure 11. According to the figures, it can be say that in generally, predict ability of two methods for this problem is similar. Thus, from sample to sample increasing or decreasing of error amount is similar. Although error ratio increases to 9% for flow, it is not to exceed 1.6% for stability. Detailed list was prepared and given in Table A2.




Figure 9. Distribution of error rates obtained from IKE and ANN for flow




Figure 10. Distribution of error rates obtained from IKE and ANN for stability




Figure 11. Distribution of error rates obtained from IKE and ANN for MQ

The IKE was applied to Marshall Test parameters. 49 samples were used for training set and 12 samples were used for test set. Blows, sample height, density, void, VMA, and VFA were selected as input parameters and flow stability, and MQ were selected as target parameters. The IKE predicted the real values of the parameters with a high accuracy rate. MAPE values were determined as 1.849, 0.361, and

1.568 for flow, stability, and MQ respectively. Also high level of R^2 was calculated between predicted and real test results [26]. In this study, test set samples increased to 77 samples. The same algorithm and degree of correspondence were used. Test results showed that new MAPE values changed as 3.078, 0.427, and 3.234. It was understood that although new data set was not introduced to algorithm,

observed error ratios for flow, stability, and MQ are at acceptable levels.

Applications of IKE to asphalt pavement tasks are quite new. In this research, genetic algorithm was applied to Marshall test parameters. It is understood that a practical solution is possible with the IKE method for understanding Marshall test parameters and in some measure, in context with the permanent deformation with the MQ method or flow comment.

Neural networks (NNs) were applied for the prediction of Marshall test results for polypropylene (PP) modified asphalt mixtures. Marshall stability and flow tests were carried out on specimens fabricated with different type of PP fibers and also waste PP at optimum bitumen content. The proposed NN model uses the physical properties of standard Marshall specimens such as PP type, PP percentage, bitumen percentage, specimen height, unit weight, voids in mineral aggregate, voids filled with asphalt and air voids in order to predict the Marshall stability, flow and Marshall Quotient values obtained at the end of mechanical tests. The proposed neural network models for stability, flow and Marshall Quotient have shown good agreement with experimental results ($R^2=0.97$, $R^2= 0.81$, $R^2= 0.87$). The proposed neural network model and formulation of the available stability, flow and Marshall Quotient of asphalt samples is quite accurate, fast and practical for use by other researchers studying in this field [2]. In this study, used NN model gives high accuracy results. It was obtained averagely 96.986%, 99.639%, and 96.914% accuracy results for flow, stability and MQ. Marshall test parameters predicted by IKE and ANN were compared with real test results. ANN gives slightly more accuracy results than IKE. The reader must not forget that the obtained results at the end of this study are valid only for this problem.

4. Conclusions

An intuitive k-NN estimator has been used for modeling the features and outputs of asphalt mixtures. Relationships between features and target parameters of the problem have been chosen same as previous study [26]. Dataset of asphalt mixture has been extended and larger test set has been prepared and tested with the algorithm. Validity of IKE on new data has been researched. Also, ANN model has been established and the performance of IKE and ANN models has been compared. Below considerations can be drawn from this investigation.

The results generally show small differences between the predicted and measured flow, stability, and MQ values of the mixtures. ANN model reveals slightly lower MAPE values than IKE. Error ratios (MAPE) of ANN are 3.014, 0.361, and 3.086 for flow, stability

and MQ. IKE gives slightly high values (3.078, 0.427, and 3.234). Generally, high R^2 value and low RMSE value achieved from both model. As a result, the developed ANN models have a slightly better prediction rate than the IKE model since the ANN model have a higher R^2 value and lower RMSE and MAPE values in comparison with the IKE model.

Although new data set consist of 77 samples (it was not introduced to model previously) was tested with IKE, error ratio (MAPE) increased to 3.078, 0.427, and 3.234 from 1.849, 0.361, and 1.568 for flow, stability and MQ. The values are in acceptable level of correctness. It is concluded that validity of Intuitive k-NN estimator continues on new data too.

Both IKE and ANN model can estimate accurately the flow number, stability and MQ without carrying out sophisticated and time-consuming laboratory tests with any other testing equipment. Using the methods can provide convenience to the laboratory working. Samples prepared for determined the flow and stability values can be used for other test method.

References

- [1] Ibrahim M. A. (2007). Performance evaluation of Superpave and Marshall asphalt mix designs to suite Jordan climatic and traffic conditions. *Construction and Building Materials*, 21, 1732–1740.
- [2] Tapkın S, Cevik A, Usar U. (2010). Prediction of Marshall test results for polypropylene modified dense bituminous mixtures using neural networks. *Expert Systems with Applications*, 37(6), 4660–4670.
- [3] Ozgan E. (2011). Artificial neural network based modeling of the Marshall Stability of asphalt concrete. *Expert Systems with Applications*, 38, 6025–6030.
- [4] Hınısloglu S, Agar E. (2004). Use of waste high density polyethylene as bitumen modifier in asphalt concrete mix. *Materials Letters*, 58, 267–271.
- [5] Kuloglu N. (1999). Effect of astragalus on characteristics of asphalt concrete. *Journal of Materials in Civil Engineering*, 11(4), 283–286.
- [6] Robertus C, Mulder EA, Koole RC. (1995). SBS modified bitumen for heavy duty asphalt pavements. In: Second international conference on roads and airfield pavement technology, Singapore.
- [7] Zoorob SE, Suparma LB. (2000). Laboratory design and investigation of the properties of continuously graded asphaltic concrete containing recycled plastics aggregate replacement (plastiphalt). *Cement and Concrete Composites*, 22, 233–242.

- [8] Nijboer LW. (1957). Some considerations of the Marshall test method for investigating bituminous masses. *Strasse Autobahn*, 210–4.
- [9] Haddadi S, Ghorbel E, Laradi N. (2008) Effects of the manufacturing process on the performances of the bituminous binders modified with EVA. *Construction and Building Materials*, 22, 1212–9.
- [10] Mirzahosseini MR, Aghaeifar A, Alavi AH, Gandomi AH, Seyednour R. (2011). Permanent deformation analysis of asphalt mixtures using soft computing techniques. *Expert Systems with Applications*, 38, 6081–6100.
- [11] Ozsahin TS, Oruc S. (2008). Neural network model for resilient modulus of emulsified asphalt mixtures, *Construction and Building Materials*, 22, 1436–1445.
- [12] Gopalakrishnan K, Manik A. (2010). Co-variance matrix adaptation evolution strategy for pavement backcalculation. *Construction and Building Materials*, 24, 2177–2187.
- [13] Attoh-Okine NO. (2001). Grouping pavement condition variables for performance modeling using self-organizing maps. *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 112–125.
- [14] Lee BJ, Lee HD. (2004). Position-invariant neural network for digital pavement crack analysis. *Computer-Aided Civil and Infrastructure Engineering*, 19(2), 105–118.
- [15] Mei X, Gunaratne M, Lu JJ, Dietrich B. (2004). Neural network for rapid evaluation of shallow cracks in asphalt pavements. *Computer-Aided Civil and Infrastructure Engineering*, 19(3), 223–230.
- [16] Ceylan H, Guclu A, Tutumluer E, Thompson MR. (2005). Backcalculation of full-depth asphalt pavement layer moduli considering nonlinear stressdependent subgrade behavior. *The International Journal of Pavement Engineering*, 6(3), 171–182.
- [17] Attoh-Okine NO. (2005). Modeling incremental pavement roughness using functional network. *Canadian Journal of Civil Engineering*, 32(5), 805–899.
- [18] Saltan M, Sezgin H. (2007). Hybrid neural network and finite element modeling of sub-base layer material properties in flexible pavements. *Materials & Design*, 28(5), 1725–1730.
- [19] Tapkin S, Cevik A, Usar U. (2009). Accumulated strain prediction of polypropylene modified marshall specimens in repeated creep test using artificial neural networks. *Expert Systems with Applications*, 36(8), 11186–11197.
- [20] Banzhaf W, Nordin P, Keller R, Francone FD. Genetic programming—An introduction on the automatic evolution of computer programs and its application. Heidelberg/San Francisco: dpunkt/Morgan Kaufmann; 1998.
- [21] Koza J, Genetic programming, on the programming of computers by means of natural selection. Cambridge, MA: MIT Press; 1992.
- [22] Cevik A, Cabalar AF. (2009). Modeling damping ratio and shear modulus of sand–mica mixtures using genetic programming. *Expert Systems with Applications*, 36(4), 7749–7757.
- [23] Cevik A. (2007). A new formulation for web crippling strength of cold-formed steel sheeting using genetic programming. *Journal of Constructional Steel Research*, 63(7), 867–883.
- [24] Gandomi AH, Alavi AH, Kazemi S, Alinia MM. (2009). Behavior appraisal of steel semirigid joints using linear genetic programming. *Journal of Constructional Steel Research*, 65(8–9), 1738–1750.
- [25] Johari A, Habibagahi G, Ghahramani A. (2006). Prediction of soil–water characteristic curve using genetic programming. *Journal of Geotechnical and Geoenvironmental Engineering*, 132(5), 661–665.
- [26] Aksoy, A. Iskender, E. Kahraman. HT. (2012). Application of the intuitive k-NN Estimator for prediction of the Marshall Test (ASTM D1559) results for asphalt mixtures. *Construction and Building Materials*, 561–569.
- [27] Kahraman HT, Bayindir R, Sagiroglu S. (2012). A new approach to predict the excitation current and parameter weightings of synchronous machines based on genetic algorithm-based k-NN estimator. *Energy Conversion and Management*, 64, 129–138.
- [28] Kelly JD, Davis L. (1991). A hybrid genetic algorithm for classification. In Proceedings of the 12th international joint conference on Artificial intelligence - Volume 2 (IJCAI'91), Vol. 2. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 645–650.
- [29] Goldberg DE. (1989). Genetic Algorithms in Search Optimization and Machine Learning. Addison Wesley, ISBN 0201157675. The University of Alabama USA.
- [30] Mitchell TM. (1997). Machine Learning, McGraw-Hill Science/Engineering/Math, 154–184.
- [31] Thodesen C, Xiao F, Amirkhanian SN. (2009). Modeling viscosity behavior of crumb rubber modified binders *Construction and Building Materials*, 23, 3053–3062.
- [32] Hao W, Lu Z, Wei P, Feng J, Wang B. (2012). A new method on ANN for variance based importance measure analysis of correlated input variables. *Structural Safety*, 38, 56–63.
- [33] Ferreira IML, Gil PJS. (2012). Application and performance analysis of neural networks for decision support in conceptual design. *Expert Systems with Applications*, 39, 7701–7708.

APPENDIX

Please see Table A1 and Table A2.

Table A1. Properties of the training set samples

Sample ID	Blows	Sample Height (mm)	Density (gr/cm ³)	Void (%)	VMA (%)	VFA (%)	Flow (mm)	Stability (kg)	MQ (kg/mm)
1	45	61.60	2.362	7.221	17.611	58.996	1.70	1154	679
2	45	62.80	2.360	7.320	17.698	58.643	1.65	1140	691
3	45	62.30	2.369	6.939	17.360	60.030	1.70	1148	675
4	45	63.20	2.357	7.443	17.808	58.205	1.65	1131	685
5	45	62.00	2.353	7.589	17.938	57.692	1.75	1152	658
6	45	62.40	2.362	7.242	17.630	58.919	1.60	1149	718
7	45	63.10	2.365	7.117	17.518	59.376	1.80	1141	634
8	50	63.90	2.372	6.840	17.273	60.398	2.45	1361	556
9	50	63.50	2.379	6.552	17.017	61.497	2.50	1350	540
10	50	63.90	2.372	6.833	17.266	60.426	2.40	1346	561
11	50	64.10	2.368	6.996	17.411	59.818	2.40	1349	562
12	50	63.00	2.372	6.828	17.262	60.443	2.30	1362	592
13	50	62.60	2.366	7.068	17.475	59.553	2.35	1361	579
14	50	62.00	2.370	6.914	17.338	60.123	2.40	1355	565
15	55	63.03	2.382	6.444	16.921	61.916	3.00	1514	505
16	55	63.97	2.386	6.291	16.785	62.522	3.10	1507	486
17	55	62.27	2.388	6.203	16.707	62.870	3.10	1522	491
18	55	61.53	2.375	6.702	17.150	60.920	3.00	1522	507
19	55	61.77	2.384	6.372	16.857	62.199	3.20	1518	474
20	55	62.07	2.378	6.599	17.058	61.316	3.20	1511	472
21	55	63.00	2.387	6.255	16.753	62.665	3.30	1509	457
22	60	63.37	2.390	6.136	16.647	63.141	3.80	1655	436
23	60	62.53	2.383	6.403	16.885	62.077	3.70	1689	456
24	60	63.03	2.386	6.277	16.772	62.578	3.90	1673	429
25	60	63.57	2.395	5.926	16.461	64.000	3.80	1662	437
26	60	63.37	2.384	6.358	16.844	62.255	3.70	1663	449
27	60	62.63	2.388	6.202	16.706	62.874	3.70	1682	455
28	60	62.47	2.394	5.965	16.496	63.838	3.60	1681	467
29	65	64.67	2.402	5.664	16.228	65.098	4.40	1702	387
30	65	62.17	2.390	6.124	16.636	63.191	4.50	1704	379
31	65	61.67	2.398	5.814	16.361	64.464	4.60	1700	370
32	65	62.60	2.404	5.582	16.155	65.447	4.30	1703	396
33	65	61.47	2.401	5.695	16.256	64.965	4.40	1706	388
34	65	62.27	2.393	6.016	16.541	63.630	4.50	1689	375
35	65	61.93	2.394	5.970	16.500	63.820	4.50	1693	376
36	70	63.50	2.413	5.221	15.835	67.027	3.50	1630	466
37	70	63.03	2.417	5.061	15.693	67.747	3.70	1631	441
38	70	63.03	2.406	5.501	16.083	65.797	3.60	1636	454
39	70	63.23	2.410	5.349	15.949	66.459	3.70	1633	441
40	70	63.07	2.403	5.623	16.191	65.274	3.50	1626	465
41	70	62.87	2.412	5.272	15.880	66.801	3.70	1639	443
42	70	62.23	2.409	5.378	15.974	66.334	3.60	1637	455
43	75	62.97	2.443	4.037	14.784	72.690	3.30	1558	472
44	75	62.27	2.455	3.565	14.364	75.182	3.40	1566	461
45	75	62.13	2.449	3.814	14.585	73.851	3.45	1563	453
46	75	61.93	2.457	3.497	14.304	75.552	3.20	1572	491
47	75	61.90	2.449	3.814	14.586	73.848	3.20	1560	488
48	75	62.47	2.454	3.609	14.403	74.945	3.30	1557	472
49	75	62.70	2.460	3.383	14.202	76.182	3.30	1546	468

