

Kısmi En Küçük Kareler Yapısal Eşitlik Modellemesi (Kekk-Yem)

Seda Başar Yılmaz¹

Özet

Kısmi en küçük kareler (PLS) yöntemi, En Küçük Kareler (OLS) Yöntemini temele alarak geliştirilmiş, bağımsız ve bağımlı doğrusal olmayan yapılarla ve karmaşık veri yapıları ile başa çıkabilen bir makine öğrenimi tekniğidir. Bünyesinde barındırdığı özellikler sayesinde literatürde sıklıkla kullanılan En Küçük Kareler, Temel Bileşenler Analizi, Çoklu Olabilirlik gibi metotlara alternatif bir yöntem olarak kullanılmaktadır. Bu avantajlar modelin yarı parametrik bir yöntem olmasından kaynaklı normal dağılım gibi bazı varsayımlardan muaf olması, bünyesinde çoklu doğrusallık gibi model sorunlarının barındırmaması olarak sayılabilir. İlk olarak kimya ve biyoloji alanlarında kullanılmış olsa da kullanım kolaylığı ve model yapısı ekonomi, psikoloji gibi birçok sosyal bilimlerde tercih edilmesine sebep olmaktadır. Son yıllarda ise yöntemin algoritmasının ölçülebilir ve ölçülemeyen (gizil) değişkenler arasındaki ilişkileri irdelemeye yarayan yapısı sayesinde yapısal eşitlik modellemelerinde (SEM) sıklıkla kullanılmaya başlanmıştır. PLS-SEM olarak bilinen yöntem; küçük örneklerde ve önsel bilginin zayıf olduğu durumlarda kullanılabilmesi, normallik varsayımını zorunlu kılmaması ve karışık ilişkinin var olduğu durumlarda tahmini kolaylaştırması gibi avantajlara sahiptir. Yöntemin avantajlarının yanı sıra SmartPLS, WarpPLS, ADANCO gibi kullanıcı dostu programların da varlığı sosyal bilimlerde çalışmalarında yaygınlaşmasını sağlamıştır. Bölümde öncelikle PLS' nin özellikleri ve matematiksel alt yapısı hakkında bilgi verilecektir. Sonrasında Yapısal Eşitlik Modellemesinde PLS' nin tahmin aşamaları anlatılacaktır. Son olarak PLS-SEM kullanımını göstermek amaçlı örnek veri setleri üzerinden uygulamalar gerçekleştirilecektir.

1 Dr. Öğr., Üyesi Van Yüzüncü Yıl Üniversitesi, sedabasar@yyu.edu.tr,
ORCID ID: 0000-0003-3949-3490

KISMI EN KÜÇÜK KARELER (KEKK-PLS)

Herman Wold (1966) tarafından geliştirilmiş PLS yöntemi, boyut indirgemenin temel alındığı, Kısmi En Küçük Kareler Analizi ve Çoklu Doğrusal Regresyon yöntemlerinden oluşmaktadır. Özellikle bağımsız değişkenin fazla olduğu durumlarda ortaya çıkabilecek çoklu doğrusallık sorunu tahmincilerin varyanslarının büyük olmasına neden olur ve böylece Klasik En Küçük Kareler metodunu kullanılamaz hale getirmektedir. Bu durumda kullanılabilecek PLS yöntemi algoritmalar yardımıyla değişkenlerin daha az sayıda ve aralarında çoklu doğrusal bağlantı problemi olmayan bileşenlere indirgeyip hem bağımlı değişkendeki hem de bağımsız değişkenlerdeki değişim açıklamaktadır. (Bulut & Alın, 2009).

Farklı yaklaşımlara sahip olmakla beraber PLS, Temel Bileşen Regresyonu (PCR) gibi bağımsız değişkenler arasındaki ilişkileri ele almak ve bağımlı değişkeni tahmin etmek için kullanılır. Ancak PCR bağımlı değişkenle doğrudan ilişkileri olması gerekmeyen bağımsız değişkenler arasındaki en yüksek varyansı yakalayan bileşenleri seçerken, PLS hem bağımlı değişkenle hem de bağımsız değişkenlerle en yüksek korelasyona sahip bileşenleri bulur. Böylelikle değişkenler arasındaki ilişkiyi en iyi açıklayacak yapıyı bulur. PLS, tıpkı PCR gibi bağımsız değişkenlerin doğrusal kombinasyonlarını bulur, ancak bu doğrusal kombinasyonlar bileşen ya da gizli (latent) değişkenler olarak adlandırılır ve boyut indirgeme ile elde edilir.

PLS avantajları sayesinde biyoloji ve kimya alanında sıklıkla kullanılmasına olanak sağlar. Höskuldsson (1988) çalışmasında yöntemin matematiksel ve istatistiksel yapısını geliştirerek istatistiksel çalışmalarda da kullanılabileceğini göstermiştir. Son yıllarda ise avantajları sayesinde PLS sıklıkla Yapısal Eşitlik Model tahminlerinde kullanılmaktadır.

PLS yöntemi kovaryans yapı analizlerine kıyasla daha az varsayıma ihtiyaç duymasına rağmen tutarlı tahmin sonuçları sunabilir. Bu da PLS'yi teorileri test etmek için önemli bir yöntem haline getirir. PLS yaklaşımının bir diğer özelliği tek bir yapısal denklem modeli içinde bile, biçimlendirici (formatif) ve yansıtıcı (reflektif) göstergelerle başa çıkma yeteneğidir. Bu, PLS yönteminin yapısal denklem modellerinin açıklayıcı analizler içinde uygun olduğunu gösterir (Götz et al., 2009). Ayrıca kovaryans tabanlı yöntemler (Maksimum Olabilirlik veya Genelleştirilmiş En Küçük Kareler) yapı analizleri tahmini yapılırken bazı varsayımların sağlanması durumunda kullanılmaktadır. Örneğin yapısal analizlerinde en sık kullanılan Maksimum Olabilirlik yönteminin sonuçları sadece çok değişkenli normallik varsayımı karşılandığında etkili ve tarafsızdır. Ayrıca örneklem büyüklüğü konusunda da oldukça duyarlıdır (Hair et al., 2006). Tüm bu şartlar sağlandığında

bile formatif ölçüm modellerinde yetersiz şekilde belirleme yapılmasına neden olabilmektedir. İşte bu sorunlara PLS metodu alternatif bir yöntem olmaktadır.

PLS Model Tahmini

PLS algoritmalarında amaç açıklayıcı (X) ve bağımlı (Y) olmak üzere iki değişken matrisi üzerinden X'Y kovaryans matrisini en çoklayan bileşen sayısını bulmaktır.

$$Y = X\beta + \varepsilon \quad (1.1)$$

$$X = TP' + E \quad (1.2)$$

$$Y = UC' + G \quad (1.3)$$

Burada Y, açıklayıcı değişkenlerin $(n \times m)$ matrisidir. X ise (1.1)'de verilen doğrusal ilişki aracılığıyla bir $(n \times k)$ matrisidir. Burada n gözlem sayısını, m Y değişkeninin sayısını, k ise X değişkeninin sayısını ifade etmektedir. PLS, X ve Y matrislerini (1.2) ve (1.3)'teki doğrusal modellere göre ayrıştırır.

ε ise;

$$\varepsilon = (\varepsilon_1 + \varepsilon_2 + \dots + \varepsilon_n) \quad (1.4)$$

$$E(\varepsilon) = 0 \quad (1.5)$$

$$Var(\varepsilon_i) = \sigma^2 \quad (1.6)$$

T $(n \times A)$ X'in puan matrisi, P $(k \times A)$ X'in yükleme matrisi, U $(n \times A)$ Y'nin puan matrisi ve C $(m \times A)$ Y'nin yükleme matrisidir. E $(n \times k)$ ve G $(n \times m)$ sırasıyla X ve Y için artık matrislerdir. A, gizil değişkenlerin sayısını tanımlar. Ortogonal puan matrisi $T_i = (t_{(i)}^1, t_{(i)}^2, \dots, t_{(i)}^A)$

$$t_{(i)}^A = \sum_k w_{(i)j}^a x_{(i)j} \quad (T_i = X_{(i)} W_{(i)}) \quad (1.7)$$

şeklinde elde edilir.

$((k-1) \times A)$ boyutundaki $W_{(i)}$ X'in ağırlık matrisidir. $w_{(i)j}^a$, a'inci bileşende i'inci değişkenin j'inci değişkene katkısını temsil eder. $x_{(i)}$ yanıt değişkeni olduğunda, $i = (1, 2, \dots, m)$ ve $j = (1, 2, \dots, k)$ $x_{(i)j}$, j'inci değişkeni tanımlar ve $t_i^a = (t_{(i)1}^a, t_{(i)2}^a, \dots, t_{(i)n}^a)^T$, T, a'inci bileşen için puan vektörüdür.

Bunları kullanarak, j'inci açıklayıcı değişken ve yanıt değişkeni $x_{(i)}$;

$$x_{(i)j} = \sum_a t_{(i)}^a p_{(i)j}^a + \varepsilon_{(i)j} \quad (1.8)$$

$$x_i = \sum_a c_{(i)}^a t_{(i)}^a + f_{(i)} \quad (1.9)$$

Şeklinde yazılabilir.

