

Article Type: Research Article

**MODELLING AND ESTIMATION OF ACADEMIC SUCCESS OF PROSPECTIVE TEACHERS WITH DISTANCE LEARNING COURSES****Meltem ÖZMUTLU***Specialist , Bahçeşehir University, Turkey, meltem.ozmutlu@es.bau.edu.tr  
ORCID: 0000-0002-3812-4610***Ergün AKGÜN***Assist Prof., Bahçeşehir University, Turkey, ergun.akgun@de.bau.edu.tr  
ORCID: 0000-0002-7271-6900**Received:09.02.2020**Accepted: 15.11.2020**Published: 15.12.2020***ABSTRACT**

Distance education is a learning method that can be used at all levels of education. The main reason for this is that has facilities for both teachers and students. It is in an active position in the grade averages of the students, as in the courses taken face to face in distance education courses. The extent to which the courses taken by the distance education method play an active role in the academic success of the students is an important issue as well as controversial issue. Considering this situation, the academic achievements of the students of the Faculty of Educational Sciences were wondered within the scope of this study, and the process of estimating their graduation grade point averages was made. The data of the of the graduates of Computer Education and Instructional Technologies (CEIT), English Language Teaching (ELT), Preschool Education (ECE) and Guidance and Psychological Counseling within the Faculty of Educational Sciences were collected. From the data collected, students' gender, department, university entrance score and letter grades of four courses they took jointly with distance education were used as variables. Interval calculations are made by taking students' GPAs into account and two categorical variables, "succeeded" and "failed", are derived. After sweeping and categorical differentiation procedures, the classification method was applied to the data set. The best performance was acquired from "Gaussian Naïve Bayes (Model 3.1)" with 82.8% within "Naïve Bayes Classifiers" among the performance segments with 15 techniques. These acquired performance values illustrate high levels of accurate estimation with the data from the study.

**Keywords:** Classifier analysis, academic success estimation, distance learning, naïve bayes.

## **INTRODUCTION**

Online learning is a concept which arose from the relationship between technological developments and distance learning, and which is very challenging to define. Some authors define online learning as the tool of sharing the technology utilized by the lecturer (Lowenthal, Wilson & Parrish, 2009; Regan et al., 2012), while Oblinger, Oblinger, and Lippincott (2005) define it as online cases, for they take the word online as their basis. The most commonly used definition, on the other hand, is that online learning is the fulfillment of the learning experience through some technological devices (Condrad, 2002). Aside from the variety of definitions of online learning, many authors qualify online learning as web-based learning, distance learning, and web-based courses (Dringus & Cohen, 2005; Triacca, Bolchini, Botturi & Inversini, 2004). Moore, Dickson-Deane and Galyen (2010) explain that the reason why the authors use these concepts interchangeably is the offering of the learning opportunity to students. In this direction, Massive Open Online Courses (MOOC) is defined as an online learning style that aims to enable learners to learn about subjects related to different fields and disciplines through free online courses (Liyaganawardena, Adams & Williams, 2013).

While academic success is defined as the acquisition of necessary knowledge and skills with the achievements determined for the completion of the courses (York, Gibson & Renkin, 2015), whether there are different factors affecting the academic success of students is also a topic discussed in the literature (Hung, Chou, Chen & Own, 2010; Lim, 2001; Wang & Newlin, 2002; Yükseltürk & Bulut, 2007). It is stated that the online learning environments are used in accordance with the obligations in universities, as well as they provide students with a flexible study environment from the point of view of the student. As a result of this opportunity and obligation it offers, online learning environments increase. The increase in the use of these environments enables researchers to conduct studies that can predict their academic success in the online learning environment, as well as to determine what students need in online learning environments (Kruger-Ross & Waters, 2013). However, schools have very limited data to predict students' academic success in online environments. Likewise, students have limited data in order to predict the suitability of the courses they have taken through distance education for them (Berenson, Boyles & Weaver, 2008). Some of the work done in the name of academic estimation was carried out by obtaining data from Massive Open Online Courses (MOOC). The main reason for this is that predictive models aim to see users' participation and results in MOOCs (Garner & Brooks, 2018). Students enrolled in a course on MOOC have been predicted through their background activities, and it has been determined whether the students will receive a certificate at the end of the certified courses. Within the scope of the research, students were examined and classified in terms of both motivation and grades. The researchers stated that the students were divided into different groups motivationally and then the grading estimation was made possible within these groups (Xu & Yang, 2016). Almeda, Zuech, Utz, Higgins, Reynolds and Baker (2018) stated that, apart from factors similar to other studies, the course designs and faculty members were also tried to be taken into consideration by controlling which factors were effective for predicting the success of students taking courses online. According to the results of the research obtained by the classification and regression models, it provides a prediction about whether the students are successful

according to what they have realized in the video, forums, comment content and interactive sections, while the readings and some comments provide a more limited prediction about their grading.

Yükseltürk and Bulut (2007) investigated the extent to which variables such as age, sex, educational level, control focus, and student learning style, on the one hand, and motivational beliefs such as internal and external goal orientation, control beliefs, self-sufficiency, test concern, and components of self-oriented learning, on the other, affect student success in online learning environments. Two lecturers of the course “C programming language and Data Structures and Algorithms”, selected for the study, were interviewed about the factors that influence the success of students in online courses. In order to check student success in online courses, first, 80 volunteer students completed four different online surveys: Demographic Questionnaire, Internal-External Control Focus Scale, Learning Style Inventory, and Motivational Strategies for Learning. Then, semi-structured interviews were carried out with the two course lecturers to collect expert opinions. According to the results of the four online surveys, there was a significant correlation between the student’s internal goal orientation, self-sufficiency, cognitive strategy usage, self-regulation, and success in courses that are carried out in online learning environments. This shows that the designated characteristics influence course success. On the other hand, educational level and external control focus reveal a negative correlation with student success. The interviews with lecturers also helped unravel the reasons why students fail their online courses. Which were revealed as the motivation and adaptation issues they were facing. The student responses show that they were highly motivated in online courses in the beginning, whereas this motivation gradually dropped throughout time. The motivational losses of the students cause a drop in their in-class success as well (Yükseltürk & Bulut, 2007). Finally, in these studies, it is stated that the general characteristics of students do not have a significant effect on their success in online courses (Lim, 2001; Wang & Newlin, 2002; Yükseltürk & Bulut, 2007).

Researchers have also carried out studies to determine the relationship between student success in distance learning courses and gender. However, the general conclusion has been that the variable of gender does not have any effect on success in online learning environments (Yükseltürk & Bulut, 2007). It was also observed that the variable of gender is related to differences in the usage frequencies of students’ online learning environments. While online learning provides a low cost and easily accessible environment to men, it offers a collaborative study environment to women (Arbaugh, 2000). Young and McSporry (2001) also examined the differences created by the gender factor in online learning. They first selected an Internet and Web Design course and used three different methods – preliminary and final test, student evaluation results, and the course’s website usage statistics – to collect data from 1999 and 2000 spring, fall, and summer terms. Men reported that they are more experienced in Internet and Html than women. The results of their focus group studies show that men make a rapid start, and then gradually go into a decline in online learning, whereas women follow a linear road. In short, women’s self-regulation and time management skills in online learning are more developed, while such skills among men are less developed. It shows, in fact, that cannot show their performance in evaluation exams and use of websites (Young & McSporry, 2001).

Another factor of success in online learning that has been examined is the participants' ages. According to Moore and Kearsley (2005), individuals who take distance learning courses have an age range between 25 and 50. This requires an understanding of adult nature and their states in online learning environments. An online survey was conducted at a university in the American Midwest during the 2005 spring and summer terms with graduate students in online courses. Their demographic data and data concerning self-orientation and learning strategies were collected. It was revealed that students' ages did not exert a significant effect on their success in online learning environments (Colorado & Eberle, 2010).

This study was conducted with students who graduated from the Faculty of Educational Sciences and took online courses before they graduated. The aim of this study is to estimate students' graduation GPAs based on the letter grades from their online courses. In order to carry out the estimating process, the letter grades of 4 online courses taken by a total of 174 students from BOTE, PDR, ECE and ELT departments were used until their graduation.

## **METHOD**

When the literature is examined within the scope of this research, it has been determined that the number of studies for which the graduation average is estimated according to the courses taken by distance education is quite low. In this case, the data mining method was used in order to provide meaningful information and to realize the estimation of the obtained data set. Data mining is defined as determining the rules that enable estimation with the collected data (Karabatak, 2008). The classification method has also been preferred in data mining. Detailed information is given under this heading regarding the research method.

## **Study Group**

Within the scope of the study, it was aimed to estimate the graduation averages of the students of the Faculty of Educational Sciences from the letter grades of the courses they took through distance education. For this purpose, the data of 174 undergraduate students who graduated from the Faculty of Educational Sciences, Computer and Instructional Technology Education (CEIT), English Language Teaching (ELT), Preschool Teaching (ECE) and Guidance and Psychological Counseling (PDR) departments were used in the study. While 69.54 percent (121 people) of the students are female students, 30.45 percent (53 people) are male students. The distribution of the departments is as CEIT 69, ELT 69, ECE 17 and PDR 63 persons. The courses taken through distance education were taken by the students in different periods, and the students continued by taking the courses that are continuation of each other mostly in the fall and spring semesters. Students who failed the course or were not satisfied with their grade preferred to retake their classes in the summer term. 129 of the students in the study graduated at the end of 8 semesters, 25 of them 7 semesters, 8 of them 6, 7 of them 9, 2 of them 10, 1 of them 11 and 2 of them 12 semesters. As of the 2012 academic year, students use the Learning Management System (LMS) as they have been found, and the system is familiar for students who have taken distance education courses after 2012.

### **Data Collection**

The researcher obtained the ethical committee permission for administering the scales to the by the decision of the Bahçeşehir University Scientific Research and Publication Ethics Committee. Accordingly, the study was conducted with the grades of and other specific information about the graduates of the Computer and Instructional Technologies Education (CEIT), English Teaching (ELT), Preschool Teaching (ECE) and Psychological Counseling and Guidance (PDR) departments under the Faculty of Educational Sciences. Among the data, primarily the letter grades of four different online courses that students took through distance education in different periods until graduation are included. Additionally, the lecturers who taught these courses, student departments, genders, university placement scores, and graduation GPAs were drawn from the system. Before the list of graduates was prepared, we visited the department responsible for the controlling and conducting of distance learning courses to confirm the academic semester in which the aforementioned courses had begun being taught. The students who took these courses face-to-face were deleted from the data set. Furthermore, the data from students who transferred from within or outside of the university or carry international student status, aside from the placements of the Assessment Selection and Placement Center placements at the Faculty of Educational Sciences, were swiped and excluded from the study. After these procedures, the data from 174 students were ready for analysis.

