

## Birinci Tür Hata'nın Kontrolü ve Adımsal (Stepwise) Çoklu Kar ıla tırma Testleri

Nurhan DO AN<sup>1</sup>, smet DO AN<sup>1</sup>

### ÖZET

Varyans Analizi, ikiden çok ortalamanın kar ıla tırılmasında, ortalamalar arasında fark olup olmadığını belirlemekte, ancak bu farklılı ın nereden kaynaklandığını belirleyememektedir. Çoklu kar ıla tırma yöntemleri ortalamalar arasındaki farklılıklar hakkında çok daha detaylı bilgi vermektedir. Bu amaçla çok sayıda çoklu kar ıla tırma testi önerilmiştir. Ancak hangi durumda hangi testin kullanılacağına karar vermek kolay değildir. Bu çalışmada amaç, son yıllarda daha yoğun olarak kullanılmaya başlanan ancak ara tırmacılar tarafından daha az bilinen yedi farklı adımsal çoklu kar ıla tırma testlerini tanıtmaktır.

**Anahtar Kelimeler:** Varyans analizi; birinci tür hata; adımsal çoklu kar ıla tırma yöntemleri.

### The Control of Type I Error Rate and Stepwise Multiple Comparison Procedures: A Review

#### ABSTRACT

Analysis of variance determines whether the difference between averages when more than two averages compare, but it cannot determine origin of this difference. Detailed information about the difference between means is derived by using multiple comparison tests. Many different tests have been suggested for this purpose. The present article reviews of stepwise multiple comparison procedures. The review was motivated by examples of multiple comparison practices. Making a decision about which test to use is not easy task. The aim of this study is to introduce seven different stepwise multiple comparison tests which are less known by the researchers.

**Keywords:** Analysis of variance; type I error rate; stepwise multiple comparison procedure.

#### GİRİŞ VE AMAÇ

Varyans analizi, ikiden çok ortalamanın kar ıla tırılmasında, ortalamalar arasında fark olup olmadığını belirlemekte, ancak farklılı ın kaynağını belirleyememektedir. Çoklu kar ıla tırma yöntemleri ise üç ya da daha fazla denemenin hangisinin daha iyi hangisinin daha kötü olduğuna karar verebilmek, ortalama etkilerini kar ıla tırmak, yanlış bir karar verme olasılı ının kontrol edilmesinde hangi denemenin ne kadar daha iyi ya da ne kadar daha kötü olduğuna karar vermektir.

Rao ve Swarupchand (1)'a göre çoklu kar ıla tırma terimi bir grup içindeki varyanslar, oranlar ya da ortalamalar arasındaki farklılı ın istatistiksel anlamlılığı için yapılan testleri ifade etmektedir. Çoklu kar ıla tırma yöntemleri, çokluluk etkisinden kaynaklanan hatalı sonuç çıkarmaların düzenli kontrolünü göz önünde bulunduran istatistiksel yöntemlerdir. Çoklu kar ıla tırma yöntemleri uygulamalardaki önemliliğinden dolayı temel bir problemdir ve farklı yollarla kullanıcılara yol göstermektedirler. Ara tırmacıların amacına göre literatürde görülen dört tip çoklu kar ıla tırma yöntemi söz konusudur. Bunlar;

- Tüm ikili çoklu kar ıla tırmalar (**all-pairwise multiple comparison (MCA)**,  $i, j$  olmak üzere tüm  $\mu_i - \mu_j$  farklarının kar ıla tırılması dikkate alınmaktadır),
- En iyi ile çoklu kar ıla tırmalar (**multiple comparison with the best (MCB)**,  $i, j$  ve  $i=1,2,\dots,k$  olmak üzere tüm  $\mu_i - \max_j \mu_j$  farklarının kar ıla tırılması dikkate alınmaktadır),

<sup>1</sup> Afyon Kocatepe Üniversitesi, Tıp Fakültesi, Biyoistatistik Anabilim Dalı - AFYONKARAH SAR

**Correspondence:** Dr. Nurhan DO AN, e-posta: ndogan@aku.edu.tr

- Bir kontrol ile çoklu karılaştırmalar (multiple comparison with a control (MCC),  $i=1,2,\dots,k-1$  olmak üzere tüm  $\mu_i-\mu_k$  farklarının karılaştırılması dikkate alınmaktadır),
- Ortalama ile çoklu karılaştırmalar (multiple comparison with the mean (MCM),  $i=1,2,\dots,k$  olmak üzere tüm  $\mu_i-\mu$  farklarının karılaştırılması dikkate alınmaktadır).

Çoklu karılaştırma konusunun istatistiksel olarak en çok karışıklık yaratan konulardan biri olduğu ve bu konu ile ilgili literatürde oldukça farklı önerilerin bulunduğu ifade edilmektedir (2). Halen bir grup ortalamasının çoklu karılaştırma sonuçları gerçeğe yansırken hangi yöntemin hangi durumda kullanılması gerektiği konusunda görüş birliği bulunmamaktadır. Araştırmacılar, biraz farklı gerekçelerle de olsa kendi tercihlerini yaparak benzer problemlerin çözülmesinde farklı çoklu karılaştırma sonuçları kullanmaktadırlar (3).