$c_{(i)}^a$, a' inci bileşenin üzerindeki x_i tepkisinin yüklemesidir ve $p_{(i)j}^a$, a'inci bileşenin üzerindeki $x_{(i)j}$ 'nin yüklemesidir. $(k-1)x$ değişkeninin geri kalanı için x_i modelinin katsayıları;

$$b_{ik} = \sum_a c_{ia} w_{ka}, \quad j \neq i \quad (1.10)$$

formülü ile hesaplanır.

PLS iteratif(yinelemeli) bir yöntemdir. Tüm hesaplamalardan sonra, $X_{(i)}$ matrisi (1.11)'deki gibi sönmülmendirilir ve tüm hesaplamalar sönmülmendirilmiş $X_{(i)}$ ile yinelenir. Tekrarlar, tüm A bileşenleri elde edilene kadar sürer. $X_{(i)}$ 'yi sönmüleyerek, ortogonal bileşen puanları garanti altına alınır.

$$X_{(i)}^a = X_{(i)}^{a-1} - t_{(i)}^a p_j^a \quad (1.11)$$

Bu bileşenler, orijinal verilerin bir alt uzayı olan yeni bir vektör uzayına sahiptir. PLS, maksimum kovaryansa sahip bu ortogonal latent değişkenleri üretir. A, k' ya eşit olduğunda, PLS ve MLR aynı sonuçları verir. Her yinelemede yeni gizli değişkenler üretme süreci, kullanılan algoritmaya bağlıdır (Olmez, 2018).

Yapısal Eşitlik Modellemesi (YEM)

İngilizcesi Structural Equation Modelling (SEM) olan Yapısal Eşitlik Modelleri, gözlenen ve gözlenemeyen(gizil-latent) değişkenler arasındaki nedensel ilişkiler hakkındaki hipotezleri test etmede kullanılan kapsamlı bir istatistiksel yaklaşımdır (Sümer, 2000). Gizil değişkenlerin kendi aralarındaki ve gizil değişkenlerle gözlenebilen değişkenler arasındaki nedensel ilişkileri incelemek için geliştirilmiştir (Şencan, 2005). İki farklı istatistik geleneği Psikometri ve ekonometrinin melezi olarak ortaya çıkmıştır (Cokluk et al., 2010). Yapısal Eşitlik Modeli kullanımının ilk örnekleri sosyal bilimler alanında sosyoloji için 1977, psikoloji için 1980 ve 1986, ekonomi alanında ise 1972 ve 1984 yıllarında görülmektedir. Ayrıca 1980'li yıllarda sosyal bilimlerde ve kendi disiplinlerinde önde gelen akademik yayınlarda Yapısal Eşitlik Modeli kullanımıyla ilgili çalışmalar gözlenmeye başlanmıştır (Bollen,

1989). Zamanla esnekliği ve genelliği nedeniyle, bu yöntem birçok disiplinde oldukça popüler hale gelmiştir (Mueller & Hancock, 2018).

Yapısal Eşitlik Modellemesinin gösteriminde semboller kullanılmaktadır. Örneğin ölçülemeyen değişkenler daire ve elips şekilleri ile gösterilirken, ölçülebilen değişkenler kare ve dikdörtgen şekilleri ile gösterilir. Oklar ise ilişkilerin yönünü belirtir. Semboller modellenen ilişkinin özetlenebilmesini ve daha anlaşılır olmasını sağlamaktadır.


SEM Tahmini

Yapısal Denklem Modeli iki alt modelden oluşur: Ölçüm modeli ve yapısal model. Ölçüm modeli her bir gizli değişken ile ilişkili olduğu gözlenebilen değişkenler arasındaki ilişkileri ifade ederken, yapısal model gizli değişkenler arasındaki ilişkileri inceler.

Ölçüm modelinin denklemi ölçülebilen ve ölçülemeyen(gizil) değişkenler arasındaki ilişkinin yönüyle bağlantılıdır. Ölçüm modeli kurulurken amaç gözlenen değişkenlerinin tahmini ise reflektif(yansıtıcı) ilişki, gizil değişkendeki varyansı maksimum derecede açıklayabilmek ise formatif(biçimlendirici) ilişki oluşturulur. Ayrıca reflektif ilişkilerde reflektif değişkenlerin, başka bir değişken ile değiştirilmesi durumunda yapının niteliğini bozulmamaktadır. Ancak formatif ilişkilerde formatif değişkenlerin değişikliği (örneğin modele dahil edilmemesi) durumunda ilişkinin eksik açıklanması sorunu ortaya çıkmaktadır (Bollen & Lennox, 1991).

Ölçümün reflektif yapıda olması için aşağıdaki 3 şartı sağlaması gerekmektedir.

1. Amacın gözlenen değişkenlerin tahmini ve açıklaması olduğu durumlarda kullanılır.
2. Gizil değişkenin gözlenen değişkenleri etkilemesi gerekir ve bu durumda nedensel ilişkiyi gösteren okun yönü gizil değişkenden gözlenen değişkene doğru olur.
3. Her bloktaki ölçüm değişkenleri arasında oluşabilecek çoklu doğrusallık probleminin çözümü için kullanılır. ((Chin, 1998); (Türkyılmaz & Özkan, 2007)).




Şekil.1. Reflektif İlişki

Yukarıda Şekil.1 ile gösterilen reflektif ilişkinin denklemi ise;

$x_i = \lambda_i \xi + \delta_i$ şeklinde gösterilir. Burada δ_i 'inci gösterge için rastgele hatayı ve λ_i 'inci göstergenin dışsal olan gizli değişken ξ üzerindeki yüklenmesini gösterir. Böylece her gözlemlenebilir gösterge x_i , ortak gizli değişken ξ ve bazı benzersiz hata δ_i 'nin bir fonksiyonudur (Lee & Cadogan, 2013).

Formatif modellerin özellikleri ise şunlardır;

1. Formatif değişkenler model içinde gizil değişkenin oluşumunda neden değişkeni olarak yer almaktadır.
2. Formatif yapılar da değişkenlerin birbirleri ile ilişkili olmaları ya da aynı gizil değişken üzerinde etkili olmaları gerekli değildir.
3. Formatif modeller, doğrusal regresyonda olduğu gibi, formatif değişkenler yardımıyla ölçülen gizil değişkenin hatasının tahmin edilmesine olanak verir (Diamantopoulos, 2006).




Şekil.2. Formatif İlişki

Şekil 2’ de gösterilen formatif modelin denklemi ise şu şekilde ifade edilir;

$$\eta = \gamma_1\chi_1 + \gamma_2\chi_2 + \dots + \gamma_n\chi_n + \zeta \quad (2.1)$$

Burada gizli değişken η içseldir ve χ_1 ’den χ_n ’e ve γ_1 ’den γ_n ’e bazı gözlemlenebilir değişkenlerin fonksiyonu olarak kabul edilir. ζ ise bir yapı yüzeyinde hata terimidir ve genellikle η ’nin $\chi_1 - \chi_n$ tarafından yakalanamayan kalan nedenlerini temsil ettiği kabul edilmektedir.




Şekil.3. Bileşik Değişken İlişkisi

Şekil 3’te verilen bileşik değişken modeline ait denklem model 2’deki model ile aynı olmakla beraber, formatif değişken C ile adlandırılmış ve altıgenle gösterilmiştir. $\zeta = 0$ olması hatada $\chi_1 - \chi_n$ ‘den başka bir herhangi bir ek nedenin var olmadığını gösterir (Grace & Bollen, 2008).

$$C = w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (2.2)$$

Hem (2) hem de (3) denklemleri, ek bir içsel değişken veya değişkenler olmadan tahmin edilemez ve (Bagozzi, 2007), bu da γ ve w değerlerinin (ve dolayısıyla η ve C ’nin) modeli tahmin etmek için hangi içsel değişkenlerin kullanıldığına bağlı olduğu anlamına gelir (Heise, 1972). Ayrıca Şekil 2’de ve 3’te sunulan modeller yeterince tanımlanmadıkları için oldukları gibi tahmin edilemezler. Bu nedenle son yıllarda bağımlı değişkenin bilinmediği durumlarda da kullanılabilen MIMIC modellerin kullanımı önem kazanmıştır.

Özellikle, Şekil 4’de gösterilen formatif modelleri, odaksal bir gizli değişken (η), bazı reflektif değişkenler (γ ler) ve bazı formatif değişkenler (χ ler) içerir ve böylece kavramsal modelleri tahmin ederken biçimlendirici değişkenlerin dahil edilmesine olanak tanır ((Jarvis et al., 2003);(Kline, 2006)).



Şekil.4. MIMIC Model

Bazı dışsal değişkenler yardımıyla direkt ölçülmesi mümkün olmayan reflektif gizil değişkeni modellemeye yarayan bir yöntem olarak açıklanabilen MIMIC modelde de eşanlı olarak çözülen 2 model bulunmaktadır. Bunlar yapısal model ve ölçüm modelidir. (Tenenhaus, 2004).