Within the scope of the research, the courses taken by the students through distance education were Atatürk's Principles and History of Turkish Republic I-II and Turkish Language and Literature I-II In these courses, the lecturers provide the students with weekly videos and documents and course material and they do online midterm exams and quizzes at certain intervals, mostly in the 5th week. Final exams are held face to face with the students.

### **Data Analysis**

In addition to obtaining useful information from large data repositories or clusters, data mining also undertakes the analysis and prediction of collected or existing data (Ahmad, Ismail and Aziz, 2015). It is stated that the most preferred methods in data mining, especially when predicting students' success, are classification, clustering and association (Kumar & Ramaswami, 2010). According to Chamillard (2006), data mining techniques are used in the field of education because they have the opportunity to develop predictive models for students' success in their courses. The inferred estimation model also enables faculty members to find a solution by determining the academic performance levels of their students. Classification, one of the data mining techniques, is to place the object in a class or category in line with its characteristics. In education, instructors also benefit from classifying their students in terms of knowledge, motivation and behavior (Hamalainen & Vinni, 2011).

Naïve Bayes assumes that the effect of the parameter value of a certain class is independent from another parameter value in line with the probability theory of Bayes and is defined as a predictive approach used to

estimate the values of the data in line with the results obtained from different data (Pandey & Pal,2011). Naïve Bayes is one of the oldest classification algorithms effective even in its simplest form (Wu et al., 2008) and Naïve Bayes classification is characterized as both a descriptive and predictive type of algorithm (Pandey & Pal, 2011).

Data from the graduates were taken as outputs from the registration system. From within this output, we excluded students who had taken four common courses in in-class settings and not via distance learning. Additionally, students who transferred from other universities or other departments from the same university or those who carried international student status were deleted from the list. Subsequently, the data was rendered ready for analysis. The department names in the data set were revised with their abbreviations as CEIT, ELT, ECE and PDR. The letter grades of students from the selected courses were arranged in alphabetical order.

Graduation GPAs from the system were rendered into the two categorical variables “succeeded” and “failed”. Interval calculations were carried out to calculate the distribution of these categorical variables to GPA. In order to find the range to be used in the calculation, the highest and the lowest grade point average of the students was determined. The lowest grade was subtracted from the highest, and the remaining number was subjected to division to the number of categories, which was determined to be two.

$$\text{Interval} = \frac{3,89 - 2,15}{2}$$

According to this calculation, those with a GPA of 3.02 and lower were shown with the categorical variable of “Failed”, while those with a GPA above that were shown with “Succeeded”. Categories that were qualified as “Failed” and “Succeeded” in MATLAB are defined as “Failed students” and “Succeeded students”. Much like the definitions of fail and succeed, students who are qualified to be “failed students” were those within or below the calculated average and those “Succeeded students” were the ones with a GPA above the calculated average. Once all the arrangements in the data set were completed, it was analyzed with the classifier rule in MATLAB and decision trees were established. Decision trees comprise one of the classification methods.

## **FINDINGS (RESULTS)**

This section of the study reveals the findings acquired with the classification method concerning the collected data and estimation of graduation GPAs. The names of the distance learning courses students took, their lecturers’ names and letter grades, as well as data such as gender, university entry score, and which department they studied in were used. The collected data were subjected to a classifier method application with the aid of MATLAB and percentages were acquired through classification model techniques.

Many experiments were made using MATLAB with the collected data, and we attempted to determine the most successful estimation. The models’ estimation performances, created with 15 different techniques from

five different classification methods regarding student success status at the end of the semester the students graduate, are provided in Table 1.

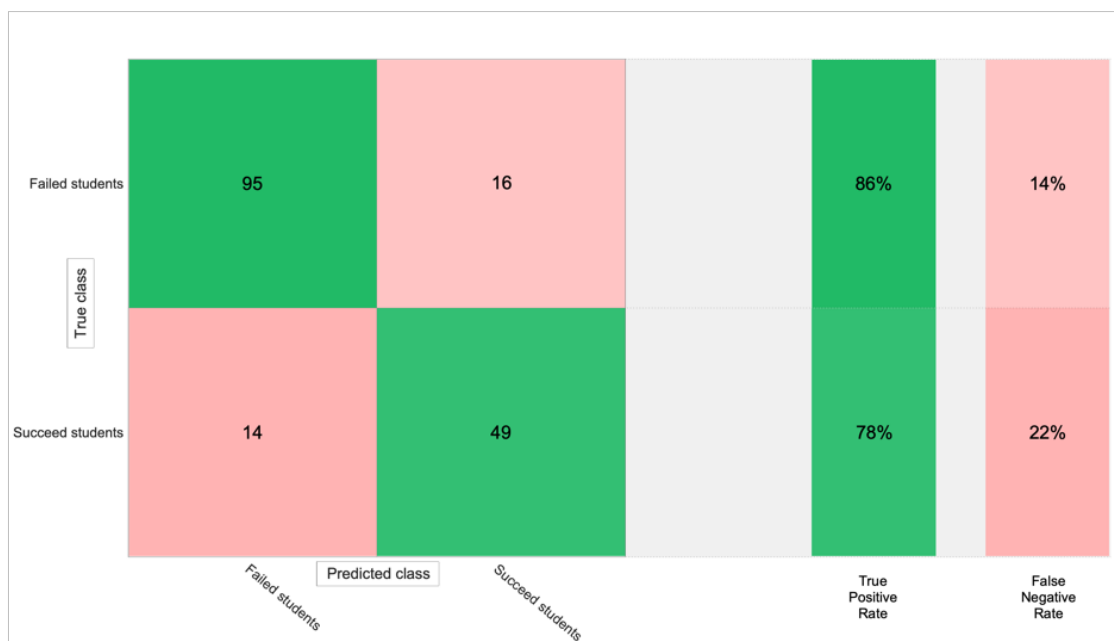
**Table 1** Accuracy of Classifier Models

Classifier	Model No	Model Type	Accuracy (%)
1. Decision Trees	1.1	Fine Tree	69.0 %
	1.2	Medium Tree	69.0 %
	1.3	Coarse Tree	68.4 %
2. Logistic Regression	2.1	Logistic Regression	70.7 %
3. Naive Bayes	<b>3.1</b>	<b>Gaussian Naive Bayes</b>	<b>82.8 %*</b>
	3.2	Kernel Naive Bayes	77.6 %
4. Support Vector Machines	4.1	Linear SVM	73.0 %
	4.2	Quadratic SVM	73.0 %
	4.3	Cubic SVM	71.3 %
	4.4	Fine Gaussian SVM	63.8 %
	4.5	Medium Gaussian SVM	75.9 %
	4.6	Coarse Gaussian SVM	69.5 %
5. Ensemble	5.1	Boosted Trees	72.4 %
	5.2	Bagged Trees	70.1 %
	5.3	RUSBoosted Trees	67.8 %

\*Best Accuracy Model, Cross-Validation Folds: 5 Folds, Prediction Speed ~6200 obs/sec, Training Time 0.20041 sec

An examination of Table 1 shows that “Gaussian Naive Bayes (Model 3.1)” has the best performance of the classifier models. This model carried out accurate classification with a ratio of 82.8% for student academic success by utilizing their departments, genders, university entry scores, and the end of term grades from four common courses that were taught online. The Area Under Curve value regarding the classification was AUC = 0.78.

In order to have a better understanding of the correct and incorrect classification accuracy of the estimation performance of the established model, the Confusion Matrix of True Positive Rates & False Negative Rates is provided below (Figure 1).



**Figure 1.** Confusion Matrix of True Positive Rates & False Negative Rates

An examination of Figure 1 shows that 86% of the academic success predictions of the 111 students who actually failed were accurate ( $n=95$ ), whereas 14% were in the succeeded category, which was an inaccurate estimation ( $n=16$ ). On the other hand, 78% of the 63 succeed students ( $n=49$ ) were classified accurately and 22% were ( $n=14$ ) classified inaccurately.

“Failed students” within Figure 1 means that the graduation GPAs are equal to or lower than 3.02, which were acquired with interval calculations. “Succeeded students”, on the other hand, have a graduation GPA that is higher than 3.02. The comparison of different variables used in the estimation of student graduation GPAs is provided in Figure 2. The comparisons shed light on the relationships between the variables. The light blue flat lines in the figure are within the category of “failed” and refer to students whose GPAs were accurately estimated, whereas the discrete blue lines reflect students in the “failed” category whose estimations were erroneous. Flat, orange lines, on the other hand, show that an accurate estimation was found for the graduation GPAs for the students within the “succeed” category, whereas the discrete orange lines show that those within the “succeed” category had erroneous estimations.






Figure 2. Parallel Coordinates Plot of Variables

## CONCLUSION and DISCUSSION

In order to estimate the graduation grade point average of the Faculty of Educational Sciences students, 7 variables were used as input data: the gender of the graduated students, the department, the university exam score and the letter grades of the four courses taken at different times up to the graduation stage. A total of 174 graduates were included in the list, which was later subjected to the classifier method in an attempt to estimate their graduation GPAs. Before deployment, a data sweeping procedure was conducted, and the graduation GPAs were divided into the two categories “fail” and “succeed”. An interval value calculation was carried out to establish two categorical variables. The resulting conclusion was that the Gaussian Naïve Bayes model yields the best performance among classifier models, with a performance value of 82.8%. Such a ratio indicates that students’ graduation GPAs can be determined with the letter grades from the distance learning courses they have taken.

Ren, Rangwala and Johri (2016) state that data mining is used in the analysis of data collected through MOOCs in their studies. In his study, he predicted the grades that students will receive together with their previous studies, and in his previous studies, he found that the features of participation in the lessons and the features of examining the materials were effective factors in predicting the students' grades. Another study, conducted in Pakistan, attempted to estimate the performance values of students by taking certain ratios from the grades of 201 students until they graduated from the 4-year Department of Information Technologies. In order to carry out this study, a certain percentage from each academic year’s average was taken and graduation GPA was divided into five categories. RapidMiner was used for data mining. All data was relayed into the program and the estimation procedure was executed. The study determined that students’ first- and second-year grades play an active role in the estimation of their graduation GPAs. Further, another attempt was made to determine which courses reveal low or high performances and four courses were found to play active roles in

this sense. Intriguingly, the study's results can be interpreted to claim that students get similar grades every year (Asif, Merceron, Ali & Haider, 2017). Muen, Zafar and Manzoor (2016), on the other hand, estimated and analyzed the academic performance of students based on their academic records and forum participation. The data from two undergraduate courses were used as the data set and Naïve Bayes, Artificial Neural Network, and Decision Tree were employed as classification algorithms. The researchers attempted to determine which of the aforementioned classifier algorithms shows the best performance, which turned out to be Naïve Bays, with an overall estimation accuracy of around 86%.