Araştırmacılar, literatürde yer alan klasik çoklu karılaştırma testlerini kullanırken gerçekte çoklu karılaştırma testlerinin kullanılmasının bir sonucu olarak ortaya çıkan birinci tür hatanın kontrolüne ilişkin önemli kararlar ile yüz yüze kalmaktadırlar. Bir araştırmada, ilk önce anlamlılık düzeyinin ( $\alpha$ ) belirlenmesi gerekmektedir. Anlamlılık düzeyinin, araştırmacının doğasına uygun olarak belirlenmesi gerekirken pratikte kabul edilmiş bazı anlamlılık düzeyleri araştırmacılar tarafından kullanılmaktadır. İkinci olarak araştırmacılar, analiz edilecekleri hata oranını (karılaştırma başarıma veya deneysel ortak hata oranı) belirlemek durumundadırlar. Karılaştırma başarıma hata oranı ( $\alpha_{PC}$ ), belirlenen anlamlılık düzeyinde her bir karılaştırma için yokluk hipotezinin yanlışlıkla reddedilmesi olasılığını göstermektedir.  $\alpha_{PC}$ 'nin en önemli dezavantajı, karılaştırma sayısının ( $m$ ) artması ile paralel olarak dezinin yaklaşık  $1-(1-\alpha)^m$  kadar artmasıdır. Bu dezavantajından dolayı  $\alpha_{PC}$  ile ilgili eleştiride bulunanlar  $\alpha_{PC}$  yerine deneysel ortak hata oranının ( $\alpha_{FW}$ ) kontrol edilmesini önermektedirler.  $\alpha_{FW}$  dezinin kontrolü ile hipotezler ailesindeki bir ya da daha fazla hipotezin yanlışlıkla reddedilmesi olasılığı  $\alpha$ , belirlenen anlamlılık düzeyine ayarlanmaktadır.  $\alpha_{FW}$  dezinin kontrolü ile ilgili sonuçların temel avantajı, karılaştırma sayısının artması ile paralel olarak  $\alpha_{FW}$  dezinin artmamasıdır (4).

Tukey (5), karılaştırma sayısına bağlı olarak 0.05'lik eş zamanlı hata oranının sırasıyla; 6 karılaştırma için %1, 10 karılaştırma için %0.5, 21-28 karılaştırma için %0.2, 45-55 karılaştırma için %0.1, 105 karılaştırma için %0.05, 253 karılaştırma için %0.02, 496 karılaştırma için %0.01 ve 990 karılaştırma için %0.005 karılaştırma başarıma hata oranına karşılık geldiğini ifade etmektedir.

Bir örnek ile deneysel ortak hata kavramı daha iyi anlaşılabilir hale getirilebilir. Örneğin, dört grup olsun ve ikili olarak bu gruplara ait ortalamaların karılaştırılması istensin. Bu durumda altı farklı ikili karılaştırma söz konusudur. Altı farklı ikili karılaştırmanın söz konusu olduğu bu kümeyle aile (family) denmektedir. Eş anlamlılık seviyesinde her bir ikili karılaştırma için t testi kullanılırsa, sadece her bir karılaştırma için anlamlılık seviyesinin sağlanması garanti edilmiş olur, tüm aile için bu durum söz konusu değildir. Bundan dolayı deneysel

ortak hatanın kontrol edilmesinde çoklu karılaştırma testlerinin kullanılması gereklidir.

Bir araştırmada, araştırmacı tarafından kullanılacak hata oranı ve anlamlılık düzeyi belirlendikten sonra uygun bir, çoklu karılaştırma testi seçilmelidir. Literatürde yer alan çoklu karılaştırma testleri ya eş zamanlı (simultaneously) ya da adımsal (stepwise) olarak çoklu karılaştırma sonuçlarını gerçeğe yansıtmaktadır. Eş zamanlı çoklu karılaştırma sonuçlarında tüm ikili karılaştırma sonuçları sabit bir anlamlılık düzeyi dikkate alınırken, adımsal çoklu karılaştırma testlerinde ikili karılaştırma sonuçlarının her biri için anlamlılık düzeyi yeniden belirlenmektedir.

Adımsal ve eş zamanlı çoklu karılaştırma testleri karılaştırma sonuçlarında deneysel ortak hata oranının kontrol edilmesinde daha etkin olması, hipotezler arasında mantıksal ilişkiler olması durumunda daha çok güce sahip olması ve yalnızca sürekli verilere değil aynı zamanda sıralı ve kategorik verilere de uygulanabilmesi gibi özelliklerinden dolayı adımsal testler öne çıkmaktadır (6). Bu çalışmada amaç, son yıllarda daha yoğun olarak kullanılmaya başlanan ancak araştırmacılar tarafından daha az bilinen adımsal çoklu karılaştırma testlerini tanıtmaktır.

