

Fleiss Kappa ve Krippendorff Alpha Uyum Katsayılarının Örneklem Genişliği, Değerlendirici Sayısı ve Kullanılan Ölçeğin Kategori Sayısından Etkilenme Durumları Üzerine Bir Benzetim Çalışması

Effect of Sample Size, The Number of Raters and
the Category Levels of Diagnostic Test on
Krippendorff Alpha and the Fleiss Kappa
Statistics for Calculating Inter Rater Agreement:
A Simulation Study

E. Arzu KANIK^a,
Gülhan OREKİCİ TEMEL^a,
İrem ERSÖZ KAYA^b

^aBiyostatistik AD,
Mersin Üniversitesi Tıp Fakültesi,

^bBilgisayar Sistemleri AD,
Mersin Üniversitesi Teknik Eğitim Fakültesi,
Mersin

Geliş Tarihi/Received: 12.02.2010
Kabul Tarihi/Accepted: 15.04.2010

Yazışma Adresi/Correspondence:
E. Arzu KANIK
Mersin Üniversitesi Tıp Fakültesi,
Biyostatistik AD, Mersin,
TÜRKİYE/TURKEY
arzukanik@gmail.com

ÖZET Amaç: Bu çalışmanın amacı, aynı materyal üzerinde hastanın durumu hakkında klinik karar veren birden fazla değerlendirme arasındaki uyum hesaplanırken kategorik veriler için kullanılan Krippendorff Alpha ve Fleiss Kappa istatistiklerini, örnek genişliği, değerlendirme sayısı ve kullanılan ölçeğin kategori sayısından nasıl etkilendiklerini ortaya koymaktır. **Gereç ve Yöntemler:** Fleiss Kappa ve Krippendorff Alpha uyum katsayılarının değerlendirme sayıları arasında hiç uyum olmadığı (değerlendiriciler arasındaki karar rasgele) ve yüksek uyumun (değerlendiriciler arasındaki ortak karar 0.90 düzeyinde) olduğu durumlarda sonuçların örnek genişliklerinden, değerlendirme sayısından ve tanı testinin kategori sayısından nasıl etkilendiğini incelemek amacıyla bir Monte Carlo benzetim çalışması yapılmıştır. Benzetim çalışması Matlab 7 paket programı kullanılarak yapılmıştır. **Bulgular:** Örnek büyülüğünün küçük, orta ve yüksek olması sonuçları değiştirmekle birlikte değerlendirme sayılarında çok güçlü bir uyum varken değerlendirme sayısının en az 5 ve tanı testinin kategori sayısının 10'a çıkma durumunda Krippendorff Alpha katsayısının beklenen değerinin (0.90) daha büyük tahminler yaptığı gözlenmiştir. **Sonuç:** Bu çalışmada örnek büyülüğünün 30 olarak alınmasının Fleiss Kappa ve Krippendorff Alpha uyum katsayılarının her ikisi için de parametreyi doğru tahmin etmek için yeterli bir büyülüklük olduğu saptanmıştır. Değerlendiriciler arası uyum hesaplanırken değerlendirme sayısı ve kategori sayısının 5 ten fazla olduğu durumlarda Krippendorff Alpha kullanırken tahminlerin gerçek değerinden yaklaşık 1,05 kat daha fazla olabildiği dikkate alınmalıdır.

Anahtar Kelimeler: Gözlemevi değişkenliği; Sonuçların yeniden üretilenabilirliği

ABSTRACT Objective: The aim of the study is to introduce how the Krippendorff Alpha and the Fleiss Kappa statistics that are designed for the categorical data used for calculating the measurement of agreement of more than one raters who make clinical decisions about the state of patients, were affected by the sample size, the number of raters and the category levels of diagnostic test. **Material and Methods:** A Monte Carlo simulation study was performed to assess how the Fleiss Kappa and Krippendorff Alpha coefficients were affected by the sample sizes, number of the raters and the category number of the diagnostic test for two situations; no consistency and high consistency. Simulation study was done by using Matlab 7.0. **Results:** It was observed that sample size's being small, medium and large didn't change the results. While there was high agreement between readers, Krippendorff Alpha Coefficient estimate higher than expected value (0.90) in case of the minimum number of reader was 5 and the number of diagnostic test's category was 10. **Conclusion:** In this study, the sample size as 30 would be sufficient to make accurate estimation for the two methods. In calculating the measurement of inter-rater agreement, it must be considered that when using Krippendorff Alpha for the models including more than 5 raters and categories, the estimates are made about 1, 05 times much more than the actual values.