Yapısal Eşitlik Model Tahmininde PLS Yönteminin Kullanımı

Nedenselliği ifade eden çift taraflı ilişkilerin modellenememesi, Path katsayılarının yüklerinin tahmininde ortalama hata karelerin büyük, yükler ve Path katsayılarının sapmalı olma ihtimali (Rönkkö & Evermann, 2013) gibi olumsuz yönleri olsa da PLS-SEM yapısal eşitlik modellerini tahmin etmek için giderek daha fazla kullanılmaktadır (Hair et al., 2014). Bunun birden çok nedeni bulunmaktadır. Teorik bir çerçeve test edilmek istendiğinde, yapısal modelin karmaşık birçok yapı, gösterge ve model ilişkisi içerdiği ve örneklem büyüklüğünün kısıtlı olduğu durumlarda, ikincil/arşiv verileriyle çalışmak istendiğinde, biçimlendirici yapıyı kurabilmeye de imkân sağlaması başlıca nedenler olarak gösterilebilir. Yapısal Eşitlik Modellerinde, çok değişkenli normallik varsayımı ve büyük örneklem genişliği gibi varsayımların sağlanması zorunluluğu olan kovaryans tabanlı yöntemlerin (CB-SEM) aksine PLS-SEM normal dağılım göstermeyen küçük örneklemelerde daha etkin sonuçlar elde edilmesine olanak tanır. Ancak literatürde bazı araştırmacıların, popülasyonun geniş ve kolay erişilebilir olmasına rağmen, oldukça küçük örneklem boyutlarıyla analiz gerçekleştirmek amacıyla PLS-SEM yöntemini hatalı ve yanıltıcı biçimde kullandıkları görülmektedir. Bu tür uygulamalar, yöntemin akademik itibarı üzerinde belirli ölçüde olumsuz bir etki yaratmıştır (Marcoulides et al., 2009). PLS-SEM ölçüm ve yapısal model ilişkilerini eşzamanlı olarak değil, ayrı ayrı hesaplayarak küçük örneklemde de iyi çözümler sunabilme özelliğine ek olarak büyük örneklemelerde de çok iyi sonuç verir (Hair, Risher, et al., 2019). Ayrıca PLS-SEM neredeyse her zaman normal dağılım göstermeyen sosyal bilim

çalışmaları verilerinde avantajlı olsa da sınırlı sayıda durumda verilerin normal dağılmaması PLS-SEM sonuçlarını da etkilemektedir (Sarstedt et al., 2017). Bu durumda bootstrapping yönteminin kullanılması sorunu bir noktaya kadar çözmektedir (Efron, 1987). Fakat sadece bu nedenden PLS-SEM yöntemini seçmek doğru olmayabilir. Diğer taraftan CB-SEM model uyum kavramına büyük ölçüde dayanırken, PLS-SEM’de bu durum daha az geçerlidir (Hair, Sarstedt, et al., 2019). Bu nedenle bazı araştırmacılar PLS-SEM’in teori testi ve doğrulama için uygun olmadığına dair yanlış bir yargıya varmışlardır (Westland, 2015). Ancak birkaç araştırmacı PLS-SEM için model uygunluğu ölçümlemlerini onaylamıştır (Henseler et al., 2016b). Yine de bu ölçümler değerlendirilirken hassas davranılmalıdır. Örneğin CB-SEM’de kullanılan Ki-kare tabanlı model uyum ölçüleri kullanılamaz. SRMR gibi kriterler bile dikkatle ele alınmalıdır (Henseler, 2017; Henseler et al., 2016a). Ayrıca bazı araştırmacılar CB-SEM’de uygulanan model uyum kavramının PLS-SEM için de önemli olup olmadığını irdelemişlerdir (Hair et al., 2017a; Lohmöller, 1989; Rigdon, 2012). Bu nedenlerle PLS-SEM analizinde öncelikle tahmin ve teori arasındaki etkileşime öncelik verilip sonrasında sonuçlar doğrulanmalıdır (Shmueli, 2010). Bu bağlamda araştırmacılar son zamanlarda PLS-SEM’in tahmin odaklı yapısına uygun yeni değerlendirme prosedürleri önermişlerdir (Shmueli et al., 2016).

Yapısal Eşitlik Modellemesinde de kullanılan PLS, En Küçük Kareler (EKK-OLS) Yöntemini temele alarak geliştirilmiştir. Tahmin yapmak için 2 aşamalı bir metot uygular. İlk aşamasını dış modelin tahmini ikinci aşamayı ise iç modeli/yapısal modeli tahmin etmek oluşturur.

• İlk Aşama

Bu aşamayı ölçüm modelindeki (dış model) yüklemeleri ve ağırlıkları tahminlemek oluşturur. Bu amaçla kendilerine bağlı olan ölçüm değişkenleriyle olan ilişkilerini ve varsa birden fazla gizil değişkenin birbirleriyle olan ilişkisini kullanarak tahmin yapar. İlk olarak ölçüm değişkenlerinin (x_{jh}) ağırlıklı ortalaması gizil değişkenin değeri olarak gösterilir;

$$Y_j \propto \left[\sum w_{jh} (x_{jh} - \bar{x}_{jh}) \right] \quad (3.1)$$

Y_j gizil değişkeni ifade ederken, denklemin sağ tarafından elde edilen değer standardize edileceğinden “=” yerine “ $\propto$ ” işareti kullanılır ve standardize edilen gizil değişken (3.3) deki gibi hesaplanır.

$$Y_j = \sum \tilde{w}_{jh} (x_{jh} - \bar{x}_{jh}) \quad (3.2)$$

Burada $\tilde{w}_{jh}$ ölçüm modelinin ağırlık katsayısını ifade eder ve hesaplanmasında 2 yöntem vardır;

i. **Mod A**

$$w_{jh} = \text{cor}(x_{jh}, Z_{jh}) \quad (3.3)$$

ii. **Mod B**

Burada X_j sütunları $(x_{jh} - \bar{x}_{jh})$ şeklinde tanımlanan matris iken, ağırlık katsayısı;

$$w_{jh} = (X_j' X_j)^{-1} X_j' Z_j \quad (3.4)$$

formülü ile hesaplanır.

Ağırlık katsayısı hesaplanırken reflektif ölçüm modeli içsel gizil değişkenler için Mod A yöntemi, formatif modeli dışsal gizil değişkenler için Mod B kullanılır (Vinzi et al., 2009).

Ağırlık katsayısı hesaplandıktan sonra gizil değişkenin ortalama değeri ($\hat{m}_j$)

$$\hat{m}_j = \sum \tilde{w}_{jh} \bar{x}_{jh} \quad (3.5)$$

olduğundan gizil değişken;

$$\xi_j = \sum \tilde{w}_{jh} \bar{x}_{jh} = \hat{Y}_j + \hat{m}_j \quad (3.6)$$

şeklinde hesaplanır. Model içinde birden fazla gizil değişken olduğu durumda aralarındaki ilişkisi ise

$$Z_j = \sum e_{ij} Y_i \quad (3.7)$$

formülü ile hesaplanır. Bu denklemde; i. gizil değişkenlerin (Y_i) dış modelden elde edilen değerinin ağırlıklı ortalaması j. gizil değişkenin (Z_j) iç modelden tahmin edilen değerine eşittir. e_{ij} ise iki gizil değişken arasındaki ilişki katsayısını gösterir ve 3 farklı yolla hesaplanabilir. Bunlar;

- i. Anakütle Merkezi Yöntemi (Centroid Method)
- ii. Faktör Ağırlıklandırma (Factor Weighting)
- iii. İz Ağırlıklandırma (Path Weighting) yöntemleridir.

• **İkinci Aşama**

İkinci aşamayı yapısal modeli tahmin etmek oluşturur. Bunu ise ilk aşamada hesaplanan ağırlıkları kullanılarak gizil değişken hesaplaması üzerinden yapar (Chin, 1998).

$$\begin{aligned} \xi_j &= \sum \tilde{w}_{jh} x_{jh} \\ \eta_{jh} &= \sum \tilde{w}_{jh} y_{jh} \end{aligned} \quad (3.8)$$

Yapısal modelde içsel gizil değişken sayısınınca yapısal model kurularak değerleri bilinen gizil değişkenler arasındaki yapısal ilişkiler basit veya çoklu regresyon şeklinde hesaplanır. Burada;

$$\begin{aligned}
 \xi &= (\xi_1, \xi_2, \dots, \xi_n) : \text{Dışsal gizil değişken vektörü,} \\
 \eta &= (\eta_1, \eta_2, \dots, \eta_n) : \text{İçsel gizil değişken vektörü,} \\
 \tilde{A} &: \text{Dışsal gizil değişken için regresyon katsayıları vektörü,} \\
 \hat{A} &: \text{İçsel gizil değişken için regresyon katsayıları vektörü,} \\
 \zeta &: \text{Hata Vektörü olarak gösterilirse, (3.7) deki denklem;} \\
 \eta &= \tilde{A}\xi + \hat{A}\eta + \zeta \quad (3.9)
 \end{aligned}$$

şeklinde yazılabilir ve bu denklem üzerinden gizil değişken tahminlenir.