The estimation of undergraduate students' graduation GPA averages, the focus of the current study, was also covered in various studies within the literature (Kappe & Flier, 2012; Osmanbegovic & Suljic, 2012; Şengür & Tekin, 2013; Tosun, 2007). However, as studied within the scope of this study, there are no studies that estimate the graduation grade averages of undergraduate students in line with the letter grades of both distance education courses. Studies within the literature take the fundamental courses of undergraduate students as their bases and use them for the estimation of students' graduation grades (Şengür & Tekin, 2013) or for the estimation of success in courses related to other courses they have taken before (Akgün & Demir, 2018). Such orientations among the studies can be linked with the lack of distance learning courses at the locations where they were carried out. In addition, this study investigates whether or not the lecturers of these courses have any influence on students' letter grades.

## **RECOMMENDATIONS**

In the studies that will be carried out as a continuity of this study, it can be ensured that the graduation grade averages of the students can be estimated by taking the letter grades in the common and face-to-face courses taken by students on the basis of all faculties. In this way, deficiencies in face-to-face courses have been identified, and these deficiencies can be eliminated and students can increase their grade point average by getting higher grades. This study can also apply to the whole school to see the extent to which distance learning courses determine students' graduation GPAs. These courses can be given in in-class environments as well, in which case, the difference between letter grades and students' graduation GPA estimation can be determined, as well as that between the distance learning and in-class environments. This determination of the differences may ensure that conditions regarding face-to-face and distance learning are in need of improvement are identified. This difference determination can be effective in the face-to-face and distance education deficiencies or mistakes. In addition to all these different variables from those employed within the scope of this study may be included in the future studies. This may go further in determining the extent to which students succeed in the courses they take via distance learning and how this success influences their overall GPAs. Naser, Zaqout, Ghosh, Atallah, and Alajrami (2015) and Karamouzis and Vrettos (2008) tried to predict students' academic success in their studies, but they did not use faculty members as variables in this estimation. Therefore, estimation can be made by considering the effect of faculty members on students' success or graduation grade point averages among the new studies to be carried out.

**ETHICAL TEXT**

"In this article, the journal writing rules, publication principles, research and publication ethics and journal ethical rules were followed. The responsibility belongs to the author for any violations that may arise regarding the article."

**REFERENCES**

- Ahmad, F., Ismail, N. H., & Aziz, A. A. (2015). The prediction of students' academic performance using classification data mining techniques. *Applied Mathematical Sciences*, 9(129), 6415-6426.  
<http://dx.doi.org/10.12988/ams.2015.53289>
- Akgün, E., & Demir, M. (2018). Modeling Course Achievements of Elementary Education Teacher Candidates with Artificial Neural Networks. *International Journal of Assessment Tools in Education*, 5(3), 491-509.  
<http://dx.doi.org/10.21449/ijate.444073>
- Almeda, M. (2018). Comparing the Factors That Predict Completion and Grades Among For Credit and Open/MOOC Students in Online Learning. *Online Learning*, 22(1), 1-18.  
<http://dx.doi.org/10.24059/olj.v22i1.1060>
- Arbaugh, J. B. (2000). An exploratory study of the effects of gender on student learning and class participation in an Internet-based MBA course. *Management Learning*, 31(4), 503-519.  
[https://journals.sagepub.com/doi/pdf/10.1177/1350507600314006?casa\\_token=qnViKzvDo7UAAAA:zVz86k7ugc21OMZTzLqGPE627WhcN54zwWwELNGBzdLxhI05bbZrvRNmytIO8P5ztve-zC6VSq\\_obg](https://journals.sagepub.com/doi/pdf/10.1177/1350507600314006?casa_token=qnViKzvDo7UAAAA:zVz86k7ugc21OMZTzLqGPE627WhcN54zwWwELNGBzdLxhI05bbZrvRNmytIO8P5ztve-zC6VSq_obg)
- Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). Analyzing undergraduate students' performance using educational data mining. *Computers & Education*, 113, 177-194.  
<https://doi.org/10.1016/j.compedu.2017.05.007>
- Berenson, R., Boyles, G., & Weaver, A. (2008). Emotional intelligence as a predictor of success in online learning. *The International Review of Research in Open and Distributed Learning*, 9(2).1-17.  
<https://doi.org/10.19173/irrodl.v9i2.385>
- Chamillard, A. T. (2006). Using student performance predictions in a computer science curriculum. *ACM SIGCSE Bulletin*, 38(3), 260-264. <https://doi.org/10.1145/1140123.1140194>
- Colorado, J. T., & Eberle, J. (2012). Student demographics and success in online learning environments. *Emporia Research Studies*, 46(1), 4-10. <https://esirc.emporia.edu/bitstream/handle/123456789/380/205.2.pdf>
- Conrad, D. (2002). Deep in the hearts of learners: Insights into the nature of online community. *International Journal of E-Learning & Distance Education*, 17(1), 1-19.  
<http://www.ijede.ca/index.php/jde/article/view/133/114>
- Dringus, L. P., & Cohen, M. S. (2005, October). An adaptable usability heuristic checklist for online courses[Conference Paper]. *Proceedings Frontiers in Education 35th Annual Conference*,  
<https://doi.org/10.1109/FIE.2005.1611918>

- Gardner, J., & Brooks, C. (2018). Student success prediction in MOOCs. *User Modeling and User-Adapted Interaction, 28*(2), 127-203. <http://doi.org/10.1007/s11257-018-9203-z>
- Hämäläinen, W., & Vinni, M. (2010). Classifiers for educational data mining. C. Romero, S. Ventura, S. Pechenizkiy & R.S. Baker (Ed.). *Handbook of Educational Data Mining*. (pp. 57-74). CRC Press.
- Hung, M. L., Chou, C., Chen, C. H., & Own, Z. Y. (2010). Learner readiness for online learning: Scale development and student perceptions. *Computers & Education, 55*(3), 1080-1090. <https://doi.org/10.1016/j.compedu.2010.05.004>
- Kappe, R., & van der Flier, H. (2012). Predicting academic success in higher education: what's more important than being smart?. *European Journal of Psychology of Education, 27*(4), 605-619. <https://doi.org/10.1007/s10212-011-0099-9>
- Karabatak, M. (2008). *Özellik seçimi, sınıflama ve öngörü uygulamalarına yönelik birliktelik kuralı çıkarımı ve yazılım geliştirilmesi*[Doctorial dissertation, Fırat University]. <https://acikerisim.firat.edu.tr/xmlui/bitstream/handle/11508/20399/222091.pdf?sequence=1&isAllowed=y>
- Karamouzis, S. T., & Vrettos, A. (2008, October). An artificial neural network for predicting student graduation outcomes[Conference Paper]. In *Proceedings of the World Congress on Engineering and Computer Science* (pp. 991-994).
- Kumar, S. P., & Ramaswami, K. S. (2010, December). Fuzzy K-means cluster validation for institutional quality Assessment [Conference Paper]. In *2010 International Conference on Communication and Computational Intelligence (INCOCCI)* (pp. 628-635). IEEE.
- Kruger-Ross, M. J., & Waters, R. D. (2013). Predicting online learning success: Applying the situational theory of publics to the virtual classroom. *Computers & Education, 61*, 176-184. <https://doi.org/10.1016/j.compedu.2012.09.015>
- Lim, C. K. (2001). Computer self-efficacy, academic self-concept, and other predictors of satisfaction and future participation of adult distance learners. *American Journal of Distance Education, 15*(2), 41-51. <https://doi.org/10.1080/08923640109527083>
- Liyanagunawardena, T. R., Adams, A. A., & Williams, S. A. (2013). MOOCs: A systematic study of the published literature 2008-2012. *The International Review of Research in Open and Distributed Learning, 14*(3), 202-227. <https://doi.org/10.19173/irrodl.v14i3.1455>
- Lowenthal, P. R., Wilson, B., & Parrish, P. (2009, October). Context matters: A description an typology of the Online learning landscape [Conference Paper]. 2009 AECT International Convention
- Moore, J. L., Dickson-Deane, C., Galyen, K., & Chen, W. (2010, June). Designing for E-learn, Online, and Distance Learning Environments: Are They the Same?. <https://www.researchgate.net/publication/233751524>
- Moore, M. ve Kearsley, G. (2005). *Distance education: A system view*. Wadsworth.
- Mueen, A., Zafar, B., & Manzoor, U. (2016). Modeling and predicting students' academic performance using

- data mining techniques. *International Journal of Modern Education and Computer Science*, 8(11), 36.  
<https://doi.org/10.5815/ijmeecs.2016.11.05>
- Naser, S. A., Zaqout, I., Ghosh, M. A., Atallah, R., & Alajrami, E. (2015). Predicting student performance using artificial neural network: In the faculty of engineering and information technology. *International Journal of Hybrid Information Technology*, 8(2), 221-228. <http://dx.doi.org/10.14257/ijhit.2015.8.2.20>
- Oblinger, D., Oblinger, J. L., & Lippincott, J. K. (2005). *Educating the net generation*. EDUCAUSE.
- Osmanbegovic, E., & Suljic, M. (2012). Data mining approach for predicting student performance. *Economic Review: Journal of Economics and Business*, 10(1), 3-12. <http://hdl.handle.net/10419/193806>
- Pandey, U. K., & Pal, S. (2011). Data Mining: A prediction of performer or underperformer using classification. *International Journal of Computer Science and Information Technologies*, 2(2), 686-690.  
<https://arxiv.org/pdf/1104.4163.pdf>
- Regan, K., Evmenova, A., Baker, P., Jerome, M. K., Spencer, V., Lawson, H., & Werner, T. (2012). Experiences of instructors in online learning environments: Identifying and regulating emotions. *The Internet and Higher Education*, 15(3), 204-212. <https://doi.org/10.1016/j.iheeduc.2011.12.001>
- Ren, Z., Rangwala, H., & Johri, A. (2016). Predicting performance on MOOC assessments using multi-regression models. *International Educational Data Mining Society*
- Şengür, D., & Tekin, A. (2013). Öğrencilerin mezuniyet notlarının veri madenciliği metotları ile tahmini. *International Journal Of Informatics Technologies*, 6(3), 7-16.  
[https://www.researchgate.net/profile/Doenues\\_Senguer/publication/325260601\\_Prediction\\_of\\_Student's\\_Grade\\_Point\\_Average\\_by\\_Using\\_the\\_Data\\_Mining\\_Methods/links/5b01c7a6a6fdccf9e4f6562f](https://www.researchgate.net/profile/Doenues_Senguer/publication/325260601_Prediction_of_Student's_Grade_Point_Average_by_Using_the_Data_Mining_Methods/links/5b01c7a6a6fdccf9e4f6562f)  
Prediction-of-Students-Grade-Point-Average-by-Using-the-Data-Mining-Meth
- Tosun, S. (2007). *Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırması: öğrenci başarıları üzerine bir uygulama*[Master thesis, Istanbul Technical University].  
<https://polen.itu.edu.tr/bitstream/11527/5847/1/7221.pdf>
- Triacca, L., Bolchini, D., Botturi, L., & Inversini, A. (2004). Mile: Systematic usability evaluation for e-Learning web applications. In *EdMedia+ Innovate Learning* (pp. 4398-4405).  
[https://doc.rero.ch/record/5377/files/1\\_Botturi\\_AACE\\_2004.pdf](https://doc.rero.ch/record/5377/files/1_Botturi_AACE_2004.pdf)
- Wang, A. Y., & Newlin, M. H. (2002). Predictors of web-student performance: The role of self-efficacy and reasons for taking an on-line class. *Computers in human behavior*, 18(2), 151-163.  
[https://doi.org/10.1016/S0747-5632\(01\)00042-5](https://doi.org/10.1016/S0747-5632(01)00042-5)
- Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q., Motoda, H., Mclachlan, G.J., Ng, A., Liu, B., Yu, P. S., Zhou, Z. H., Steinbach, M., Hand, D.J. & Steinberg, D. (2008). Top 10 algorithms in data mining. *Knowledge and information systems*, 14(1), 1-37. <http://doi.org/10.1007/s10115-007-0114-2>
- Xu, B., & Yang, D. (2016). Motivation classification and grade prediction for MOOCs learners. *Computational intelligence and neuroscience*, 2016(),1-7. <https://doi.org/10.1155/2016/2174613>
- York, T. T., Gibson, C., & Rankin, S. (2015). Defining and Measuring Academic Success. *Practical Assessment, Research & Evaluation*, 20(5),1-20. <https://doi.org/10.7275/hz5x-tx03>

