

Article Type:

Research Paper

Original Title of Article:

The effects of model based missing data methods on guessing parameter in case of ignorable missing data

Turkish Title of Article:

İhmal edilebilir kayıp veri durumunda model tabanlı kayıp veri baş etme yöntemlerinin şans parametresine etkisi

Author(s):

Duygu KOÇAK

For Cite in:

Koçak, D. (2018). The effects of model based missing data methods on guessing parameter in case of ignorable missing data. *Pegem Eğitim ve Öğretim Dergisi*, 8(1), 155-172, <http://dx.doi.org/10.14527/pegegog.2018.007>

Makale Türü:

Özgün Makale

Orijinal Makale Başlığı:

The effects of model based missing data methods on guessing parameter in case of ignorable missing data

Makalenin Türkçe Başlığı:

İhmal edilebilir kayıp veri durumunda model tabanlı kayıp veri baş etme yöntemlerinin şans parametresine etkisi

Yazar(lar):

Duygu KOÇAK

Kaynak Gösterimi İçin:

Koçak, D. (2018). The effects of model based missing data methods on guessing parameter in case of ignorable missing data. *Pegem Eğitim ve Öğretim Dergisi*, 8(1), 155-172, <http://dx.doi.org/10.14527/pegegog.2018.007>

The Effects of Model Based Missing Data Methods on Guessing Parameter in Case of Ignorable Missing Data

Duygu KOÇAK ^{*a}

^aAlanya Alaaddin Keykubat University, EducationFaculty, Antalya/Turkey



Article Info

DOI: 10.14527/pegegog.2018.007

Article History:

Received 25 March 2017
Revised 08 August 2017
Accepted 15 August 2017
Online 01 December 2017

Keywords:

Guessing parameter,
Guessing success,
Item response theory,
Missing values,
Ignorable missing data.

Article Type:

Research paper

Abstract

The present study aims to investigate the effects of model based missing data methods on guessing parameter in case of ignorable missing data. For this purpose, data based on Item Response Theory with 3 parameters logistic model were created in sample sizes of 500, 1000 and 3000; and then, missing values at random and missing values at completely random were created in ratios of 2.00%, 5.00% and 10.00%. These missing values were completed using expectation-maximization (EM) algorithm and multiple imputation methods. It was concluded that the performance of EM algorithm and multiple imputation methods was efficient depending on the rate of missing values on the data sets with missing values completely at random. When the missing value rate was 2.00%, both methods performed well in all sample sizes; however, they moved away from reference point as the number of missing values increased. On the other hand, it was also found that when the sample size was 3000, the cuts were closer to reference point even when the number of missing values was high. As for missing values at random mechanism, it was observed that both methods performed efficiently on guessing parameter when the number of missing values was low. Yet, this performance deteriorated considerably as the number of missing values increased. Both EM algorithm and multiple imputation methods did not perform effectively on guessing parameter in missing values at random mechanism.

İhmal Edilebilir Kayıp Veri Durumunda Model Tabanlı Kayıp Veri Baş Etme Yöntemlerinin Şans Parametresine Etkisi

Makale Bilgisi

DOI: 10.14527/pegegog.2018.007

Makale Geçmişi:

Geliş 25 Mart 2017
Düzeltilme 08 Ağustos 2017
Kabul 15 Ağustos 2017
Çevrimiçi 01 Aralık 2017

Anahtar Kelimeler:

Üst-bilişsel farkındalık,
Pedagojik alan bilgisi,
Sınıf içi etkinlikler,
Tekli durum çalışması.

Makale Türü:

Özgün makale

Öz

Bu çalışmada, kayıp veri durumunda model tabanlı kayıp veri baş etme yöntemlerinin ihmal edilebilir şans parametresi üzerindeki etkilerinin belirlenmesi amaçlanmıştır. Bu amaçla 500, 1000 ve 3000 örneklem büyüklüğünde tek boyutlu Madde Tepki Kuramı 3 parametrelili lojistik modeline uygun olarak üretilen verilerde %2.00, %5.00 ve %10.00 oranlarında tamamen rastgele kayıp ve rastgele kayıp mekanizmalarına uygun olacak şekilde kayıp veri oluşturulmuştur. Oluşturulan kayıp veriler, beklenti maksimizasyon algoritması ve çoklu atama yöntemleri ile tamamlanmıştır. Veri setinde tamamen rastgele kayıp mekanizmasında kayıp veri olması durumunda çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin kayıp veri oranına da bağlı olarak performansının iyi olduğu sonucuna ulaşılmıştır. Tüm örneklem büyüklüklerinde kayıp veri oranı %2.00 olduğunda her iki yöntemin de en iyi performansı sergilediği, kayıp veri oranı arttıkça referans değerden uzaklaştığı görülmektedir. Buna karşın, örneklem büyüklüğü 3000 olduğunda kayıp veri oranı yüksek de olsa referans değere daha yakın kesitimler sundukları sonucuna ulaşılmıştır. Rastgele kayıp veri mekanizmasında ise kayıp veri oranı düşük olduğunda her iki yöntemin de şans parametresi üzerinde iyi performans gösterdiği ancak kayıp veri oranı arttıkça bu performansta önemli düşüşlerin olduğu sonucuna ulaşılmıştır. Çoklu atama ve beklenti maksimizasyon algoritması ile atama yöntemlerinin her ikisi de rastgele kayıp veri mekanizmasında şans parametresi üzerinde iyi performans göstermemektedir.

* Author: duygu.kocak@alanya.edu.tr

Orcid ID: <https://orcid.org/0000-0003-3211-0426>

Introduction

Critical in assessment and testing theories in the fields of education and psychology, the ultimate aim is to interpret unobservable (latent) variables based on the observable ones. In spite of its common use, classical testing theory has important drawbacks. Estimation of item and test parameters depending on specific groups and thus the variation of estimations from one group to another is one of the reasons of criticism. Even though item parameters vary from one group to another, guessing success as one of these parameters is invariant and independent of groups and item samples since it is determined based on the number of options in the item. When the respondent does not possess the desired behaviour and reaches the correct answer totally by luck, this is called “guessing success”. This is a possible phenomenon in all multiple choice items (Turgut & Baykul, 2010).