PLS-SEM yönteminin uyum kriterleri (Hair, Risher, et al., 2019) aşağıdaki gibi özetlenebilir:

Model reflektif yapıda kurulduğunda;

1. Gösterge Güvenilirliği (Yükler)
2. İç Tutarlılık Güvenilirliği (Bileşik güvenilirlik)
3. Cronbach's Alpha
4. ρ_A (Dijkstra & Henseler, 2015)
5. Yakınsak Geçerliliği (AVE)
6. Ayırışma Geçerliliği (HTMT, Fornell-Larcker kriteri, Çapraz yükler)

Model formatif yapıda kurulduğunda;

1. Yakınsak Geçerliliği (AVE)
2. Çoklu doğrusallık (VIF)
3. Ağırlıkların istatistiksel önemi
4. Anlamlı bir ağırlığa sahip göstergelerin geçerliliği
5. Anlamlı olmayan ağırlığa sahip göstergelerin geçerliliği


Yapısal model için;

1. R^2 değeri
2. Q^2 değeri
3. PLSpredict
4. Model karşılaştırmaları

5. Sağlamlık kontrolleri (CTA-PLS, İçsellik v.s)


Uygulamalı Örnek

Bu bölümde elektronik bankacılık hizmetlerinin müşteri tatmini üzerine etkileri ve sadakat değişkeni ile etkisi araştırılmak istenmiştir. Model kuramsal temel alınarak Şekil 5'teki gibi oluşturulmuştur. Bu nedenle kullanılacak veri seti 190 gözleme sahip bir anket verisidir. Model Güvenilirlik, Fiziksel özellikler, Cevap verme/İletişim, Tatmin, Katılım ve Sadakat olmak üzere 6 gizil değişkene sahiptir. Bu gizil değişkenler üzerinde etkisi olan 20 tane gösterge değişken vardır. Gösterge değişkenlerin dağılımı ise; 4 güvenilirlik, 3 fiziksel, 5 cevap verme, 2 tatmin, 3 katılım ve 3 sadakat olacak şekilde yapılmıştır. Gizil değişken ilişkileri ise; Cevap vermenin Güvenilirliği, Fiziksel özelliklerin Katılım değişkenini, Katılım ve Güvenilirlik değişkeninin Tatmini, Tatminin ise Sadakati etkilediği şeklinde belirlenmiştir.




Şekil.5. Örnek için Oluşturulan Teorik Model

Modelin analiz edilmesi için SmartPLS programından faydalanılacaktır. Bu nedenle öncelikle programın açılması ve verilerin tanıtılması gerekmektedir. Program açıldığında Şekil 6'daki gibi bir ekran gelecektir.



Şekil.6. SmartPLS Ana Ekran

Burada öncelikle yeni proje  sembolü seçilir, yeni bir çalışma alanı oluşturulur ve “**import data file**” seçeneği ile veriler programa tanıtılır. Verilerin programa eklenme aşamasında verilerin tanımlayıcı istatistiklerinin var olduğu ara ekran gelir ve onaylanması gerekir. Veriler tanıtıldıktan sonraki aşama veriler için kullanılmak istenen yöntemin seçilmesidir. Bu çalışma kapsamında kurulacak model PLS SEM yöntemi ile analiz edileceğinden  sembolü seçilmelidir. Seçimden sonra Şekil 7’ de gösterilen sayfada planlanan model kurulmalıdır.




Şekil.7. SmartPLS PLS-SEM Çalışma Sayfası

Modeli kurmak için önce planlanan modeldeki gizil değişken  sembolü seçilerek çalışma sayfasına taşınır. Açılan kutucuğa isimleri yazılarak çalışma sayfasına konumlandırılır. İsimlendirilmeleri yapılır. Ardından sol tarafta yer alan gösterge değişkenler seçilerek ilişkide oldukları gizil değişkenlere bağlanır. Model kurma aşamasında son işlem gizil değişkenlerin arasındaki ilişkiyi belirlemek ve tanıtmaktır. Bunun için  sembolü tıklanır ve oklar aracılığıyla ilişkilerin yönü kuramsal temel dikkate alınarak belirlenir. Bu aşamada gizil değişkenlere tıklanınca sağ tarafta açılan “**tools**” bölümü sayesinde gösterge değişkenlerin gizil değişkenin ne tarafında yer alacağı, gizil değişkenlerin şekli ve rengi gibi şekilsel değişiklikler yapılabilmektedir.

Modelin Şekil 5’te tanımlaması yapılmış hali görünmektedir. Bu aşamadan sonra kurulan modelin tahmin edilmesi gerekir. Bunun için sayfanın üst kısmında ki  sembolüne tıklanır. Açılan ara ekranda

modele uygulanabilecek yöntemler yer alır. Burada ilk sırada PLS-SEM algorithm, ikinci sırada ise “Bootstrapping” seçeneği mevcuttur. Bootstrapping (Ön yükleme) dış ağırlıklar dış yükler ve yol katsayıları gibi tahminlerin standart hatalarını belirleyerek anlamlı olup olmadıklarını test etmek için kullanılan parametrik olmayan bir prosedürdür (Ringle et al., 2024). İstatistiki anlamlılık, R^2 gibi değerlerin hesaplanması için ilk yöntemi de içinde barındıran bootstrapping seçilerek model tahminlenir. Bu yöntem uygulanırken açılan Şekil 8’de gösterilen ara ekranda tahmin özellikleri üzerinde değişiklik yapılabilir.



Şekil. 8. Hesaplama Ekran Menüü

Bu çalışmada alt örnek sayısı “5000”, sonuçların miktarı yavaş, güven aralığı yöntemi yavaş, test türü çift kuyruklu ve önem düzeyi 0.05 olarak belirlenmiştir. Kriterler belirlendikten sonra “**Start calculation**” bölümüne tıklanarak hesaplama başlatılır. Hesaplama süresi ekrandaki “**Subsamples**” değerine göre değişiklik gösterir.

Bootstrapping

Bootstrapping is a nonparametric procedure that can be used to test statistical significance of PLS-SEM results such path coefficients, outer weights, Cronbach's alpha, HTMT, and R² values. [More info.](#)

BT setup **PLS setup** **Data**

Subsamples 5000

☒ Do parallel processing

Amount of results Most important (faster)

☐ Save results per sample

Confidence interval method Percentile bootstrap

Test type Two tailed

Significance level 0.05000


Random number generator Fixed seed

☐ Open report

[Default settings](#) [Close](#) [Start calculation](#)


Şekil.9. Bootstrapping Model Menüsü

Hesaplamalar yapıldıktan sonra modelin Path katsayıları ve gösterge değişken yükleri parantez içinde anlamlılıkları ile birlikte grafik olarak Şekil 10'daki gibi elde edilmiş olur.




Şekil. 10. Hesaplanan Modelin Grafik Çıktısı

Analiz sonuçları ile detaylı bilgiler ise çalışma sayfasının sol tarafında yer alır. Şekil 11'de gösterilen "Graphical output" bölümünde grafik üzerinde görülmesi istenen bilgiler belirlenebilir.



Şekil.11. Grafik Düzenleme Menüsü

Yine çalışma sayfasının sol tarafında “**Final results**” bölümünde yapısal model sonucu olarak kabul edilen Path katsayıları, dolaylı, direkt, toplam etkileri ve ölçüm model sonuçları olan gösterge değişkenlerinin gizil değişkenle arasındaki ilişkiyi gösteren yüklemeleri ve ağırlıkları, toplam etkiler bilgileri yer almaktadır. Nihai Sonuçlar menüsü Şekil 12’de gösterilmiştir.



Şekil.12.Nihai Sonuçlar Menüsü

Yapısal model sonuçlarının yer aldığı Şekil 13’deki Path katsayıları incelendiğinde tüm değerlerin anlamlı olduğu görülmektedir. Cevap verme boyutunun güvenilirlik boyutu üzerinde etkisi 0,792’dir. Fiziksel özellikleri ifade eden Fiziksel boyutunun katılıma etkisi ise 0.55’dir. Müşteri tatmini üzerine etkili Güvenilirlik ve Katılım değişkenlerinin katsayıları sırasıyla 0.688, 0.25’tir. Bu sonuca göre müşterinin Tatmini üzerinde Güvenilirlik değişkeni daha etkilidir. Son olarak müşterinin Sadakati üzerinde Tatminin etkisi 0.794 ile modeldeki en yüksek katsayıya sahiptir.

Path coefficients - Mean, STDEV, T values, p values						Copy to Excel/Word	Copy t
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O /STDEV)	P values		
CEVAP VERME -> GÜVENİLİRLİK	0.792	0.795	0.032	24.995	0.000		
FİZİKSEL -> KATILIM	0.550	0.553	0.057	9.723	0.000		
GÜVENİLİRLİK -> TATMİN	0.688	0.688	0.040	17.103	0.000		
KATILIM -> TATMİN	0.250	0.249	0.051	4.857	0.000		
TATMİN -> SADAKAT	0.794	0.796	0.035	22.762	0.000		

Şekil.13. Path Katsayıları Sonuç Ekranı

Dolaylı etkileri gösteren Şekil 14 incelendiğinde Cevap Verme değişkeninin Güvenilirlik üzerinden Tatmine etkisi 0.545, Güvenilirlik ve Tatmin üzerinden Sadakate etkisi 0.433 birimdir. Yine Güvenilirlik boyutunun Tatmin üzerinden Sadakate etkisi 0.546 değeri ile dolaylı etkiler içinde en yüksek katsayıya sahiptir. Fiziksel özellikler boyutunun Katılım üzerinden Tatmine ve Katılım ile Tatmin üzerinden Sadakat boyutuna etkisi sırasıyla 0.137, 0.109'dur. Zayıf ilişki olarak adlandırılacak bu ilişkiyle beraber tüm dolaylı etkilerin anlamlı olduğu görülmektedir.

Specific indirect effects - Mean, STDEV, T values, p values						Copy to Excel/Word	Copy t
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O /STDEV)	P values		
KATILIM -> TATMİN -> SADAKAT	0.198	0.199	0.043	4.563	0.000		
GÜVENİLİRLİK -> TATMİN -> SADAKAT	0.546	0.548	0.041	13.268	0.000		
CEVAP VERME -> GÜVENİLİRLİK -> TATMİN	0.545	0.547	0.041	13.185	0.000		
CEVAP VERME -> GÜVENİLİRLİK -> TATMİN -> SADAKAT	0.433	0.436	0.041	10.586	0.000		
FİZİKSEL -> KATILIM -> TATMİN	0.137	0.139	0.035	3.896	0.000		
FİZİKSEL -> KATILIM -> TATMİN -> SADAKAT	0.109	0.111	0.030	3.659	0.000		

Şekil.14.Dolaylı Etkiler Sonuç Ekranı

Tüm gösterge değişkenlerinin yüklemeleri ise analizin ilk aşaması olan ölçüm modelinin tahmini sonuçlarını göstermektedir. Biri hariç tüm yüklerin literatürde kabul gören 0.70 değerinin üstünde ve anlamlı olduğu Şekil 15'te görülmektedir.