### 1. Adımsal (Stepwise) Çoklu Karılaştırma Testleri

Eş zamanlı yürütülen çoklu karılaştırma testlerinin olması durumunda birinci tür hatanın kontrol edilmesi konusu tartışılan bir konudur. Bu kontrolün sağlanmasında, ayrı ayrı hipotezlerin test edilmesinde kullanılan önemlilik seviyesi, test edilen hipotez sayısı dikkate alınarak uyarlanmaktadır. En basit ve belki en iyi bilinen uyarılama sonucu, genel olarak kabul edilebilir birinci tür hata riskinin test edilen hipotez sayısına bölünmesidir. Bu yaklaşım Etkilik [1] ile verilen Bonferroni eşitsizliği üzerine yapılandırılmaktadır.

$$\Pr\{\sum_{i=1}^m (P_i \leq \alpha/m)\} \quad [1]$$

Bonferroni eşitsizliğinde,  $0 < \alpha < 1$ 'dir ve  $m (i = 1,2,\dots,m)$  test edilecek hipotez sayısını göstermektedir. Etkilik 1 orijinal Bonferroni sonucu olarak isimlendirilir. Bonferroni sonucunun iki avantajından biri, uygulanmasının kolay olmasıdır. İkinci ise çok farklı çoklu test durumlarında kullanılabilir olmasıdır. Sonucunun dezavantajı ise her bir hipotezi ayrı ayrı reddetme gücünün düşük olmasıdır (7). Orijinal Bonferroni sonucunun çok sayıda uyarılama hali geliştirilmiş ve uygulanmaktadır. Bonferroni'ye alternatif olarak uyarılama durumlarından altı tanesi literatürde oldukça yoğun olarak kullanılmaktadır. Bunlar sırasıyla; Holm (8), Shaffer (9), Holland ve Copenhaver (10), Hochberg (11), Hommel (12) ve Rom (13) tarafından geliştirilmiş yöntemlerdir. Bonferroni sonucunun uyarlamaları olan bu yöntemlerin amacı, tümel (overall) olarak birinci tür hata riskini artırmadan ayrı ayrı testler için gücü artırmaktır.

Dunnnett ve Tamhane (14) önemlilik seviyelerini düzeltmek için geliştirilen yöntemleri tek adımlı (single step), azalan adımlı (step down) ve artan adımlı (step up) yöntemler olarak üç farklı şekilde kategorize etmişlerdir. Tek adımlı sonucunda (orijinal Bonferroni) olası tüm hipotezlerin ayrı ayrı testi için tek bir kriter kullanılmaktadır. Azalan ve artan adımlı yöntemlerde ise test edilecek hipotezler kendi  $p$

de erlerine göre sıralanır. Azalan  $\alpha$  amalı yöntemlerde (Holm, Shaffer, Holland ve Copenhaver yöntemleri) teste en küçük  $p$  de erine sahip hipotez ile başlanırken, artan  $\alpha$  amalı yöntemlerde (Hochberg, Hommel ve Rom yöntemleri) teste en büyük  $p$  de erine sahip hipotez ile başlanmaktadır. Artan  $\alpha$  amalı yöntemler bağımsızlık testleri için Simes (15) tarafından ispatlanan eşitsizlik üzerine oturmaktadırlar. Simes (15) tarafından,  $H_0 = \{H_{(1)}, H_{(2)}, \dots, H_{(m)}\}$  hipotezlerine sırasıyla karşılık gelen ve  $p$  de erlerini gösteren  $p_{(1)}, p_{(2)}, \dots, p_{(m)}$  de erleri için,

$$\Pr\{i=1, \dots, m \mid P_{(i)} \leq j/m\} \leq (0 \leq j \leq 1) \quad [2]$$

eşitsizliğin geçerli olduğu ispatlanarak  $P_{(j)} \leq j/m$  olması durumunda  $j=1, 2, \dots, m$  için  $H_0$  hipotezinin reddedildiği gösterilmiştir. Bonferroni leminin bir uyarlaması olan bu leminde de birinci tür hata olasılığı bağımsız testler için de erine eşittir.

Bu çalışmada, genel olarak birinci tür hata oranını,  $\alpha$  test edilecek hipotezlerin her biri için ayrı ayrı kullanılacak birinci tür hata oranını ve  $P_{(i)}$  ise  $H_{(i)}$   $i=1, 2, 3, \dots, m$  olmak üzere test edilecek  $m$  tane hipoteze karşılık gelen gözlenen  $P$  de erlerini gösterecektir.

Wright (16), gözlenen  $P$  de erinin  $P'$  olarak düzeltilmesini önermiştir. Wright, herhangi bir hipotez için düzeltilmiş  $P$  de erini, genel olarak kurulabilecek hipotezlerin tamamı arasında reddedilen hipotezlere ait en küçük önemlilik seviyesi olarak tanımlamıştır.  $m$  tane hipotezin orijinal Bonferroni lemi ile test edildiği durumda  $P'_{(i)} = mP_{(i)}$  dir. Her bir düzeltilmiş  $P$  de eri istenen önemlilik seviyesi ile karşılaştırılmalı ve  $P'_{(i)}$  ise hipotez reddedilmelidir. Düzeltilmiş  $P$  de eri sabitlenmiş yaklaşıma karşı sonuçların hangi önemlilik seviyesinde olduğu unun gösterilmesini sağlar.