Table A2. Test set samples and Marshall test parameters

	Blows	Sample Height (mm)	Density (g/cm ³)	Void (%)	VMA (%)	VFA (%)	Test results			IKE predicted			ANN predicted		
							Flow	Stability	MQ	Flow	Stability	MQ	Flow	Stability	MQ
1	45	62.23	2.359	7.347	17.722	58.546	1.70	1154	679	1.70074	1145.232029	673.375	1.68422	1150.201767	682.929
2	45	62.00	2.364	7.140	17.539	59.290	1.65	1152	698	1.70074	1146.411968	674.068	1.68892	1151.942453	682.058
3	45	63.47	2.368	6.992	17.407	59.834	1.80	1143	635	1.70074	1141.818462	671.368	1.70253	1147.861729	674.208
4	45	63.23	2.354	7.538	17.892	57.870	1.80	1144	636	1.70074	1142.62391	671.841	1.69248	1140.338472	673.766
5	45	61.83	2.353	7.582	17.931	57.717	1.85	1147	620	1.70074	1145.232029	673.375	1.68734	1159.769031	687.336
6	45	62.03	2.363	7.204	17.596	59.057	1.60	1152	720	1.70074	1147.214191	674.540	1.69473	1151.458601	679.435
7	45	63.67	2.361	7.250	17.637	58.891	1.60	1149	718	1.70074	1143.027471	672.078	1.68014	1141.153198	679.200
8	45	63.30	2.365	7.114	17.515	59.387	1.80	1151	639	1.70074	1141.818462	671.368	1.69119	1144.456667	676.717
9	45	63.60	2.363	7.191	17.584	59.106	1.70	1148	675	1.70074	1143.027471	672.078	1.68879	1142.426738	676.478
10	45	63.00	2.367	7.038	17.448	59.665	1.60	1155	722	1.75071	1146.411968	654.825	1.70470	1146.537333	672.574
11	45	62.00	2.364	7.137	17.536	59.300	1.70	1152	678	1.75071	1146.411968	654.825	1.68771	1151.974571	682.567
12	50	62.90	2.368	6.988	17.404	59.849	2.50	1356	542	2.37513	1357.609075	571.593	2.36768	1356.451311	572.902
13	50	61.83	2.371	6.878	17.306	60.258	2.30	1358	590	2.37513	1357.013412	571.342	2.37695	1365.526500	574.487
14	50	62.47	2.373	6.797	17.234	60.563	2.30	1348	586	2.37513	1357.013412	571.342	2.39441	1361.845347	568.760
15	50	62.57	2.371	6.875	17.303	60.270	2.40	1350	563	2.37513	1357.013412	571.342	2.37302	1360.104828	573.154
16	50	61.47	2.377	6.637	17.092	61.170	2.45	1369	559	2.37513	1354.814083	570.416	2.44961	1370.921713	559.649
17	50	61.73	2.369	6.949	17.369	59.994	2.60	1360	523	2.37513	1357.609075	571.593	2.35050	1366.035740	581.168
18	50	62.83	2.373	6.799	17.236	60.552	2.50	1351	540	2.32513	1357.013412	583.628	2.38993	1359.526284	568.855
19	50	64.00	2.364	7.162	17.558	59.210	2.50	1354	541	2.37513	1355.817318	570.839	2.42525	1346.944067	555.383
20	50	63.83	2.368	6.990	17.406	59.841	2.40	1355	565	2.37513	1355.817318	570.839	2.38496	1350.826211	566.394
21	50	64.03	2.377	6.633	17.088	61.187	2.40	1345	560	2.45051	1353.616046	552.381	2.40890	1354.487216	562.285
22	50	63.63	2.373	6.790	17.228	60.589	2.40	1357	565	2.42513	1353.616046	558.163	2.37231	1355.084212	571.210
23	55	63.43	2.372	6.826	17.260	60.451	3.00	1499	500	3.10161	1484.44562	478.604	3.10355	1508.324169	485.999
24	55	62.37	2.376	6.679	17.130	61.008	3.10	1516	489	3.10161	1517.406274	489.231	3.08504	1516.908194	491.699
25	55	64.17	2.379	6.559	17.023	61.470	2.90	1489	514	3.10161	1512.60907	487.685	3.10421	1499.660673	483.105
26	55	64.57	2.370	6.916	17.340	60.116	3.00	1498	499	3.10161	1482.069567	477.838	3.13594	1497.846147	477.638
27	55	62.10	2.374	6.759	17.200	60.706	2.90	1516	523	3.10161	1517.406274	489.231	3.08360	1518.682887	492.503
28	55	62.77	2.382	6.438	16.915	61.942	3.00	1512	504	3.10161	1514.807314	488.393	3.10533	1513.277939	487.316
29	55	63.67	2.374	6.754	17.196	60.722	3.10	1493	481	3.10161	1512.60907	487.685	3.10675	1505.785068	484.682
30	55	62.53	2.377	6.646	17.100	61.136	3.10	1507	486	3.10161	1514.807314	488.393	3.09086	1515.529176	490.326
31	55	62.37	2.385	6.324	16.814	62.390	3.00	1501	500	3.10161	1514.807314	488.393	3.19320	1516.752035	474.995
32	55	63.37	2.379	6.569	17.032	61.432	3.20	1502	469	3.10161	1512.60907	487.685	3.10100	1507.665149	486.187
33	55	63.57	2.372	6.818	17.253	60.481	3.10	1487	480	3.10161	1481.523945	477.662	3.10038	1507.206704	486.136
34	60	63.83	2.397	5.852	16.395	64.308	3.90	1653	424	3.70000	1666.825006	450.493	3.75398	1659.364169	442.028
35	60	62.53	2.393	6.005	16.531	63.674	3.70	1671	452	3.70000	1670.633592	451.523	3.70453	1675.244638	452.216
36	60	62.97	2.389	6.170	16.677	63.004	3.70	1682	454	3.70000	1672.445395	452.012	3.72898	1671.622272	448.279
37	60	61.87	2.390	6.132	16.644	63.156	3.80	1685	443	3.70000	1676.040572	452.984	3.66648	1681.322032	458.565
38	60	63.03	2.386	6.294	16.787	62.509	3.80	1684	443	3.70000	1672.445395	452.012	3.75562	1671.630487	445.101
39	60	62.37	2.397	5.850	16.393	64.314	3.70	1676	453	3.70000	1670.633592	451.523	3.52642	1675.908970	475.244
40	60	62.47	2.384	6.356	16.843	62.262	3.80	1671	440	3.70000	1672.445395	452.012	3.73019	1677.528654	449.716
41	60	62.73	2.389	6.164	16.672	63.028	3.90	1678	430	3.70000	1672.445395	452.012	3.71396	1674.130296	450.767
42	60	62.27	2.396	5.892	16.431	64.139	3.90	1684	432	3.70000	1670.633592	451.523	3.62129	1677.009200	463.097
43	60	62.23	2.382	6.437	16.915	61.943	3.90	1673	429	3.70000	1672.445395	452.012	3.73071	1679.701890	450.237
44	60	63.67	2.387	6.243	16.743	62.710	3.80	1667	439	3.80132	1667.026754	438.539	3.78540	1664.628074	439.749
45	65	62.37	2.406	5.502	16.084	65.792	4.30	1696	394	4.50000	1698.211706	377.380	3.94155	1696.600988	430.440
46	65	64.27	2.400	5.736	16.292	64.792	4.40	1705	388	4.50000	1700.01000	377.780	4.39769	1697.500344	385.998
47	65	62.47	2.397	5.851	16.394	64.310	4.30	1702	396	4.50000	1697.81006	377.291	4.53128	1697.798574	374.684
48	65	63.87	2.403	5.608	16.178	65.339	4.40	1703	387	4.50000	1700.01000	377.780	4.43621	1697.253903	382.591
49	65	62.27	2.403	5.608	16.178	65.337	4.60	1694	368	4.50000	1698.211706	377.380	4.32704	1696.728083	392.122
50	65	64.57	2.406	5.491	16.074	65.843	4.60	1703	370	4.45028	1700.01000	382.001	4.35881	1696.763771	389.272
51	65	62.43	2.394	5.979	16.508	63.779	4.60	1701	370	4.50000	1697.81006	377.291	4.50610	1698.415985	376.915
52	65	61.87	2.399	5.780	16.331	64.607	4.60	1700	370	4.50000	1698.412317	377.425	4.54046	1697.221599	373.799
53	65	64.67	2.408	5.422	16.013	66.141	4.50	1698	377	4.45028	1700.01000	382.001	4.26808	1696.646800	397.520
54	65	63.27	2.392	6.043	16.564	63.521	4.50	1698	377	4.50000	1697.81006	377.291	4.39163	1698.663642	386.796
55	65	64.37	2.399	5.775	16.326	64.630	4.40	1702	387	4.50111	1700.01000	377.687	4.37344	1697.537200	388.147

Table A2. Test set samples and Marshall test parameters (continue)

Blows	Sample Height (mm)	Density (g/cm ³)	Void (%)	VMA (%)	VFA (%)	Test results			IKE predicted			ANN predicted			
						Flow	Stability	MQ	Flow	Stability	MQ	Flow	Stability	MQ	
56	70	62.97	2.401	5.689	16.251	64.991	3.70	1641	444	3.55035	1634.206291	460.294	3.61279	1631.348581	451.548
57	70	62.57	2.411	5.303	15.908	66.662	3.50	1632	466	3.55035	1635.003058	460.519	3.61678	1634.950178	452.045
58	70	62.77	2.416	5.114	15.740	67.507	3.50	1629	465	3.55035	1634.003672	460.237	3.60991	1634.834791	452.874
59	70	64.17	2.402	5.652	16.218	65.148	3.60	1622	451	3.55035	1632.404974	459.787	3.61073	1621.175882	448.989
60	70	63.57	2.407	5.453	16.041	66.006	3.50	1627	465	3.55035	1632.404974	459.787	3.61355	1627.827165	450.478
61	70	63.70	2.410	5.340	15.940	66.502	3.70	1627	440	3.55035	1635.003058	460.519	3.61422	1627.382138	450.272
62	70	64.10	2.403	5.620	16.189	65.285	3.60	1635	454	3.55035	1632.404974	459.787	3.61107	1622.129755	449.211
63	70	63.87	2.408	5.421	16.012	66.146	3.80	1634	430	3.55035	1632.404974	459.787	3.61314	1625.450527	449.872
64	70	63.80	2.412	5.264	15.873	66.838	3.70	1629	440	3.55035	1635.003058	460.519	3.61441	1626.968012	450.134
65	70	63.30	2.402	5.657	16.222	65.126	3.60	1628	452	3.55035	1634.206291	460.294	3.61234	1629.157203	450.998
66	70	63.57	2.409	5.385	15.980	66.303	3.60	1632	453	3.65034	1635.003058	447.904	3.61418	1628.240202	450.514
67	75	63.07	2.441	4.116	14.853	72.291	3.42	1548	453	3.27510	1564.008824	477.546	3.34963	1556.205236	464.590
68	75	62.73	2.447	3.896	14.658	73.420	3.35	1559	465	3.27510	1564.008824	477.546	3.34607	1559.791106	466.156
69	75	62.97	2.453	3.643	14.434	74.759	3.35	1555	464	3.27510	1563.807725	477.485	3.35680	1555.831145	463.487
70	75	63.87	2.449	3.817	14.588	73.833	3.40	1549	456	3.27510	1564.008824	477.546	3.34919	1545.968704	461.595
71	75	63.47	2.456	3.530	14.333	75.372	3.20	1555	486	3.27510	1561.42403	476.757	3.36456	1549.288423	460.473
72	75	62.27	2.442	4.084	14.825	72.450	3.20	1571	491	3.27510	1564.008824	477.546	3.33552	1566.306423	469.583
73	75	63.17	2.438	4.242	14.965	71.657	3.45	1554	451	3.27510	1564.008824	477.546	3.37818	1555.139169	460.348
74	75	62.97	2.444	4.014	14.763	72.812	3.40	1556	458	3.27510	1564.008824	477.546	3.34600	1557.078149	465.354
75	75	63.67	2.449	3.801	14.573	73.921	3.25	1559	480	3.27510	1564.008824	477.546	3.35078	1548.180176	462.036
76	75	61.97	2.451	3.741	14.520	74.238	3.30	1573	477	3.32735	1566.808093	470.888	3.28592	1568.954143	477.478
77	75	62.07	2.446	3.928	14.690	73.250	3.25	1573	484	3.30151	1561.42403	472.942	3.31843	1568.344156	472.616

Development of Programming Learning Environment with Compiler Techniques

Sefa ARAS*¹, Eyüp GEDİKLİ^{1a}

¹ Karadeniz Teknik Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, 61830, Trabzon

(Alınış / Received: 14.12.2018, Kabul / Accepted: 31.12.2018, Online Yayınlanma / Published Online: 31.12.2018)

Keywords

Programming Learning
Environment,
Compiler,
Lexical Analysis,
Syntax Analysis,
Finite State Machines.

Abstract: In this study, a task-based programming learning environment with simple syntax was developed. Existing environments are applications that are mostly programming with visual components, are difficult to develop and contribute to the transition to real programming languages. Within the developed environment, a new programming language has been defined, which is close to the actual programming languages. The programming learning environment has been developed as open source using computer science and engineering techniques, and is a framework for researchers seeking to develop such an environment. The language in the programming learning environment is verified by lexical and syntax analysis steps. Finite state machines control the success of the task. Regular expressions allow users to parse the code written by the user and make the necessary analysis on the code.

1. Introduction

Programming learning improves cognitive skills as well as teaching computer science concepts. Providing this improvement depends on the success of programming learning. While learning programming with real programming languages, individuals face syntax difficulties. Solving these difficulties takes longer than programming. This problem has revealed programming learning environments. In programming learning environments, programming is usually done using visual components [1]. However, programming with visual components leads to difficulties for individuals in transition to real programming languages. This leads to the need for a learning environment that resembles real programming languages.

In the Scratch environment where tasks are performed with visual components, puzzle components that can take values are used [2]. By assigning values to certain fields with the correct parts, assignments, operations, conditions and loops can be performed. In Vimap [3] consisting of multidimensional blocks in which programming instructions are represented by drag and drop, certain

values are written into blocks. Greenfoot, which is Java-based and supports object-oriented programming, has been developed for young people [4]. RoBlock is a web based visual programming language consisting of eight modules. The user learns programming by performing tasks in each mode [5].