- Young, S., & McSparran, M. (2001). Confident men-successful women: Gender differences in online Learning. In *EdMedia+ Innovate Learning* (pp. 2110-2112). <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.680.5283&rep=rep1&type=pdf>
- Yükseltürk, E., & Bulut, S. (2007). Predictors for student success in an online course. *Journal of Educational Technology & Society*, 10(2), 71-83. <https://www.jstor.org/stable/jeductechsoci.10.2.71>

## **UZAKTAN EĞİTİMLE ALINAN DERSLER İLE ÖĞRETMEN ADAYLARININ AKADEMİK BAŞARISININ MODELLENMESİ VE DEĞERLENDİRİLMESİ**

### **ÖZ**

Uzaktan eğitim, eğitimin her kademesinde yararlanılabilecek bir öğrenme yöntemidir. Bunun en temel nedeni ise hem öğretmen hem de öğrenci açısından kolaylıklara sahip olmasından kaynaklanmaktadır. Uzaktan eğitim ile alınan derslerde yüz yüze alınan derslerde olduğu gibi öğrencilerin not ortalamalarında aktif konumda yer almaktadır. Uzaktan eğitim yöntemi ile alınan derslerin ne derece öğrencilerin akademik başarılarında etkin rol oynadığı önem arz eden bir konu niteliğini taşımasının yanı sıra tartışmalı bir konu konumundadır. Bu durum göz önünde bulundurularak çalışma kapsamında Eğitim Bilimleri Fakültesi öğrencilerinin akademik başarıları merak edilmiş olup mezuniyet genel not ortalamalarının tahminleme işlemi yapılmıştır. Eğitim Bilimleri Fakültesi bünyesinde yer almakta olan Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü (CEIT), İngilizce Öğretmenliği Bölümü (ELT), Okul Öncesi Öğretmenliği Bölümü (ECE) ve Rehberlik ve Psikolojik Danışmanlık Bölümü (PDR) bölümleri mezun öğrencilerinin verileri toplanmıştır. Toplanan verilerden öğrencilerin cinsiyeti, bölümü, üniversite giriş puanı ve uzaktan eğitim ile ortak almış oldukları dört dersin harf notları değişken olarak kullanılmıştır. Öğrencilerin mezuniyet genel not ortalamaları göz önünde bulundurularak aralık hesaplaması yapılarak “başarılı” ve “başarısız” olmak üzere iki kategorik değişken çıkarılmıştır. Ayrıklaştırma ve kategorik farklılaştırma prosedürlerinden sonra, veri kümesine sınıflandırma yöntemi uygulanmıştır. En iyi performans, 15 teknik performans dilimleri arasında “Naive Bayes Classifiers” içinde %82.8 ile “Gaussian Naive Bayes (Model 3.1)” den elde edilmiştir. Elde edilen bu performans değeri çalışmadaki veriler ile doğru tahminleme yapılması oranının yükseldiğini göstermektedir.

**Anahtar Kelimeler:** Sınıflandırma analizi, akademik başarı tahmini, uzaktan eğitim, naïve bayes.

## GİRİŞ

Çevrimiçi öğrenme, teknolojik gelişmeler ile uzaktan eğitim arasındaki ilişkiden ortaya çıkan ve tanımlaması zor olarak nitelendirilen bir kavramdır. Bazı yazarlar çevrimiçi öğrenmeyi eğitmenin kullanmış olduğu teknolojiyi paylaşım aracı olarak belirtirken (Lowenthal, Wilson ve Parrish, 2009; Regan, Evmenova, Baker, Jerome, Spencer, Lawson ve Werner, 2012), Oblinger, Oblinger ve Lippincott (2005) çevrimiçi kelimesini merkeze alarak çevrimiçi olan durumların tümü olarak tanımlamaktadır. En yaygın olarak kullanılan tanım ise bazı teknolojik araçlar yardımı ile öğrenme deneyiminin gerçekleşmesi şeklindedir (Condrad, 2002). Çevrimiçi öğrenme için yapılan tanımlamalar dışında birçok yazar çevrimiçi öğrenmeyi web tabanlı öğrenme, uzaktan öğrenme ve web tabanlı kurslar olarak nitelendirmektedir (Dringus ve Cohen, 2005; Triacca, Bolchini, Botturi ve Inversini, 2004). Moore, Dickson-Deane ve Galyen (2010), yazarların bu kavramları aynı anlamda kullanmasının nedenini tümünün amacının öğrenen kişiye öğrenme imkânı sunması olarak açıklamaktadır. Bu doğrultuda, Kitleli Çevrimiçi Açık Kurslar (MOOC) öğrencilerin ücretsiz çevrimiçi kurslar aracılığıyla farklı alan ve disiplinlerle ilgili konular hakkında bilgi edinmelerini sağlamayı amaçlayan çevrimiçi bir öğrenme stili olarak tanımlanmaktadır (Liyaganawardena, Adams ve Williams, 2013).

Akademik başarı, derslerin tamamlanması için belirlenen başarılarla gerekli bilgi ve becerilerin kazanılması olarak tanımlanırken (York, Gibson ve Renkin, 2015), öğrencilerin akademik başarısını etkileyen farklı faktörlerin olup olmadığı da literatürde tartışılan bir konudur (Hung, Chou, Chen ve Own, 2010; Lim, 2001; Wang ve Newlin, 2002; Yükseltürk ve Bulut, 2007). Çevrimiçi öğrenme ortamlarının üniversitelerdeki yükümlülüklere uygun olarak kullanıldığı ve öğrencilere öğrenci açısından esnek bir çalışma ortamı sağladığı belirtilmektedir. Sunduğu bu fırsat ve yükümlülüklerin bir sonucu olarak, çevrimiçi öğrenme ortamları artmaktadır. Bu ortamların kullanımının artması araştırmacıların çevrimiçi öğrenme ortamında akademik başarılarını tahmin edebilecek çalışmalar gerçekleştirmesinin yanı sıra çevrimiçi öğrenme ortamlarında öğrencilerin ihtiyaç duydukları şeyleri tespit etmeye yönelik çalışmalar yapmasını sağlamaktadır (Kruger-Ross ve Waters, 2013). Bununla birlikte, yöneticiler ve eğitmenler, öğrencilerin akademik başarısını çevrimiçi ortamlarda tahmin etmek için sınırlı verilere sahiptir. Benzer şekilde, öğrenciler uzaktan eğitim yoluyla aldıkları derslerin kendileri için uygunluğunu tahmin etmek için de sınırlı veriye sahiptir (Berenson, Boyles ve Weaver, 2008). Akademik tahminleme adına yapılan çalışmaların bir kısmı, MOOC'dan veri elde edilerek gerçekleştirilmiştir. Bunun temel nedeni, tahminleme modellerinin kullanıcıların katılımını ve sonuçlarını MOOC'larda görmeyi amaçlamasıdır (Garner ve Brooks, 2018). MOOC'da bir kursa kayıtlı olan öğrenciler, arka plan etkinlikleri ile tahmin edilmiş ve öğrencilerin sertifikalı derslerin sonunda bir sertifika alıp almayacakları belirlenmiştir. Araştırma kapsamında öğrenciler hem motivasyon hem de notlar açısından incelenmiş ve sınıflandırılmıştır. Araştırmacılar, öğrencilerin motivasyonel olarak farklı gruplara ayrıldığını ve daha sonra bu gruplar içinde değerlendirme tahmininin mümkün olduğunu belirtmiştir (Xu ve Yang, 2016). Almeda, Zuech, Utz, Higgins, Reynolds and Baker (2018) çalışmasında çevrimiçi olarak ders alan öğrencilerin başarılarını tahmin için hangi faktörlerin etken olduğunu kontrol edip, diğer çalışmalarla benzerlik gösteren faktörler dışında ders tasarımlarının ve öğretim üyelerinin de göz önünde bulundurulmaya çalışıldığını belirtmiştir. Sınıflandırma ve regresyon modelleri ile elde



edilmiş olan araştırma sonuçlarına göre öğrencilerin video, forumlar, yorum içerikli kısımlar ve etkileşimli olan bölümlerde gerçekleştirmiş olduklarına göre başarılı olup olmadıklarına dair bir öngöründe bulunmayı sağlamakta iken gerçekleştirmiş okumalar ve yapmış oldukları bazı yorumlar notlandırmalarına dair daha kısıtlı bir öngörü sağlamaktadır.