### 1.1. Orijinal Bonferroni lemi (Tek $\alpha$ amalı)

Orijinal Bonferroni leminde  $\alpha' = \alpha/m$  olarak hesaplanır. Her bir  $H_{(i)}$  hipotezi  $P_{(i)} < \alpha'$  ise reddedilir. Böylece genel olarak birinci tür hata oranı test edilecek mümkün tüm hipotezler arasında eşit olarak bölünmüş olur.

### 1.2. Holm lemi (Azalan $\alpha$ amalı)

Holm (8), reddedilen her bir hipotez için ardıcıl olarak düzenlenen farklı anlamlılık seviyeleri önermiştir.  $H_{(1)}, H_{(2)}, \dots, H_{(m)}$  hipotezlerine karşılık gelen ve  $p$  de erlerini gösteren  $P_{(1)}, P_{(2)}, \dots, P_{(m)}$  de erleri sırasıyla en büyükten en küçüğe do ru sıralansın. Holm'un önerdiği leme göre ilk önce  $p_{(m)} \leq \alpha/m$  olup olmadığına bakılır. Eğer bu koşul sağlanıyorsa diğer hipotezlere bakılmaz. Ters durumda  $H_{(m)}$  reddedilir ve sonraki hipotezin testine geçilir. Bu durumda  $P_{(m-1)} \leq \alpha/(m-1)$  olup olmadığına bakılır. Eğer bu koşul sağlanıyorsa diğer hipotezlere bakılmaz. Ters durumda  $H_{(m-1)}$  reddedilir ve sonraki hipotez olan  $H_{(m-2)}$  hipotezinin test edilmesine geçilir. Süreç bu şekilde devam ettirilerek ya sonraki adıma geçilir ya da hipotezlerin test edilmesi lemi sonlandırılır. Holm'un önerdiği ardıcıl artan kriter ile istatistiksel anlamlılık için istatistiksel güç kazanılır. Çünkü orijinal Bonferroni lemi ile reddedilen herhangi bir hipotez Holm lemi ile de reddedilmi olacaktır.

### 1.3. Shaffer lemi (Azalan $\alpha$ amalı)

Shaffer (9), testin herhangi bir  $\alpha$  amasındaki do ru yokluk hipotezine ait maksimum sayının sıklıkla, Holm leminde payda da yer alan  $m-i+1$  ( $i=1, 2, \dots, m$ ) taneden az olduğunu göstermiştir. Shaffer tarafından önerilen leme göre, test edilecek  $H_0: \mu_1 = \mu_2, H_0: \mu_1 = \mu_3$  ve  $H_0: \mu_2 = \mu_3$  ekindeki üç hipotezden eşer  $H_0: \mu_1 = \mu_2$  hipotezi yanlı ise diğer iki hipotezden de en az biri yanlıdır. Bu durum dikkate alınarak  $k$  de eri karşılaştırılacak grup sayısını göstermek üzere  $k = 3, \dots, 10$  için Schaffer tarafından do ru yokluk hipotezlerinin mümkün maksimum sayılarını içeren bir tablo hazırlanmıştır. Schaffer, Holm lemine katkıda bulunan iki öneri sunmuştur.

Shaffer'ın birinci lemine göre;  $H_0 = \{H_{(1)}, H_{(2)}, \dots, H_{(m)}\}$  hipotezlerine karşılık gelen ve  $P$  de erlerini gösteren  $P_{(1)}, P_{(2)}, \dots, P_{(m)}$  de erleri sırasıyla en küçükten en büyüğe do ru sıralansın.  $t_i$  de eri  $m$  tane hipotezden en az  $i-1$  tanesinin yanlı olduğu varsayılarak mümkün do ru yokluk hipotezlerinin maksimum sayısı olarak tanımlanmaktadır. Eğer  $t_i^*, p_{(i^*)} > \alpha/t_i^*$  'i sağlayan en küçük tamsayı ise  $H_{(1)}, \dots, H_{(i^*-1)}$  hipotezleri reddedilir.

Shaffer'ın ikinci lemine göre ise;  $t_i$  de eri  $m$  tane hipotezden spesifik  $H_{(1)}, \dots, H_{(i-1)}$  hipotezlerinin yanlı olduğu varsayılarak mümkün do ru yokluk hipotezlerinin maksimum sayısı olarak tanımlanmaktadır. Bu durumda  $t_i$  de erinin birinci leminde kullanılacak de ere göre daha küçük olması söz konusudur. Shaffer'ın önerilerinden ikincisini gerçekleştirmek birincisine göre daha zor olmasına rağmen testin gücünün artmasını sağlamaktadır. Bir örnek ile Shaffer tarafından önerilen ikinci yöntemin daha iyi anlaşılması sağlanabilir. Dört grup ve bu grupların ortalamaları arasında  $X_A < X_B < X_C < X_D$  biçiminde bir sıralama söz konusu olsun. İlk karşılaştırma için