Item Response Theory (IRT), a recent common theory, explains the relationship between the individual's estimated characteristics and his or her response through a mathematical function. IRT, which can estimate individuals' skills based on items and independent of tests, can estimate guessing parameter specific to item and independent of group. Guessing parameter (c) can provide the possibility of answering an item by guessing and indicates the starting point on Y axis in item characteristic curve. It can have a value between .00 and 1.00 as it refers to possibility (Lord & Novick, 1968). As guessing parameter gets closer to .00, the item's and thus the test's certainty and explanation increase (Hambleton, Swaminathan & Rogers, 1991). Baker (2001) argues that guessing parameter should not be higher than .35 whereas for Harris (1989), it should not exceed .30. Warm (1978) and Akindele (2003) suggest that guessing parameters higher than .30 are not good and items at .20 or lower can be considered as good items. When guessing parameter is higher than .00, this decreases test information. Yet, if c has higher values, this can also lower the test information (Baker, 2001). The information given by a test shows how much the test can provide information regarding the characteristic aimed to estimate (Hambleton et al., 1991; Reid, Kolakowsky-Hayner, Lewis & Armstrong, 2007). Furthermore, the information provided by a test can be used to calculate the standard error and reliability in IRT (De Mars, 2010; Hambleton & Jones, 1993). Therefore, guessing parameter is an important parameter in IRT affecting reliability and validity. In a three-parameter model, the possibility of an individual giving the correct response to an item can be calculated considering item difficulty, selectivity, and guessing parameter (Crocker & Algina, 1986; Embretson & Reise, 2000; Hambleton et al., 1991). Thus, c parameter has a significant role in estimating skills. However, in order to be able to identify the underlying characteristics being estimated and interpret test and item parameters, individuals first need to respond to the items. Thus, if individuals fail to respond to some of the items due to various reasons or skip some of them, this will result in missing values in data sets and hinder the possibility of making such estimation.

Hohensinn and Kubinger (2011) refer to missing values as a common problem that can never be totally avoided despite carefully planned research procedures. The standard statistical calculations in data sets are done on matrices composed of lines made of observations (from individuals) and columns consisting of variables; and the pores of matrices should be totally full. When an item is left unresponded; in other words, has missing values, statistical calculations cannot be performed owing to the blanks in the matrix. Rubin (1976) maintains that estimations can allow subjectivity when missing values are not at an ignorable level. That missing values can be ignored means that missing values are randomly formed and do not have a specific pattern; that the distribution of the data will not show a deviation or difference; and that, in case there is a multi-variable data which show normal distribution, the process of forming missing values for each variable will be equal. Rubin (1976) states that there will be no difference between the estimations of complete data sets and sets with missing values if missing values are proved to be random. Thus, whether missing values are formed randomly or completely randomly should be identified. Otherwise, it should be noted that a non-ignorable missing value can result in subjectivity.

The existence of missing values in missing completely at random (MCR) mechanism indicates that missing values do not have a relationship with any variables. Donders, Heijden, Stijnen and Moons (2006) maintain that the group of variables without missing values is a sample of the target population when the data set is known to have missing values completely at random. Therefore, most methods result in objective estimations in case of MCR assumption (Satici, 2009). When there are missing values in a variable and when this does not have a relationship with the variable where missing values are and when these have a relationship with other variables, then they are missing values at random (MR). Enders (2010) states that MR explains the possibility of missing values and the systematic relationship with one or more variables. It has been suggested that when missing value mechanism is MR, model based or multiple imputation methods will yield in objective estimations (Donders et al., 2006; Satici, 2009). If the possibility of missing values is associated to its variable and other variables, then it is missing at non-random (MNR). The methods used for missing value analyses are not suitable in case of MNR and cannot avoid subjectivity (Enders, 2010).

In addition to being random or not, it is also important to determine the level or amount of missing values since missing values formed at random because of any reason can result in reducing the data set and thus weakening the estimations. While statistical analyses cannot be performed on data sets with missing values, there is a possibility of subjectivity due to systematic differences between the individuals who responded and the ones who did not (Rubin, 1987). Therefore, the rate of missing values should also be considered as an important factor.

There was significant advancement in developing methods to deal with missing values in 20th century. Graham (2009) explains the reason that statistical analyses developed at the beginning of the 20th century could be performed on complete data sets. Almost none of these analyses had a mechanism do deal with data sets with missing values. This resulted in a need to develop methods to work with data sets with missing values and led to new statistical methods to deal with such data sets (Graham, 2009).

There are two approaches to score measuring instruments. These are multiple scoring and two-category scoring. Erkuş (2012) describes two-category measuring tools as the ones used to determine the existence of a phenomenon with yes-no, there is-there isn't, true-false options. The most common method used to deal with missing values in two-category data sets is to accept the missing ones as "wrong" or "unapplied". However, it is known that both of these methods result in subjective and mistaken estimations. Therefore, more complex methods developed to work on such cases should be applied (Hohensinn & Kubinger, 2011). It is suggested that model based methods will generate objective estimations in MCR and MR mechanisms (Graham, 2009).

Model based missing value methods are missing value methods based on the estimation of parameters depending on the possibility and a posterior distributions in a model created from observations. The main advantage of these models is their flexibility. They conduct calculations through model assumptions avoiding temporary methods. They provide variance estimations considering missing values. There are various models to use for estimations based on models. Particularly, expectation-maximization (EM) algorithm, which started by Lord (1955) and developed into theory by Dempster, Laird and Rubin (1977) and multiple imputation developed in a study by Rubin (1987) are among the model based methods.

Having missing values in data sets is an unavoidable issue in research and thus, there is a need to use a model to deal with missing values. Otherwise, the estimations can be subjective and result in arriving at misleading conclusions and decisions. It is believed that in two-category tests related to cognitive field, guessing parameter as an issue can lead to subjective estimations that can result in wrong conclusions. Therefore, in case of ignorable missing values, how guessing parameter in one dimension item response theory in three-parameter logistic model is affected from methods used to deal with missing values. Therefore, the study aims to identify the effects of multiple imputation and expectation-maximization (EM) algorithm methods used in data sets with ignorable missing values on guessing parameter in one-dimension item response theory in three-parameter logistic model.

Method

Research Design

Since the aim of the present study is to identify the effects of multiple imputation and expectation–maximization (EM) algorithm methods used in data sets with ignorable missing values on guessing parameter (c) in one-dimension item response theory in three-parameter logistic model, the study is basic research (Karasar, 2007). The results are meant to contribute to the existent literature and is suitable for basic research design.

Data Generation and Analysis

In order to develop the data for the study and the desired rates of missing values suitable to missing value mechanisms, R program (R Development Core Team, 2011) was utilized. To estimate the guessing parameter in three-parameter logistic model in item response theory, {ltm} pack in R program was used.

The data were generated based on three-parameter logistic model in item response theory. The item number in the generated data was fixed to 20, the sample sizes were 500, 1000 and 3000, and the response category was determined to be 2 (1-0 scoring). Item difficulty in the data sets was limited to -2.00, +2.00 interval, item differentiation to .50 and 2.00 interval, and guessing parameter to between .00 and .25.

The rates of missing values in the data generated were determined to be 2.00 %, 5.00 % and 10.00 %. When developing MCR mechanism, pores were deleted in 2.00 %, 5.00 % and 10.00 % rates in the codes written in R program. As for MR mechanism, another variable with three categories (1, 2 and 3) was assigned in equal rates randomly. Missing values were then created randomly on the levels generated. On the 1st level, 10.00 % of the pores were deleted, 30.00 % on the 2nd level and 60.00 % of the pores in the 3rd level were deleted to obtain missing values in 2.00 %, 5.00 %, and 10.00 % in total. The generated data sets with missing values were then completed using multiple imputation and imputation with expectation–maximization (EM) algorithm methods. It has been indicated that imputation of a level between 3 and 10 is sufficient when using multiple imputation method (McKnight et al., 2007). The multiple imputation value was determined to be 5. The completed data sets were analysed for the second time based on three-parameter logistic model in order to determine the guessing parameter and the reference points in the complete data sets were interpreted.