In this study, a programming learning environment which is simple syntax, task-based, motivates users with intelligent feedback, motivation with gamification is developed. Within the developed environment, a new programming language has been defined, which is close to the actual programming languages. Lexical and syntax analysis steps verify the language developed in the programming learning environment. Finite automats control the success status of task. Regular expressions allow users to parse the code written by the user and make the necessary analysis on the code.

In the second part of the work, the method and the used tools, in the third part system architecture, in the last part the results are given.

2. Method

It is stated in the literature that programming learning environments developed with visual components improve cognitive skills and reduce syntax difficulty [6-8]. However, it is difficult for individuals who learn programming using visual components to switch to real programming languages [9, 10]. Therefore, the language used in the programming learning environment developed is very close to the real programming languages and the better learning process is aimed with the intelligent feedbacks.

2.1. The Tools Used

The programming learning environment has been developed on the web because it does not require installation according to the desktop and mobile applications. The JavaScript programming language, which can work without the need for plugins, is preferred for playing animations. IntelliJ as editor, Apache Server for presentation and Mozilla Firefox as browser. In the developed programming learning environment, compiler techniques have been realized by using regular expressions and finite state machines.

2.2. Compiler Techniques

Compilers for each programming language have been developed to make programs written in different programming languages workable on different machines. The compilers convert the source code to the target program [11]. The compilers perform this process in several stages. In theory, these stages are followed in sequence, but in practice this sequence is not always followed, and sometimes the stages can be combined [12]. The operation diagram of compiler is given in Figure 1.




Figure 1. Compiler operation diagram

A basic compiler usually consists of four stages [13]:

Table 1. Token Table

Source Code	Token
text	ID
"text"	STR
number	INT
;	END
,	BR
+	ADD
-	SUB
*	MUL
/	DIV
(LBT

)	RBT
{	LCB
}	RCB
[LBB
]	RBB
text = expression	ID EQU EXP
text = expression + expression	ID EQU EXP ADD EXP
text = expression - expression	ID EQU INT SUB INT
text = expression * expression	ID EQU INT MUL INT
text = expression / expression	ID EQU INT DIV INT
expression (logical operators) expression	EXP LOG EXP
eger (logical expression) { code }	IF LBT LEXP RBT LCB CODE RCB
degilse eger (logical expression) { code }	ELIF LBT LEXP RBT LCB CODE RCB
degilse { code }	ELSE LCB CODE RCB
tekraret (number) { code }	FOR LBT INT RBT LCB CODE RCB
oldugu surece(logical expression) { code }	WHL LBT LEXP RBT LCB CODE RCB
[] text = number	LBB RBB ID EQU INT
text[number] = expression	ID LBB INT RBB EQU EXP
program { code }	MAIN LCB CODE RCB
text(expression) { code }	FUNC LBT EXP RBT LCB CODE RCB

1. *Lexical Analysis:* In the lexical analysis phase, first white characters (space character, tab, new line, etc.) are filtered out. Then the characters in the source code are separated by symbols called tokens. Lexical analysis is also called the stage of preparation for the phase of syntactic analysis [11-13].

The tokens and their equivalents for the programming language developed within the programming learning environment are given in Table 1. The programming language is fully covered by creating tokens for each command and symbol. The expression in the source code; variable (ID), text (STR), or number (INT). Logical operators only generate conditional expressions. Logical expressions are formed by comparing two expressions with each other. The end of logical statements can be true or false.

$$a = 10 * (5 + 10) \tag{1}$$

An example calculation is given in (1). With the developed programming language, this calculation is performed as follows:

- sayi = 10 * (5 + 20);

In the calculation process of equation 1 is given in the state of Figure 2 was parsed into tokens by the compiler.

ID EQU INT MUL LBT INT ADD INT RBT END
sayi = 10 * (5 + 20) ;

Figure 2. Token of equation 1

The main purpose of the lexical analysis phase is to facilitate work in the next phase of syntax analysis. Simple systems perform lexical analysis and syntax

analysis together. However, the separation of these stages has advantages such as efficiency and modularity [12].

2. Syntax Analysis: The syntax analysis phase parse the token list created during the lexical analysis phase into a tree structure called a syntax tree. For this reason, this stage is also called parsing. If the code is not accepted at this stage, it is indicated as a syntax error together with the corresponding error message. [11-13].

The finite automata in Figure 3 control the tokens given in Figure 2 during the syntax analysis phase. The finite automata changes state according to the token list. The expected tokens(s) for each case vary. An unexpected token in the current situation causes a syntax error. The finite automata is that the encoder accepts the appropriately coded computation. Examining Figure 3, the finite state machine accepts infinite number of left parentheses in case number 2, infinite right parentheses in number 3 case. However, for each left bracket, a right bracket must appear. Parentheses are checked with regular expressions before the computation is verified by the finite automata. Controlling the parentheses first provides ease of operation. If there is an error in the parentheses, a parenthesis error is given without checking at the codes.




Figure 3. Proposed finite automata for the operations

3. Type Checking: An expression in the code block can be variable, text, or number. When assigning and operator operations are performed, the data type must be decided. Variables (ID) always begin with a character, followed by a number or character. Texts (STR) only accept characters, numbers (INT) only accept numbers [12].




Figure 4. Variable name definition

The finite automata in Fig. 4 is used to verify the variable name. Lowercase letters are represented [a-z], uppercase letters are represented [A-Z] and numbers are represented by [0-9].

4. Code Generation: The ultimate goal of a compiler is to translate code written in a high-level programming language into programs that can run on a computer. The codes written in this context should be transformed into a programming language that can understand the environment in which the work should be performed [13]. This language can be scripting languages for the browser while being machine codes for the computer.

The developed programming learning environment is working on browsers. The code written in the environment needs to be converted into JavaScript, which is a scripting language. The code written in the learning environment is prepared to work in the browser because of the successful passage of the analysis steps. The written code is converted into JavaScript programming language using regular expressions and executed in the browser.

The insertion sorting algorithm function written in the developed programming language is given in Figure 5. This function is tokenize by parsing the lexical and syntax analysis steps into the final tokens. These tokens are converted into JavaScript programming language using regular expressions. The sorting algorithm in the JavaScript programming language is given in Figure 6.

```

1 sirala([], dizi, n)
2 {
3   olduđu sürece(i < n)
4   {
5     anahtar = dizi[i];
6     j = i - 1;
7     olduđu sürece(j >= 0 && dizi[j] > anahtar)
8     {
9       dizi[j + 1] = dizi[j];
10      j = j - 1;
11    }
12    dizi[j + 1] = anahtar;
13  }
14 }

```

Figure 5. Insertion sort algorithm

```

1 function sirala(dizi, n)
2 {
3   while(i < n)
4   {
5     anahtar = dizi[i];
6     j = i - 1;
7     while(j >= 0 && dizi[j] > anahtar)
8     {
9       dizi[j + 1] = dizi[j];
10      j = j - 1;
11    }
12    dizi[j + 1] = anahtar;
13  }
14 }

```

Figure 6. Insertion sort algorithm in Javascript

3. System Architecture

The general code notations of the developed environment are given in Table 1. The environment needs to verify these codes in the analysis phase. In the analysis phase, the code written before is parsed into symbols called tokens. The finite automata given in Figures 7-9 in terms of the writing rules verify obtain tokens.




Figure 7. Proposed finite automata for the functions

Function and program (main) blocks are being verified by shown the automata in Figure 7. Functions can take variable(s) as parameters, the program block does not accept parameters. The automata given in Figure 3 verify once the function and program blocks are appropriately generated, the code blocks.




Figure 8. Proposed finite automata for the loops

The automata given in Fig. 8 confirms the loops. Loops; It consists of “tekraret” (for) and “oldugu surece” (while) codes. The for command executes the code in the blocks specified number times, the while command executes the code in the block as long as the given condition is correct.

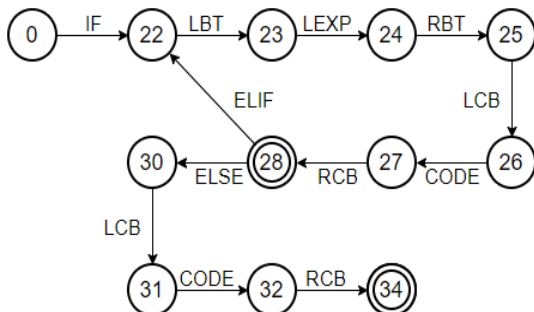


Figure 9. Proposed finite automata for the conditions

The automata given in Fig. 9 checks the conditions. Conditions; “eger” (if), “degilse eger” (else if) and “degilse” (else). Else if and else commands are not accepted by the automata without if command. The else command can come only once, and only at the end,

while an unlimited number of else if command can come after if command arrives.

3.1. Task System

In the developed learning environment, the user is progressing successfully by fulfilling the tasks given in the predefined scenarios. In Figure 10, an example task is given.

```

1 [] dizi = 5;
2 sayac = 1;
3 tekraret(5)
4 {
5     dizi[sayac] = sayac;
6     sayac = sayac + 1;
7 }
    
```

Figure 10. Example task code

The automata given in Figs. 11 and 12 control the example given in Fig. 10.




Figure 11. Task Controller

The automata given in Figure 11 control the general structure. The status does not change except for the codes given in the figure. Loop is being verified by shown the automata in Figure 12.




Figure 12. Loop Controller for Task

4. Conclusions

In this study, it was tried to develop an open source programming learning environment using compiler techniques. The developed environment provides a framework for future environments and expected to allow the user to proceed faster to use real programming languages. Through the developed framework, subsequent learning can determine the user's learning ability and deficiencies. Algorithms can provide information on how to develop logic skills. A comprehensive new language can be created with the existing infrastructure.

References

[1] Özyurt, Ö., Özyurt, H., Aras, S. (2016, May). Çocukların Kodlama Öğrenebilecekleri Ortamların İncelenmesi. In International Computer and Instructional Technologies Symposium (ICITS) on (pp. 399-400).

[2] Resnick, M., Maloney, J., Monroy-Hernández, A., Rusk, N., Eastmond, E., Brennan, K., Kafai, Y. (2009). Scratch: programming for all. Communications of the ACM, 52(11), 60-67.

- [3] Sengupta, P., Farris, A. V., Wright, M. (2012). From agents to continuous change via aesthetics: learning mechanics with visual agent-based computational modeling. *Technology, Knowledge and Learning*, 17(1-2), 23-42.
- [4] Kölling, M. (2010). The greenfoot programming environment. *ACM Transactions on Computing Education (TOCE)*, 10(4), 14.
- [5] García, P. G., De la Rosa, F. (2016). RoBlock-Web App for Programming Learning. *International Journal of Emerging Technologies in Learning*, 11(12).
- [6] Bers, M. U., Flannery, L., Kazakoff, E. R., Sullivan, A. (2014). Computational thinking and tinkering: Exploration of an early childhood robotics curriculum. *Computers and Education*, 72, 145-157.
- [7] Papadakis, S., Kalogiannakis, M., Zaranis, N. (2016). Developing fundamental programming concepts and computational thinking with ScratchJr in preschool education: a case study. *International Journal of Mobile Learning and Organisation*, 10(3), 187-202.
- [8] Fessakis, G., Gouli, E., Mavroudi, E. (2013). Problem solving by 5–6 years old kindergarten children in a computer programming environment: A case study. *Computers and Education*, 63, 87-97.
- [9] Armoni, M., Meerbaum-Salant, O., Ben-Ari, M. (2015). From scratch to “real” programming. *ACM Transactions on Computing Education (TOCE)*, 14(4), 25.
- [10] Koorsse, M., Cilliers, C., Calitz, A. (2015). Programming assistance tools to support the learning of IT programming in South African secondary schools. *Computers and Education*, 82, 162-178.
- [11] Aho, A. V., Sethi, R., Ullman, J. D. (2007). *Compilers: principles, techniques, and tools (Vol. 2)*. Reading: Addison-wesley.
- [12] Mogensen, T. Æ. (2009). *Basics of Compiler Design*. Torben Ægidius Mogensen.
- [13] De Graaf, D. (2017). *Practical use of Automata and Formal Languages in the compiler field*.

Farklı Kür Koşullarının Kolemanit İkameli Betonların Dayanımına Etkisi

Tuba KÜTÜK SERT^{1a}, Cuma KARA^{*2}

¹Recep Tayyip Erdoğan Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 53100, Rize

²Artvin Çoruh Üniversitesi, Borçka Acarlar Meslek Yüksekokulu, İnşaat Bölümü, 08000, Artvin

(Alınış / Received: 28.12.2018, Kabul / Accepted: 31.12.2018, Online Yayınlanma / Published Online: 31.12.2018)

Anahtar Kelimeler

Beton
Kür Koşulları
Kolemanit

Özet: Kolemanit % 0, % 1, % 2, % 3, % 4 ve % 5 oranlarında çimentoya ikame edilmiş ve hazırlanan beton türleri farklı kür koşullarında bekletilmiştir. Farklı kür koşullarında bekletilen beton türleri üzerinde 90. günde ultrases geçiş hızı ve basınç dayanımı deneyleri gerçekleştirilmiştir. Sonuç olarak bütün kür koşullarında en yüksek dayanım % 3 kolemanit ikamesi ile elde edilirken, en düşük dayanım ise % 5 kolemanit ikamesi olan beton türünde meydana gelmiştir.

The Effect of Different Curing Conditions on Strength of Concrete Substituted Colemanite

Keywords

Concrete
Curing Conditions
Colemanite

Abstract: Colemanite 0 %, 1 %, 2 %, 3 %, 4 % and 5 % of the cement were replaced and prepared concrete types were kept under different curing conditions. On the 90 th day, ultrasound pulse velocity and compressive strength tests were performed on the concrete types which were kept under different curing conditions. As a result, the highest strength was obtained with 3% colemanite substitution in all curing conditions while the lowest strength was in the concrete type with 5 % colemanite substitution.

1. Giriş

Türkiye maden kaynaklarının çeşitliliği açısından önemli bir potansiyele sahiptir. Maden kaynaklarının ülke ekonomisine katkı sağlaması için ise rezerv miktarının yeterli miktarda olması önemli bir husustur. Dünyadaki önemli bor yatakları Türkiye, Rusya ve Amerika Birleşik Devletlerinde bulunmaktadır. Bu bağlamda Türkiye ise dünyadaki toplam bor rezervinin % 72.8'ine sahiptir. Rezerv açısından Türkiye'de en çok bulunan bor cevherlerinden birisi de kolemanit (2CaO.3B2O3.5H2O) mineralleridir [1]. Kolemanit minerali günümüzde kullanılmakta ve gelecekte kullanımı muhtemel alanlarda çalışmalar yapılmaktadır. Dünyada en çok kullanılan yapı malzemelerinden birisi olan beton üretiminde kolemanitin kullanılabilirliği üzerine yapılan

çalışmalar bulunmakta ve çalışmalara devam edilmektedir [2, 3, 4].