$H_0: X_A = X_D$  yokluk hipotezi kurulur. Yönteme göre mümkün do ru olabilecek maksimum sayıda  $H_0$  aranması gerekmektedir. Buna göre;  $H_0: X_A = X_D, H_0: X_A = X_C, H_0: X_A = X_B, H_0: X_B = X_D, H_0: X_B = X_C$  ve  $H_0: X_C = X_D$  hipotezleri do ru olabilir. Görüldüğü üzere birinci  $\alpha$  amada dikkate alınması gereken maksimum sayıdaki do ru olabilecek hipotez sayısı 6'dır. Eğer  $H_0: X_A = X_D$  hipotezi reddedilirse ya  $H_0: X_B = X_D$  ya da  $H_0: X_A = X_C$  hipotezinin test edilmesi gerekmektedir.  $H_0: X_A = X_C$  hipotezinin test edilmesi durumunda;  $H_0: X_A = X_C, H_0: X_A = X_B$  ya da  $H_0: X_B = X_C$  hipotezleri do ru olabilir.  $H_0: X_A = X_C$  hipotezinin reddedilmesi durumunda  $H_0: X_B = X_D$  hipotezinin de test edilmesi gerekir. Bu durumda;  $H_0: X_B = X_D, H_0: X_B = X_C$  ya da  $H_0: X_C = X_D$  hipotezleri do ru olabilir. Buradan da anlaşılacağı üzere ikinci  $\alpha$  amada dikkate alınacak maksimum sayıdaki do ru olabilecek hipotez sayısı 3'tür. Eğer ikinci  $\alpha$  ama sonucunda hem  $H_0: X_A = X_C$  hem de  $H_0: X_B = X_D$  hipotezleri reddedilirse üçüncü  $\alpha$  amaya geçilir. Bu  $\alpha$  amada geriye kalan  $H_0: X_A = X_B, H_0: X_B = X_C$  ya da  $H_0: X_C = X_D$  hipotezlerinden herhangi biri test edilebilir. Dolayısıyla üçüncü  $\alpha$  amada maksimum sayıda do ru olabilecek hipotez sayısı yine 3'tür. Dördüncü  $\alpha$  amada dikkate alınması gereken maksimum sayıda do ru olabilecek hipotez sayısının 2, beinci  $\alpha$  amada ise 1 olacağı açıktır.

#### 1.4. Holland-Copenhaver lemi (Azalan A amalı)

Holland ve Copenhaver (10), Sidak (17) tarafından geliştirilen,  $m$  kararla tırılacak hipotez sayısını göstermek üzere  $\alpha/m = 1 - (1 - \alpha)^{1/m}$  ile itli ini kullanarak her bir hipotez testi için bir kriter hazırlanmıştır.  $H_{(1)}, H_{(2)}, \dots, H_{(m)}$  hipotezlerine karşılık gelen ve  $P$  değerlerini gösteren  $p_{(1)}, p_{(2)}, \dots, p_{(m)}$  değerleri sırasıyla en küçükten en büyüğe doğru sıralansın.  $p_{(i)} > 1 - (1 - \alpha)^{1/(m-i+1)}$  olacak şekilde  $1$  ile  $m$  arasındaki en küçük tamsayı değer  $i$  olsun. Bu durumda Holland-Copenhaver lemine göre  $H_{(m)}$ 'ye karşı  $H_{(i)}$ 'ye dokunulmaksızın  $H_{(i-1)}$ 'e karşı  $H_{(1)}$  reddedilir. Holland ve Copenhaver leminde kullanılan kriter, Holm leminde kullanılan kriterden biraz daha geniştir, bundan dolayı ayrı ayrı her bir hipotez testi için güç biraz daha fazladır.

#### 1.5. Hochberg lemi (Artan A amalı)

Hochberg (11), Simes (15) ile itli i üzerine oturtulmuş bir artan a amalı yöntem geliştirmiştir.  $H_{(1)}, H_{(2)}, \dots, H_{(m)}$  hipotezlerine karşılık gelen ve  $p$  değerlerini gösteren  $p_{(1)}, p_{(2)}, \dots, p_{(m)}$  değerleri sırasıyla en küçükten en büyüğe doğru sıralansın.  $p_{(1)}, p_{(2)}, \dots, p_{(m)}$  değerleri düzeltilmiş önemlilik seviyelerini göstermek üzere  $\alpha_{(m)}, \alpha_{(m-1)}, \dots, \alpha_{(1)}$  ise tüm hipotezler reddedilir. Aksi durumda,  $H_{(m)}$  alıkonularak  $p_{(m-1)}$  değeri  $\alpha_{(m-1)}$  ile karşılaştırılır. Eğer  $p_{(m-1)} > \alpha_{(m-1)}$  ise geri kalan tüm hipotezler reddedilir. Eğer bu da sağlanmaz ise  $H_{(m-1)}$  değeri alıkonularak  $p_{(m-2)}$  değeri  $\alpha_{(m-2)}$  değeri ile karşılaştırılır ve süreç bu şekilde sürdürülür. Hochberg lemi için,  $\alpha_{(m)} = \alpha, \alpha_{(m-1)} = \alpha/2, \dots, \alpha_{(1)} = \alpha/m$  dir. Hipotezlerin test edilmesinde en büyük  $p$  değeri ile başlanması durumunda Hochberg lemi her bir hipotez için Holm lemi ile aynı kriteri kullanmaktadır. Sonuç olarak, Hochberg lemi Holm lemi ile reddedilen hipotezleri benzer şekilde reddederken Holm lemi ile incelenmeyen ancak reddedilmesi mümkün hipotezleri de test eder.