Outer loadings - Mean, STDEV, T values, p values						Copy to Excel/Word
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values	
CV2 <- CEVAP VERME	0.800	0.801	0.028	28.726	0.000	
CV3 <- CEVAP VERME	0.742	0.741	0.042	17.803	0.000	
CV4 <- CEVAP VERME	0.701	0.699	0.048	14.628	0.000	
ET2 <- CEVAP VERME	0.669	0.666	0.060	11.122	0.000	
ET3 <- CEVAP VERME	0.795	0.793	0.037	21.396	0.000	
GM1 <- GÜVENİLİRLİK	0.838	0.837	0.036	23.317	0.000	
GM2 <- GÜVENİLİRLİK	0.844	0.844	0.029	28.961	0.000	
GM4 <- GÜVENİLİRLİK	0.801	0.800	0.037	21.711	0.000	
GM5 <- GÜVENİLİRLİK	0.823	0.823	0.027	30.364	0.000	
KK2 <- FİZİKSEL	0.920	0.921	0.015	59.720	0.000	
KK3 <- FİZİKSEL	0.920	0.919	0.015	59.960	0.000	
KT1 <- KATILIM	0.872	0.870	0.024	36.796	0.000	
KT2 <- KATILIM	0.883	0.882	0.026	34.088	0.000	
KT3 <- KATILIM	0.871	0.870	0.025	35.187	0.000	
SD2 <- SADAKAT	0.899	0.898	0.016	54.678	0.000	
SD4 <- SADAKAT	0.912	0.913	0.015	60.562	0.000	
SD5 <- SADAKAT	0.901	0.900	0.022	41.383	0.000	
SE5 <- FİZİKSEL	0.828	0.825	0.040	20.860	0.000	
TT1 <- TATMİN	0.930	0.930	0.013	71.048	0.000	

Şekil.15. Gösterge Değişken Yükleri Sonuç Ekranı

PLS-SEM, gizil değişkenler ile gözlenen göstergeler arasındaki ilişkileri tahmin ederken iteratif bir algoritma kullanır. Bu süreçte, her bir göstergeye ait olduğu gizil değişken üzerinde katkı sağlayacak şekilde ağırlıklar atanır. Şekil 15'teki değerlere bakıldığında, tüm dış ağırlıkların istatistiksel olarak anlamlı olduğu, ancak bu göstergelerin modele katkı seviyelerinin farklılık gösterdiği görülmektedir.

Outer weights - Mean, STDEV, T values, p values						Copy to Excel/Word
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values	
CV2 <- CEVAP VERME	0.325	0.326	0.026	12.659	0.000	
CV3 <- CEVAP VERME	0.254	0.253	0.020	12.864	0.000	
CV4 <- CEVAP VERME	0.218	0.217	0.020	10.680	0.000	
ET2 <- CEVAP VERME	0.252	0.251	0.024	10.319	0.000	
ET3 <- CEVAP VERME	0.290	0.290	0.021	13.688	0.000	
GM1 <- GÜVENİLİRLİK	0.298	0.298	0.016	18.546	0.000	
GM2 <- GÜVENİLİRLİK	0.291	0.291	0.017	17.208	0.000	
GM4 <- GÜVENİLİRLİK	0.310	0.310	0.018	17.599	0.000	
GM5 <- GÜVENİLİRLİK	0.312	0.312	0.016	19.809	0.000	
KK2 <- FİZİKSEL	0.404	0.406	0.031	12.963	0.000	
KK3 <- FİZİKSEL	0.409	0.409	0.023	17.757	0.000	
KT1 <- KATILIM	0.380	0.380	0.027	14.235	0.000	
KT2 <- KATILIM	0.380	0.380	0.026	14.875	0.000	
KT3 <- KATILIM	0.382	0.383	0.026	14.880	0.000	
SD2 <- SADAKAT	0.385	0.385	0.017	22.954	0.000	
SD4 <- SADAKAT	0.393	0.394	0.018	22.247	0.000	
SD5 <- SADAKAT	0.327	0.327	0.013	25.933	0.000	
SE5 <- FİZİKSEL	0.304	0.303	0.027	11.343	0.000	
TT1 <- TATMİN	0.513	0.513	0.011	46.828	0.000	
TT2 <- TATMİN	0.556	0.556	0.015	37.062	0.000	

Şekil.15. Gösterge Değişken Ağırlıkları Sonuç Ekranı

Final results bölümünün altında Şekil 16 da gösterilen “**Quality criteria**” yer almaktadır. Burada modelin ne kadar iyi tahminleme yaptığını gösteren kriterler bulunmaktadır. R^2 , f^2 , AVE, Cronbach’s Alfa, HTMT ve VIF değerleri görüntülenebilmektedir.

▼ **Quality criteria**

- ▶ R-square
- ▶ R-square adjusted
- ▶ f-square
- ▶ Average variance extracted (AVE)
- ▶ Composite reliability (rho_c)
- ▶ Composite reliability (rho_a)
- ▶ Cronbach's alpha
- ▶ Heterotrait-monotrait ratio (HTMT)
- ▶ Latent variable correlations
- ▶ Outer model collinearity statistics (VIF)
- ▶ Inner model collinearity statistics (VIF)

Şekil.16. Kalite Kriterleri Menüsü

Bazı kalite kriterleri menüsündeki bazı sonuçlar birleştirilerek Tablo 1, Tablo 2 ve Tablo 3’te sunulmuştur. Öncelikle içsel gizil değişkenlerin açıklanma gücünü gösteren R^2 değerleri sonrasında modelin yakınsak ve ayrışma geçerliliğini sağlayıp sağlamadığını gösteren bilgilere yer verilecektir.

Tablo 1’e bakıldığında modelin Katılım değişkenini zayıf, fakat Tatmin, Sadakat ve Güvenilirlik gibi içsel gizil değişkenleri %60’tan fazla açıkladığı görülmektedir. Bu değerler değişkenlerin açıklama gücünün yüksek olduğunu gösterir.

Tablo.1.Değişkenlerin R^2 Değerleri

	R^2	R^2 Adj
GÜVENİLİRLİK	0.627	0.633
KATILIM	0.302	0.309
SADAKAT	0.631	0.635
TATMİN	0.685	0.689

Tablo 2’de modelin yakınsak geçerliliği ile ilgili olan kriterler birlikte sunulmuştur. Tüm gizil değişkenlerin AVE değerlerinin 0.50’ten büyük olması açıklanan varyansın yeterli düzeyde olduğunu gösterir. Ancak Tatmin

ve Sadakat yapıları çok güçlü iken Cevap Verme yapısının açıklanan varyansı zayıf ama kabul edilebilir seviye ölçülmüştür. Ayrıca tüm gizil değişkenler için $CR > 0.80$ ve $\text{Alpha} > 0.70$ olması iç tutarlılığın ve güvenilirliğin yüksek olduğunu gösterir. Dolayısıyla modelin yakınsak geçerliliği sağlanmış görünmektedir.

Tablo.2.Değişkenlerin Yakınsak Geçerlilik Sonuçları

	AVE	CR	Cronbach's Alpha	ρ_A
CEVAP VERME	0.552	0.860	0.797	0.809
FİZİKSEL	0.793	0.920	0.869	0.891
GÜVENİLİRLİK	0.683	0.896	0.845	0.845
KATILIM	0.766	0.907	0.847	0.847
SADAKAT	0.818	0.931	0.889	0.895
TATMİN	0.875	0.933	0.857	0.861

Yakınsak geçerliliğinden sonra modelin ayrışma geçerliliğinin de sağlanması gerekir. Modelin ayrışma geçerliliğini yorumlamak için gerekli olan HTMT (Heterotrait-Monotrait Ratio of Correlations) değeri 0.85'ten küçük iken ayrışım geçerliliği olduğunu, $0.86 < \text{HTMT} \leq 0.90$ iken gevşek ama kabul edilebilir ayrışma geçerliliğine ve $\text{HTMT} > 0.90$ durumunda ise ayrışma geçerliliği problemine işaret eder (Henseler et al., 2015).

Modelin HTMT sonuçları incelendiğinde Tatmin $\leftrightarrow$ Güvenilirlik 0.902 ile sınırda olması, Güvenilirlik $\leftrightarrow$ Cevap Verme 0.951 ve Tatmin $\leftrightarrow$ Güvenilirlik 0.933 değerleri ile ayrışma geçerliliği sorunu olabileceğini gösterebilir. Ancak ayrışma geçerliliğinde kullanılan bir diğer yöntem; AVE değerlerinin karekökü ile değişkenler arası korelasyon değerlerinin kıyaslanmasıdır (Fornell & Larcker, 1981). Bu aşamada ayrışma geçerliliği için AVE değerlerinin karekökü alınarak korelasyonlar ile karşılaştırılıp tekrar değerlendirilebilir.