Yükseltürk ve Bulut (2007) çalışmalarında yaş, cinsiyet, eğitim seviyesi, kontrol odağı ve öğrencinin öğrenme stili gibi değişkenlerin, içsel ve dışla hedef yönelimi, kontrol inançları, öz yeterlilik ve test kaygısı gibi motivasyonel inançların ve öz yönlendirmeli öğrenme bileşenlerinin çevrimiçi öğrenme ortamında alınan derslerde öğrenci başarısını ne ölçüde etkilediğinin cevabını aramaktadır. Bu sorularına ek olarak çalışma için seçilmiş olan "C programlama dili ile Veri Yapıları ve Algoritmalar" dersinin iki eğitmeninin öğrencilerin çevrimiçi derslerdeki başarılarını etkileyen faktörler hakkındaki görüşlerini alınmıştır. Çevrimiçi olan derslerde öğrenci başarısına bakmak adına öncelikle olarak 80 gönüllü öğrenciye Demografik Anket, İç-Dış Kontrol Odağı Ölçeği, Öğrenme Stili Envanteri ve Öğrenme için Motive Stratejileri formu olmak üzere dört farklı çevrimiçi anket uygulaması yapılmıştır. Dersin iki eğitmeni ile görüşme için ise yarı yapılandırılmış görüşme kullanılarak uzmanların görüşü alınmıştır. Gerçekleştirilmiş olan dört çevrimiçi anket uygulamasının sonuçlarına göre öğrencinin içsel hedef yönelimi, öz yeterlilik, bilişsel strateji kullanımı ve öz düzenleme ile çevrimiçi öğrenme ortamında gerçekleşen derslerin başarıları arasında anlamlı bir korelasyon bulunmaktadır. Bu durum belirtilen özellikler ile ders başarısını etkilediğini göstermektedir. Eğitim düzeyi ve dış kontrol odağı ise öğrencilerin başarıları ile negatif bir korelasyona sahip durumdadır. Eğitmenlerle yapılan görüşme sonucuna göre ise çevrimiçi derslerde öğrencilerin başarısız olma nedenlerinin motivasyon ve uyum sağlama sorunları ile karşı karşıya kaldıklarından dolayı meydana geldiği tespit edilmiştir. Öğrencilerin vermiş olduğu yanıtlar öğrencilerin başlangıçta çevrimiçi derslerde yüksek motivasyonda olduklarını göstermekte iken eğitmenlerin görüşleri öğrencilerin bu motivasyonlarının süreç ilerledikçe düşmüş olduğu yönündedir. Öğrencilerin süreçteki motivasyon kayıpları da ders içi başarılarında düşüş yaşamalarına neden olmaktadır (Yükseltürk ve Bulut, 2007). Son olarak, bu çalışmalarda, öğrencilerin genel özelliklerinin çevrimiçi kurslardaki başarıları üzerinde önemli bir etkisi olmadığı belirtilmektedir (Lim, 2001; Wang ve Newlin,2002; Yükseltürk ve Bulut, 2007).

Araştırmacılar öğrencilerin uzaktan eğitim derslerindeki başarıları ile cinsiyetleri arasındaki ilişkiyi belirleyecek çalışmalar yürütmüştür. Ancak çalışmalar cinsiyet değişkeninin çevrimiçi öğrenme ortamlarındaki başarıyı etkileyecek bir etkisinin olmadığı kanısına varmıştır (Yükseltürk ve Bulut, 2007). Cinsiyet değişkeninin öğrencilerin çevrimiçi öğrenme ortamlarını kullanım sıklıklarını etkileyerek farklılık yarattığı görülmektedir. Erkeklerle göre çevrimiçi öğrenme düşük maliyetli ve erişim kolay bir ortam niteliği taşıırken, kadınlara göre çevrimiçi öğrenme ortamları işbirlikçi çalışma ortamı sağlayıcı olmaktadır (Arbaugh, 2000). Young ve McSparran (2001) çalışması içerisinde çevrimiçi öğrenmede cinsiyet faktörünün yaratmış olduğu farklılığı incelemiştir. Bunun içinde öncelikli olarak İnternet ve Web Tasarım dersini seçmiş ve ön ve son test, öğrenci değerlendirme sonuçları ve dersin web sitesinin kullanım istatistiği olmak üzere üç farklı yöntem ile 1999 ve 2000 bahar, güz ve yaz dönemlerinde veri toplamıştır. Çalışmanın sonuçlarına göre erkekler kendilerinin kadınlardan İnternet ve Html konusunda daha deneyimli olduğunu bildirmektedir. Odak grup görüşmesinin

sonuçları ise erkeklerin çevrimiçi öğrenmede hızlı başlayıp düşüş yaşadığını kadınların ise lineer bir yol takip ettiğini göstermektedir. Kısacası çevrimiçi öğrenmede kadınların öz düzenleme ve zaman yönetimi becerileri daha gelişmiş iken erkeklerin bu becerileri daha az gelişim göstermiştir. Bu durumda değerlendirme sınavlarında ve siteleri kullanımlarında performanslarını gösteremediklerini kanıtlamaktadır (Young ve McSporran, 2001).

Çevrimiçi öğrenmede başarı konusunda çalışmalar içerisinde incelenen bir diğer faktör katılımcıların yaşları olmaktadır. Moore ve Kearsley (2005)'e göre uzaktan eğitim alan bireylerin çoğunun yaş aralığı 25 ile 50 arasında değişiklik göstermektedir. Bu durum da yetişkinlerin doğasını anlamının sonrasında çevrimiçi öğrenme ortamlarındaki durumlarını anlamayı gerektirmektedir. Orta Batı'da yere alan bir üniversitenin 2005 bahar ve yaz dönemleri boyunca çevrimiçi derslere kayıtlı lisansüstü öğrencileri ile yürütülen çalışmada online anket uygulanarak öğrencilerin demografik bilgileri ve kendi kendini yönlendirme ile öğrenme stratejileri verileri toplanmıştır. Toplanan veriler doğrultusunda elde edilen sonuçlara göre öğrencilerin yaşlarının çevrimiçi öğrenme ortamlarındaki başarılarını etkileyecek derecede öneme sahip olmadığı tespit edilmiştir (Colorado ve Eberle, 2010).

Bu çalışma, Eğitim Bilimleri Fakültesi'nden mezun olan ve mezun olmadan önce çevrimiçi ders alan öğrencilerle gerçekleştirilmiştir. Bu çalışmanın amacı, öğrencilerin mezuniyet not ortalamalarını uzaktan eğitim aracılığıyla gerçekleştirilmiş derslerinden alınan harf notlarına göre tahmin ederek modellemesini yapmaktır. Tahmin etme sürecini yürütmek için CEIT, PDR, ECE ve ELT bölümlerinden toplam 174 öğrencinin mezuniyetlerine kadar almış oldukları 4 çevrimiçi dersin harf notları kullanılmıştır.

## **YÖNTEM**

Bu araştırma kapsamında alan yazın incelemesi yapıldığı zaman uzaktan eğitim ile alınan derslere göre mezuniyet ortalamasının tahmin edilmiş olduğu çalışmalarının sayısının oldukça az olduğu tespit edilmiştir. Bu durumda göz önünde bulundurularak elde edilen veri setinin anlamlı bilgiler verebilmesi ve tahminlemeyi gerçekleştirmesi adına veri madenciliği yöntemi kullanılmıştır. Veri madenciliği, toplanan veriler ile tahminleme yapılabilmesini sağlayan kuralların belirlenmesi olarak tanımlanmaktadır (Karabatak, 2008). Veri madenciliği içerisinde de sınıflama metodu tercih edilmiştir. Araştırma yöntemine yönelik olarak bu başlık altında detaylı bilgiler paylaşılmıştır.

## **Çalışma Grubu**

Bu araştırmanın kapsamı dahilinde Eğitim Bilimleri Fakültesi öğrencilerinin uzaktan eğitim yoluyla almış oldukları derslere dair harf notlarından mezuniyet ortalamalarının tahmin edilmesi amaçlanmıştır. Bu amaç doğrultusunda Eğitim Bilimleri Fakültesi Bilgisayar ve Öğretim Teknolojileri Eğitimi (CEIT), İngilizce Öğretmenliği (ELT), Okul Öncesi Öğretmenliği (ECE) ve Rehberlik ve Psikolojik Danışmanlık (PDR) bölümlerinden mezun olmuş 174 lisans öğrencisi çalışmaya dahil edilmiştir. Öğrencilerin yüzde 69.54'ü (121 kişi) kadın öğrenci iken, yüzde 30.45'i (53 kişi) erkek öğrencidir. Bölümlerin dağılımı ise CEIT 69, ELT 69, ECE 17 ve PDR 63 kişidir. Uzaktan

eğitim yoluyla alınan dersler, öğrenciler tarafından farklı dönemlerde alınmış ve öğrenciler çoğunlukla sonbahar ve ilkbahar dönemlerinde birbirlerinin devamı olan dersleri alarak devam etmiştir. Dersi başarısız olan veya notlarından memnun olmayan öğrenciler, yaz döneminde derslerini tekrar almayı tercih etmiştir. Öğrencilerin 129'u 8 dönem sonunda mezun olurken, 25'i 7 dönem, 8'i 6, 7'si 9, 2'si 10, 1'i 11 ve 2'si 12 dönem sonunda mezun olmuştur. 2012 akademik yılı itibarıyla öğrenciler, Eğitim Yönetim Sistemi (LMS) kullanmıştır. Dolayısıyla 2012'den sonra uzaktan eğitim aracılığıyla ders alan öğrenciler sistemi daha önce deneyimlemişlerdir.

### **Verilerin Toplanması**

Araştırma kapsamına öncelikli olarak kişilerin bilgilerini edinebilmek ve kullanabilmek için Bahçeşehir Üniversitesi Bilimsel Araştırma ve Yayın Etiği Kurulunun etik kurul izni araştırmacı tarafından alınmıştır. Bu doğrultuda, araştırma Eğitim Bilimleri Fakültesi bünyesinde yer almakta olan Bilgisayar ve Öğretim Teknolojileri Eğitimi (CEIT), İngilizce Öğretmenliği (ELT), Okul Öncesi Öğretmenliği (ECE) ve Rehberlik ve Psikolojik Danışmanlık (PDR) bölümlerinin mezun olmuş öğrencilerinin notları ve bazı bilgileri alınarak gerçekleştirilmiştir. Veriler arasında öncelikli olarak öğrencilerin mezun olana kadar farklı dönemlerde uzaktan eğitim yoluyla almış oldukları dört farklı çevrimiçi derse ait harf notları yer almaktadır. Bu verilere ek olarak almış olunan bu dersleri alan öğrencilerin bölümleri, cinsiyetleri, üniversite yerleştirme puanları ve mezuniyet not ortalamaları sistem üzerinden çekilmiştir. Mezun öğrencilerin listesini belirleme öncesinde uzaktan eğitim ile verilmiş olan derslerin kontrolünün ve ders yürütme işlemlerinin sağlanmış olduğu birim ile görüşülerek derslerin uzaktan eğitim ile verilmeye başlanmış olduğu akademik dönem kesinleştirilmiştir. Edinilen bilgiler doğrultusunda seçilmiş olan bu dört dersin yüz yüze verilmiş olduğu dönemlerde dersi almış olan öğrencilerin isimleri veri setinden silinmiştir. Buna ek olarak örneklem içerisine Eğitim Bilimleri Fakültesine ÖSYM yerleştirmeleri haricinde yatay, dikey geçiş yapan ya da uluslararası öğrenci niteliğini taşıyan öğrencilerin verileri temizlenmiş ve çalışmaya dahil edilmemiştir. Tüm bu veri temizleme işlemlerinden sonra, çalışma kapsamı dahilinde 174 mezun öğrencinin verileri analiz edilmek için hazır hale getirilmiştir.