Kolemanit mineralinin beton üretiminde kullanılması ile yapısında bulunan bor oksitinin (B₂O₃) betonun sertleşme süresini uzattığı ve erken yaşlarda basınç dayanımını düşürdüğü bilinmektedir [5, 6]. Kolemanit minerali ile üretilen betonların basınç dayanımı zamanla artış göstermektedir [7]. Üretimi gerçekleştirilen betonların dayanım kazanımına kadar geçen süre içerisinde bulunduğu kür koşulları betonun dayanımını etkilemektedir. Betonun dayanımının gelişiminde kür koşullarının etkisinin belirlenmesi amacıyla birçok çalışma yapılmış ve betonun yeterli dayanım kazanıncaya kadar kür edilmesinin önemli olduğu belirtilmektedir [8, 9].

Bu çalışmada kolemanit mineralinin kullanımı ile geç dayanım kazanan betonların farklı koşullarda kür

edilmesinin basınç dayanımına etkilerinin belirlenmesi hedeflenmiştir. Beton üretiminde kolemanit minerali % 0, % 1, % 2, % 3, % 4 ve % 5 oranlarında çimentoya ikame edilerek betonlar farklı kür koşullarında bekletilmiştir. Beton numuneler üzerinde ultrases geçiş hızı ve basınç dayanımı deneyleri yapılmıştır.

2. Materyal ve Metot

Beton karışımlarında kullanılan malzemeler CEM I 42.5 R çimentosu, kolemanit, kırmataş agregası, süper akışkanlaştırıcı (SA) katkı maddesi ve şebeke suyundan oluşmaktadır. Çimentoya ait fiziksel ve kimyasal özellikler Tablo 1'de verilmiştir.

Tablo 1. Çimentoya ait fiziksel ve kimyasal özellikler.


Analiz	Deneysel	Değerler
Fiziksel	Yoğunluk, gr/cm ²	3.12
	Özgül yüzey, cm ² /g	3362
	45 µm elek kalıntısı, %	3.0
	Priz baş. sür., dk	155
	Priz bit. sür., dk	215
	Hacim sabitliği, mm	1.50
Kimyasal	Oksitler	%
	SiO ₂	19.00
	Al ₂ O ₃	4.52
	Fe ₂ O ₃	3.36
	CaO	62.64
	MgO	2.98
	SO ₃	3.03
	Kızdırma kaybı	3.03
	Çözünmez kalıntı	0.29
	Tayin edilemeyen	1.14

Çalışmada kullanılan öğütülmüş kolemanit minerali, Eti Maden İşletmeleri Genel Müdürlüğü Bigadiç Bor İşletme Müdürlüğü maden ocağından temin edilmiştir. Öğütülmüş kolemanit mineralinin minimum % 82'si 75 µm elek altı olup kimyasal özellikleri Tablo 2'de görülmektedir [10].

Tablo 2. Kolemanite ait kimyasal özellikler [10].

Analiz	Oksit	%
Kimyasal	B ₂ O ₃	40.00±0.50
	CaO	27.00±1.00
	SiO ₂	4.00-6.50
	SO ₄	Maks. 0.60
	Fe ₂ O ₃	Maks. 0.08
	Al ₂ O ₃	Maks. 0.40
	MgO	Maks. 3.00
	SrO	Maks. 1.50
	Na ₂ O	Maks. 0.50
	Nem	Maks. 1.00

Kırmataş agregalarının tane dağılımı standartlarda belirtilen esaslara göre belirlenmiş olup agregalara ait deneysel granülometri eğrisi Şekil 1'de verilmiştir [11, 12].



Şekil 1. Granülometri eğrisi

Kırmataş agregalarının yoğunluk ve su emme değerleri belirlenmiş ve Tablo 3'te gösterilmiştir [13].

Tablo 3. Kırmataş agregalara ait fiziksel özellikler.

Deneysel	Agrega boyutu	Değerler
Yoğunluk	0-5, mm	2.63, g/cm ³
	5-12, mm	2.70, g/cm ³
	12-25, mm	2.72, g/cm ³
Su emme	0-5, mm	2.30, %
	5-12, mm	1.65, %
	12-25, mm	1.20, %

Kolemanit minerali % 0, % 1, % 2, % 3, % 4 ve % 5 oranlarında çimentoya ikame olarak kullanılmış olup, betonların karışım hesapları standartlara uygun olarak belirlenmiştir [14, 15]. % 0 (K0), % 1 (K1), % 2 (K2), % 3 (K3), % 4 (K4) ve % 5 (K5) olmak üzere altı tür beton karışımı hazırlanmış ve taze betonlar 100x100x400 mm prizmatik boyuttaki kalıplara her seriden 9'ar adet toplamda ise 54 adet olmak üzere numune üretimi gerçekleştirilmiştir. Kolemanit ikamesiz (K0) beton karışımına giren 1 m³'lük malzeme miktarları Tablo 4'te verilmiştir.

Tablo 4. K0 beton türünün 1 m³'lük malzeme miktarı.

Malzemeler	Miktarlar
Çimento, kg	350
Su, lt	157.5
SA, kg	2.8
0-5 kırma kum, mm	925
5-12 kırmataş, mm	409
12-25 kırmataş, mm	589

K0, K1, K2, K3, K4 ve K5 olarak kodlama yapılan her bir beton türünden 3'er adet olmak üzere numuneler üç farklı şekilde kür koşullarına maruz bırakılmıştır:

- Birinci grup (G1) beton numuneleri 7 gün suda kür edilerek 90. güne kadar laboratuvar ortamında bekletilmiştir.
- İkinci grup (G2) beton numuneleri 28 gün suda kür edildikten sonra 90. güne kadar laboratuvar ortamında bekletilmiştir.
- Üçüncü grup (G3) beton numuneleri ise 90 gün boyunca su kürüne maruz bırakılmıştır. Beton numunelere uygulanan kür koşulları ve süresi Tablo 5'te görülmektedir.


Tablo 5. Kür koşulu ve süresi.

Gruplar	Su kürü süresi	Laboratuvar ortamı süresi
G1	7 gün	83 gün
G2	28 gün	62 gün
G3	90 gün	0 gün

Kür uygulamalarının ardından 100x100x400 mm boyutundaki numuneler basınç dayanımı deneyi için taş kesme makinası ile 100x100x100 mm boyutlara getirilmiştir. Elde edilen küp beton numunelerin ultrases geçiş hızı ve basınç dayanımı belirlenmiştir [16, 17].

3. Bulgular

K0, K1, K2, K3, K4 ve K5 beton türlerine ait numuneler farklı kür koşullarına maruz bırakılmış ve 90. gün sonunda ultrases geçiş hızı değerleri belirlenmiştir. Elde edilen ultrases geçiş hızı değerleri Şekil 2’de görülmektedir. G1 kür koşulundaki beton numunelerin ultrases geçiş hızları 4.60 km/s - 4.70 km/s, G2 kür koşulunda 4.65 km/s - 4.77 km/s, G3 kür koşulunda ise 4.66 km/s - 4.82 km/s aralığında ölçülmüştür. Bütün kür koşullarında en düşük ultrases geçiş hızı K5, en yüksek ultrases geçiş hızı ise K3 beton numunesine aittir.

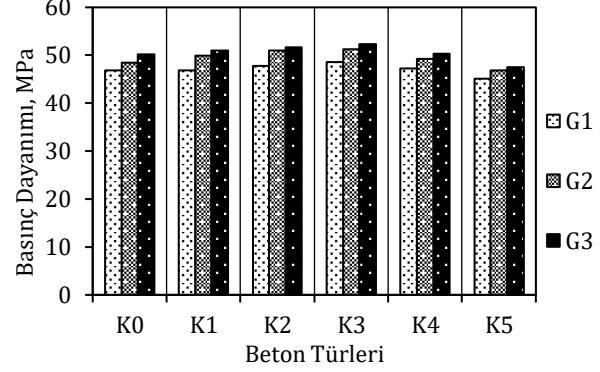
**Şekil 2.** Ultrases geçiş hızı değerleri

Farklı kür koşullarının beton türüne bağlı olarak ultrases geçiş hızı üzerindeki etkisini görmek amacıyla kolemanit ikamesi (K1, K2, K3, K4 ve K5) ile elde edilen betonların ultrases geçiş hızlarının kolemanit ikamesiz (K0) betonun ultrases geçiş hızına göre yüzdeleri hesaplanmıştır. K1, K2, K3, K4 ve K5 beton türlerinin K0 beton numunesine göre hesaplanan ultrases geçiş hızı yüzdeleri Tablo 6’da verilmiştir.

Tablo 6. Ultrases geçiş hızı yüzdeleri.

Beton türleri	Kür koşulları		
	G1	G2	G3
K0	100.00	100.00	100.00
K1	99.92	100.44	99.40
K2	101.49	101.33	100.59
K3	102.15	102.31	102.05
K4	100.86	100.34	99.63
K5	99.92	99.57	98.59

Kolemanit mineralinin çimentoya ikame edilmesi ile farklı kür koşullarında dayanım gelişimi için yapılan çalışmada 100x100x100 mm küp beton örneklerinin 90. gün sonunda basınç dayanım tek eksenli basınç dayanımı deneyi ile belirlenmiştir. Bulunan basınç dayanımı değerleri Şekil 3’te görülmektedir. G1 kür koşulundaki beton numunelerin basınç dayanımı 45.11 MPa – 48.64 MPa, G2 küründe 46.88 MPa – 51.26 MPa, G3 kür koşulunda ise 47.55 MPa – 52.30 MPa aralığında bulunmuştur.

**Şekil 3.** Basınç dayanımı değerleri

Farklı kür koşullarında aynı tür betonların elde edilen basınç dayanımı sonuçlarına göre en yüksek değerler en uzun su kürü olan G3 kür koşullarında, en düşük basınç dayanımı sonuçları ise G1 kür koşullarında elde edilmiştir. K1, K2, K3, K4 ve K5 beton türlerinin K0 beton numunesine göre hesaplanan basınç dayanımı yüzdeleri Tablo 7’de verilmiştir.

Tablo 7. Basınç dayanımı yüzdeleri.

Beton türleri	Kür koşulları		
	G1	G2	G3
K0	100.00	100.00	100.00
K1	100.16	103.06	101.37
K2	102.03	105.09	102.70
K3	103.96	105.74	104.07
K4	100.97	101.63	100.01
K5	99.42	96.70	94.62

Tablo 7 incelendiğinde görülmektedir ki kolemanit ikamesinin % 4’ e kadar kullanılması ile bütün kür koşullarında dayanım değerleri kolemanit ikamesiz betondan yüksek sonuçlanmıştır. Kolemanit ikamesinin % 5 olduğu K5 beton türünde ise dayanım K0 beton türüne göre dayanımı düşürmüştür. K3 beton türü ise G1, G2 ve G3 kür koşullarında K0 beton türüne göre en yüksek basınç dayanımını sağlamıştır.

4. Tartışma ve Sonuç

Ultrases geçiş hızı bilinen beton numunelerin beton kalitesi hakkında yaklaşık bir tahmin yapılabilmektedir [18]. Ultrases geçiş hızı değerleri ile beton kalitesi arasındaki ilişki ise ultrases geçiş hızı değerinin 4.5 km/s’den büyük olması durumunda betonun kalitesi “çok iyi” olarak nitelendirilmektedir [19]. Çalışmada G1, G2 ve G3 kür koşullarında beklenen bütün beton türlerinde elde edilen ultrases

geçiş hızı değerleri 4.60 km/s ile 4.82 km/s aralığında ölçülmüştür. Ultrases geçiş hızı sonuçlarına göre farklı kür koşullarında bekletilen beton türlerinin kalitesi “çok iyi” olarak nitelendirilebilir.

Şekil 3 ile Tablo 7 incelendiğinde kolemanitin % 1, % 2, % 3, % 4 ve % 5 oranlarında çimento ikame edilmesiyle elde edilen beton türlerinde kolemanitin % 5 ikame edilmesi tüm kür koşullarında basınç dayanımını düşürmüştür. Kolemanit ikamesi ile G1 kür koşulunda K1, K2, K3 ve K4 beton türleri K0 beton türüne göre sırasıyla % 0.16, % 2.03, % 3.96 ve % 0.97 basınç dayanımını artırırken K5 beton türü ise % 3.58 basınç dayanımını düşürmüştür. G2 kür koşulunda K5 beton türünde % 3.30 dayanım kaybı, K1, K2, K3 ve K4 beton türlerinde ise % 3.06, % 5.09, % 5.74 ve % 1.63 dayanım artışı meydana gelmiştir. G3 küründe ise dayanım artışı sırasıyla % 1.37, % 2.70, % 4.07 ve % 0.01 olarak K1, K2, K3 ve K4 beton türlerinde dayanım kaybı ise % 5.38 ile K5 beton türünde olduğu belirlenmiştir. Literatürde bor minerallerinin B₂O₃ içeriğinden dolayı yüksek oranlarda kullanılmasının dayanım değerlerini düşürdüğü % 5'e kadar kullanılması önerilmektedir [5]. Yapılan bir çalışmada ise en iyi dayanım sonuçlarının % 3 ve % 5 kolemanit ikame edilmesi ile elde edildiği belirtilmektedir [20]. Elde edilen basınç dayanımı değerleri sonucunda kolemanit ikamesi ile en yüksek dayanım % 3 kolemanit ikamesi ile elde edilmesine rağmen % 4 kolemanit ikamesi kolemanit ikamesiz betonun dayanım değerinden yüksek değerler vermiştir. % 5 kolemanit ikamesi ise G1, G2 ve G3 kür koşullarında % 3.30 ile % 5.38 arasında dayanım kaybı oluşturmaktadır.

G1, G2 ve G3 kür koşullarında bekleyen K0, K1, K2, K3, K4 ve K5 türlerinin en yüksek basınç dayanımı sonuçları G3 kür koşulunda, en düşük dayanım değerleri ise G1 kür koşulunda meydana gelmiştir. Beton numunelerin su kürü süresi arttıkça dayanım artışı da artmıştır.

Sonuç olarak bütün kür koşullarında ultrases geçiş hızı ve basınç dayanımı en düşük K5 beton numunesinde en yüksek basınç dayanımı ise K3 beton numunesinde görülmüştür. Beton numunelerin su kürüne maruz kalma süresi arttıkça ultrases geçiş hızı ve basınç dayanımı artmıştır. Elde edilen sonuçlara göre betonlara uygulanan su kürü süresinin artması, betonun dayanımını olumlu yönde etkilemektedir.

Teşekkür

Yazarlar çalışmada kullanılan kolemanit mineralini tedarik eden Eti Maden İşletmeleri Genel Müdürlüğüne teşekkür eder.