Heterotrait-monotrait ratio (HTMT) - Confidence intervals				
	Original sample (O)	Sample mean (M)	2.5%	97.5%
FİZİKSEL <-> CEVAP VERME	0.831	0.832	0.735	0.917
GÜVENİLİRLİK <-> CEVAP VER...	0.951	0.952	0.875	1.016
GÜVENİLİRLİK <-> FİZİKSEL	0.852	0.852	0.738	0.939
KATILIM <-> CEVAP VERME	0.477	0.480	0.339	0.617
KATILIM <-> FİZİKSEL	0.633	0.632	0.503	0.747
KATILIM <-> GÜVENİLİRLİK	0.513	0.513	0.366	0.647
SADAKAT <-> CEVAP VERME	0.767	0.768	0.674	0.856
SADAKAT <-> FİZİKSEL	0.799	0.799	0.680	0.890
SADAKAT <-> GÜVENİLİRLİK	0.865	0.867	0.792	0.930
SADAKAT <-> KATILIM	0.669	0.667	0.539	0.778
TATMİN <-> CEVAP VERME	0.863	0.863	0.777	0.938
TATMİN <-> FİZİKSEL	0.836	0.835	0.736	0.916
TATMİN <-> GÜVENİLİRLİK	0.933	0.934	0.873	0.987
TATMİN <-> KATILIM	0.644	0.643	0.516	0.754
TATMİN <-> SADAKAT	0.902	0.903	0.833	0.962

Şekil.17. HTMT Sonuç Ekranı

Yine çalışma sayfasının sol tarafında Kalite kriterlerinin altında modelin uyumunu gösteren “**Model Fit**” Bölümü vardır. Şekil 18’de gösterilen bölümde modelin SRMR (Standardized Root Mean Square Residual), d_ ULS (Squared Euclidean distance) ve d_ G (Geodesic distance) bilgileri yer almaktadır.

▼ Model fit

SRMR

d_ ULS

d_ G

Şekil.18. Model Uyum İyiliği Kriterleri Menüü

Varsayımlarsağlandıktan sonra araştırmacılar, önceliklesaturated (doğru) model fit değerlerine yani, tüm parametrelerin serbest bırakıldığı modelin veriye uyumuna bakar. Sonuçlar gözlenen ve tahmin edilen kovaryanslar arasındaki farkı gösteren SRMR’nin 0,08’den düşük olduğunu gösteriyorsa (Hu & Bentler, 1998) ve tam model uyumu testi anlamlı değilse (d_ ULS ve d_ G < %95 veya < %99 önyükleme yüzdesi olmalıdır), ortak faktör modellenmesine odaklanan tutarlı PLS tahminini tercih etmelidir. Model

uyum kriterleri tatmin edici bir sonuç vermezse, araştırmacıların göz önünde bulundurması gereken iki alternatif çözüm vardır (Cheah et al., 2018);

İlk olarak; eğer ölçüm modeli uyumu zayıfsa, araştırmacılar öncelikle kalıntı korelasyon matrisini incelemelidir. Kalıntılar 2,5'in altında ise sorun yoktur; yani 2,5–4,0 arasındaki değerler dikkate alınmalı ama genellikle model değişikliğini gerektirmez. Ancak kalıntı 4,0'ın üzerinde ise modelde ciddi uyumsuzluk vardır ve ilgili ögenin çıkarılması gerekebilir. Kalıntılar modelin iyiliğini değerlendirmede tanışal bir araç olarak kullanılır.

İkinci olarak; zayıf model uyumu, araştırmacının modelinin yanlış olduğunu göstermez; aksine, verilerden daha fazla bilgi elde edilebileceğine işaret eder (Jöreskog, 1969). Özellikle bileşik tabanlı veri popülasyonlarında, geleneksel PLS tahmini, yansıtıcı modeller için PLSc'ye kıyasla daha uygun sonuçlar vermektedir. PLSc, örneklem büyüklüğü artsa dahi bileşik tabanlı popülasyonda önyargılı tahminler üretebilir (Sarstedt et al., 2016). Bu nedenle, verilerin doğası bilinmediğinde yansıtıcı ölçüm modellerinin değerlendirilmesinde geleneksel PLS yöntemi tercih edilmelidir. Öte yandan, ortak faktör popülasyonlarından veri tahmini amaçlandığında PLSc, dört veya daha fazla göstergeli modellerde ve yeterli büyüklükteki örneklem (n $\geq$ 250) kullanıldığında, katsayıların ortalama mutlak hatasını azaltarak daha doğru sonuçlar sunmaktadır (Sarstedt et al., 2016).


Modelin uyum iyiliğini gösteren kriterler birleştirilerek Tablo 3'te verilmiştir. Bu bulgular, geleneksel PLS-SEM için, hem doygun (Saturated) hem de tahmin edilen modellerde (Estimated) SRMR, dULS ve dG sonucunun bootstrap dağılımlarının %99 yüzdelik değerlerini aştığı göstermiştir. Bu nedenle aynı örnek Consistent PLS Bootstrapping (Tutarlı Önyükleme) yöntemi ile tekrar analiz edilecek ve sonuçlarda farklılık gösterip göstermediği belirlenecektir.

Tablo.3. Model Uyum Kriterleri

Saturated model	Değer	95%	99%
SRMR	0.077	0.053	0.057
dULS	1.255	0.597	0.689
dG	0.621	0.428	0.462
Estimated model	Değer	95%	99%
SRMR	0.116	0.084	0.093
dULS	2.808	1.481	1.815
dG	0.691	0.446	0.489

Tutarlı önyükleme, tutarlı PLS-SEM (PLSc-SEM) algoritmasını kullanır. Önyükleme, yol katsayıları, Cronbach alfa, HTMT ve R^2 değerleri gibi çeşitli PLS-SEM sonuçlarının istatistiksel önemini test etmeye izin veren parametrik olmayan bir prosedürdür.

Modelin başka bir yöntemle tahminlenmesi için tekrar  Calculate sembolüne tıklanır ve Consistent PLS Bootstrapping yöntemi seçilir. Böylelikle hesaplama başlatılır. Şekil 19'da hesaplama sonucu modelin grafik gösterimi mevcuttur. Yapılan bu hesaplamanın detaylı sonuçları ve geçerlilik değerleri sırasıyla aşağıda gösterilmiştir.



Şekil.19. Hesaplanan PLSc-SEM Modelinin Grafik Çıktısı

Şekil 20 gizil değişkenler arasındaki Path katsayılarını, Şekil 21 ise değişkenler arasındaki dolaylı ilişkileri göstermektedir. Sonuçlara göre tüm gizil değişkenlerin anlamlı olduğu ve Katılım değişkeninin Tahmin üzerindeki etkisi dışındaki tüm değişkenlerin arasındaki ilişki katsayılarında artış olduğu görülmektedir. Ancak aynı artış dolaylı etkiler üzerinde görülmemektedir. Dolaylı etkilerden Cevap Verme boyutunun güvenilirlik ve tatmin üzerinden Sadakat üzerine etkisi dışında tüm dolaylı etkilerde ilk yöntemle göre azalma olduğu görülmüştür.

Path coefficients - Mean, STDEV, T values, p values					
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
Cevap verme -> Güvenilirlik	0.958	0.960	0.033	29.402	0.000
Fiziksel -> Katılım	0.633	0.633	0.062	10.269	0.000
Güvenilirlik -> Tatmin	0.820	0.822	0.054	15.187	0.000
Katılım -> Tatmin	0.221	0.218	0.068	3.246	0.001
Tatmin -> Sadakat	0.904	0.906	0.032	27.903	0.000

Şekil.20. Path Katsayıları Sonuç Ekranı

Specific indirect effects - Mean, STDEV, T values, p values					
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O /STDEV)	P values
Güvenilirlik -> Tatmin -> Sadakat	0.741	0.745	0.054	13.658	0.000
Katılım -> Tatmin -> Sadakat	0.200	0.198	0.063	3.181	0.001
Cevap verme -> Güvenilirlik -> Tatmin	0.785	0.789	0.059	13.261	0.000
Fiziksel -> Katılım -> Tatmin	0.140	0.138	0.046	3.022	0.003
Cevap verme -> Güvenilirlik -> Tatmin -> Sadakat	0.710	0.715	0.059	12.090	0.000
Fiziksel -> Katılım -> Tatmin -> Sadakat	0.127	0.126	0.043	2.959	0.003

Şekil.21. Dolaylı Etkiler Sonuç Ekranı

Şekil 22 ve 23 ise ölçüm modeli ilişkilerini ifade eden gösterge değişkenlerin yüklemeleri ve ağırlıklarını göstermektedir. Gösterge değişkenlerinin yüklerinde ilk yöntemle göre bazı değerlerin yükseldiği bazılarının ise düştüğü görülmektedir. Ancak hepsi anlamlı ve yapının üzerinde orta düzeyde güçlüdür. Gösterge değişken ağırlıkları ise ilk modelle aynı sonuçlara sahiptir.