#### 1.6. Hommel lemi (Artan A amalı)

Hommel (12) lemi de Simes (15) ile itli i üzerine oturtulmuştur. Lem düzeltilmiş kritik değerleri iki a amada belirlemektedir.  $J = \{i' \in \{1, 2, \dots, m\} : p_{(m-i'+k)} > k/i'; k=1, 2, \dots, i'\}$  olsun. Lemnin ilk a amasında elde edilen  $p$  değerleri kullanılarak  $J$ 'nin eleman sayısı belirlenir. İkinci a amada  $j'$   $J$ 'nin en büyük değeri olmak üzere  $j' = |J|$  kullanılarak reddetmede kullanılacak anlamlılık seviyesi elde edilir. Eğer  $J$  boş ise tüm  $H_{(i)}$  ( $i=1, 2, \dots, m$ ) hipotezleri reddedilir. Eğer  $J$  boş değilse  $p_{(i)} > j'/i'$  oldu u sürece  $H_{(i)}$  reddedilir.

Örnek bir uygulama ile Hommel lemi anlamlı hale getirilebilir. Küçükten büyüğe doğru sıralanmış  $p$  değerleri sırasıyla  $p_{(1)}=0.0011, p_{(2)}=0.0145, p_{(3)}=0.0291$  ve  $p_{(4)}=0.0562$  olsun.  $\alpha=0.05$  anlamlılık seviyesinde test edilecek olan dört tane ( $m=4$ ) hipotezin olduğu varsayalım. Birinci a amadaki  $j'$  değerinin belirlenmesi  $k$  değerine göre karar verilecek olan bir veya daha fazla sayıda test içerebilir ve birkaç basamak gerektirebilir. Birinci adımda  $i'=1$  alınır ve  $i'$  her bir adım için birer birer artırılır (her bir adım içinde  $k=1, 2, \dots, i'$ ).

Birinci adım yalnızca bir test içerir.  $m=4, i'=1, k=1$  alındığında  $p_{(m-i'+k)} = p_{(4-1+1)} = p_{(4)} = 0.0562$  olur. Kritik değer ise  $k/i' = 1(0.05)/1 = 0.05$ 'tir.  $p_{(4)} > 0.05$  oldu undan

$i$  lemi  $j'=1$  alınarak devam ettirilir.

İkinci adım iki test içerir. İkinci adımdaki ilk test için,  $i'=2, k=1$  alındığında  $p_{(m-i'+k)} = p_{(4-2+1)} = p_{(3)} = 0.0291$  olur.  $k/i' = 1(0.05)/2 = 0.025$ 'tir.  $p_{(3)} > 0.025$  oldu undan  $i$  lemi devam eder. İkinci adımdaki ikinci test için  $i'=2, k=2$  alındığında  $p_{(m-i'+k)} = p_{(4-2+2)} = p_{(4)} = 0.0562$  olur. Kritik değer ise  $k/i' = 2(0.05)/2 = 0.05$ 'tir. Hem  $p_{(3)} > 0.025$  hem de  $p_{(4)} > 0.05$  oldu undan  $i$  lemi  $j'=2$  alınarak devam ettirilir.

Üçüncü adım üç test içerir. Üçüncü adımdaki ilk test için  $i'=3, k=1$  alındığında  $p_{(m-i'+k)} = p_{(4-3+1)} = p_{(2)} = 0.0145$  olur.  $k/i' = 1(0.05)/3 = 0.0167$ 'dir.  $p_{(2)} < 0.0167$  oldu undan  $i$  lemin birinci a amasına son verilir. En büyük  $J$  değeri  $2$  oldu undan  $j'=2$  alınır.

Her bir test için genel olarak  $p_{(m-i'+k)}$  ile elde edilen  $P$  değeri  $k/i'$  ile hesaplanan kriter değeri ile karşılaştırılır. Eğer  $p_{(m-i'+k)} > k/i'$  ise hesaplamalar sonraki  $p_{(m-i'+k)}$  ile devam eder. Bir adımdaki tüm testler için  $p_{(m-i'+k)} > k/i'$  oldu u sürece  $j'$  birer birer artırılır aksi durumda hesaplamaya son verilir.

Hommel leminin ikinci a amasında  $p_{(i)} > k/i'$  oldu u sürece  $H_{(i)}$  reddedilir. Mevcut örnek için  $j'=2, \alpha_{(i)} = 0.05/2 = 0.025$  oldu undan  $H_{(1)}$  ve  $H_{(2)}$  hipotezleri reddedilir. Eğer birinci adımda  $p_{(4)}$  değeri  $0.05$ 'ten küçük olsaydı tüm hipotezler reddedilirdi.