Kaynakça

[1] Etimaden, 2015-2019 dönemi stratejik planı: <http://www.etimaden.gov.tr/storage/uploads/>

[2018/05/Stratejik plan 2015 2019.pdf](#). (Erişim Tarihi: 20.12.2018)

- [2] Kula, İ., Olgun, A., Erdogan, Y. & Sevinc, V. (2001). Effects of colemanite waste, cool bottom ash, and fly ash on the properties of cement. *Cement and Concrete Research*, 31, 491-494.
- [3] Glinicki, M. A., Antolik, A. & Gawlicki, M. (2018). Evaluation of compatibility of neutron-shielding boron aggregates with Portland cement in mortar. *Construction and Building Materials*, 164, 731-738.
- [4] Kutuk-Sert, T. (2016). Stability analyses of submicron-boron mineral prepared by mechanical milling process in concrete roads. *Construction and Building Materials*, 121, 255-264.
- [5] Erdoğan, Y., Zeybek, M. S. & Demirbaş, A. (1998). Cement mixes containing colemanite from concentrator wastes. *Cement and Concrete Research*, 28(4), 605-609.
- [6] Gezmen, T. & Türkel, S. (2017). Bor minerali ve uçucu kül içeren harçların mekanik özelliklerinin ve sülfata dayanıklılığının incelenmesi. *Dokuz Eylül Üniversitesi-Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 19(57), 757-778.
- [7] Binici, H., Sevinç, A. H. & Durgun, M. Y. (2010). Properties of barite, basaltic pumice, colemanite and blast furnace slag concretes. *KSU Journal of Engineering Sciences*, 13(1), 1-13.
- [8] Alyamaç, K. E. & İnce, R. (2007). Kür süresinin betonun kırılma parametreleri üzerine etkisinin incelenmesi. 2007 tarihli 8. Uluslararası Kırılma Konferansı.
- [9] Özcan, F. (2017). Farklı dayanım sınıflarına ait betonların basınç dayanımlarına değişen kür şartlarının etkisi. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 6(1), 115-121.
- [10] Etimaden, Ögütülmüş kolemanit: <http://www.etimaden.gov.tr/storage/uploads/2018/01/16-2017-Ground-Colemanite-75-Micron.pdf>. (Erişim Tarihi: 20.12.2018).
- [11] Türk Standardları Enstitüsü. (2009). TS 706 EN 12620+A1: Beton agregaları. Ankara: Türk Standardları Enstitüsü.
- [12] Türk Standardları Enstitüsü. (2012). TS EN 933-1:2012(EN): Agregaların geometrik özellikleri için deneyler bölüm 1: Tane büyüklüğü dağılımı tayini - Eleme metodu. Ankara: Türk Standardları Enstitüsü.
- [13] Türk Standardları Enstitüsü. (2013). TS EN 1097-6: Agregaların mekanik ve fiziksel özellikleri için deneyler bölüm 6: Tane yoğunluğu ve su emme oranının tayini. Ankara: Türk Standardları Enstitüsü.

- [14] Türk Standardları Enstitüsü. (2016). TS 802: Beton karışım tasarımı hesap esasları. Ankara: Türk Standardları Enstitüsü.
- [15] Türk Standardları Enstitüsü. (2017). TS EN 206:2013+A1: Beton - Özellik, performans, imalât ve uygunluk. Ankara: Türk Standardları Enstitüsü.
- [16] ASTM International. (2002). ASTM C 597-83: Standard Test Method for Pulse Velocity Through Concrete. American Society For Testing And Materials, USA.
- [17] Türk Standardları Enstitüsü. (2010). TS EN 12390-3: Beton - Sertleşmiş beton deneyleri - Bölüm 3: Deney numunelerinin basınç dayanımının tayini. Ankara: Türk Standardları Enstitüsü.
- [18] Durmuş, G. & Bekem, İ. (2010). Yüksek sıcaklığın ve farklı soğutma koşulunun kalker agregalı betonlar Üzerindeki etkilerinin araştırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25(4), 741-748.
- [19] Kara, C. (2018). Çay atığının doğal lif olarak betonda kullanılabilirliği. *Doğal Afetler ve Çevre Dergisi*, 4 (2), 156-161.
- [20] Korkut Sevim, U. (2011). Colemanite ore waste concrete with low shrinkage and high split tensile strength. *Materials and Structures*, 44, 187-193.

Beton Basınç Dayanımının JAYA ve Öğretme-Öğrenme Tabanlı Optimizasyon (TLBO) Algoritmalarıyla Modellenmesi

Hasan Tahsin ÖZTÜRK*¹

¹Karadeniz Teknik Üniversitesi, Of Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, 61830, Trabzon

(Alınış / Received: 30.12.2018, Kabul / Accepted: 31.12.2018, Online Yayınlanma / Published Online: 31.12.2018)

Anahtar Kelimeler

Beton
Basınç Dayanımı
JAYA Algoritması
TLBO Algoritması

Özet: Bu çalışmada, laboratuvarında üretilen küp numunelerin, basınç dayanımları belirlenmiş, ultrasonik dalga iletim hızı ölçümleri, Schmidt çekiciyle sıçrama sayısı ölçümleri yapılmış ve tartımla boşluk oranları belirlenmiştir. Ultrason testinden elde edilen dalga iletim hızı, Schmidt çekiciyle belirlenen sıçrama sayısı ve tartım yoluyla hesaplanan boşluk oranı arasında bir regresyon ilişkisi kurarak bu ilişki yardımıyla beton dayanımını tahmin etmek amaçlanmaktadır. Deneylerden elde edilen verilerin regresyon fonksiyonlarına Öğretme-öğrenme tabanlı optimizasyon algoritması (TLBO) ve JAYA algoritmaları uygulanmıştır. Giriş parametreleri, ultrason ölçümleri, Schmidt çekiciyle elde edilen sıçrama sayısı ve tartımla hesaplanan boşluk oranı sonucu elde edilen ortalama dalga iletim hızıdır. Öğretme-öğrenme tabanlı optimizasyon algoritması (TLBO) ve JAYA algoritmalarının karşılaştırılması için, algoritmalar; karesel, üstel, doğrusal, S fonksiyonu, Ters, Ln fonksiyonu ve üs adlarıyla anılan yedi farklı regresyon formuna uygulanmıştır. Modellerin başarımını değerlendirmek için; ortalama karesel hata, ortalama karesel hatanın karekökü, ortalama mutlak hata, ortalama mutlak hata oranı ve belirleme katsayısı gibi beş istatistiksel endeks kullanılmıştır.

Modelling Compressive Strength of Concrete via Teaching-Learning Based Optimization and JAYA Algorithms

Keywords

Concrete
Compressive Strength
JAYA Algorithm
TLBO Algorithm

Abstract: In this study, compressive strength tests, ultrasonic wave transmission speed measurements, Schmidt rebound test hammer measurements were made on the cube samples and void ratios were determined by weighing. It is aimed to estimate the concrete strength with these measurements by establishing a regression relation between the wave transmission speed obtained from the ultrasound test, rebound values from Schmidt rebound hammer and void ratio calculated by weighting. Teaching-learning-based optimization (TLBO) and JAYA algorithms were applied to regression functions of the data from the tests. The input parameters are the average wave transmission speed obtained as a result of ultrasound measurements, rebound values from Schmidt rebound hammer and void ratio calculated by weighting. The accuracy of TLBO method is compared with those of the JAYA algorithm. These methods are applied to seven different regression forms: quadratic, exponential, linear, S function, Inverse, Ln function and power. To evaluate the performance of the models, five statistical indices, i.e., sum square error, root mean square error, mean absolute error, average relative error, and determination coefficient, are used.

1. Giriş

Beton dayanımının tahmin edilebilmesi, özellikle mevcut yapıların dayanımlarının belirlenmesinde önem arz etmektedir. Teknik literatürdeki çalışmaların bir kısmı beton birleşimine giren malzemeleri ve çökme değerini kullanmak suretiyle betonun basınç dayanımının tahmini üzerinde çalışmışlardır [1-5]. Bu çalışmada ise beton birleşimine giren malzemelerin bilinmediği, mevcut bir yapı üzerinde yapılabilecek tahribatsız deneylerle beton dayanımının belirlenebilmesi incelenmektedir. Burada yapıdan alınacak karot numuneler üzerinde yapılacak modelleme çalışmasıyla elde edilen regresyon ifadesi sayesinde diğer bir deyişle modelin kalibre edilmesiyle yapının farklı yerlerinde yapılan tahribatsız ölçümlerle geliştirilen modeli kullanmak suretiyle beton dayanımı tahminini yapılabilmesi sağlanmaktadır. Çalışmada ultrasonik test yöntemiyle elde edilen dalga geçiş hızı, test çekiciyle elde edilen geri sekme sayısı ve porozite gibi parametrelerin kullanılması durumları araştırılarak daha düşük hata oranıyla tahmin yapabilmeyi sağlayan parametrelerin belirlenmesine çalışılmıştır.

Veriler KTÜ Of Teknoloji Fakültesi İnşaat Mühendisliği Bölümü Yapı Laboratuvarında üretilen küp numunelerden alınan ölçümler sonucunda elde edilmiştir (Şekil 1).

Teknik literatürde sezgisel algoritmalar kullanılarak en uygun regresyon denklemlerinin belirlenmesine yönelik çeşitli çalışmalar bulunmaktadır. Bu çalışmaların başlıcalarında; Bir dizi laboratuvar deneyi verileri yardımıyla tahkimat yapısı geometrisinin belirlenmesinde Yapay Arı Koloni ve Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması [6], Cd(II)'nin içme suyu arıtma tesisi atık çamuru üzerine adsorpsiyonunun modellenmesinde Yapay Arı Koloni Algoritması [7], bir derede çözünmüş halde bulunan oksijen konsantrasyonunu tahmininde Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması [8], taşkın debilerinin tahmininde Yapay Arı Koloni ve Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması [9] kullanılmıştır.



Şekil 1. Laboratuvar ortamında yapılan çalışmalardan görülen durumlar

Bu çalışmada porozite değeri, ölçülen ultrases hızı, test çekiciyle elde edilen sıçrama sayısı ve beton basınç dayanımı gibi parametreler kullanılarak modelleme yapabilmek için çeşitli regresyon denklemleri içindeki katsayılar optimize edilmektedir. Teknik literatürdeki yöntemlerden farklı olarak bu çalışmada kullanılan regresyon bağıntılarının minimum hatayı (ortalama karesel hata) verecek şekilde düzenlenerek katsayılarının optimizasyonunda sezgisel algoritmalar olan Öğretme-Öğrenme Tabanlı Optimizasyon (TLBO) ve JAYA algoritmaları kullanılmıştır.

2. Yöntem

Çalışmada numunenin porozite değeri, ölçülen ultrases hızı ve test çekiciyle elde edilen sıçrama sayısı bağımsız değişkenler, beton basınç dayanımı ise bağımlı değişken olarak dikkate alınmıştır. Laboratuvarımızda yapılan deneylere ilişkin verilerin istatistiksel bilgileri Tablo 1'de görülmektedir.

Tablo 1. Verilere ilişkin istatistiksel bilgiler

	En küçük Değer	En Büyük Değer	Ortalama	Standart Sapma	Varyasyon Katsayısı	Korelasyon
Boşluk Oranı	0.008	0.079	0.17	0.046	58.362	-0.838
Dalga Hızı (m/s)	3625	4284.636	5017	342.35	7.99	0.826
Sıçrama Sayısı	16.5	26.823	37	4.476	16.688	0.859
Basınç Dayanımı (MPa)	26.89	38.319	51.53	5.744	14.99	1

Bağımsız değişkenlerle, bağımlı değişkenin modellenmesinde kullanılan regresyon denklemleri sırasıyla; doğrusal, üs, üstel, karesel, s, ters ve Ln fonksiyonları üç bağımsız değişken için aşağıda verilmektedir.

$$y_{doğrusal} = w_0 + w_1x_1 + w_2x_2 + w_3x_3 \quad (1)$$

$$y_{üs} = w_0 \cdot x_1^{w_1} \cdot x_2^{w_2} \cdot x_3^{w_3} \quad (2)$$

$$y_{üstel} = w_0 + \exp(w_1 + w_2x_1 + w_3x_2 + w_4x_3) \quad (3)$$

$$y_s = \exp\left(w_0 + \frac{w_1}{x_1} + \frac{w_2}{x_2} + \frac{w_3}{x_3}\right) \quad (4)$$

$$y_{ters} = w_0 + \frac{w_1}{x_1} + \frac{w_2}{x_2} + \frac{w_3}{x_3} \quad (5)$$

$$y_{Ln} = w_0 + w_1 \ln(x_1) + w_2 \ln(x_2) + w_3 \ln(x_3) \quad (6)$$

$$y_{karesel} = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_3 + w_4 x_1 x_2 + w_5 x_1 x_3 + w_6 x_2 x_3 + w_7 x_1^2 + w_8 x_2^2 + w_9 x_3^2 \quad (7)$$

Çalışmada yukarıdaki denklemlerin katsayılarının algoritmalarla belirlenmesi sürecinde amaç fonksiyonu olarak ortalama karesel hatanın (MSE) minimizasyonu olarak seçilmiştir. Ortalama karesel hata, D deneysel sonucu, T ise bağıntıyla tahmin edilen sonucu göstermek üzere:

$$MSE = \frac{1}{N} \sum_{i=1}^N (T_i - D_i)^2 \quad (8)$$

ifadesiyle hesaplanmaktadır. Bununla birlikte dikkate alınan veriler için ortalama karesel hatanın karekökü (RMSE):

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (T_i - D_i)^2 \right]^{\frac{1}{2}} \quad (9)$$

ortalama mutlak hata (MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |T_i - D_i| \quad (10)$$

ortalama mutlak hata oranı (MAPE):

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|T_i - D_i|}{D_i} \quad (11)$$

ve belirleme katsayısı (R^2) değerleri:

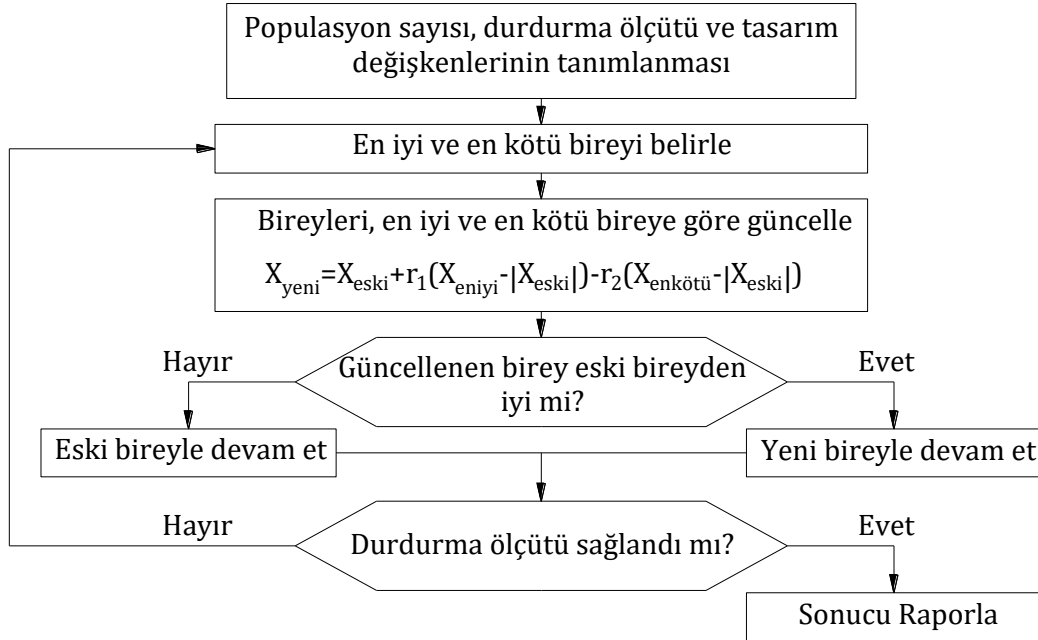
$$R^2 = 1 - \frac{\sum_{i=1}^N (T_i - D_i)^2}{\sum_{i=1}^N (T_i - \bar{T})^2} \quad (12)$$

bağıntıları kullanılmak suretiyle hesaplanmış ve bulgular kısmında çizelge halinde sunulmuştur.