Results

The effects of multiple imputation and imputation with expectation–maximization (EM) algorithm as methods of dealing with missing values and on guessing parameter are displayed below first for missing completely at random and then for missing at random mechanisms.

Figure.1 shows the effects of multiple imputation and imputation with expectation–maximization algorithm methods on guessing parameter in missing completely at random mechanism when the sample size is 500. The results indicate that both methods provide close estimations to complete data sets when the missing value is 2.00 %. When the missing value rate is increased, guessing parameter estimations obtained from completed data sets get further from reference point. Both method show similar performance and when the missing value rate is 10.00 %, both get the furthest from reference point. In other words, the performance of multiple imputation and imputation with expectation–maximization algorithm methods scale down as the missing value rate increases.




Figure 1. The effects of multiple imputation and imputation with expectation–maximization (EM) algorithm methods on guessing parameter missing completely at random mechanism ($n=500$).




Figure 2. The effects of multiple imputation and imputation with expectation–maximization (EM) algorithm methods on guessing parameter missing completely at random mechanism ($n=1000$).

Figure.2 presents the effects of multiple imputation and imputation with expectation–maximization algorithm methods on guessing parameter in missing completely at random mechanism when the sample size is 1000. When the missing value is 2.00 %, it is observed that both methods provide estimations close to reference point. However, when the rate of missing value is 5.00 %, their performance fall and the effects of both methods on guessing parameter drop. As missing value rate increases, imputation with expectation–maximization algorithm method is observed to provide closer estimations to reference point compared to multiple imputation method.

When the sample size is 3000 and when the missing value mechanism is completely at random, multiple imputation and imputation with expectation–maximization (EM) algorithm methods are found to yield close estimations to reference point when the missing value rate is 2.00 %. The performance scales down as the rate of missing value inclines. In other words, as missing value rate increases, guessing parameter estimated through completed data sets with multiple imputation and imputation with expectation–maximization (EM) algorithm methods gets further from reference point. However, compared to sample sizes of 500 and 1000, a better performance is obtained as the missing value rate increases. Therefore, it can be suggested that multiple imputation and imputation with expectation–maximization (EM) algorithm methods perform partly well on guessing parameter in high missing value rate if the sample size is large enough.

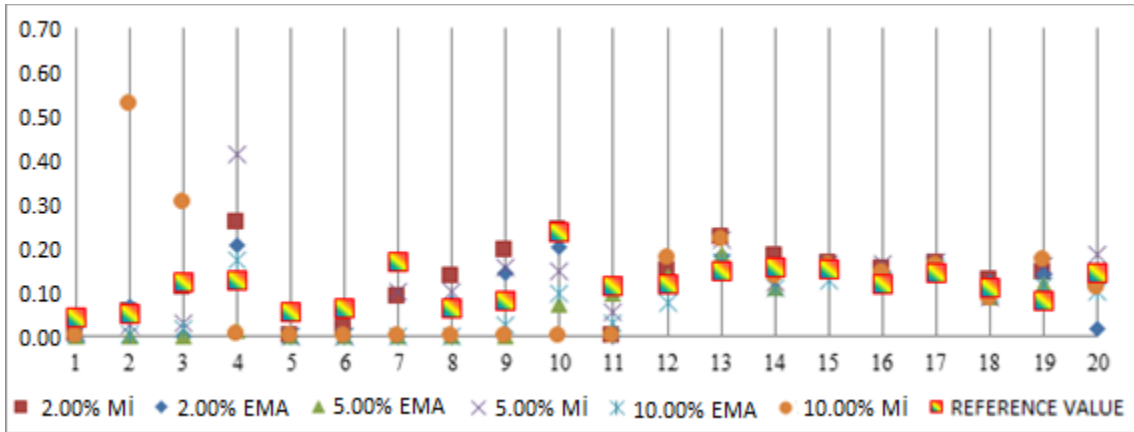


Figure 3. The effects of multiple imputation and imputation with expectation–maximization (EM) algorithm methods on guessing parameter missing completely at random mechanism (n=3000).




Figure 4. The effects of multiple imputation and imputation with expectation–maximization (EM) algorithm methods on guessing parameter missing at random mechanism (n=500).

Figure.4 presents the effects of multiple imputation and imputation with expectation–maximization algorithm methods on guessing parameter in missing at random mechanism when the sample size is 500. The results indicate that the performance of multiple imputation and imputation with expectation–maximization (EM) algorithm methods on guessing parameter differed in all missing value rates for MR mechanism and that estimations were not close to reference point. Thus, it is shown that model based methods used to deal with missing values performed weak on guessing parameter in MR mechanism and lead to lower or higher estimations than expected.

When the sample size in MR mechanism is 1000, the effects of multiple imputation and imputation with expectation–maximization algorithm methods on guessing parameter are displayed in Figure 5. Both methods perform relatively well when the rate of missing value is 2.00 %. When the rate of missing values increase, the performance of both methods is observed to fall generating higher estimations for guessing parameter or in other words, a guessing parameter with a higher value than reference point is obtained.




Figure 5. The effects of multiple imputation and imputation with expectation-maximization (EM) algorithm methods on guessing parameter missing at random mechanism ($n=1000$).

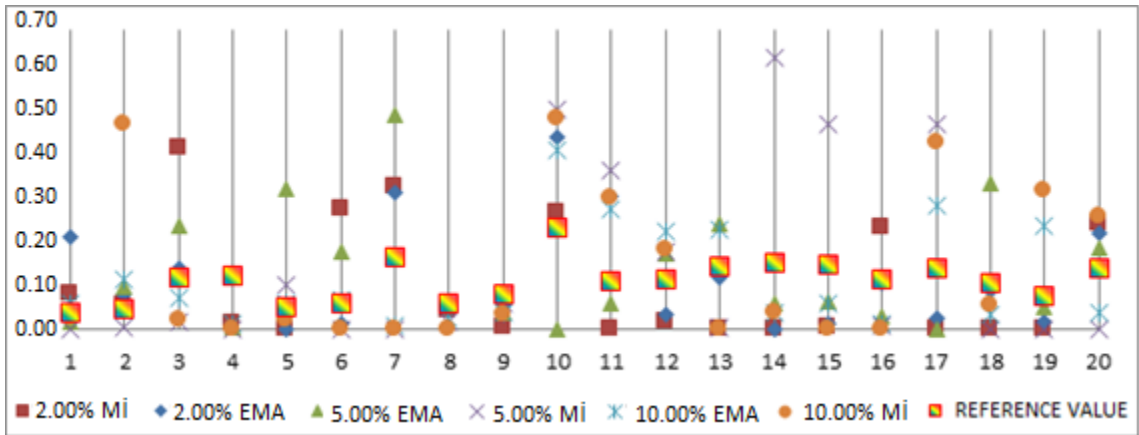


Figure 6. The effects of multiple imputation and imputation with expectation-maximization (EM) algorithm methods on guessing parameter missing at random mechanism ($n=3000$).