Hommel lemi yalnızca testlerin sırasını değil aynı zamanda  $\alpha$  değerleri hesaplanırken, hesaplanan  $P$  değerlerini de göz önünde bulundurmaktadır.

#### 1.7. Rom lemi (Artan A amalı)

Rom (13) istatistiksel gücü artırmak için Hochberg (11) leminin uyarlanmış bir biçimini önermiştir. Gücün artırılması, test istatistikleri başlımsız oldu unda birinci tür hata oranının tam olarak önemsiz düzeyinin kontrol edildi i uygun düzeltilmiş anlamlılık düzeyinin belirlenmesi ile sağlanmaktadır.

Hochberg leminde olduğu gibi  $H_{(1)}, H_{(2)}, \dots, H_{(m)}$  hipotezlerine karşılık gelen ve  $P$  değerlerini gösteren  $p_{(1)}, p_{(2)}, \dots, p_{(m)}$  değerleri sırasıyla en küçükten en büyüğe doğru sıralansın. Eğer  $p_{(m)} > \alpha_{(m)}$  ise tüm hipotezler reddedilir, aksi halde  $H_{(m)}$  alıkonulur ve  $p_{(m-1)}$  değeri  $\alpha_{(m-1)}$  ile karşılaştırılır. Lem sıralanmış  $P$  değerleri düzeltilmiş anlamlılık düzeyinden küçük oluncaya kadar devam eder. Rom leminde, düzeltilmiş anlamlılık düzeyinin elde edilmesi Hochberg lemindekinden farklıdır. Her iki leminde de  $\alpha_{(m)} = \alpha$  ve  $\alpha_{(m-1)} = \alpha/2$  e itlikleri geçerlidir fakat geride kalan  $m-2$  tane anlamlılık düzeyi farklıdır. Rom leminde,

$$\alpha_{m-i+1} = \left[ \sum_{j=1}^{i-1} \alpha^j - \sum_{j=1}^{i-2} \binom{i}{j} \alpha^{(i-j)} \right] / i \quad [3]$$

ile itli i ile düzeltilmiş anlamlılık düzeyleri tekrarlı olarak belirlenir. Burada  $i = 1, 2, \dots, m$ 'dir. Hommel leminde kullanılan  $p_{(1)}=0.0011, p_{(2)}=0.0145, p_{(3)}=0.0291$  ve  $p_{(4)}=0.0562$  değerleri kullanılarak  $\alpha=0.05$  anlamlılık seviyesinde Rom lemi gösterilebilir. Buna göre;

$$\begin{aligned} \alpha_{(4)} &= 0.05, \\ \alpha_{(3)} &= \alpha_{(4)} / 2 = 0.025, \end{aligned}$$

$$P'_{(2)} = [ + 2-3( '2_{(3)} )] / 3 = 0.0169 \text{ ve}$$

$$P'_{(1)} = [ + 2+ 3-4( '3(3))- 6( '2_{(2)} )] / 4 = 0.0126 \text{ olur.}$$

$P_{(2)} < '2_{(2)}$  oldu undan  $H_{(2)}$  hipotezi ile  $P_{(2)}$  de erinden küçük  $P$  de erlerine sahip tüm hipotezler reddedilir, geri kalan hipotezler kabul edilir.

## SONUÇ

Deneysel çalı malardaki temel amaç, elde edilen sonuçlar ve denemeler arasındaki anlamlı ili kileri aç ı çıkarmaktır. Bir grup denemeden elde edilen ortalamalar arasında önemli farklılık olup olmadı ının belirlenmesinde çoklu kar ıla tırma testleri kullanılabilir. Uygun çoklu kar ıla tırma testinin kullanılması ara tırmacılara do ru, eksiksiz ve elveri li sonuçların elde edilmesinde ve elde edilen bilgiler arasındaki ili kilerin yorumlanmasında yardımcı olur (18). Hangi durumda hangi çoklu kar ıla tırma testinin kullanılacağı na ya da çoklu kar ıla tırma testlerinin aynı ko ullar altında hangisinin daha fazla istatistiksel güce sahip oldu unun belirlenmesi amacıyla yapılmı çalı malar az sayıda da olsa literatürde yer almaktadır (7,19,20). Jaccard ve ark. (20) tarafından yapılan çalı mada e zamanlı çoklu kar ıla tırma testleri ile ilgili hangi durumlarda hangi testin kullanılması gerekti ine ili kin çok detaylı bilgiler verilmi tir. Olejnik ve ark. (7) tarafından yapılan çalı ma ise tamamen adımsal çoklu kar ıla tırma testlerini içermektedir. Bu çalı maya göre adımsal çoklu kar ıla tırma testleri içinde Holm i lemi en dü ük, Rom i lemi ise en yüksek güce sahiptir. Demirhan ve ark. (19) tarafından yapılan çalı mada ise e zamanlı çoklu kar ıla tırma testlerinin hemen tamamı ile adımsal çoklu kar ıla tırma testlerinin bir kısmı dikkate alınarak toplam 18 farklı çoklu kar ıla tırma i lemi kar ıla tırılmı tir. Bu çalı maya göre adımsal çoklu kar ıla tırma testlerinden;