Verilerin %80'i katsayıların optimizasyonunda kullanılmıştır. Geri kalan %20'si optimizasyon sürecinde kullanılmayıp, geliştirilen modelin test edilmesinde kullanılmaktadır. Böylece optimizasyonda kullanılmayıp dışarıdan girilen veriler için modelin başarımı denetlenmiştir.

2.1. Jaya Algoritması

JAYA Algoritması en iyi çözüme ulaşarak zafer kazanmaya çalışan bu özelliğiyle Sanskritçede zafer anlamına gelen bir kelime olan JAYA ile adlandırılan bir algoritmadır. Algoritma başarıya ulaşmak için sürekli iyi çözümlere yaklaşmaya, başarısızlıktan uzaklaşmak için ise kötü çözümlerden uzaklaşmaya çalışmaktadır. Sözkonusu algoritmaya ilişkin ayrıntılı bilgiye kaynak [10]'dan ulaşılabilir. JAYA algoritmasına ilişkin akış diyagramı Şekil 2'de verilmektedir.

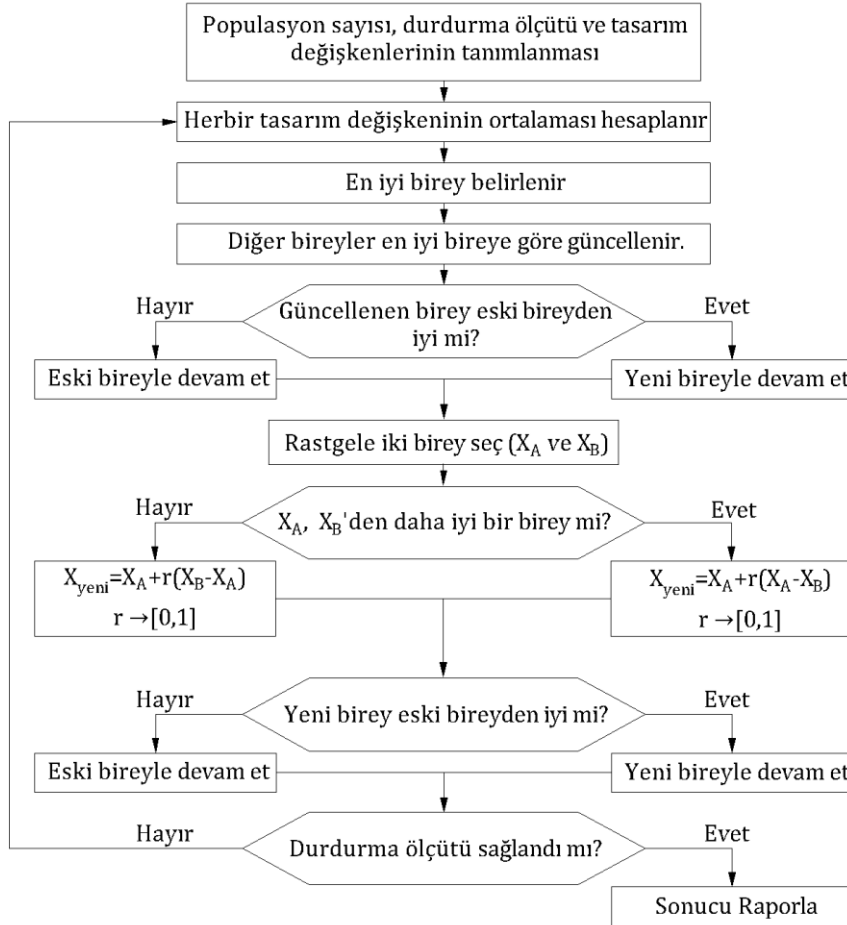


Şekil 1. JAYA algoritması akış diyagramı

2.2. Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması

Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması, öğretmenin sınıftaki öğrenciler üzerindeki etkisini taklit eden sezgisel bir algoritma olduğu

bilinmektedir. Söz konusu algoritmaya ilişkin ayrıntılı bilgiye kaynak [11-12]'den ulaşılabilir. Öğretme-Öğrenme Tabanlı Optimizasyon Algoritmasına ilişkin akış diyagramı Şekil 3'de verilmektedir.



Şekil 3. Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması Akış Diyagramı

3. Bulgular

Yazılım MATLAB programlama dilinde kodlanmıştır. Fonksiyonlarda optimize edilecek tasarım değişkeni sayısı farklı olduğundan herbiri için tasarım değişkeni sayısına göre maksimum iterasyon sayısı belirlenmiştir. Ayrıca JAYA algoritması herbir iterasyonda 1 amaç fonksiyonu değerlendirmesi yaparken, Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması iki adet amaç fonksiyonu değerlendirmesi yapmaktadır. Durum böyle olunca Jaya algoritmasının iterasyon sayısı iki katına çıkarılmıştır. Her bir tasarım değişkeni için 20000 amaç fonksiyonu değerlendirilmesi baz alınarak iterasyon sayıları belirlenmiştir. Her iki algoritmada da popülasyon boyutu 20 alınmıştır. Buna göre fonksiyon tiplerine göre algoritmaların iterasyon sayıları Tablo 3'de verilmektedir.

Tablo 3. Fonksiyon tiplerine göre algoritmaların iterasyon sayıları

Fonksiyon Türü	İterasyon Sayısı	
	JAYA Algoritması	TLBO Algoritması
Doğrusal	4000	2000
Üs	4000	2000
Üstel	5000	2500
Karesel	10000	5000
S fonksiyonu	4000	2000
Ters Fonk.	4000	2000
Ln Fonksiyonu	4000	2000

Algoritmalarla herbir fonksiyon türü için 20 şer bağımsız koşum gerçekleştirilmiş ve bu bağımsız koşullardan elde edilen en iyi sonuçlar Jaya Algoritması için Tablo 4.'de, Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması için Tablo 5.'de verilmektedir.

Tablo 4. Jaya Algoritmasıyla elde edilen en iyi hata değerleri

	Optimizasyon Veri Seti					Test Veri Seti		
	Jaya Algoritması							
	MSE	RMSE	MAE	MAPE	R2	MSE	MAPE	R2
Doğrusal	3.6848	1.9196	1,5930	0,0417	0,8930	8.6069	0.0663	0.6681
Üs	3,6151	1,9013	1,5628	0,0413	0,8950	8,4647	0,0697	0,6736
Üstel	3,4474	1,8567	1,5528	0,0411	0,8999	8,0762	0,0659	0,6886
Karesel	3.4208	1.8495	1.5168	0.0396	0.9007	8.3076	0.0657	0.6797
S fonksiyonu	4.8163	2.1946	1.8129	0.0483	0.8602	9.3452	0.0720	0.6397
Ters Fonk.	5.4921	2.3435	1.9101	0.0503	0.8406	9.6914	0.0741	0.6263
Ln Function	4.1431	2.0355	1.7176	0.0454	0.8797	8.4212	0.0674	0.6753

Tablo 5. Öğretme-Öğrenme Tabanlı Optimizasyon Algoritmasıyla elde edilen en iyi hata değerleri

	Optimizasyon Veri Seti					Test Veri Seti		
	Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması							
	MSE	RMSE	MAE	MAPE	R2	MSE	MAPE	R2
Doğrusal	3.6847	1.9196	1.5930	0,0417	0.8930	8.6046	0.0663	0.6682
Üs	3.6150	1.9013	1.5637	0.0413	0.8950	8.4592	0.0697	0.6738
Üstel	3.4325	1.8527	1.5420	0.0407	0.9003	8.1880	0.0661	0.6843
Karesel	3.2965	1.8156	1.4848	0.0391	0.9043	8.0925	0.0654	0.6880
S fonksiyonu	4.8145	2.1942	1.8126	0.0483	0.8602	9.3219	0.0719	0.6406
Ters Fonk.	5.4921	2.3435	1.9100	0.0503	0.8406	9.6838	0.0741	0.6266
Ln Function	4.1431	2.0355	1.7176	0.0454	0.8797	8.4170	0.0673	0.6755


Elde edilen sonuçlar incelendiğinde her iki algoritmayla elde edilen en küçük ortalama karesel hata değerinin de karesel fonksiyon kullanılarak bulunduğu anlaşılmaktadır. Durum böyle olunca söz konusu verileri temsil eden en iyi modelin karesel fonksiyon olduğu görülmektedir. Ayrıca belirleme katsayıları incelendiğinde de karesel fonksiyonun en yüksek değere sahip olduğu görülmektedir.

Diğer taraftan Öğrenme-Öğretme Tabanlı Optimizasyon Algoritmasıyla elde edilen ortalama karesel hata değerinin, Jaya Algoritmasıyla elde edilenden küçük bir miktar daha düşük olduğu görülmektedir. Karesel fonksiyonda, Öğrenme-Öğretme Tabanlı Optimizasyon Algoritması kullanılarak gerçekleştirilen 20 bağımsız koşumun en küçük ortalama karesel hatayı veren koşum için belirlenen katsayıları aşağıdaki Tablo 6.'da verilmektedir. Bu tabloda x_1 porozite değerini, x_2 ultrasonik test yöntemiyle elde edilen dalga geçiş hızı, x_3 test çekicisiyle elde edilen sıçrama sayısını temsil etmektedir.

Karesel fonksiyon için, Öğrenme-Öğretme Tabanlı Optimizasyon Algoritması kullanılarak gerçekleştirilen 20 bağımsız koşumun ortalama yakınsama grafiği Şekil 4.'de görülmektedir.

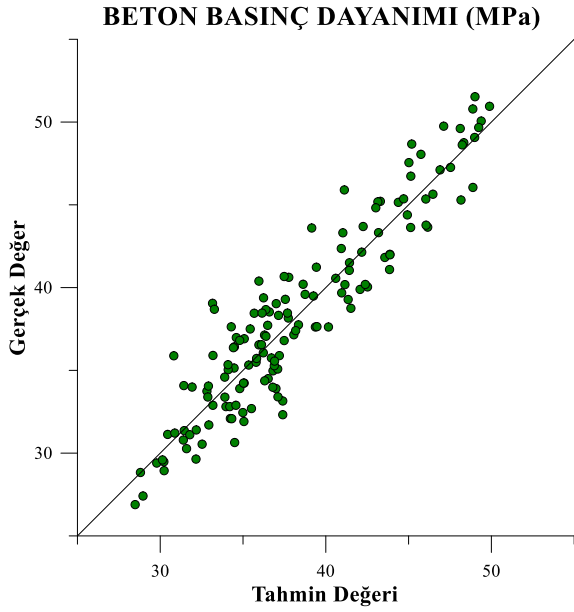
Tablo 6. Karesel fonksiyon için Öğretme-Öğrenme Tabanlı Optimizasyon Algoritmasıyla elde edilen optimum katsayılar

Fonksiyon			
$y_{karesel} = w_0 + w_1x_1 + w_2x_2 + w_3x_3 + w_4x_1x_2$			
$+w_5x_1x_3 + w_6x_2x_3 + w_7x_1^2 + w_8x_2^2 + w_9x_3^2$			
Katsayılar			
w_0	0.32199964	w_5	0.01875103
w_1	-0.43909813	w_6	-1
w_2	0.31796247	w_7	0.21323478
w_3	0.25089190	w_8	0.52411896
w_4	-0.19248456	w_9	0.60092705

**Şekil 4.** Ortalama Yakınsama Grafiği

Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması kullanılarak karesel fonksiyon modeliyle tahmin

edilen dayanımlarla gerçek değerlerin karşılaştırma grafiği Şekil 5.'de verilmektedir.



Şekil 5. Karesel fonksiyon modeliyle tahmin edilen dayanımlarla gerçek değerlerin karşılaştırma grafiği

4. Sonuç

Elde edilen bulgular değerlendirildiğinde kullanılan regresyon denklemlerinden en küçük ortalama karesel hata değeri karesel fonksiyon ile elde edilmiştir. En kötü hata değeri ise ters fonksiyon için belirlenmiştir. Durum böyle olunca söz konusu verileri temsil eden en iyi modelin karesel fonksiyon olduğu görülmektedir. Ayrıca belirleme katsayıları incelendiğinde de karesel fonksiyonun en yüksek değere sahip olduğu görülmektedir. Belirleme katsayısının elde edilen 0.9043 değeri geliştirilen modelin bağlı değişken ile bağımsız değişkenler arasında yeterli geçerlilikte bir ilişki kurabildiğini göstermektedir. Öğretme-Öğrenme Tabanlı Optimizasyon Algoritması ve JAYA Algoritması karşılaştırıldığında bu iki algoritmadan Öğretme-Öğrenme Tabanlı Optimizasyon Algoritmasının daha düşük hata değerine ve daha yüksek belirleme katsayısına (R2) ulaşabildiği görülmektedir.

Teşekkür

Bu çalışma Karadeniz Teknik Üniversitesi Bilimsel Araştırma Projeleri Biriminin FAY-2016-5429 nolu projesiyle desteklenmiştir.