Figure.6 shows the effects of multiple imputation and imputation with expectation-maximization algorithm methods on guessing parameter in missing at random mechanism when the sample size is 3000. Both methods provide estimations close to reference point when the missing value rate is 2.00 %. However, when the sample size is 500 or 1000 or when the rate of missing value increases, the performance of these methods drop down. In addition, it is not possible to say that the performance was the same for all items when the missing value rate is low (2.00 %).

Discussion, Conclusion & Implementation

The results of the present study, which investigated the effects of model based missing data methods on guessing parameter in case of ignorable missing data, show that expectation-maximization (EM) algorithm and multiple imputation methods performed well depending on the rate of missing value in MCR mechanism. When the rate of missing values is 2.00 %, both methods showed good performance in all sample sizes, but got further from the reference point as the rate of missing value increased. Yet, when the sample size is 3000, they provided closer estimations even when the rate of missing values was high compared to smaller sample sizes. This may indicate the importance of the size

of the sample in making model estimations in item response theory. Rubin, (1987), Schaffer (1997) and Allison (2007) state that these methods provide better estimations in large samples compared to smaller ones. Agresti and Finlay (1997) claim that multiple imputation and expectation–maximization (EM) algorithm methods provide objective estimations in large samples (Baykul & Güzeller, 2013). The results of the present study are thought to be in line with these findings.

It is also concluded that both methods performed well on guessing parameter when the rate of missing values was low, but their performance weakened significantly as the rate of missing values inclined. Neither multiple imputation nor expectation–maximization (EM) algorithm methods perform well on guessing parameter in MR mechanism. Although there are studies indicating that these models perform well in MR mechanism in literature (Allison, 2003; Baraldi & Enders, 2010; Donders, Van der Heijden, Stijnen & Moons, 2006), the findings of the present study indicate to the contrary. Enders (2013) claims that the performance of all mechanisms to deal with missing values will decrease as the rate of missing values increases. The findings are in line with this claim for MCR and MR mechanisms. When the performances for MCR and MR are compared, it is found that both methods perform better in MCR mechanism. Previous studies also indicated that both methods performed well in MCR mechanism (Arnold & Kronmal, 2002, Baraldi & Enders, 2010; Barzi & Woodward, 2004; Buhi et al., 2008; Graham et al., 1994; Leite & Bretvas, 2010; Newman, 2003; Wayman, 2003). As a result, it can be suggested to use model based missing value methods in MCR mechanism. It is also suggested that more detailed information on performance can be achieved if the effect of model based missing value methods on guessing parameter is investigated considering and manipulating the sample size, the rate of missing value, item differentiation index and difficulty index.

Türkçe Sürüm

Giriş

Eğitim ve psikoloji alanında yapılan ölçmelerin ve test kuramlarının temelinde gözlenen verilerden hareketle gözlenemeyen (gizil) değişkenlere yönelik çıkarım yapmak yatmaktadır. Klasik Test Kuramı (KTK) yaygın bir kullanım alanına sahip olmasına rağmen bu kuramın önemli dezavantajları bulunmaktadır. Madde ve test parametrelerinin gruba bağlı olarak kestirilmesi ve bu yüzden gruptan gruba kestirimlerin farklılaşıyor olması eleştirilen yönlerinden biridir. Madde parametrelerinin gruptan gruba farklılaşıyor olmasına karşın yine bir madde parametresi olan şans başarısı (parametresi) gruptan ve madde örneklemeden bağımsızdır ve sabittir. Çünkü yöneltilen çoktan seçmeli maddenin seçenek sayısına bağlı olarak belirlenir ve yanıtlayıcı yoklanmak istenen davranışa sahip olmadığı halde doğru cevabı tamamen şansla bulmuşsa, bu “şans başarısı” olarak adlandırılır. Tüm çoktan seçmeli maddelerde bu durum söz konusudur (Turgut & Baykul, 2010).

Son yıllarda giderek yaygınlaşan bir diğer kuram olan Madde Tepki Kuramı'nda (MTK) bireyin ölçülen özelliğe sahip olma düzeyi ile yanıtları arasındaki ilişki matematiksel bir fonksiyon ile açıklanmaktadır. Bireylerin yeteneklerini teste bağlı kalmadan maddelerden yola çıkarak kestirebilen MTK'da şans parametresi de gruptan bağımsız olarak madde özelinde hesaplanmaktadır. Şans parametresi (c), bir maddenin tahminle yanıtlanma olasılığını vermektedir ve madde karakteristik eğrisinin Y eksenindeki başlangıç noktasını göstermektedir. Olasılık ifade ettiği için .00 ile 1.00 arasında değer almaktadır (Lord & Novick, 1968). Şans parametresi sıfıra yaklaştıkça maddenin dolayısıyla testin sunduğu bilgi ve kesinlik artar (Hambleton, Swaminathan & Rogers 1991). Baker (2001), şans parametresinin .35'ten, Harris (1989) ise .30'da büyük olmaması gerektiğini vurgulamaktadır. Warm (1978) ve Akindele (2003), şans parametresinin .30'dan büyük maddelerin iyi maddeler olmadığını, .20 ve altında değere sahip olan maddelerin ise iyi maddeler olduğunu belirtmiştir. Şans parametresinin .00'dan büyük olması düşük yetenek düzeylerinde test bilgi miktarını düşürmektedir. Bununla birlikte, c'nin büyük değerler alması test bilgisini genellikle düşürmektedir (Baker, 2001). Testin verdiği bilgi testin ölçmeyi amaçladığı özelliğe ilişkin ne kadar bilgi sağladığını gösterir (Hambleton et al. 1991; Reid, C.A., Kolakowsky-Hayner, Lewis & Armstrong, 2007). Buna ek olarak, testin verdiği bilgi MTK'da ölçmenin standart hatasını ve güvenilirliği hesaplamada kullanılır (DeMars, 2010; Hambleton & Jones, 1993). Bu nedenle şans parametresi MTK'da da güvenilirliği ve geçerliliği etkileyen önemli bir parametredir. Üç parametrelili bir modelde, bir bireyin, herhangi bir maddeye doğru cevap verme olasılığı, madde güçlük, ayırıcılık ve şans parametresi hesaba katılarak hesaplanmaktadır (Crocker & Algina, 1986; Embretson & Reise, 2000; Hambleton et al. 1991). Bu nedenle c parametresi yeteneğin kestirilmesinde de belirleyici role sahiptir. Ancak testlerle ölçülmeye çalışılan gizil özelliklere ulaşmak, test ve madde parametrelerini kestirebilmek için öncelikle bireylerin kendilerine testle yöneltilen maddelere yanıt vermesi gerekmektedir. Bu bağlamda yanıtlayıcıların kendilerine yöneltilen maddeleri herhangi bir nedenle yanıtlamaktan kaçınması, boş bırakması ya da bu maddelerin atlanması, bir diğer deyişle kayıp veri ortaya çıkması, aslında bu tür bir çıkarımı yapılabilmeyen önündeki en önemli engellerdendir.