Araştırma kapsamında öğrencilerin uzaktan eğitim yoluyla aldıkları dersler "Atatürk İlkeleri ve Türkiye Cumhuriyeti Tarihi I-II ve Türk Dili ve Edebiyatı I-II" dir. Bu derslerde öğretim görevlileri öğrencilere haftalık video, doküman ve ders materyalleri temin etmekte ve çoğunlukla 5. hafta olmak üzere belirli aralıklarla çevrimiçi ara sınav ve küçük sınavlar yapmaktadır. Final sınavları öğrencilerle yüz yüze yapılmaktadır.

### **Verilerin Analizi**

Veri madenciliği, büyük veri depolarından veya kümelerinden faydalı bilgi ediniminin yanı sıra toplanan ya da mevcut elde var olan verilerin analiz ve tahmin görevlerini de üstlenmektedir (Ahmad, Ismail ve Aziz, 2015). Veri madenciliğinde özellikle öğrencilerin başarı tahminlemesi yapılırken en çok tercih edilmekte olan metotların sınıflandırma, kümeleme ve birliktelik olduğu belirtilmektedir (Kumar ve Ramaswami, 2010). Chamillard (2006)'a göre veri madenciliği teknikleri öğrencilerin derslerindeki başarılarına dair tahmin modelleri geliştirme imkanına sahip olmuş olması nedeniyle eğitim alanında kullanılmaktadır. Çıkarılan tahminleme modeli de öğretim elemanlarının öğrencilerinin akademik performans düzeylerini belirleyerek çözüm yolu

bulmalarına olanak tanımaktadır. Veri madenciliği tekniklerinden biri olan sınıflandırma, genel ifadesiyle nesneyi sahip olmuş olduğu özellikleri doğrultusunda bir sınıfa veya kategoriye yerleştirmektir. Eğitim içerisinde de eğitimler öğrencilerini bilgi, motivasyon ve davranışları konusunda sınıflandırmadan faydalanmaktadır (Hamalainen ve Vinni, 2011).

Çalışmada yer alan Naïve Bayes'in olasılık teorisi doğrultusunda belirli bir sınıfın parametre değerinin etkisini başka bir parametre değerinden bağımsız olduğunu varsaymakta ve farklı verilerden elde edilen sonuçlara göre verilerin değerlerini tahmin etmede kullanılan öngörücü bir yaklaşım olarak tanımlaması yapılmaktadır (Pandey ve Pal,2011). Naïve Bayes, en basit şekliyle bile etkili olan en eski sınıflama algoritmalarından biridir (Wu ve diğerleri, 2008) ve Naïve Bayes hem tanımlayıcı hem de öngörücü bir algoritma türü olarak nitelendirilmektedir (Pandey ve Pal,2011).

Araştırma kapsamı içerisinde mezun öğrencilere ait olan veriler sistem üzerinden çıktı olarak alınmıştır. Alınan çıktının içerisinde seçilmiş olan dört ortak dersin uzaktan eğitim ile verilmiş olmayan akademik dönemlerinde dersi almış öğrenciler listeden silinmiştir. Buna ek olarak listeden yatay ya da dikey geçiş ve uluslararası öğrenci niteliğini taşıyan öğrenciler silinmiştir ve veriler analiz yapılabilecek hale getirilmiştir. Veri setinde yer alan bölüm adları kısaltmaları olan CEIT, ELT, ECE ve PDR şeklinde revize edilmiştir. Öğrencilerin seçilen derslerde almış oldukları harf notları ise alfabetik sıraya göre harflerle nitelendirilmiştir. Sistemden elde edilmiş olan mezuniyet genel not ortalamaları da "başarılı" ve "başarısız" olarak iki kategorik değişken haline getirilmiştir. Bu kategorik değişkenlerin genel not ortalamalarına dağılımını gerçekleştirebilmek adına aralık hesaplaması yapılmıştır. Aralık hesaplamasının yapılabilmesi adına da öncelikli olarak ranj hesaplaması için öğrencilerin mezuniyet genel not ortalamalarından en yüksek ve en düşük olanın tespit edilmiştir. Belirlenen notlarda en yüksekten düşük olan çıkarılıp sayı elde ettikten sonra iki olarak belirlenmiş olan kategori sayısına bölme işlemi gerçekleştirilmiştir.

$$\text{Aralık} = 3,89 - 2,15 / 2$$

Yapılmış olan işlem sonucuna göre genel not ortalaması 3,02 ve altından olanlar "Başarısız", üzerinde olanlar "Başarılı" kategorik değişkeni ile gösterilmiştir. MATLAB içerisinde ise "Başarısız" ve "Başarılı" olarak nitelendirilen kategoriler "Başarısız öğrenciler(Failed students) " ve "Başarılı öğrenciler (Succeed students)" olarak tanımlanmaktadır. Başarılı ve başarısız tanımlamalarında olduğu gibi "Başarısız öğrenciler" olarak nitelendirilmekte olan öğrenciler hesaplanan aralıkta ya da bu aralığın altında olan öğrenciler olurken, "Başarılı öğrenciler" belirlenen aralığın üzerinde genel not ortalamasına sahip olan öğrencileri göstermektedir. Veri setindeki tüm düzenleme işlemleri tamamlandıktan sonra veri seti MATLAB'da sınıflandırma kuralı ile analiz edilmiştir ve karar ağaçları oluşturulmuştur. Karar ağaçları sınıflandırmanın içermiş olduğu yöntemlerden bir tanesidir.

**BULGULAR**

Çalışmanın bu bölümünde araştırmanın toplanan verileri ile mezuniyet not ortalamasının tahminine dair yapılmış olan sınıflandırma metodu ile elde edilen bulgulara yer verilmiştir. Öğrencilerin uzaktan eğitim ile almış oldukları derslerin isimleri ve harf notlarının yanı sıra öğrencilere ait cinsiyet, üniversiteye giriş puanı ve hangi bölümden olduğu verileri kullanılmıştır. Toplanan veriler MATLAB yardımı ile sınıflama metodu uygulamasına sokulmuş ve ardından farklı tekniklerden elde edilen yüzdelik oranları verilmiştir.

Toplanmış veriler ile MATLAB üzerinde çok fazla sayıda deneme yapılmış olup en başarılı tahminlemeye ulaşılmaya çalışılmıştır. Öğrencilerin mezun oldukları yarıyıl sonunda başarı durumlarının tahmin edilmesine yönelik beş farklı sınıflandırma metodunda 15 farklı teknik ile oluşturulan modellerin tahmin performansları Tablo 1.'de verilmiştir.

**Tablo 1.** Sınıflandırma Modellerinin Doğruluğu

Sınıflandırıcı	Model No	Model Türü	Doğruluk (%)
1. Karar Ağaçları	1.1	Fine Tree	%69.0
	1.2	Orta Ağaç	%69.0
	1.3	Kaba Ağaç	%68.4
2. Lojistik Regresyon	2.1	Lojistik Regresyon	%70.7
3. Naive Bayes	<b>3.1</b>	<b>Gaussian Naive Bayes</b>	<b>%82.8*</b>
	3.2	Kernel Naive Bayes	%77.6
4. Destek Vektör Makinesi	4.1	Lineer DVM	%73.0
	4.2	İkinci derece DVM	%73.0
	4.3	Kübik DVM	%71.3
	4.4	Fine Gaussian DVM	%63.8
	4.5	Orta Gaussian DVM	%75.9
	4.6	Kaba Gaussian DVM	%69.5
5. Kolektif	5.1	Hızlandırma Ağacı	%72.4
	5.2	Örnekleme Ağacı	%70.1
	5.3	Rastgele alt örnekleme Hızlandırma Ağacı	%67.8

\*En iyi doğrulama modeli, Çapraz Doğrulama Kıvrımları: 5 Kıvrımlar, Tahmin Hızı ~6200 obs/sec, Deneme Süresi 0.20041 sec

Tablo 1. incelendiğinde, en iyi performansa sahip sınıflandırma modelinin naive bayes sınıflandırmaları içerisinde yer alan “Gaussian Naive Bayes (Model 3.1)” olduğu görülmektedir. Test edilen model incelendiğinde, öğrencilerin bölüm, cinsiyet, üniversite giriş puanları ve online olarak alınan ortak dört dersin dönem sonu notları kullanarak akademik başarılarını %82.8 oranında doğru sınıflandırdığı görülmektedir. Sınıflandırmaya ilişkin Eğri Altında Kalan alan (AUC) değeri AUC= 0.78 olarak bulunmuştur.

Oluşturulan modelin tahmin performansının doğru ve yanlış sınıflandırma isabetliliğinin (doğruluk) daha iyi anlaşılabilmesi için “Gerçek Pozitif Değerlerin Oranı ve Yanlış Negatif Değerlerin Oranı” karışıklık matrisi aşağıda verilmiştir (Şekil 1.).




Şekil 1. Karışıklık Matrisi

Şekil 1. incelendiğinde başarısız durumunda olan 111 öğrencinin akademik başarısının 86% (n=95) doğru, başarısız olan 14%'ünü (n=16) ise başarılı kategorisinde yanlış tahmin edildiği görülmektedir. Akademik başarı durumu “başarılı” olan 63 öğrencinin ise 78%'ini (n=49) doğru, 22%'sini ise (n=14) yanlış sınıflandırdığı görülmektedir.

Şekil 1. içerisinde yer almakta olan “Başarısız öğrenciler” ile mezuniyet ortalamasının aralık hesaplaması ile elde edilmiş olan 3,02 ile eşit ya da 3,02’den küçük olduğu anlamını taşımaktadır. “Başarılı Öğrenciler” ile mezuniyet ortalamasının 3,02’den büyük olduğu anlamını taşımaktadır. Şekil 2. ile öğrencilerin mezuniyet genel not ortalamalarını tahminlemede kullanılan farklı değişkenlerin karşılaştırılması yapılmaktadır. Gerçekleştirilmiş olan karşılaştırmalarda değişkenlerin birbirleriyle olan ilişkilerine açıklık getirmektedir. Bu şekil içerisinde yer almakta olan düz şekilde ilerleyen açık mavi çizgiler “başarısız” kategorisinde olup doğru tahminleme yapılmış olan öğrencileri gösterirken, kesikli olan mavi çizgiler “başarısız” kategorisinde olup tahminlemede yanlış yapılmış olduğu öğrencileri betimlemektedir. Düz çizgi şeklinde çizilmiş olan turuncu çizgiler ise “başarılı”

kategorisinde yer alan öğrencilerin mezuniyet genel not ortalamalarının doğru tahmin edildiğini göstermekte iken kesikli olan turuncu çizgiler “başarılı” kategorisindeki öğrencilerin genel not ortalamalarının yanlış tahmin edildiğini göstermektedir.