Outer loadings - Mean, STDEV, T values, p values					
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O /STDEV)	P values
CV2 <- Cevap verme	0.802	0.800	0.050	16.035	0.000
CV3 <- Cevap verme	0.625	0.623	0.054	11.588	0.000
CV4 <- Cevap verme	0.536	0.535	0.059	9.033	0.000
ET2 <- Cevap verme	0.620	0.618	0.070	8.871	0.000
ET3 <- Cevap verme	0.715	0.713	0.059	12.205	0.000
GM1 <- Güvenilirlik	0.747	0.747	0.052	14.451	0.000
GM2 <- Güvenilirlik	0.730	0.731	0.049	14.786	0.000
GM4 <- Güvenilirlik	0.777	0.777	0.047	16.361	0.000
GM5 <- Güvenilirlik	0.781	0.781	0.037	20.856	0.000
KK2 <- Fiziksel	0.901	0.901	0.056	16.174	0.000
KK3 <- Fiziksel	0.913	0.911	0.057	16.072	0.000
KT1 <- Katılım	0.804	0.801	0.060	13.305	0.000
KT2 <- Katılım	0.803	0.801	0.057	14.015	0.000
KT3 <- Katılım	0.808	0.808	0.060	13.408	0.000
SD2 <- Sadakat	0.889	0.887	0.034	25.812	0.000
SD4 <- Sadakat	0.908	0.907	0.036	25.560	0.000
SD5 <- Sadakat	0.755	0.754	0.048	15.625	0.000
SE5 <- Fiziksel	0.679	0.675	0.074	9.190	0.000
TT1 <- Tatmin	0.832	0.832	0.033	25.124	0.000
TT2 <- Tatmin	0.902	0.901	0.025	36.466	0.000

Şekil.22. Gösterge Değişken Yükleri Sonuç Ekranı

Outer weights - Mean, STDEV, T values, p values					
	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
CV2 <- Cevap verme	0.325	0.326	0.026	12.659	0.000
CV3 <- Cevap verme	0.254	0.253	0.020	12.864	0.000
CV4 <- Cevap verme	0.218	0.217	0.020	10.680	0.000
ET2 <- Cevap verme	0.252	0.251	0.024	10.319	0.000
ET3 <- Cevap verme	0.290	0.290	0.021	13.688	0.000
GM1 <- Güvenilirlik	0.298	0.298	0.016	18.546	0.000
GM2 <- Güvenilirlik	0.291	0.291	0.017	17.208	0.000
GM4 <- Güvenilirlik	0.310	0.310	0.018	17.599	0.000
GM5 <- Güvenilirlik	0.312	0.312	0.016	19.809	0.000
KK2 <- Fiziksel	0.404	0.406	0.031	12.963	0.000
KK3 <- Fiziksel	0.409	0.409	0.023	17.757	0.000
KT1 <- Katılım	0.380	0.380	0.027	14.235	0.000
KT2 <- Katılım	0.380	0.380	0.026	14.875	0.000
KT3 <- Katılım	0.382	0.383	0.026	14.880	0.000
SD2 <- Sadakat	0.385	0.385	0.017	22.954	0.000
SD4 <- Sadakat	0.393	0.394	0.018	22.247	0.000
SD5 <- Sadakat	0.327	0.327	0.013	25.933	0.000
SE5 <- Fiziksel	0.304	0.303	0.027	11.343	0.000
TT1 <- Tatmin	0.513	0.513	0.011	46.828	0.000
TT2 <- Tatmin	0.556	0.556	0.015	37.062	0.000

Şekil.23. Gösterge Değişken Ağırlıkları Sonuç Ekranı

İçsel gizil değişkenlerin açıklama gücünü gösteren Tablo 4'te Güvenilirlik değişkeni %91 ile en yüksek açıklama gücüne sahip değişkendir. Katılım ise %39 ile en düşük açıklama gücüne sahiptir. Ancak buna rağmen ilk yöntemle göre daha yüksek değere sahiptir. Tablo 4'teki R^2 değerleri ilk değerler ile karşılaştırıldığında daha yüksek olduğu görülmektedir.

Tablo.4. Değişkenlerin R^2 Değerleri

	R^2	R^2 Adj
Güvenilirlik	0.917	0.917
Katılım	0.401	0.397
Sadakat	0.818	0.817
Tatmin	0.907	0.906

Tablo 5 modelin yakınsak geçerliliğini gösteren AVE, CR ve Cronbach's Alpha değerlerinin bir arada gösteren bir tablodur. Modelin açıklanan varyans değerlerinden Cevap verme değişkeni dışında tüm değerler 0.50'nin üstünde, Cevap verme ise 0.50'nin altındadır. Ancak CR değeri 0.7'den büyük olduğu için tamamen elenmesi gerekmez. Ayrıca tüm değişkenlerin CR, ρ_A ve Cronbach's Alpha değerleri oldukça yüksektir. Böylelikle modelin yakınsak geçerliliğinin sağlanmış olduğu kabul edilebilir.

Tablo.5. Değişkenlerin Yakınsak Geçerlilik Sonuçları

	AVE	CR	Cronbach's Alpha	ρ_A
Cevap verme	0.443	0.809	0.796	0.809
Fiziksel	0.702	0.891	0.874	0.891
Güvenilirlik	0.576	0.845	0.845	0.845
Katılım	0.648	0.847	0.847	0.847
Sadakat	0.728	0.895	0.888	0.895
Tatmin	0.753	0.861	0.859	0.861

Yakınsak geçerliliğinden sonra ayrışma geçerliliğini kontrol etmek için programın sunduğu HTMT değeri incelenir. Şekil 24'te modelin HTMT değerleri yer almaktadır. Tatmin <-> Sadakat (0.902), Güvenilirlik <-> Cevap Verme (0.951) ve Tatmin <-> Güvenilirlik (0.933) sonuçları ile ayrışma geçerliliği sorununun bu yöntemde de devam ettiği görülmektedir. Bu boyutların ankette tekrar gözden geçirilmesi gerekmektedir.

Heterotrait-monotrait ratio (HTMT) - Confidence intervals				
	Original sample (O)	Sample mean (M)	2.5%	97.5%
Fiziksel <-> Cevap verme	0.831	0.832	0.735	0.917
Güvenilirlik <-> Cevap verme	0.951	0.952	0.875	1.016
Güvenilirlik <-> Fiziksel	0.852	0.852	0.738	0.939
Katılım <-> Cevap verme	0.477	0.480	0.339	0.617
Katılım <-> Fiziksel	0.633	0.632	0.503	0.747
Katılım <-> Güvenilirlik	0.513	0.513	0.366	0.647
Sadakat <-> Cevap verme	0.767	0.768	0.674	0.856
Sadakat <-> Fiziksel	0.799	0.799	0.680	0.890
Sadakat <-> Güvenilirlik	0.865	0.867	0.792	0.930
Sadakat <-> Katılım	0.669	0.667	0.539	0.778
Tatmin <-> Cevap verme	0.863	0.863	0.777	0.938
Tatmin <-> Fiziksel	0.836	0.835	0.736	0.916
Tatmin <-> Güvenilirlik	0.933	0.934	0.873	0.987
Tatmin <-> Katılım	0.644	0.643	0.516	0.754
Tatmin <-> Sadakat	0.902	0.903	0.833	0.962

Şekil.24.HTMT Sonuç Ekranı

Son olarak modelin genel uyumunu gösteren Tablo 6'daki Sonuçlar, kavramsal modelin reflektif ilişki için, PLSc-SEM'in geleneksel PLS-SEM'e göre daha iyi bir uyum sergilediğini göstermektedir. Hem doygun hem de

tahmin edilen modeller için PLS'e ait dULS ve dG, bootstrap dağılımlarının %99'luk yüzdelik değerini aşmadığını ortaya koymaktadır. Ayrıca SRMR uyum değerlerinin 0.08 eşik değerinin altında olduğunu göstermiştir. Sonuç olarak PLS-SEM'in uyum iyiliği değerlendirmesinde daha iyi performans gösterdiği görülmektedir.

Tablo.6. Model Uyum Kriterleri

Saturated model	Değer	95%	99%
SRMR	0.061	0.051	0.061
dULS	0.780	0.554	0.784
dG	0.486	0.374	0.516
Estimated model	Değer	95%	99%
SRMR	0.065	0.061	0.071
dULS	0.885	0.787	1.045
dG	0.500	0.392	0.506

PLS-SEM, çeşitli sosyal bilim disiplinlerinde uygulamasını genişleterek metodolojik olarak gelişmeye devam etmektedir. Geliştirilen yeni uyum iyiliği kriterleri sonuçların kapsamlı ve şeffaf bir şekilde raporlanması için, ikincil veri kullanımının artması ise yöntemin daha fazla disiplinde araç olarak kullanılmasına vesile olmaktadır. Bazı eleştiriler mevcut olsa da birçok araştırmacı, özellikle tahmin ve keşifsel modelleme için tamamlayıcı bir SEM tekniği olarak değerini kabul etmektedir. Sonuç olarak, PLS-SEM, dikkatli bir şekilde uygulandığında ve raporlandığında araştırmacılar için değerli bir yöntemdir ve tahmin odaklı ve keşifsel yapısal eşitlik modellemesi için benzersiz yetenekler sunmaktadır. Devam eden metodolojik gelişmeler, PLS-SEM'in kullanılabilirliğini ve uygulama alanlarını artırmaya, sosyal bilimlerin sahip olduğu dezavantajların azalmasına yardımcı olacaktır. Kısıtların ortadan kalkması çalışmaların çeşitlenmesine, sorunların belirlenmesine ve bu sorunların çözümü noktasında fayda sağlayacaktır. Ayrıca ikincil veri üzerinde çalışmayı mümkün kılması, araştırmacıların daha geniş veri setlerinden yararlanarak maliyet ve zaman açısından verimli çalışmalar yürütmesine ve araştırma odağını doğrulayıcı modellemeden nedensel-öngörüsül modellemeye kaydıracaktır.