Hohensinn ve Kubinger (2011), kayıp değerlerin genellikle karşılaşılan bir problem olduğunu ve araştırma süreci uzmanlar tarafından ne kadar dikkatli planlanırsa planlansın tam olarak önüne geçilmesinin mümkün olmadığını belirtmiştir. Çünkü toplanan veriler üzerinde yapılmak istenen standart istatistiksel işlemler satırları gözlemlerden (bireylerden) sütunları değişkenlerden oluşan matrisler üzerinden yapılmaktadır ve bu matrisin tüm gözlemlerinin dolu olması gerekmektedir. Bir bireyin herhangi bir maddeye yanıt vermemesi durumunda bir diğer ifadeyle kayıp veri olması durumunda matriste oluşan boşluk nedeniyle istenen istatistiksel işlemler yapılamayacaktır. Rubin (1976), oluşan kayıp verilerin ihmal edilebilir düzeyde olmamasının kestirimlerde yanlılığa yol açacağını ifade etmektedir. Kayıp verilerin ihmal edilebilir olması, kayıp verilerin rastgele olarak oluştuğu yani herhangi bir örüntü/yanlılık içermediği, dolayısıyla veri dağılımında bir sapma ya da farklılık oluşmayacağı, verinin çok değişkenli

olması durumunda çok değişkenli normal dağılım varsayımı sağlandığı takdirde, her bir değişkene ilişkin kayıp veri oluşma durumunun eşit olacağı anlamına gelmektedir. Rubin (1976), kayıp verilerin rastgele olduğu kanıtlandığı durumda eksiksiz veri seti ve kayıp veri içeren veri setlerinden yapılacak kestirimler arasında manidar bir fark olmayacağını belirtmektedir. Bu nedenle kayıp verilerin tamamen rastgele ya da rastgele olup olmadığının incelenmesi gerekmektedir. Aksi durumda ihmal edilemez bir kayıp ile karşılaşılığında bunun yanlılığa yol açacağı unutulmamalıdır.

Veri setinde tamamen rastgele kayıp (TRK) mekanizmasında kayıp veri olması, kayıpların ne diğer değişkenlerle, ne de bulunduğu değişken ile ilişkili olmadığını ifade etmektedir. Donders, Heijden, Stijnen ve Moons (2006), verinin TRK olduğu bilindiğinde, kayıp veri içermeyen değişkenler kümesinin, hedef kitlenin rastgele örnekleme olduğunu belirtmiştir. Bu nedenle, kayıp veri incelemeleri için TRK varsayımında birçok yöntem yansız sonuçlar vermektedir (Satıcı, 2009). Herhangi bir değişkende kayıp veri olması olasılığı, modeldeki diğer değişkenlerle ilişkili ve bulunduğu deęışkendeki gözlenen deęerlerle ilişkisiz ise kayıp veri rastgele kayıptır (RK). Enders (2010), RK durumunun aslında kayıp veri olasılığı ile bir veya daha fazla deęişkenin arasındaki sistematik ilişkiyi açıkladığını belirtmiştir. Kayıp veri mekanizması RK olduğu durumda model tabanlı ve çoklu veri atama gibi yöntemlerin objektif sonuçlar vereceği belirtilmektedir (Donders et al. 2006; Satıcı, 2009). Herhangi bir deęışkendeki kayıp verinin olasılığı modeldeki diğer deęişkenlerle ve kendi deęişkeniyle ilişkili ise kayıp veri rastgele olmayan kayıptır (ROK). ROK mekanizmaları altında kayıp veri analizi mevcut yöntemleri kullanmaya uygun deęildir ve oluşan yanlılık giderilememektedir (Enders, 2010).

Kayıp verinin ihmal edilebilir yani rastgele olup olmamasının yanında oranı yani miktarı da önem taşımaktadır. Çünkü herhangi bir nedenle oluşan kayıp veriler, veri setinin daralmasına ve buna baęlı olarak da yapılacak kestirimlerin zayıflamasına yol açar. Kayıp verilerin mevcut olduğu veri setleri üzerinde istatistiksel analizler yapılamadığı gibi, yanıtlayan ve yanıtlamayan bireyler arasında, çoğunlukla sistematik olan farklılıklardan dolayı, bir yanlılık oluşmasına da neden olabilir (Rubin, 1987). Bu nedenle arařtırmalarda kayıp veri miktarının da göz önünde bulundurularak sonuçlarda doęacak yanlılıklara çözüm aranması doęru olacaktır.

Kayıp veriyle baş etme yöntemlerinin gelişimi incelendiğinde 20. Yüzyılda bu alanda önemli yol kat edildiği görülmektedir. Graham (2009), bunun nedeni olarak çoęu 20. Yüzyılın başlarında geliştirilmiş istatistiksel analizlerin eksiksiz veri setleri üzerinden yapılabiliyor olmasını göstermektedir. İstatistiksel analizlerin neredeyse tamamı, kayıp veri içeren veri setlerinde kayıp veri sorununa dair herhangi bir mekanizma içermemektedir. Bu durum kayıp veri sorunu ile baş etme yöntemlerine ihtiyaç duyulmasına neden olmuştur. Bu ihtiyaç doęrultusunda kayıp veri sorunuyla baş etmede istatistiksel yöntemler geliştirilmiştir (Graham, 2009).

Ölçme araçlarının puanlanmasında iki tür yaklaşım vardır. Bunlar çoklu puanlama ve iki kategorili puanlamadır. İki kategorili puanlanan maddelerde doęru-yanlış, var-yok, evet-hayır gibi işaretlemelerle ölçülmeye çalışılan özelliğin varlığı ya da yokluğu belirlenmeye çalışılmaktadır (Erkuş, 2012). İkilili puanlanan maddelerden oluşan testlerde karşılaşılan kayıp verilerde en yaygın yaklaşımlar, bu kayıp verilerin “yanlış” ya da “uygulanmamış” olarak kabul edilmesidir. Söz konusu her iki yaklaşımın da yanlı ve hatalı kestirimlere yol açtığı bilinmektedir. Bu nedenle bu tür kayıp verilere yönelik olarak geliştirilmiş daha karmaşık kayıp veri baş etme yöntemlerinin kullanımı gerekli görülmektedir (Hohensinn & Kubinger, 2011). Bu doęrultuda model tabanlı yöntemlerin kullanılmasının hem rastgele kayıp hem de tamamen rastgele kayıp mekanizmasında yansız kestirimleri sağlayacağı belirtilmektedir (Graham, 2009).

Model tabanlı kayıp veri baş etme yöntemleri gözlenmiş deęerler üzerinden kurulan bir modelde olabilirlik ve sonsal dağılımlara baęlı olarak parametrelerin kestirilmesine dayanan kayıp veri yöntemleridir. Bu yöntemlerin en büyük avantajları esneklikleridir. Geçici yöntemlerden kaçınarak model varsayımları altında çözümleme yaparlar. Kayıp verileri de hesaba katarak varyans kestirimleri sunarlar. Model üzerinden hesaplamalar yapılması planlandığında birçok modelden söz edilebilir. Özellikle Lord'un (1955) çalışmasıyla başlayan, Dempster Laird ve Rubin (1977) ile teorisi ortaya konulan beklenti maksimizasyon algoritması (BMA), Rubin (1987) çalışmasında önerilen çoklu atama (ÇA) gibi yöntemler model tabanlı yöntemlerdir.