Kaynakça

- [1] Ni, H. G., & Wang, J. Z. (2000). Prediction of compressive strength of concrete by neural networks. *Cement and Concrete Research*, 30(8), 1245-1250.
- [2] Topcu, I. B., & Sarıdemir, M. (2008). Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy

- logic. *Computational Materials Science*, 41(3), 305-311.
- [3] Yuan, Z., Wang, L. N., & Ji, X. (2014). Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS. *Advances in Engineering Software*, 67, 156-163.
- [4] Nikoo, M., Torabian Moghadam, F., & Sadowski, Ł. (2015). Prediction of concrete compressive strength by evolutionary artificial neural networks. *Advances in Materials Science and Engineering*, 2015.
- [5] Yu, Y., Li, W., Li, J., & Nguyen, T. N. (2018). A novel optimised self-learning method for compressive strength prediction of high performance concrete. *Construction and Building Materials*, 184, 229-247.
- [6] Uzlu, E., Kömürçü, M. İ., Kankal, M., Dede, T., & Öztürk, H. T. (2014). Prediction of berm geometry using a set of laboratory tests combined with teaching-learning-based optimization and artificial bee colony algorithms. *Applied Ocean Research*, 48, 103-113.
- [7] Öztürk, N., Şentürk, H.B., Gündoğdu, A., & Duran, C., (2014). Cd(II)'nin İçme Suyu Arıtma Tesisi Atık Çamuru Üzerine Adsorpsiyonu: Modelleme ve Optimizasyon, 7. *Ulusal Analitik Kimya Kongresi Bildiriler Kitabı*, 234-234.
- [8] Bayram, A., Uzlu, E., Kankal, M., & Dede, T. (2015). Modeling stream dissolved oxygen concentration using teaching-learning based optimization algorithm. *Environmental Earth Sciences*, 73(10), 6565-6576.
- [9] Anılan, T., Uzlu, E., Kankal, M., & Yüksek, O. (2018). The estimation of flood quantiles in ungauged sites using teaching-learning based optimization and artificial bee colony algorithms. *Scientia Iranica*, 25(2), 632-645.
- [10] Rao, R. (2016). Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems. *International Journal of Industrial Engineering Computations*, 7(1), 19-34.
- [11] Rao, R. V., Savsani, V. J., & Vakharia, D. P. (2011). Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, 43(3), 303-315.
- [12] Rao, R. V., Savsani, V. J., & Vakharia, D. P. (2012). Teaching-learning-based optimization: an optimization method for continuous non-linear large scale problems. *Information sciences*, 183(1), 1-15.

Damage Detection and Damage Determination Methods in Reinforced Concrete Buildings

Yusuf YANIK^{1a}, Gonca KAMBER YILMAZ^{*1}, Temel TÜRKER^{2b}

¹ Karadeniz Teknik Üniversitesi, Of Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, 61830, Trabzon

² Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 61080, Trabzon

(Received: 29.12.2018, Accepted: 31.12.2018, Published Online: 31.12.2018)

Keywords

Damage Detection
Causes of Damage
Modal Analysis

Abstract: There are many causes of damage for damage to buildings in our country. The most important of these is the earthquake loads used during the project phase of the buildings. In addition, the mistakes made in the manufacturing process, the concessions given to the building safety to gain from the usage area constitute a significant part of the causes of the building damage. In addition, the selection of the structural system of buildings, different settlements on the ground, fire, freeze-thaw, impact and blasting effects are also damage causes. In this study, causes of damage in reinforced concrete buildings and damage detection methods are investigated. Determining the damage and determining the cause of the damage play an important role in taking precautions against future cases and repairing existing damages.

Betonarme Binalarda Hasar Tespiti ve Hasar Belirleme Yöntemleri

Anahtar Kelimeler

Hasar Tespiti
Hasar Sebepleri
Modal Analiz

Özet: Ülkemizde yapılan binalarda oluşan hasarların birçok nedeni bulunmaktadır. Bunların başında, yapıların projelendirilme aşamasında kullanılan ve önemli ölçüde dikkate alınan deprem yükleri gelmektedir. Bunun dışında imalat aşamasında yapılan hatalar, kullanım alanından kazanmak için yapı güvenliğinden verilen tavizler yapı hasar sebeplerinin önemli bir kısmını oluşturmaktadır. Ayrıca binaların taşıyıcı sisteminin seçimi, zeminde oluşan farklı oturmaları, yangın, donma-çözünme, çarpma ve patlatma etkileri de hasar sebeplerindedir. Bu çalışmada, betonarme binalarda oluşan hasarların sebepleri ve hasar belirleme yöntemleri üzerinde inceleme yapılmıştır. Hasarların belirlenmesi ve hangi nedenlerden dolayı meydana geldiğinin tespit edilmesi ileride oluşabilecek vakalara karşı önlem alınmasında ve mevcut hasarların onarılmasında son derece önemli rol oynamaktadır.

1. Giriş

Büyük bir bölümü deprem kuşağında yer alan ülkemizde, ilk deprem yönetmeliği 1947 yılında yayımlanmış, bunu 1953, 1961, 1968, 1975, 1998 ve 2007 yönetmelikleri izlemiştir. Bütün iyi niyetli çabalara rağmen depremin oluşturabileceği etkiler iyi anlaşılammış ve meydana gelen depremlerde binlerce kişi hayatını kaybetmiştir. Deprem afetine yeterli önemin verilmemesi, Türkiye'yi depreme dayanıksız bir yapı stoğu ile karşı karşıya bırakmıştır. Yapıların hasar tespitlerinin yapılması ve gerek görüldüğü durumlarda da güçlendirilme çalışmaları,

1997 yılında meydana gelen Adana-Ceyhan ve 1998 yılında meydana gelen Kocaeli ve Düzce depremlerinden sonra önem kazanmıştır. Bu depremlerden elde edilen deneyim ve bilimsel gelişmeler dikkate alınarak Türkiye Bina Deprem Yönetmeliği son olarak revize edilerek 18 Mart 2018 tarihli Resmî Gazete'de yayınlanmıştır. Yönetmeliğin yürürlüğe giriş tarihi 1 Ocak 2019 olarak belirlenmiştir. Mevcut yapı stoğunun önemli bir kısmının deprem dayanımının yetersiz oluşu, kentsel dönüşüm adı altında yapılan çalışmalar, gelişen teknolojiye bağlı olarak yapı modellerinin ve

*İlgili Yazar: gonckamber@ktu.edu.tr. ORCID: 0000-0002-6894-6076

^aORCID: 0000-0002-5487-5254

^bORCID: 0000-0001-5632-693X

malzeme çeşitliliğinin artması gibi sebeplerle yönetmelikte güncellemeye gidilmiştir [1].

Yapıda deprem sırasında oluşan hasar şekillerine bakıldığında; zemin özellikleri, yapı- zemin etkileşimi, taşıyıcı sistem elemanlarının malzeme ve işçilik kalitesi, boyutu ve konumlandırılması, hatta taşıyıcı olmayan sistem durumunun yapının deprem sırasındaki davranışı üzerinde etkili olduğu görülmektedir. Bu etkenlerden biri veya birkaçının yetersiz veya yanlış olmasına bağlı olarak deprem sırasında binada ciddi hasarlar meydana gelmektedir. Bu hasarların giderilmesi ve yapıyı yeniden güvenli bir hale getirmek için güçlendirmeye gidilmesi şarttır. Donatı yerleştirme hataları, hatalı yapılmış konsollar ve çıkmalar, kullanım alanından kazanmak için yapı güvenliğinden verilen tavizler yapı hasar sebeplerinin önemli bir kısmını oluşturmaktadır. Bu çalışmada betonarme binalarda oluşan hasarların sebepleri, türleri ve hasar belirleme yöntemleri derlenerek sunulmuştur.

2. Betonarme Binalarda Hasar Sebepleri

Betonarme binalarda oluşan hasarların büyük çoğunluğu; imalatta yapılan hatalar, taşıyıcı sistem seçiminden kaynaklı sebepler, zemin hareketleri, deprem, yangın ve donma, çarpma, patlatma ve aşırı yüklenme sonucu oluşmaktadır.

2.1. İmalat Kusurları

Yapının ya da yapı elemanlarının imalatı sırasında oluşan ve yapının istenilenden farklı bir davranış göstermesine neden olan etkilerdir. Bir yapının iskeleti anlamına gelen taşıyıcı sistemi hatasız olmalıdır. Yapının taşıyıcı sistemi yapının fonksiyonuna uygun, statik ve dinamik yüküne, çevre etkilerine ve en önemlisi deprem etkilerine karşı mukavemetli olmalıdır. Bunun için yapı imalatında malzeme seçiminin, tasarımının, uygulamasının ve denetiminin önemi büyüktür.

Betonarme yapılarda beton karışımına giren malzemelerin kaliteli ve istenilen standartta olması gerekir. Deprem ve afet bölgelerindeki can ve mal kaybının, büyük çoğunluğu yapı malzemesi kalitesinin düşük olmasından kaynaklanmaktadır. Yapı malzemelerinin kendilerinden beklenen özelliklere sahip olmamaları sonucu yapılarda çok büyük hasarlar meydana gelir. Bu nedenle yapı malzeme kalitesinin mimarlar, mühendisler, uygulamacılar ve yapı sahipleri tarafından iyi bilinmesi gerekmektedir.

Genel olarak binalarda oluşan hasar sebepleri;

- Yanlış malzeme seçimi kullanılması (korozyonlu alanlarda yapılacak binalarda uygun çimento sınıfının seçilmemesi),
- Temel altına grobeton dökülmemesi,

- Yanlış ve yetersiz donatı detayları,
 - Etriye sıklaştırmasının yapılmaması,
 - Donatı filiz boylarının az bırakılması,
 - Yapım aşamasında denetim eksikliği,
 - Beton kürünün yapılmaması
- olarak sıralanabilmektedir.

2.2. Taşıyıcı Sistem Seçiminden Kaynaklanan Sebepler

2.2.1. Yumuşak Kat Oluşumu

Birbirine dik iki deprem doğrultusunun herhangi biri için, bodrum katlar dışında, herhangi bir kattaki ortalama görelî kat ötelemesi oranının bir üst veya bir alt kattaki ortalama görelî kat ötelemesi oranına bölünmesi ile tanımlanan rijitlik düzensizliği katsayısının 2.0'den fazla olması durumudur. Diğer bir deyişle komşu katlar arası rijitlik düzensizliğidir [2].

2.2.2. Zayıf Kat Oluşumu

Betonarme binalarda, birbirine dik iki deprem doğrultusunun herhangi birinde, herhangi bir kattaki toplam etkili kesme alanının, bir üst kattaki toplam etkili kesme alanına oranı olarak tanımlanan dayanım düzensizliği katsayısının 0.80'den küçük olması durumudur. Diğer bir deyişle komşu katlar arası dayanım düzensizliğidir [2].

2.2.3. Zayıf Kolon Güçlü Kiriş Oluşumu

Sadece çerçevelerden veya perde ve çerçevelerin birleşiminden oluşan taşıyıcı sistemlerde, her bir kolon-kiriş düğüm noktasına birleşen kolonların taşıma gücü momentlerinin toplamı, o düğüm noktasına birleşen kirişlerin kolon yüzündeki kesitlerindeki taşıma gücü momentleri toplamından en az %20 daha büyük olmalıdır [2]. Eğer bu sağlanmazsa plastik mafsallar kirişlerde değil kolonlarda oluşur.

2.3. Zemin Hareketleri

2.3.1. Zemin Sıvılaşması

Yeraltı su seviyesi altındaki tabakaların geçici olarak mukavemetlerini kaybederek, katı yerine viskoz sıvı gibi davranmalarına zemin sıvılaşması denilmektedir. Zeminin sıvılaşmasının kendisi hasara sebep olan bir olay değildir. Ancak, bu olayın büyük yer değiştirmelere sebep olması, büyük hasarları doğuran temel göçmelerine sebep olur. Deprem hareketi ile oluşan zemin sıvılaşması, büyük kütleler halinde şev akmalarına sebep olabilir [3].

2.3.2. Zeminde Oluşan Farklı Oturmalar

Üzerindeki yükün etkisi ile kohezyonlu zeminlerin zamanla sıkılaşıp çökmesine oturma denir. Bu sıkışma zemin gözenekleri içinde bulunan suyun uzaklaşması sonucu oluşur. Yapı hasarında etkin konumda olan oturma, elastik (ani) ve konsolidasyon oturması olarak ikiye ayrılmaktadır. Bu iki elemanın toplamı olan oturma yapıda yapısal hasar oluşturmaktadır. Bu nedenle her iki oturma bileşeninin büyüklüğünün saptanması önem taşımaktadır [4].

2.4. Deprem

Deprem genel anlamda, yer kabuğunda beklenmedik bir anda ortaya çıkan enerji sonucunda meydana gelen sismik dalgalanmalar ve bu dalgaların yeryüzünü sarsması olayıdır. Depremlerde betonarme yapıların hasara uğraması, betonda kalıcı şekil değiştirmeler ortaya çıkması doğal bir durumdur. Betonarme depreme kalıcı şekil değiştirmeler yaparak karşı koyar. Bu hasar yapıda can ve mal kaybına yol açmayan, yapının onarımı ile tekrar kullanılmasına izin verebilen boyuttadır. Bu hasar düzeyinin üzerindeki hasarlar ise depreme dayanıklı yapılar için normal kabul edilemez. Bir yapının ömrü boyunca niteliklerini kaybetmeden hizmet görebilmesi için zemin, proje, malzeme, uygulama (işçilik) ve denetim gibi yapı süreçlerinin kaliteli yaşanması gereklidir [5].

2.5. Yangın ve Donma

Yangın, maddenin ısı ve oksijenle birleşmesi sonucu oluşan yanma reaksiyonlarının neden olduğu doğal afettir. Yangında zarar görme derecesine bağlı olarak beton sarı, pembe, gri renk değişimlerine uğrar. Malzeme ısınarak suyunu kaybettikçe ısıya bağlı olarak iç gerilmeler ve çatlaklar artar, dağılma etkisi yaratır. Yangının çelik üzerinde de yıkıcı etkileri olmaktadır. Isınan çelik uzar, birleştiği noktalarda değişimler meydana getirir ve bazen bütün yapıyı yıkabilecek güç oluşturur. Çeliğin sıcaklığı yükseldikçe taşıma gücü kaybolur [6].

Donma olayı cisimlerin hacimlerinde bir değişime neden olur. Tekrarlı olması durumunda ise betonun çatlaması sonucu dayanım kaybına neden olmaktadır.

2.6. Çarpma, Patlatma ve Aşırı Yükleme

Çarpma ve patlatma dış etkiler sonucu ani gelişen olaylardır. Betonarme binalar sabit, hareketli, rüzgâr, deprem, kar yükünün etkisi altındadır. Bu yükler ve birleşimlerinin binanın taşıma kapasitesinin üzerinde olmaması istenir.