Şekil 2. Değişkenlerin Paralel Koordinat Grafiği

## SONUÇ ve TARTIŞMA

Eğitim Bilimleri Fakültesi öğrencilerinin mezuniyet genel not ortalamasının tahmin edilebilmesi için mezun öğrencilere ait cinsiyet, bölüm, üniversite sınav puanı ve mezuniyet aşamasına kadar bölümlerin farklı zamanlarda almış oldukları dört dersin harf notları olmak üzere 7 değişken girdi verisi olarak kullanılmıştır. Toplamda 174 mezun öğrencinin verilerinin yer almış olduğu listede sınıflandırma metodu kullanılarak mezuniyet genel not ortalaması tahmin edilmeye çalışılmıştır. Metodun kullanılmaya başlanmasından önce verilerin temizleme işlemi yapılmasının ardından mezuniyet genel not ortalamaları “başarılı” ve “başarısız” olmak üzere iki kategoriye ayrılmıştır. İki kategorik değişken oluşturulabilmesi içinde aralık değer hesaplaması yapılmıştır. Gerçekleştirilmiş olan denemeler sonucunda sınıflandırma metodunun modellerinden olan Gaussian Naive Bayes modelinin en iyi performans sağladığı sonucuna ulaşılmıştır. En iyi olarak tanımlanmış olan performans değere %82.8’dir. Elde edilen bu oran doğrultusunda öğrencilerin mezuniyet not ortalamalarının uzaktan eğitim ile almış oldukları bu derslerin harf notları doğrultusunda tespit edilmesinin mümkün olduğunun göstergesi olarak kabul edilebilir.

Ren, Rangwala ve Johri (2016) çalışmalarında MOOC’lar aracılığıyla toplanan verilerin analizinde veri madenciliği kullanımının söz konusu olduğunu belirtmektedir. Çalışması içerisinde de öğrencilerin önceki çalışmaları ile birlikte alacakları notların tahminlemesini yapmış olup öğrencilerin önceki çalışmalarında derslere katılımın, materyalleri inceleme özelliklerinin öğrencilerin notlarını tahminlemede etkin faktörler olduğunu tespit etmiştir. Pakistan’da yapılan bir başka çalışmada, 4 yıllık Bilgi Teknolojileri bölümünden mezun olana

kadar 201 öğrencinin sınıflarından belirli oranlar alarak öğrencilerin performans değerlerini tahmin etmeye çalışılmıştır. Bu çalışmanın gerçekleştirilebilmesi adına her akademik yılın ortalaması belli yüzdelik oranda alınmış olup mezuniyet genel not ortalaması da beş kategoriye ayrılmıştır. Veri madenciliği yapabilmek adına RapidMiner programı kullanılarak tüm veriler program içerisine aktarılmış ve tahminleme işlemi gerçekleştirilmiştir. Yapılan araştırma doğrultusunda birinci ve ikinci sene notlarının öğrencilerin mezuniyet not ortalamalarını tahmin etmede etken rol oynadığı tespit edilmiştir. Ayrıca çalışma içerisinde hangi derslerin düşük veya yüksek performans gösterimi sağladığı belirlenmeye çalışılmış olup dört dersin etken rol oynadığı kanıtlanmıştır. Tüm bunlara ek olarak elde edilen sonuçlar öğrencilerin her yıl benzer notlar aldığını söylemenin mümkün olduğunu göstermektedir (Asif, Merceron, Ali ve Haider, 2017). Muen, Zafar ve Manzoor (2016) çalışmasında ise öğrencilerin akademik kayıtları ve forum katılımlarına göre akademik performanslarını tahmin ve analiz etmeye yer vermiştir. Çalışma kapsamı dahilinde de iki lisans dersi öğrencilerinin verilerini veri seti olarak kullanmış ve bu veri seti üzerinde Naive Bayes, Yapay Sinir Ağı ve Karar Ağacı olmak üzere üç farklı sınıflandırma algoritması kullanmayı tercih etmiştir. Tüm bu sınıflandırma algoritma çeşitlerini deneyerek hangisi ile en iyi performansın gösterildiğini tespit etmiştir. Yapılan teste göre de Naive Bayes genel tahmin doğruluğunda %86'ya ulaştığı için en iyi performans gösteren sınıflandırıcı olarak seçilmiştir.

Bu araştırma içerisinde tahmin edilmekte olan lisans öğrencilerinin mezuniyet genel not ortalamaları literatür içerisinde de farklı çalışmalar içerisinde yer almaktadır (Kappe ve Flier, 2012; Osmanbegoviç ve Suljic, 2012; Şengür ve Tekin, 2013; Tosun, 2007). Ancak bu çalışma kapsamınca çalışılmış olduğu şekilde lisans öğrencilerinin uzaktan eğitim ile almış oldukları derslerin harf notları doğrultusunda mezuniyet genel not ortalamalarının tahmin edildiği çalışmalara rastlanmamıştır. Literatürde yer alan çalışmalar lisans seviyesindeki öğrencilerin temel derslerini baz alarak öğrenci mezuniyet notlarının tahminlemesinde (Şengür ve Tekin, 2013) ya da öğrencilerin almış oldukları derslerden yola çıkarak almış oldukları derslerle bağlantılı derslerin başarı tahminlemesinde (Akgün ve Demir, 2018) bulunmuştur. Çalışmalar içerisinde bu tür yönelimlerin olması çalışma yapılan yerlerde uzaktan eğitim ile verilen derslerin olmamasından kaynaklandığı söylenebilir.

## **ÖNERİLER**

Yapılmış olan bu çalışmanın devamlılığı olarak yapılacak olan çalışmalarda tüm fakülte bazında öğrencilerin almış oldukları ortak ve yüz yüze olan derslerinde harf notları alınarak öğrencilerin mezuniyet genel not ortalamalarının tahmin edilmesi sağlanabilir. Bu sayede yüz yüze yapılan derslerdeki eksikliklerinde tespiti gerçekleştirilmiş olup bu eksikliklerin giderilmesi ve öğrencilerin daha yüksek notlar alarak genel not ortalamalarını yükseltmeleri sağlanabilir. Bu çalışma, uzaktan eğitim kurslarının öğrencilerin mezuniyet not ortalamalarını ne ölçüde belirlediğini görmek için tüm okula da uygulanabilir. Bu dersler sınıf içi ortamlarda da verilebilir, bu durumda, harf notları ile öğrencilerin mezuniyet not ortalaması tahmini arasındaki farkın yanı sıra uzaktan eğitim ve sınıf içi ortamlar arasındaki farklar da belirlenebilir. Bu farklılıkların belirlenmesi, yüz yüze ve uzaktan eğitim ile ilgili koşulların iyileştirilmeye çalışması sağlanabilir. Fark tespiti ile yüz yüze ve uzaktan eğitim eksikliklerinde veya hatalarında etkili olabilir. Tüm bu değişkenlere ek olarak, bu çalışma kapsamında



kullanılanlardan farklı değişkenler ilerdeki çalışmalara dahil edilebilir. Bu durum, öğrencilerin uzaktan eğitim yoluyla aldıkları derslerde ne kadar başarılı olduklarını ve bu başarının genel not ortalamalarını nasıl etkilediğini belirlemede daha da ileri gidebilmesini sağlayabilir. Naser, Zaqout, Ghosh, Atallah ve Alajrami(2015) ve Karamouzis ve Vrettos (2008) çalışmalarında öğrencilerin akademik başarısını tahmin etmeye çalışmış ancak öğretim üyelerini yine bu tahminleme içerisinde değişken olarak kullanmamıştır. Dolayısıyla yapılacak yeni çalışmalar içerisinde öğretim üyelerinin de öğrencilerin başarılarında ya da mezuniyet genel not ortalamaları üzerinde etkisi göz önünde bulundurularak tahminleme işlemi gerçekleştirilebilir.

## ETİK METNİ

“Bu makalede dergi yazım kurallarına, yayın ilkelerine, araştırma ve yayın etiği kurallarına, dergi etik kurallarına uyulmuştur. Makale ile ilgili doğabilecek her türlü ihlallerde sorumluluk yazarlara aittir.”

## KAYNAKÇA

- Ahmad, F., Ismail, N. H., & Aziz, A. A. (2015). The prediction of students' academic performance using classification data mining techniques. *Applied Mathematical Sciences*, 9(129), 6415-6426.  
<http://dx.doi.org/10.12988/ams.2015.53289>
- Akgün, E., & Demir, M. (2018). Modeling Course Achievements of Elementary Education Teacher Candidates with Artificial Neural Networks. *International Journal of Assessment Tools in Education*, 5(3), 491-509.  
<http://dx.doi.org/10.21449/ijate.444073>
- Almeda, M. (2018). Comparing the Factors That Predict Completion and Grades Among For Credit and Open/MOOC Students in Online Learning. *Online Learning*, 22(1), 1-18.  
<http://dx.doi.org/10.24059/olj.v22i1.1060>
- Arbaugh, J. B. (2000). An exploratory study of the effects of gender on student learning and class participation in an Internet-based MBA course. *Management Learning*, 31(4), 503-519.  
[https://journals.sagepub.com/doi/pdf/10.1177/1350507600314006?casa\\_token=qnViKzvDo7UAAAA:zVz86k7ugc210MZTzLqGPE627WhcN54zwWwELNGBzdLxhI05bbZrvRNmytIO8P5ztve-zC6VSq\\_obg](https://journals.sagepub.com/doi/pdf/10.1177/1350507600314006?casa_token=qnViKzvDo7UAAAA:zVz86k7ugc210MZTzLqGPE627WhcN54zwWwELNGBzdLxhI05bbZrvRNmytIO8P5ztve-zC6VSq_obg)
- Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). Analyzing undergraduate students' performance using educational data mining. *Computers & Education*, 113, 177-194.  
<https://doi.org/10.1016/j.compedu.2017.05.007>
- Berenson, R., Boyles, G., & Weaver, A. (2008). Emotional intelligence as a predictor of success in online learning. *The International Review of Research in Open and Distributed Learning*, 9(2), 1-17.  
<https://doi.org/10.19173/irrodl.v9i2.385>
- Chamillard, A. T. (2006). Using student performance predictions in a computer science curriculum. *ACM SIGCSE Bulletin*, 38(3), 260-264. <https://doi.org/10.1145/1140123.1140194>
- Colorado, J. T., & Eberle, J. (2012). Student demographics and success in online learning environments. *Emporia Research Studies*, 46(1), 4-10. <https://esirc.emporia.edu/bitstream/handle/123456789/380/205.2.pdf>