Veri setinde kayıp veri olması araştırmalarda önüne geçilemez bir sorundur ve bu nedenle bir kayıp veri baş etme yöntemi ile bu sorunun çözülmesi gerekmektedir. Aksi durumda kestirimlerde yanlılığa yol açılabileceği gibi testlerden elde edilen sonuçların hatalı olmasına; buna bağlı olarak da hatalı kararlar verilmesine yol açabilir. İki kategorili puanlanan bilişsel alana yönelik testlerde hâlihazırda kritik bir sorun olan ve yanlı kestirime, hatalı kararlara yol açabilen şans parametresinin kayıp veri durumunda bu yönünü pekiştirebileceği düşünülmektedir. Bu nedenle ihmal edilebilir kayıp veri durumunda tek boyutlu madde tepki kuramı 3 parametrelili lojistik modelinde (3PLM) şans parametresinin model tabanlı kayıp veri baş etme yöntemlerinden nasıl etkilendiğinin belirlenmesi bir ihtiyaç olarak görülmektedir. Bu nedenle, araştırmada veri setinde ihmal edilebilir kayıp veri olması durumunda kayıp veri baş etme yöntemlerinden çoklu atama ve beklenti maksimizasyon algoritması ile atama yöntemlerinin tek boyutlu madde tepki kuramı 3 parametrelili lojistik modelinde şans parametresine etkisinin belirlenmesi amaçlanmıştır.

Yöntem

Araştırmanın Deseni

Araştırmada, model tabanlı kayıp veri baş etme yöntemlerinden beklenti maksimizasyon algoritması ve çoklu veri atama yöntemlerinin tek boyutlu Madde Tepki Kuramı üç parametrelili lojistik modelinde şans (c) parametresine etkisini yapay veri setleri kullanarak ortaya koymayı amaçlaması nedeniyle temel araştırma niteliğindedir (Karasar, 2007). Araştırma bu haliyle mevcut bilgilere katkı sağlayıcı nitelikte olup, temel araştırma ile uyumludur.

Verilerin Üretilmesi ve Veri Analizi


Araştırmada verilerin üretilmesinde, üretilen eksiksiz veri setlerinde kayıp veri mekanizmalarına uygun ve istenen oranlarda kayıp veri oluşturulmasında R programı kullanılmıştır (R Development Core Team, 2011). Madde tepki kuramı üç parametrelili lojistik modelinde şans parametresinin hesaplanmasında R programı içerisinde yer alan {lrm} paketinden yararlanılmıştır.

Veriler, MTK tek boyutlu lojistik modellerinden 3PLM temel alınarak üretilmiştir. Üretilen veri setlerinde madde sayısı 20 olarak sabitlenmiş, örneklem büyüklüğü 500, 1000 ve 3000, yanıt kategorisi iki (1-0 puanlama) olarak belirlenmiştir. Veri setlerinde madde gücülüğü -2.00, +2.00 aralığında, madde ayıricılığı .50 ile 2.00 aralığında, şans parametresi ise .00 ile .25 arasında sınırlandırılmıştır.

Üretilen veri setlerinde oluşturulacak kayıp veri oranı % 2.00, % 5.00 ve % 10.00 olarak belirlenmiştir. Belirlenen oranlarda TRK mekanizması oluşturulurken R programında yazılan kod ile gözenek sayısının % 2.00, % 5.00 ve % 10.00 oranlarında silinmesi ile kayıp verili setler elde edilmiştir. RK mekanizması için öncelikle veri setine üç kategorisi (1, 2 ve 3) olan sıralama ölçeği düzeyinde bir başka değişken rastgele olarak eşit oranlarda tanımlanmıştır. Oluşturulan düzeylerden farklı oranlarda kayıp veriler rastgele oluşturulmuştur. 1. düzeyden % 10.00, 2. düzeyden % 30.00 ve 3. düzeyden % 60.00 olacak şekilde gözenekler silinerek ayrı ayrı toplamda % 2.00, % 5.00 ve % 10.00 kayıp oluşturulmuştur. Elde edilen eksikli veri setleri Çoklu Atama (ÇA) ve Beklenti Maksimizasyon Algoritması ile Atama (BMA) yöntemleri ile tekrar tamamlanmıştır. Çoklu değer atama tekniğinin kullanılması durumunda 3 – 10 arasında değer atama işleminin yapılmasının yeterli olacağı belirtilmektedir (McKnight et al., 2007). Çoklu atamada atama sayısı 5 olarak belirlenmiştir. Tamamlanan veri setleri yeniden 3PLM'ye göre analiz edilerek şans parametresi belirlenmiş ve eksiksiz veri setindeki değerler referans alınarak yorumlanmıştır.


Bulgular

Model tabanlı kayıp veri baş etme yöntemlerinden çoklu atama ve beklenti maksimizasyon algoritması ile atama yöntemlerinin şans parametresi üzerindeki etkileri öncelikle tamamen rastgele kayıp ardından rastgele kayıp mekanizmaları için aşağıda sunulmuştur.



Şekil 1. Tamamen rastgele kayıp mekanizmasında çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin şans parametresine etkisi (n=500).


Şekil.1’de örneklem büyüklüğü 500 olduğunda TRK mekanizmasında ÇA ve BMA yöntemlerinin şans parametresi üzerine etkisi verilmiştir. Her iki yöntemin de kayıp veri oranı % 2.00 olduğunda eksiksiz veri setine yakın kestirimler sunduğu görülmektedir. Kayıp veri oranı arttığında tamamlanan veri setlerinden elde edilen şans parametresi kestirimleri referans değerden uzaklaşmaktadır. Her iki yöntem de benzer performans göstermekle birlikte kayıp veri oranı % 10.00 olduğunda her ikisi de referans değerden en uzak kestirimleri sunmuştur. Bir diğer ifadeyle ÇA ve BMA yöntemlerinin performansı kayıp veri oranı arttıkça düşmektedir.



Şekil 2. Tamamen rastgele kayıp mekanizmasında çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin şans parametresine etkisi (n=1000).


Şekil.2’de örneklem büyüklüğü 1000 olduğunda TRK mekanizmasında ÇA ve BMA yöntemlerinin şans parametresi üzerine etkisi verilmiştir. Kayıp veri oranı % 2.00 olduğunda her iki yöntemin de referans değere en yakın kestirimleri sunduğu görülmektedir. Kayıp veri oranı % 5.00 olduğunda performanstan düşüş yaşandığı buna bağlı olarak da kayıp veri oranı arttığında her iki yöntem için de şans parametresi

üzerindeki performansın düştüğü görülmektedir. Kayıp veri oranı arttıkça bu iki yöntemin performansı birbiriyle kıyaslandığında ise BMA yönteminin ÇA yöntemine göre referans değere daha yakın kestirimler sunacak şekilde performans sergilediği görülmektedir.




Şekil 3. Tamamen rastgele kayıp mekanizmasında çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin şans parametresine etkisi (n=3000).