3. Hasar Belirleme Yöntemleri

Hasarlı, onarılacak ya da güçlendirilecek bir yapı tıpkı doktorunun önüne gelmiş bir hasta gibidir. Hastanın durumunun belirlenmesi için muayene, tıbbi incelemeler, röntgen, ultrason gibi ölçme yöntemleri uygulanıyorsa yapı için de benzer bir şekilde incelemelerin yapılması ve bir teşhis koyulması gerekir.

Yapının hasar durumları değerlendirilirken birçok yöntem kullanılabilir. Bu yöntemlerden bazıları yapının sadece belli bir bölgesi hakkında fikir sağlarken bazıları yapının bütünü hakkında fikir vermektedir. Gerek yerel incelemeler olsun gerek genel incelemeler olsun alınan numuneler ya da yapı üzerinde gerçekleştirilen incelemeler statik yüklemeler ve dinamik yüklemelerle gerçekleştirilmektedir. İncelemelerden elde edilen sonuçlar benzer numuneler ya da yapılar üzerinde deneysel veya analitik olarak gerçekleştirilen incelemelerden elde edilen sonuçlarla karşılaştırılır. Yapı ya da yapı elemanları üzerinde gerçekleştirilen deneysel incelemelerde yapı ya da yapı elemanına hasar verilerek ya da hasar verilmeksizin inceleme yapılabilir [7].

3.1. Yerine (İncelenen Alana) Göre

İncelenen alana göre hasar belirleme yöntemleri yerel (lokal) ve genel(global) yöntemler olmak üzere ikiye ayrılmaktadır.

3.1.1. Yerel (Lokal) Yöntemler

Hasar tespitinde yerel değerlendirme yapmayı sağlayan yöntemler karot alma, donatı tespiti, ultrases cihazıyla inceleme, Schmidt çekici ölçümleri ve radarla tarama olarak sınıflandırılabilir.

3.1.1.1. Karot Alma

Yapının belirli bölgelerinden alınan belirli özelliklerdeki beton örnekleri yardımıyla yapının inşasında kullanılan betonun gerekli şartları sağlayıp sağlamadığı veya dış etkilere maruz betonun bozulup bozulmadığı tespit edilebilir. Karot alma işlemiyle malzemenin basınç dayanımı, elastisite modülü, poisson oranı, kütle yoğunluğu belirlenebilir [8].

3.1.1.2. Donatı Tespiti

Yapıda gerekli miktarda donatının uygun düzende yerleştirilip yerleştirilmediğinin belirlenmesinde kullanılmaktadır. Donatı tespiti, yüksek frekanslı manyetik dalgalar üreten cihazların betonarme eleman yüzeyinde hareket ettirilmesiyle gerçekleştirilmektedir. Donatı belirlenen bölgede

cihazın sabitlenmesiyle donatı çapı ve yüzeyden olan derinliği belirlenmektedir [7].

3.1.1.3. Ultrases İncelemesi

Beton yüzeyine tutulan ve biri verici diğeri ise alıcı olarak adlandırılan iki adet cihaz yardımıyla beton elemana sinyal gönderilmesine dayanan inceleme yöntemidir. Bu inceleme yöntemiyle betona gönderilen sinyalin hızına bağlı olarak beton dayanımı ve elastisite değeri hakkında bilgi edinilebilmektedir. Bu şekilde elde edilen veriler analitik modellerin kalibrasyonu ve yapıların güçlendirilmesinde kullanılabilir [7].

3.1.1.4. Schmidt Çekici

Beton yüzeyine Schmidt çekici olarak adlandırılan özel bir cihazla vurulması ve geri tepme değerlerinin belirlenmesi işlemidir. Bu ölçümlerde betonun yüzeyine darbe uygulanma yeri ve yönü oldukça önemlidir. Bu yöntem beton dayanımını vermez, betonun yüzey sertliğini verir. Betonun yaşına göre değişim olabileceği unutulmamalıdır.

3.1.2. Genel (Global) Yöntemler

Yapının bütünüdür davranışı hakkında bilgi sağlayan yöntemlerdir. Bu yöntemlerden en yaygın olarak kullanılanı, yapısal titreşimlerin gözlemlendiği ve yapıya ait dinamik karakteristiklerin belirlendiği Deneysel Modal Analiz yöntemidir.


Yapı dinamik karakteristiklerinin belirlenmesinde deneysel modal analiz yöntemlerinin etkin sonuç verdiği ve ölçüm yapılan yapılarda hasar oluşturulmaması nedeniyle tercih edildiği ve kabul

görüldüğü bilinmektedir. Bu yöntem, ölçümlerde kullanılan titreşim etkisinin bilinip bilinmemesine bağlı olarak Operasyonel Modal Analiz ve Geleneksel Deneysel Modal Analiz yöntemleri olmak üzere kendi içerisinde ikiye ayrılır [7].


3.1.2.1. Operasyonel Modal Analiz Yöntemi

Operasyonel Modal Analiz yöntemi yapılarda deprem, rüzgâr gibi çevresel etkilerden oluşan titreşimleri dikkate alarak yapıların dinamik karakteristiklerinin deneysel olarak belirlenmesinde kullanılan bir yöntemdir. Yapıya ait dinamik karakteristikler yapı üzerinden ölçülen tepki verilerinin zaman ve frekans tanım alanlarında işlenmesiyle elde edilmektedir.

Bu yöntemin yeterince anlaşılabilmesi için temel titreşim biçimlerinin ve rezonans etkisinin bilinmesi gerekmektedir. Titreşim, başlangıç şartları veya uygulanan dış yükler altında yapıların göstermiş olduğu tepkilerdir. Temel olarak, serbest titreşim ve zorlanmış titreşim olmak üzere iki farklı titreşim türü söz konusudur. Serbest titreşimde yapı, uygulanan başlangıç şartları altında titreşir. Bu tür titreşimde, en küçük doğal frekans yapıda en etkili olan frekanstır. Bu tür titreşim, belirli bir süre sonra yapıdaki sönümün etkisiyle sona erer. Zorlanmış titreşim ise, yapının uygulanan bir dış yük altındaki titreşimidir. Bu tür titreşim, yük yapıya etkidiği sürece devam eder. Bir yapı dış yükten dolayı titreştirildiğinde, yapının doğal frekansı ile dış yükün frekansının aynı olduğu bir duruma gelinebilir. Bu durumda yapı oldukça büyük genlikte titreşim yapar ve rezonans durumu olarak adlandırılır. Operasyonel Modal Analiz yönteminde yapıların dinamik karakteristiklerinin nasıl belirlendiği Şekil 1-2'de gösterilmiştir [9].




Şekil 1. Binanın ölçümünde kullanılan ivmeölçerler




Şekil 2. Ölçümde kullanılan veri toplama ünitesi

Ölçümden elde edilen sinyaller sinyal işleme sürecinden geçirildikten sonra Operasyonel Modal Analiz programına aktarılır. Operasyonel modal analiz programında frekans ortamında ayrışım (FOA) ve stokastik altalan belirleme (SAB) yöntemleri kullanılarak binaya ait modal parametreler elde

edilir. Frekans ortamında ayrışım (FOA) yöntemi kullanılarak elde edilen spektral yoğunluk fonksiyonu Şekil 3'te, stokastik altalan belirleme (SAB) yöntemi kullanılarak elde edilen kararlılık fonksiyonu ise Şekil 4'te verilmektedir [9].



Şekil 3. Binaya ait spektral yoğunluk fonksiyonu




Şekil 4. Binaya ait kararlılık fonksiyonu

3.1.2.2. Geleneksel Deneysel Modal Analiz Yöntemi

Deneysel modal analizde, yapıya bilinen (ölçülen) bir kuvvet verilmekte ve yapının bu kuvvete tepkisi

ölçülmektedir. Şekil 5'te görüldüğü gibi bu işlemde yapıya kuvvet uygulamak için çekiç, yapının tepkisini ölçmek için ivmeölçer ve verileri değerlendirmek için bir sinyal analizör kullanılır [10].



Şekil 5. Deneysel modal analizde genel bir ölçüm düzeneği

3.2. Yükleme Durumuna Göre

3.2.1. Statik Yöntemler

Yapıdan alınan numuneler ya da imkân varsa yapı üzerinde gerçekleştirilen statik yüklemeler altında elde edilen değerlere bağlı olarak yapının hasar durumunun değerlendirilmesine dayanan yöntemlerdir. Bu yöntemler hasarlı veya hasarsız yöntemler olabilir. Hasarlı inceleme yöntemine yapıdan alınan karot numuneler örnek olarak verilebilir. Hasarsız incelemelerde ise sistemin elastik bölgede kalacak şekilde statik yük altında test edilmesi gerekmektedir [9].

3.2.2. Dinamik Yöntemler

En yaygın olarak bilinen ve kullanılan yöntem yapısal titreşimlerin ölçülmesi ve analiz edilmesine dayanan deneysel modal analiz yöntemidir.

3.3. Yönteme Göre

3.3.1. Teorik Yöntemler

Analitik model güncellemeye dayalı hasar tespit yönteminde, analitik model üzerinde yapılan rijitlik, kütle ve sönüm gibi mekanik özellikleri değiştirilerek deneysel olarak ölçülen statik veya dinamik davranışın elde edilmesine çalışılmaktadır.

3.3.1.1. Başlangıç Analitik Model

Yapının projesinden ya da yapı üzerinde gerçekleştirilen rölemlerden elde edilen kesit özellikleri ve malzeme özellikleri dikkate alınarak oluşturulan analitik modeldir.

3.3.1.2. Kalibre Edilmiş Analitik Model

Başlangıç analitik modelin malzeme özellikleri ve sınır şartları dikkate alınarak kalibre edilmesi sonucunda elde edilen ve yapının hasarsız durumunun temsil ettiği varsayılan analitik modeldir.

3.3.1.3. Güncellenmiş Analitik Model

Yapıya ani bir etki sonrasında yapı üzerindeki ölçümlerden elde edilen sonuçlar baz alınarak kalibre edilmiş analitik modelde, kesit özellikleri (atalet momenti, kalınlık) değişken olarak dikkate alınarak deneysel ve analitik sonuçlar arasındaki farkın minimize edilmesi işlemidir.

3.3.2. Deneysel Yöntemler

Deneysel yöntemler hasarlı ve hasarsız yöntemler olmak üzere ikiye ayrılmaktadır. Hasarsız deneysel yöntemlere örnek olarak deneysel modal analiz yöntemi örnek verilebilir. Hasarlı deneysel yöntemlere örnek olarak beton basınç dayanımı deneyi örnek verilebilir.

3.4. Zemin İncelemesi

Zemin incelemesinde, numune alınması ve jeofizik yöntemler kullanılmaktadır [11].

4. Sonuçlar

Günümüzde yapılar farklı amaçlar için inşa edilmektedir. Bunların başında barınma ihtiyacımızı gideren binalar gelmektedir. Bu yapılar zaman zaman ya da zaman geçtikçe çeşitli yük, kuvvet vb. etkilere maruz kalmakta ve bu etkiler sonucunda da yapılan binalarda hasarlar meydana gelmektedir. Binalarda hasar oluşturan başlıca sebep projelendirme aşamasında da çoğunlukla etkin bir faktöre sahip olan deprem yükleri gelmektedir. Depremden kaynaklanan hasar etkisi yapının projelendirme aşamasından sonraki yani inşa edilme esnasında yapılan hatalarla daha da artmaktadır. Bu etkilerin dışında başka etmenler de bulunmaktadır. Binaların taşıyıcı sisteminin seçimi, zeminde oluşan farklı oturumları, yangın, donma-çözünme, çarpma ve patlatma etkileri de hasar sebeplerindedir. Hatalar sonucunda binalar hasar görmektedir. Bu çalışmada, betonarme binalarda oluşan hasarların sebepleri ve hasar belirleme yöntemleri üzerinde incelemeler gerçekleştirilmiştir. Yapının hasar durumları değerlendirilirken yapının sadece belli bir bölgesi hakkında fikir veren karot alma, ultrases ve Schmidt

çekici gibi yöntemler ve yapının bütünü hakkında fikir sağlayan Operasyonel ve Geleneksel Modal Analiz yöntemleri incelenmiştir. Bu yöntemlerle oluşan hasarlar belirlenmeye çalışılmıştır. Hasarları oluşturan etkilerin doğru bir şekilde belirlenmesi can ve mal kaybının azaltılmasında ve mevcut hasarların onarılmasında dikkate alınmasının oldukça önemli olduğu görülmüştür.

Kaynaklar

- [1] Türkiye Bina Deprem Yönetmeliği, <https://www.afad.gov.tr/tr/24210/Turkiye-Bina-Deprem-Yonetmeliği> (Erişim Tarihi: 28.12.2018).
- [2] Türkiye Bina Deprem Yönetmeliği, Yayınlanma Tarihi: 18.03.2018 Sayı: 30364.
- [3] Celep, Z., Kumbasar, N. (2004). Deprem Mühendisliğine Giriş ve Depreme Dayanıklı Yapı Tasarımı.
- [4] Birand, A. (2007). Temel Zemin Etkileşmesi; Oturma ve Yapı Hasarı, *Yapı Zemin*.
- [5] Uğurlu, A. (2013). Depremde Beton ve Davranışı, *TMH*, 476 (2), 57-63.
- [6] Oymael, S. Su-Rutubet ve Yangın Etkilerinin Dayanım, Malzeme Seçimi ve Bina Tasarımı ile İlişkisi, <http://www.imo.org.tr/resimler/ekutuphane/pdf/11150.pdf> (Erişim Tarihi: 28.12.2018).
- [7] Türker, T. (2015). Deneysel Yöntemlerle Hasar Tespiti Ders Notları.
- [8] Arıoğlu, E. ve Arıoğlu, M. N. (2005). Üst ve alt yapılarda beton karot deneyleri ve değerlendirilmesi. Evrim Yayınevi.
- [9] Bayraktar, A., Türker, T., Altunışık A. C., Sevim B., Şahin, A., Özcan D. M. (2010). Binaların Dinamik Parametrelerinin Operasyonel Modal Analiz Yöntemiyle Belirlenmesi, *İMO Teknik Dergi*, 337, 5185-5205.
- [10] Bayraktar, A., Türker, T. (2005). Deneysel Modal Analiz Yöntemi ile Düzlem Çerçevelerin Dinamik Karakteristiklerinin Belirlenmesi, Deprem Sempozyumu Kocaeli 2005, 1035-1041.
- [11] Yıldırım, S. (2002). Zemin incelemesi ve Temel Tasarımı. Birsen yayınevi.