- Conrad, D. (2002). Deep in the hearts of learners: Insights into the nature of online community. *International Journal of E-Learning & Distance Education*, 17(1), 1-19.  
<http://www.ijede.ca/index.php/jde/article/view/133/114>
- Dringus, L. P., & Cohen, M. S. (2005, October). An adaptable usability heuristic checklist for online courses[Conference Paper]. *Proceedings Frontiers in Education 35th Annual Conference*,  
<https://doi.org/10.1109/FIE.2005.1611918>
- Gardner, J., & Brooks, C. (2018). Student success prediction in MOOCs. *User Modeling and User-Adapted Interaction*, 28(2), 127-203. <http://doi.org/10.1007/s11257-018-9203-z>
- Hämäläinen, W., & Vinni, M. (2010). Classifiers for educational data mining. C. Romero, S. Ventura, S.Pechenizkiy & R.S. Baker (Ed.). *Handbook of Educational Data Mining*. (pp. 57-74). CRC Press.
- Hung, M. L., Chou, C., Chen, C. H., & Own, Z. Y. (2010). Learner readiness for online learning: Scale development and student perceptions. *Computers & Education*, 55(3), 1080-1090.  
<https://doi.org/10.1016/j.compedu.2010.05.004>
- Kappe, R., & van der Flier, H. (2012). Predicting academic success in higher education: what's more important than being smart?. *European Journal of Psychology of Education*, 27(4), 605-619.  
<https://doi.org/10.1007/s10212-011-0099-9>
- Karabatak, M. (2008). *Özellik seçimi, sınıflama ve öngörü uygulamalarına yönelik birliktelik kuralı çıkarımı ve yazılım geliştirilmesi*[Doctorial dissertation, Fırat University].  
<https://acikerisim.firat.edu.tr/xmlui/bitstream/handle/11508/20399/222091.pdf?sequence=1&isAllowed=y>
- Karamouzis, S. T., & Vrettos, A. (2008, October). An artificial neural network for predicting student graduation outcomes[Conference Paper]. In *Proceedings of the World Congress on Engineering and Computer Science* (pp. 991-994).
- Kumar, S. P., & Ramaswami, K. S. (2010, December). Fuzzy K-means cluster validation for institutional quality Assessment [Conference Paper]. In *2010 International Conference on Communication and Computational Intelligence (INCOCCI)* (pp. 628-635). IEEE.
- Kruger-Ross, M. J., & Waters, R. D. (2013). Predicting online learning success: Applying the situational theory of publics to the virtual classroom. *Computers & Education*, 61, 176-184.  
<https://doi.org/10.1016/j.compedu.2012.09.015>
- Lim, C. K. (2001). Computer self-efficacy, academic self-concept, and other predictors of satisfaction and future participation of adult distance learners. *American Journal of Distance Education*, 15(2), 41-51.  
<https://doi.org/10.1080/08923640109527083>
- Liyanagunawardena, T. R., Adams, A. A., & Williams, S. A. (2013). MOOCs: A systematic study of the published literature 2008-2012. *The International Review of Research in Open and Distributed Learning*, 14(3), 202-227. <https://doi.org/10.19173/irrodl.v14i3.1455>

- Lowenthal, P. R., Wilson, B., & Parrish, P. (2009, October). Context matters: A description an typology of the Online learning landscape [Conference Paper]. 2009 AECT International Convention
- Moore, J. L., Dickson-Deane, C., Galyen, K., & Chen, W. (2010, June). Designing for E-learn, Online, and Distance Learning Environments: Are They the Same?. <https://www.researchgate.net/publication/233751524>
- Moore, M. ve Kearsley, G. (2005). *Distance education: A system view*. Wadsworth.
- Mueen, A., Zafar, B., & Manzoor, U. (2016). Modeling and predicting students' academic performance using data mining techniques. *International Journal of Modern Education and Computer Science*, 8(11), 36. <https://doi.org/10.5815/ijmeecs.2016.11.05>
- Naser, S. A., Zaqout, I., Ghosh, M. A., Atallah, R., & Alajrami, E. (2015). Predicting student performance using artificial neural network: In the faculty of engineering and information technology. *International Journal of Hybrid Information Technology*, 8(2), 221-228. <http://dx.doi.org/10.14257/ijhit.2015.8.2.20>
- Oblinger, D., Oblinger, J. L., & Lippincott, J. K. (2005). *Educating the net generation*. EDUCAUSE.
- Osmanbegovic, E., & Suljic, M. (2012). Data mining approach for predicting student performance. *Economic Review: Journal of Economics and Business*, 10(1), 3-12. <http://hdl.handle.net/10419/193806>
- Pandey, U. K., & Pal, S. (2011). Data Mining: A prediction of performer or underperformer using classification. *International Journal of Computer Science and Information Technologies*, 2(2), 686-690. <https://arxiv.org/pdf/1104.4163.pdf>
- Regan, K., Evmenova, A., Baker, P., Jerome, M. K., Spencer, V., Lawson, H., & Werner, T. (2012). Experiences of instructors in online learning environments: Identifying and regulating emotions. *The Internet and Higher Education*, 15(3), 204-212. <https://doi.org/10.1016/j.iheduc.2011.12.001>
- Ren, Z., Rangwala, H., & Johri, A. (2016). Predicting performance on MOOC assessments using multi-regression models. *International Educational Data Mining Society*
- Şengür, D., & Tekin, A. (2013). Öğrencilerin mezuniyet notlarının veri madenciliği metotları ile tahmini. *International Journal Of Informatics Technologies*, 6(3), 7-16. [https://www.researchgate.net/profile/Doenues\\_Senguer/publication/325260601\\_Prediction\\_of\\_Student's\\_Grade\\_Point\\_Average\\_by\\_Using\\_the\\_Data\\_Mining\\_Methods/links/5b01c7a6a6fdccf9e4f6562f/Prediction-of-Students-Grade-Point-Average-by-Using-the-Data-Mining-Meth](https://www.researchgate.net/profile/Doenues_Senguer/publication/325260601_Prediction_of_Student's_Grade_Point_Average_by_Using_the_Data_Mining_Methods/links/5b01c7a6a6fdccf9e4f6562f/Prediction-of-Students-Grade-Point-Average-by-Using-the-Data-Mining-Meth)
- Tosun, S. (2007). *Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırması: öğrenci başarıları üzerine bir uygulama*[Master thesis, Istanbul Technical University]. <https://polen.itu.edu.tr/bitstream/11527/5847/1/7221.pdf>
- Triacca, L., Bolchini, D., Botturi, L., & Inversini, A. (2004). Mile: Systematic usability evaluation for e-Learning web applications. In *EdMedia+ Innovate Learning* (pp. 4398-4405). [https://doc.rero.ch/record/5377/files/1\\_Botturi\\_AACE\\_2004.pdf](https://doc.rero.ch/record/5377/files/1_Botturi_AACE_2004.pdf)
- Wang, A. Y., & Newlin, M. H. (2002). Predictors of web-student performance: The role of self-efficacy and reasons for taking an on-line class. *Computers in human behavior*, 18(2), 151-163. [https://doi.org/10.1016/S0747-5632\(01\)00042-5](https://doi.org/10.1016/S0747-5632(01)00042-5)
- Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q., Motoda, H., Mclachlan, G.J., Ng, A., Liu, B., Yu, P. S., Zhou,

- Z. H., Steinbach, M., Hand, D.J. & Steinberg, D. (2008). Top 10 algorithms in data mining. *Knowledge and information systems*, 14(1), 1-37. [http://doi.org/ 10.1007/s10115-007-0114-2](http://doi.org/10.1007/s10115-007-0114-2)
- Xu, B., & Yang, D. (2016). Motivation classification and grade prediction for MOOCs learners. *Computational intelligence and neuroscience*, 2016(),1-7. <https://doi.org/10.1155/2016/2174613>
- York, T. T., Gibson, C., & Rankin, S. (2015). Defining and Measuring Academic Success. *Practical Assessment, Research & Evaluation*, 20(5),1-20. <https://doi.org/10.7275/hz5x-tx03>
- Young, S., & McSparran, M. (2001). Confident men-successful women: Gender differences in online Learning. In *EdMedia+ Innovate Learning* (pp. 2110-2112). <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.680.5283&rep=rep1&type=pdf>
- Yükseltürk, E., & Bulut, S. (2007). Predictors for student success in an online course. *Journal of Educational Technology & Society*, 10(2), 71-83. <https://www.jstor.org/stable/jeductechsoci.10.2.71>

**Ek: Etik Kurul Onayı**

Evrak Tarih ve Sayı: 07/12/2020-E.4674



HİZMETE ÖZEL

T.C.  
BAHÇEŞEHİR ÜNİVERSİTESİ REKTÖRLÜĞÜ

Sayı : 20021704-604.01.02-

Konu : Proje Başvurusu (Dr. Öğr. Üyesi Ergün AKGÜN ve Meltem ÖZMUTLU)

**SAYIN DR. ÖĞR. ÜYESİ ERGÜN AKGÜN  
SAYIN MELTEM ÖZMUTLU**

Üniversitemiz Bilimsel Araştırma ve Yayın Etiği Kurulunun 25.11.2020 tarihli 2020/10 sayılı toplantısında; "Uzaktan Eğitimle Alınan Dersler ile Öğretmen Adaylarının Akademik Başarısının Modellenmesi ve Değerlendirilmesi" başlıklı araştırma makaleniz incelenmiş olup, Bilimsel Araştırma ve Yayın Etiği'ne aykırılık içermediği anlaşılmıştır. Bilgilerinize rica ederim.

Prof.Dr. Faik Tunç BOZBURA  
Rektör a.  
Rektör Yardımcısı

Evrak Doğrulamak İçin : <http://belge.bau.edu.tr/enVision-Sorgula/belgeDogrulama.aspx?V=BEAC48JKL>

/ 1  
Pin : 14212

KEP : bahcesehiruniversitesi@hs01.kep.tr  
Telefon: Fax:  
İrtibat Email: betul.ucer@bau.edu.tr

Ayrıntılı bilgi için irtibat: Betül ÜÇER  
Elektronik Ağ: [www.bahcesehir.edu.tr](http://www.bahcesehir.edu.tr)



Bu belge 5070 sayılı Elektronik İmza Kanununun 5. Maddesi gereğince güvenli elektronik imza ile imzalanmıştır. Evrak sorgulaması <http://belge.bau.edu.tr/enVision-Sorgula/belgeDogrulama.aspx?V=BEAC48JKL> adresinden yapılabilir. (PIN:14212)