Key Words: Observer variation; reproducibility of results

Tıp biliminde bir hastaya ait materyal üzerinde hastalıkın varlığı yokluğu ya da derecesi konusunda karar veren birden çok değerlendircinin uyumu özellikle altın standart bir testin bulunmadığı durumlarda oldukça önemlidir. Latent Class yöntemiyle tanı testi etkinliğinin saptanmasında değerlendircilerin uyumunun yüksek olması başarıyı artırmaktadır.^{1,2} Değerlendirici uyumunun ölçülmesinde kullanılan yöntemler, kullanılan tanı testinin sürekli ya da kategorik olmasına ve değerlendirmeye sayılarına bağlı olarak değişir. Tanı testi sonuçları kategorik yapıda ise kullanılan uyum katsayılarından birisi de Cohen Kappa istatistiğidir.^{3,4} Bu katsayı, eşit sayıda kategorisi olan tanı testinin kullanıldığı durumlarda iki değerlendirmeye arasındaki uyumu ölçmek için kullanılır. Eğer değerlendirmeye sayısı ikiden fazla ise uyulamada genellikle değerlendirmeleri ikili olarak çoklu Kappa testleriyle karşılaştırmak, çalışmaya ait I. tip hatanın artmasına neden olmaktadır. Birden çok değerlendircinin kategorik test sonuçları arasındaki uyum ölçülmesinde yaygın kullanılan iki yöntem Fleiss Kappa⁵⁻⁷ ve Kruppendorff's Alpha^{8,9} katsayılarıdır. Bu çalışmada Kruppendorff Alpha ve Fleiss Kappa istatistiklerinin örnek genişliğinden, değerlendirmeye sayısından ve kullanılan ölçeğin kategori sayısından nasıl etkilendikleri araştırılmıştır.

GEREC VE YÖNTEMLER

FLEİSS KAPPA UYUMLULUK KATSAYISI

1971'de Fleiss, ikiden fazla değerlendirmeye arasındaki uyumu genellenmiş bir Kappa istatistiği ile ortaya koymuştur. Fleiss Kappa istatistiği ikiden fazla değerlendircinin uyumunu kategorik ya da sıralı yapıda olan tanı testi sonuçlarını ölçmek amacıyla kullanılır.^{10,11}

1'den k 'ya kadar sonucu olan bir tanı testini, n değerlendirmeye N adet vaka için yorumlar ve tanı testinin her bir kategorisi, her bir vaka için ortak karar sonucu olarak başlangıç tablosu olarak düzenlenir (Tablo 1).

Tablo (1)'de

N : toplam hasta sayısını

n : Değerlendirici sayısını

TABLO 1: Fleiss Kappa uyumluluk katsayısi için ortak karar sonuçlarının gösterilmesi.

Vaka Sayısı	Tanı Testleri				
	1	2	k	P_i
1	n_{11}	n_{12}		n_{1k}	P_1
2	n_{21}	n_{22}		n_{2k}	P_2
N	n_{N1}	n_{N2}		n_{Nk}	P_N
p_j	p_1	p_2		p_k	

k : tanı testinin kategori sayısını

n_{ij} : i . hastanın tanı testi sonucuna j kararını veren değerlendirmeye sayısını

P_i : i . birey satır toplamı için toplam orantıyı

P_j : j . Kategori sütun toplamı için toplam orantıyı göstermektedir.

Fleiss Kappa istatistiği 1 nolu eşitlikte olduğu gibi hesaplanmaktadır.

$$K = \frac{\bar{P} - \bar{P}_e}{1 - \bar{P}_e} \quad (1)$$

$i=1,2,\dots,N$ ve $j=1,2\dots,k$ olmak üzere K değeri Fleiss Kappa katsayısını göstermektedir.

Fleiss Kappa $0 \leq K \leq 1$ değer alır.