Örneklem büyüklüğü 3000, kayıp veri mekanizması tamamen rastgele kayıp olduğunda çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin kayıp veri oranı %2.00 olduğunda referans değere yakın kestirimler sunacak performans sergilediği görülmektedir. Kayıp veri oranı arttıkça performans düşmektedir. Bir diğer ifadeyle kayıp veri oranı arttıkça ÇA ve BMA yöntemleri ile tamamlanan veri setlerinden kestirilen şans parametresi referans değerden uzaklaşmaktadır. Ancak örneklem büyüklüğü 500 ve 1000 olan koşullara göre kayıp veri oranı arttıkça daha iyi bir performans gözlenmektedir. Buna bağlı olarak BMA ve ÇA yöntemlerinin kayıp veri oranı yüksek olduğunda örneklem yeterince büyük şans parametresi üzerinde kısmen iyi performans gösterebileceği ifade edilebilir.




Şekil 4: Rastgele kayıp mekanizmasında çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin şans parametresine etkisi (n=500).

Şekil.4'te örneklem büyüklüğü 500 olduğunda RK mekanizmasında ÇA ve BMA yöntemlerinin şans parametresi üzerine etkisi verilmiştir. Rastgele kayıp mekanizmasında tüm kayıp veri oranlarında ÇA ve BMA yöntemlerinin şans parametresi üzerindeki performanslarının farklılaştığı ve genel olarak referans değere yakın kestirimlerin sunulmadığı görülmektedir. Buna bağlı olarak model tabanlı kayıp veri baş etme yöntemlerinin rastgele kayıp mekanizmasında şans parametresi üzerindeki performansının düşük olduğu, olması gerekenden daha düşük ya da yüksek kestirimlere yol açtığı görülmektedir.



Şekil 5. Rastgele kayıp mekanizmasında çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin şans parametresine etkisi (n=1000).

Rastgele kayıp mekanizmasında örneklem büyüklüğü 1000 olduğunda ÇA ve BMA yöntemlerinin şans parametresi üzerindeki etkileri Şekil.5'te verilmiştir. Her iki yöntemin de kayıp veri oranı %2.00 olduğunda kısmen iyi bir performans sergilediği görülmektedir. Kayıp veri oranı arttığında ise her iki yöntemin de performansında önemli düşüşler yaşanmaktadır ve genel olarak olması gerekenden daha yüksek şans parametresi elde edildiği bir diğer ifadeyle referans değerden daha yüksek şans parametresi elde edildiği görülmektedir.



Şekil 6. Rastgele kayıp mekanizmasında çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin şans parametresine etkisi (n=3000).

Şekil.6'da örneklem büyüklüğü 3000 olduğunda RK mekanizmasında ÇA ve BMA yöntemlerinin şans parametresi üzerindeki etkisi sunulmuştur. Her iki yöntemin de kayıp veri oranı %2.00 olduğunda referans değere daha yakın kestirimler yapacak şekilde performans sergilediği görülmektedir. Ancak örneklem büyüklüğü 500 ve 1000 olduğu koşullarda da olduğu gibi kayıp veri oranı arttıkça rastgele kayıp koşulunda BMA ve ÇA yöntemlerinin performansı düşmektedir. Bununla birlikte kayıp veri oranı düşük (%2.00) olduğunda da tüm maddeler için aynı şekilde performans sergilendiği söylenemez.

Tartışma, Sonuç ve Öneriler

Model tabanlı kayıp veri baş etme yöntemlerinin ihmal edilebilir kayıp veri durumunda şans parametresi üzerindeki etkisinin araştırıldığı bu çalışmada, veri setinde tamamen rastgele kayıp mekanizmasında kayıp veri olması durumunda çoklu atama ve beklenti maksimizasyon algoritması yöntemlerinin kayıp veri oranına da bağlı olarak performansının iyi olduğu sonucuna ulaşılmıştır. Tüm örneklem büyüklüklerinde kayıp veri oranı %2.00 olduğunda her iki yöntemde en iyi performansı sergilediği, kayıp veri oranı arttıkça referans değerden uzaklaşıldığı görülmektedir. Buna karşın örneklem büyüklüğü 3000 olduğunda kayıp veri oranı yüksek de olsa diğer örneklem büyüklüklerine göre daha yakın kesitimler sundukları sonucuna ulaşılmıştır. Bu durumu madde tepki kuramında model kestirimlerinin yapılmasında örneklem büyüklüğünün etkili olması ile ilişkilendirmek mümkündür. Rubin, (1987), Schaffer (1997) ve Allison (2007) ÇA ve BMA yöntemlerinin büyük örneklerde küçük örneklemelere göre daha iyi kestirimler sunduğunu belirtmiştir. Agresti ve Finlay (1997) da büyük örneklerde BMA ve ÇA yöntemlerinin yansız sonuçlar ürettiğini ifade etmektedirler (Baykul & Güzeller, 2013). Elde edilen sonuç literatür ile uyum göstermektedir.

Rastgele kayıp veri mekanizmasında ise kayıp veri oranı düşük olduğunda her iki yöntemin de şans parametresi üzerinde iyi performans gösterdiği ancak kayıp veri oranı arttıkça bu performansta önemli düşüşlerin olduğu sonucuna ulaşılmıştır. Çoklu atama ve beklenti maksimizasyon algoritması ile atama yöntemlerinin her ikisi de rastgele kayıp veri mekanizmasında şans parametresi üzerinde iyi performans göstermemektedir. Literatürde ÇA ve BMA yöntemlerinin rastgele kayıp mekanizmasında iyi performans gösterdiğine ilişkin bulgular yer almaktadır (Allison, 2003; Baraldi & Enders, 2010; Donders, Van der Heijden, Stijnen & Moons, 2006). Ancak elde edilen bulgular RK mekanizmasında kayıp veri oranı yükseldiği durumda literatür ile uyuşmamaktadır. Enders (2013), kayıp veri oranı arttıkça tüm kayıp veri mekanizmalarında kayıp veri baş etme mekanizmalarının performansının düşeceğini belirtmektedir. Elde edilen bulgular hem TRK mekanizması hem de RK mekanizması için bunu destekler niteliktedir. Tamamen rastgele kayıp mekanizması ve rastgele kayıp mekanizmasındaki performansları karşılaştırılarak incelendiğinde her iki yöntemin de TRK mekanizmasında daha iyi performans sergiledikleri sonucuna ulaşılmıştır. Literatürde ÇA ve BMA yöntemlerinin performansının incelendiği çalışmalarda her iki yöntemin de TRK koşulunda iyi sonuçlar ürettiği belirtilmiştir (Arnold & Kronmal, 2002, Baraldi & Enders, 2010; Barzi & Woodward, 2004; Buhi et al, 2008; Graham et al, 1994; Leite & Bretvas, 2010; Newman, 2003; Wayman, 2003). Bu sonuçlara bağlı olarak araştırmacılara TRK mekanizması durumunda model tabanlı kayıp veri baş etme yöntemlerini kullanmaları önerilebilir. Model tabanlı kayıp veri baş etme yöntemlerinin şans parametresi üzerindeki etkileri örneklem büyüklüğü ve kayıp veri oranı ile birlikte madde ayırıcılık indeksi ve güçlük indeksi de manipüle edilerek incelenmesi performansla ilişkin daha detaylı bilgi sunacağı düşünülmektedir.