- Bonferroni i leminin Varyans Analizi ile ilgili varsayımların sa lanmaması durumunda tercih edilmemesi gerekti i,
- Holm i leminin genel olarak grup sayısının az ve gruplardaki gözlem sayısının e it olmadı ı durumlarda tercih edilmesi gerekti i, Varyans Analizi ile ilgili varsayımların sa lanmamasından Holm i leminin etkilenmedi i,
- Hommel i leminin gruplardaki gözlem sayılarının e it olup olmamasından etkilendi i, gruplardaki gözlem sayılarının e it olması durumunda tercih edilebilece i,
- Hochberg i leminin ise gerek Varyans Analizi ile ilgili varsayımların sa lanmaması durumunda gerekse gruplardaki gözlem sayılarının e it olmaması durumlarında tercih edilmemesi gerekti i sonuçlarına ula ılmı tir.

Adımsal çoklu kar ıla tırma testleri güven aralı ı belirlenmesine müsaade eden yöntemler de illerdir. Bu yöntemler e zamanlı çoklu kar ıla tırma testlerine göre deneysel ortak hata oranını kontrol altında tutarak istatistiksel gücün artırılmasını sa layan testlerdir (21).

## KAYNAKLAR

1. Rao CV, Swarupchand U. Multiple Comparison Procedures-A Note and a Bibliography. Journal of Statistics. 2009; 16(1):66-109.
2. Games PA. 1971. Multiple Comparisons of Means. American Educational Research Journal. 1971; 8(3):531-65.
3. Hancock GR, Klockars AJ. The Quest For : Developments in Multiple Comparison Procedures in the Quarter Century Since Games (1971). Review of Educational Research. 1996; 66(3):269-306.
4. Cribbie RA, Keselman HJ. Pairwise Multiple Comparisons: A Model Comparison Approach versus Stepwise Procedures. British Journal of Mathematical and Statistical Psychology. 2003; 56(1):167-82.
5. Tukey JW. The Philosophy of Multiple Comparisons. Statistical Science. 1991; 6(1):100-16.
6. Ludbrook J. Multiple Comparison Procedures Updated. Clinical and Experimental Pharmacology and Physiology. 1998; 25(12):1032-7.
7. Olejnik S, Li J, Supattathum S, Huberty CJ. Multiple Testing and Statistical Power with Modified Bonferroni Procedures. Journal of Educational and Behavioral Statistics. 1997; 22(4):389-406.
8. Holm S. A Simple Sequentially Rejective Multiple Test Procedure. Scandinavian Journal of Statistics. 1979; 6(2):65-70.
9. Shaffer JP. Modified Sequentially Rejective Multiple Test Procedures. Journal of The American Statistical Association. 1986; 81(395):826-31.
10. Holland BS, Copenhaver MD. An Improved Sequentially Rejective Bonferroni Test Procedure. Biometrics. 1987; 43(2):417-23.
11. Hochberg Y. A Sharper Bonferroni Procedure for Multiple Tests of Significance. Biometrika. 1988; 75(4):800-2.
12. Hommel G. A Stagewise Rejective Multiple Test Procedure Based on a Modified Bonferroni Test. Biometrika. 1988; 75(2):383-6.
13. Rom DR. A Sequentially Rejective Test Procedure Based on a Modified Bonferroni Equality. Biometrika. 1990; 77(3):663-5.
14. Dunnett CW, Tamhane AC. A Step-up Multiple Test Procedure. Journal of The American Statistical Association. 1992; 87(417):162-70.
15. Simes RJ. An Improved Bonferroni Procedure for Multiple Tests of Significance. Biometrika. 1986; 73(3):751-4.
16. Wright SP. Adjusted P-Values for Simultaneous Inference. Biometrics. 1992; 48(4):1005-13.
17. Sidak Z. Rectangular Confidence Regions for the Means of Multivariate Normal Distributions. Journal of The American Statistical Association. 1967; 62(318):626-33.
18. Lowry SR. Use and Misuse of Multiple Comparisons in Animal Experiments. Journal of Animal Science. 1992; 70(6):1971-7.

19. Demirhan H, Dolgun NA, Demirhan YP, Dolgun MÖ. Performance of Some Multiple Comparison Tests Under Heteroscedasticity and Dependency. *Journal of Statistical Computation and Simulation*. 2010; 80(10):1083-100.
20. Jaccard J, Becker MA, Wood G. Pairwise Multiple Comparison Procedures: A Review. *Psychological Bulletin*. 1984; 96(3):589-96.
21. Hancock GR, Klockars AJ. Finite Intersection Tests: A Paradigm for Optimizing Simultaneous and Sequential Inference. *Journal of Educational and Behavioral Statistics*. 1997; 22(3):291-307.