(1) Nolu Eşitlikte;

\bar{P} , P_i 'lerin ortalamasını göstermek üzere \bar{P} ve \bar{P}_e ve aşağıdaki eşitliklerde verilmiştir:

$$\bar{P} = \frac{1}{N} \sum_{i=1}^N P_i = \frac{1}{Nn(n-1)} \left(\sum_{i=1}^N \sum_{j=1}^k n_{ij}^2 - Nn \right) \quad (2)$$

$$\bar{P}_e = \sum_{j=1}^k p_j^2 \quad (3)$$

$$1 = \frac{1}{n} \sum_{j=1}^k n_{ij} \quad (4)$$

$$P_i = \frac{1}{n(n-1)} \sum_{j=1}^k n_{ij} (n_{ij} - 1) = \frac{1}{n(n-1)} \sum_{j=1}^k (n_{ij}^2 - n_{ij}) = \frac{1}{n(n-1)} \left[\left(\sum_{j=1}^k n_{ij}^2 \right) - (Nn) \right] \quad (5)$$

$$P_j = \frac{1}{Nn} \sum_{i=1}^N n_{ij} \quad (6)$$

KRİPPENDORFF'S ALPHA GÜVENİRİLİK KATSAYISI

Krippendorff Alpha katsayısı tüm ölçekler için kullanılabilen bir uyum katsayısidır. Bu katsayıının en önemli avantajı tamamlanmamış veri ya da eksik veri bulundurabilir.^{12,13}

Bu katsayının genel formülü eşitlik (7)'deki gibidir.

$$\alpha = 1 - \frac{D_o}{D_e} \quad (7)$$

Eşitlik (7) de, D_o gözlenen uyumsuzluk, D_e ise beklenen uyumsuzluktur:

$$D_o = \frac{1}{n} \sum_c \sum_k O_{ck \text{ metric}} \delta_{ck}^2 \quad (8)$$

$$D_e = \frac{1}{n(n-1)} \sum_c \sum_k n_c n_{k \text{ metric}} \delta_{ck}^2 \quad (9)$$

Gözlenen uyumsuzluk $D_o = 0$ olduğunda, de-
ğerlendiricilerin mükemmel uyumlu olduğu sonu-
cuna varılır. Bu durumda güvenirlik katsayısı $\alpha = 1$
çıkar. $D_o = D_e$ olur ise güvenirlik katsayısı $\alpha = 0$ ola-
caktır. Güvenirlik katsayı $0 \leq \alpha \leq 1$ değer alır.

Krippendorff Alpha katsayısının hesaplanmasıında 1. adım olarak r tane vakaya ait m tane değerlendirmecinin sonuçlarından oluşan veri matrisi oluşturulur (Tablo 2).

Tablo (2) de:

r: Toplam vaka sayısını,

m: Toplam değerlendirme sayısını,

C_{iu} : $i.$ değerlendircinin $u.$ vaka için değerlendirme sonuçunu.

TABLO 2: Krippendorff Alpha katsayısı için veri matrisi.

Değerlendirici Sayısı	Vaka Sayısı					C_{ir}	
	1	2	.	.	u	.	r
1	C_{11}	C_{12}			C_{1u}		
i	C_{i1}	C_{i2}			C_{iu}		C_{ir}
j	C_{j1}	C_{j2}			C_{ju}		C_{jr}
.							
m	C_{m1}	C_{m2}			C_{mu}		C_{mr}
Toplam	m_1	m_2			m_u		m_r

TABLO 3: Krippendorff Alpha katsayısı için uvum matrisi.

Sonuçlar	1	.	k	.	.	
1	O_{11}		O_{1k}			n_1
.
c	O_{c1}		O_{ck}	.	.	$n_c = \sum_k O_{ck}$
	n_1		n_k			$n \sum_c \sum_k O_{ck}$

m_u : u.vakayı değerlendiren değerlendircilerin toplamını gösterir.

Eksik veri olmadığı durumda m_u değeri değerlen- dirici sayısına eşit olacaktır.

Krippendorff Alpha katsayısını hesaplamada 2. adım olarak 1. adımda oluşturulan veri matrisi, tüm eşleşen değerlendirme çiftlerinin frekanslarını içeren uyum matrisine dönüştürülür (Tablo 3).