ÖZET

Bu bölümde son yıllarda sıklıkla kullanılan PLS-SEM yönteminin tanıtımı yapılmış ve SmartPLS programı aracılığı ile çözümü anlatılmaya çalışılmıştır. PLS-SEM çalışmacıları çoğu zaman zorlayan normallik varsayımı gibi her zaman sağlanması mümkün olmayan varsayımlardan muaf olması ve çok

boyutlu problemlerin analizinde kullanılabilmesi nedeniyle araştırmacılara kolaylık sağlayan bir modeldir. Bu nedenle birçok alanda olduğu gibi ekonometrik çalışmalarda da sıklıkla kullanılmaktadır.

Ayrıca, PLS-SEM yalnızca sosyal bilimlerde değil, pazarlama, sağlık, mühendislik ve bilgi sistemleri gibi farklı disiplinlerde de yaygın olarak tercih edilmektedir. Özellikle örneklem boyutunun kısıtlı olduğu ya da model yapısının karmaşık olduğu durumlarda, klasik SEM yöntemlerine göre daha avantajlıdır.

Doğru yaklaşım izlendiğinde, PLS-SEM yöntemi değişkenler arası ilişkileri detaylı ve toplu olarak incelemeye olanak tanır. Ayrıca grafik gösterimi sayesinde çıktıların yorumlanması kolaylaşır. Ölçüm ve yapısal modellerin ayrı ayrı değerlendirilmesi, modelin güvenilirliğini artırmakta ve hipotezlerin istatistiksel olarak anlamlı biçimde test edilmesini sağlamaktadır.

Model analizleri için üretilmiş kullanıcı dostu paket programların varlığı da yöntemin tercih edilmesine katkı sağlamıştır. SmartPLS yazılımı, görsel modelleme arayüzü ve ileri düzey istatistiksel analiz seçenekleri sayesinde kullanım kolaylığı sunmaktadır. Bu kolaylığına rağmen yine de model kurma aşamalarında titiz davranılması ve uyum kriterlerinin dikkate alınması gerekmektedir.

Kaynaklar

- Bagozzi, R. P. (2007). On the meaning of formative measurement and how it differs from reflective measurement: Comment on Howell, Breivik, and Wilcox (2007).
- Bollen, K., & Lennox, R. (1991). Conventional wisdom on measurement: A structural equation perspective. *Psychological bulletin*, 110(2), 305.
- Bollen, K. A. (1989). *Structural equations with latent variables*. John Wiley & Sons.
- Bulut, E., & Alın, A. (2009). Kısmi En Küçük Kareler Regresyon Yöntemi Algoritmalarından Nipals ve Pls-Kernel Algoritmalarının Karşılaştırılması Ve Bir Uygulama. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 24(2), 127-138.
- Cheah, J.-H., Memon, M. A., Chuah, F., Ting, H., & Ramayah, T. (2018). Assessing reflective models in marketing research: A comparison between pls and plsc estimates. *International Journal of Business & Society*, 19(1).
- Chin, W. W. (1998). The partial least squares approach to structural equation modeling. *Modern methods for business research*, 295(2), 295-336.
- Cokluk, O., Sekercioglu, G., & Büyüköztürk, S. (2010). Sosyal bilimler için çok degiskenli istatistik SPSS ve LISREL uygulamaları. *Ankara: Pegem Akademi*.
- Diamantopoulos, A. (2006). The error term in formative measurement models: interpretation and modeling implications. *Journal of modelling in management*, 1(1), 7-17.
- Dijkstra, T. K., & Henseler, J. (2015). Consistent partial least squares path modeling. *MIS quarterly*, 39(2), 297-316.
- Efron, B. (1987). Better bootstrap confidence intervals. *Journal of the American statistical Association*, 82(397), 171-185.
- Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of marketing research*, 18(1), 39-50.
- Götz, O., Liehr-Gobbers, K., & Krafft, M. (2009). Evaluation of structural equation models using the partial least squares (PLS) approach. In *Handbook of partial least squares: Concepts, methods and applications* (pp. 691-711). Springer.
- Grace, J. B., & Bollen, K. A. (2008). Representing general theoretical concepts in structural equation models: the role of composite variables. *Environmental and Ecological Statistics*, 15, 191-213.
- Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. (2006). Multivariate data analysis . Uppersaddle River. In: NJ: Pearson Prentice Hall.

- Hair, J. F., Hult, G., Ringle, C. M., & Sarstedt, M. (2017a). A primer on partial least squares structural modelling (PLS-SEM). *International Journal of Research & Method in Education*, 38(2).
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European business review*, 31(1), 2-24.
- Hair, J. F., Sarstedt, M., Hopkins, L., & G. Kuppelwieser, V. (2014). Partial least squares structural equation modeling (PLS-SEM) An emerging tool in business research. *European business review*, 26(2), 106-121.
- Hair, J. F., Sarstedt, M., & Ringle, C. M. (2019). Rethinking some of the rethinking of partial least squares. *European journal of marketing*, 53(4), 566-584.
- Heise, D. R. (1972). Employing nominal variables, induced variables, and block variables in path analyses. *Sociological methods & research*, 1(2), 147-173.
- Henseler, J. (2017). Partial least squares path modeling. In *Advanced methods for modeling markets* (pp. 361-381). Springer.
- Henseler, J., Hubona, G., & Ray, P. A. (2016a). Using PLS path modeling in new technology research: updated guidelines. *Industrial Management & Data Systems*, 116(1), 2-20.
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the academy of marketing science*, 43, 115-135.
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2016b). Testing measurement invariance of composites using partial least squares. *International marketing review*, 33(3), 405-431.
- Höskuldsson, A. (1988). PLS regression methods. *Journal of chemometrics*, 2(3), 211-228.
- Hu, L.-t., & Bentler, P. M. (1998). Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological methods*, 3(4), 424.
- Jarvis, C. B., MacKenzie, S. B., & Podsakoff, P. M. (2003). A critical review of construct indicators and measurement model misspecification in marketing and consumer research. *Journal of consumer research*, 30(2), 199-218.
- Jöreskog, K. G. (1969). A general approach to confirmatory maximum likelihood factor analysis. *Psychometrika*, 34(2), 183-202.
- Kline, R. B. (2006). Reverse arrow dynamics: Formative measurement and feedback loops. *Structural equation modeling: A second course*, 43-68.
- Lee, N., & Cadogan, J. W. (2013). Problems with formative and higher-order reflective variables. *Journal of Business Research*, 66(2), 242-247.
- Lohmöller, J.-B. (1989). *Latent Variable Path Modeling with Partial Least Squares*.

- Marcoulides, G. A., Chin, W. W., & Saunders, C. (2009). Foreword: a critical look at partial least squares modeling. *MIS quarterly*, 33(1), 171-175.
- Mueller, R. O., & Hancock, G. R. (2018). Structural equation modeling. In *The reviewer's guide to quantitative methods in the social sciences* (pp. 445-456). Routledge.
- Olmez, A. (2018). *Partial least squares method for the analysis of gene expression data* Dokuz Eylul Universitesi (Turkey)].
- Rigdon, E. E. (2012). Rethinking partial least squares path modeling: In praise of simple methods. *Long range planning*, 45(5-6), 341-358.
- Ringle, C., Wende, S., & Becker, J. (2024). SmartPLS 4. Bönningstedt: SmartPLS. Retrieved from <https://www.smartpls.com>. In.
- Rönkkö, M., & Evermann, J. (2013). A critical examination of common beliefs about partial least squares path modeling. *Organizational Research Methods*, 16(3), 425-448.
- Sarstedt, M., Hair, J. F., Ringle, C. M., Thiele, K. O., & Gudergan, S. P. (2016). Estimation issues with PLS and CBSEM: Where the bias lies! *Journal of Business Research*, 69(10), 3998-4010.
- Sarstedt, M., Ringle, C. M., & Hair, J. F. (2017). Treating unobserved heterogeneity in PLS-SEM: A multi-method approach. In *Partial least squares path modeling: Basic concepts, methodological issues and applications* (pp. 197-217). Springer.
- Shmueli, G. (2010). To explain or to predict? *Statistical science*, 289-310.
- Shmueli, G., Ray, S., Estrada, J. M. V., & Chatla, S. B. (2016). The elephant in the room: Predictive performance of PLS models. *Journal of Business Research*, 69(10), 4552-4564.
- Sümer, N. (2000). Yapısal Eşitlik Modelleri: Temel Kavramlar ve Örnek Uygulamalar. *Türk Psikoloji Yazıları*.
- Şencan, H. (2005). Sosyal ve davranışsal ölçümlerde geçerlilik ve güvenirlik. *Ankara: Seçkin Matbaası*.
- Tenenhaus, M. (2004). PLS regression and PLS path modeling for multiple table analysis. COMPSTAT 2004—Proceedings in Computational Statistics: 16th Symposium Held in Prague, Czech Republic, 2004,
- Türkyılmaz, A., & Özkan, C. (2007). Development of a customer satisfaction index model: An application to the Turkish mobile phone sector. *Industrial Management & Data Systems*, 107(5), 672-687.
- Vinzi, V. E., Trinchera, L., & Amato, S. (2009). PLS path modeling: from foundations to recent developments and open issues for model assessment and improvement. *Handbook of partial least squares: Concepts, methods and applications*, 47-82.

- Westland, J. C. (2015). Partial least squares path analysis. In *Structural equation models: From paths to networks* (pp. 23-46). Springer.
- Wold, H. (1966). Estimation of principal components and related models by iterative least squares. *Multivariate analysis*, 391-420.