References

- Affi, A. A. & Elashoff, R. M. (1966). Missing observations in multivariate statistics I. Review of the literature, *Journal of the American Statistical Association*, 61, 595-605.
- Agresti, A. & Finlay, B. (1997). *Statistical methods for the social sciences*. USA: Pearson Prentice Hall.
- Akindele, B.P. (2003). *The development of an item bank for selection tests into Nigerian Universities: An exploratory study*. Unpublished doctoral thesis, University of Ibadan, Ibadan, Nigeria.
- Allison, P. D. (2003). Missing data techniques for structural equation modeling. *Journal of Abnormal Psychology*. 112(4), 545-557.
- Allison, P.D. (2009). *Missing data* (Sage University Paper Series on Quantitative Applications in the Social Sciences, 72-89). London: Sage Publication.
- Arnold, A.M. & Kronmal, R.A. (2002). Multiple imputation of baseline data in the cardiovascular health study. *American Journal of Epidemiology*, 157(1), DOI: 10.1093/aje/kwf156.
- Baker, F. B. (2001). *The basics of item response theory*. College Park, MD: ERIC Clearinghouse on Assessment and Evaluation.
- Baraldi, A.N. & Enders, C.K. (2010). An introduction to modern missing data analysis. *Journal of School Psychology*, 48, 5–37.
- Barzi, F. & Woodward, M. (2004). Imputations of missing values in practice: results from imputations of serum cholesterol in 28 cohort studies. *American Journal of Epidemiology*, 160(1), 34-45, DOI: 10.1093/aje/kwh175.
- Baykul, Y. & Güzeller, C.O. (2013). *Sosyal bilimler için istatistik: SPSS uygulamalı*. Ankara: Pegem Akademi.
- Buhi, E.R., Goodson, P. & Neilands, T.B. (2008). Out of sight , not out of mind: strategies for handling missing data. *American Journal of Health Behavior*, 32 (1), 83-92.
- Crocker, L. & Algina, J. (1986). *Introduction to classical & modern test theory*. Newyork: Holt. Rinehart and Winston.
- DeMars, C. (2010). *Item response theory: Understanding statistics measurement*. London : Oxford Press.
- Dempster, A.P., Laird, N.M. & Rubin, D.B.(1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, 39(1), 1-38.
- Donders, A.R.T., van der Heijden, G.J.M.G., Stijnen, T. & Moons, K.G.M. (2006). Review: A gentle introduction to imputation of missing values. *Journal of Clinical Epidemiology*, 59, 1087-1091, DOI: 10.1016/j.jclinepi.2006.01.014.
- Embretson, S. E., & Reise, S. P. (2000). *Item response theory for psychologists*. Mahwah, NJ: Lawrence Erlbaum Associates Publishers Enders (2010),
- Enders, C.K. (2013). Dealing with missing data in developmental research. *Child Development Perspectives*, 7 (1), 27- 31.
- Enders, C. K. (2010). *Applied missing data analysis*. New York: The Guilford Publications, Inc
- Erkuş, A. (2003). *Psikometri üzerine yazılar*. Ankara. Türk Psikologlar Derneği Yayınları.
- Graham, J. W., (2009). *Missing data: analysis and design*. New York: Springer
- Graham, J. W., Hofer, S. M., & MacKinnon, D. P. (1996). Maximizing the usefulness of data obtained with planned missing value patterns: an application of maximum likelihood procedures. *Multivariate Behavioral Research*. 31(2), 197-218.
- Hambleton R.K., Swaminathan H. & H. J. Rogers (1991). *Fundamentals of item response theory*. Newbury Park, CA: SAGE Publications, Inc.

- Hambleton, R. K., Jones R.W. & Rogers, H. J. (1993). Influence of item parameter estimation errors in test development. *Journal of Educational Measurement*, 30, 143-155.
- Harris, D. (1989). Comparison of 1-, 2-, and 3-parameter IRT models. *Educational Measurement: Issues and Practice*, 8(1), 35-41
- Hartley, H.O.(1956). Programming analysis of variance for general purpose computers. *Biometrics*, 12, 110-122.
- Hohensinn, C. & Kubinger, K.D. (2011). On the impact of missing values on the item fit and the model validness of the rasch model. *Psychological Test and Assessment Modeling*, 53 (3), 380-393.
- Karasar, N. (2007). *Bilimsel araştırma yöntemi: kavramlar, ilkeler, teknikler*. Ankara: Nobel Yayın Dağıtım
- Leite, W. & Beretvas, S.N. (2010). The performance of multiple imputation for likerttype items with missing data. *Journal of Modern Applied Statistical Methods*, 9(1), 64-74.
- Little, R. J. A. & Rubin, D. B. (1987). *Statistical analysis with missing data*. New York: Wiley.
- Lord, F. M., (1955). Estimation of parameters from incomplete data, *Journal of the American Statistical Association*, 50, 870-76.
- Lord, F. M.,& Novick, M. R.(1968). *Statistical theories of mental test scores*. Reading MA: Addison-Wesley.
- McKnight, P. E., McKnight, K. M., Sidani, S. & Figueredo, A. J. (2007). *Missing data: a gentle introduction*. New York: The Guilford Publications, Inc.
- Newman, D.A. (2003). Longitudinal modeling with randomly and systematically missing data: a simulation of ad hoc, maximum likelihood and multiple imputation techniques. *Organizational Research Methods*, 6(3), 328-362, DOI: 10.1177/1094428103254673
- R Development Core Team (2011), *R: A Language and Environment for Statistical Computing, A Foundation for Statistical Computing*, Vienna, Austria, ISBN 3-900051-070, Retrived:[<http://www.R-project.org>].
- Reid, C.A., Kolakowsky-Hayner, S.A., Lewis, A.N. & Armstrong, A.J. (2007). Modern psychometric methodology: applications of item response theory. *Rehabilitation Counselling Bulletin*, 50 (3), 177-178.
- Rubin, D. B. (1987). *Multiple imputation for nonresponse in surveys*. New York: John Wiley & Sons, Inc.
- Rubin, D. B., (1976). Inference and missing data. *Biometrika*. 63, 581-592.
- Satıcı, E. (2009). *Kayıp gözlem olması durumunda kitle ortalaması tahmini*. Unpublished doctorate dissertation, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Schafer, J. L. (1997). *Analysis of incomplete multivariate data*. New York: Chapman & Hall/Crc.
- Turgut, F. & Baykul, Y. (2010). *Eğitimde ölçme ve değerlendirme*. Ankara: PegemA Yayıncılık
- Warm, T.A. (1978). *A primer of Item response theory*. Technical report with no 941078. Oklahoma City: USA Coast Guard Institute.
- Wayman, J.C. (2003). *Multiple imputation for missing data: What is it and how can I use it?* Annual Meeting of the American Educational Research Association. Chicago, IL.