Tablo (3)'de eşleşen değerlendirme çiftlerinin frekansları eşitlik (10)'da ki gibi hesaplanmaktadır:

$$O_{ck} = \frac{\text{u. vakadaki } c-k \text{ çiftlerinin sayısı}}{m_u - 1} \quad (10)$$

Eşitlik (10)'da O_{ck} c-k değerlendirme çiftinin u. vakadaki gözlenme frekansını göstermektedir. Ve sonuçta eşitlik 11 yardımcı ile Krippendorff Alpha katsayısı hesaplanır.

$$no \min al\alpha = 1 - \frac{D_o}{D} = \frac{(n-1) \sum_c O_{cc} - \sum_c n_c (n_c - 1)}{n(n-1) - \sum n (n - 1)} \quad (11)$$

BENZETİM DENEMELERİ

Bu çalışmada Fleiss Kappa ve Kripendorff Alpha katsayılarıyla hesaplanan uyumların değerlendirmelerin kararları arasında hiç uyum yokken (rasgele) ve uyumun 0.90 olduğu iki farklı durum için, örnek genişliklerinden, değerlendirmeli sayılarından ve tanı testinin sonuçlarından nasıl etkilendiğini incelemek amacıyla bir Monte Carlo benzetim çalışması yapılmıştır. Benzetim denemeleri; veri üretimi ve katsayıların hesaplanması MatLab 7 paket programında yapılmış ve benzetim çalışmasının kodları Ek 1'de verilmiştir. Ayrıca yöntemlerin tanımlayıcı

EK 1

```

Fleiss Kappa code:
%----Fleiss Uygulamasi Basiyor----%
function fleissK(data_in,conf)

[m,N] = size(data_in);
% m = kodlayici sayisi
% N = ornek sayisi

caseTypes = unique(data_in);
fleiss_mat = [ ];
sum_cases = 0;

for i=1:N
    for j=1:m
        sum_cases = sum_cases + ismember(caseTypes, data_in(j,i));
    end
    fleiss_mat(i,:) = sum_cases;
    sum_cases = 0;
end

n=size(fleiss_mat,1);
m=sum(fleiss_mat(1,:)); %raters
a=n*m;
pj=(sum(fleiss_mat)./(a)); %overall proportion of ratings in category j
b=pi.*(1-pj);
c=a*(m-1);
d=sum(b);
kj=1-(sum((fleiss_mat.*(m-fleiss_mat)))./(c.*b)); %the value of Kappa for the j-th
category
FleissAlpha=sum(b.*kj)/d %Fleiss'es (overall) Kappa
sek=realsqrt(2*(d/2-sum(b.*(1-2.*pj))))/sum(b.*realsqrt(c));
%Kappa standard error
ci=FleissAlpha+([-1 1].*(abs(0.5*erfc(-conf/2*realsqrt(2)))*sek)); %FleissAlpha
confidence interval
z=FleissAlpha/sek; %normalized Kappa
p=(1-0.5*erfc(-abs(z)/realsqrt(2)))*2;

fid = fopen('sonuc.txt','a');
fprintf(fid,' \t %.4f \t (%d%%) = %.4f \t z = %.4f \t p = %.4f',FleissAl-
pha,(1-conf)*100,ci,z,p);
fclose(fid);

%----Krippendorff Uygulamasi Basiyor----%
function krippendorff(data_in)

[m,N] = size(data_in);
% m = kodlayici sayisi
% N = ornek sayisi

for i=1:N
    u = data_in(:,i);
    % u.ornek aliniyor.
    miss = find(isnan(u)==1);
    % eksik olan hucrelerin indisleri bulunuyor.
    u(miss) = [ ];
    % eksik hucreler siliniyor.
    mu = length(u);
    % u.ornekte kodlayici sayisi bulunuyor.
    if mu==1
        allComb = [ ]; %Tek kodlayici oldugunda kombinasyon alinmiyor.
    elseif mu==0
        allComb = [ ];
    else
        allComb = combntns(u,2);
    end
    % u.ornekte tum kombinasyonlar bulunuyor.
    hucre{i,1} = allComb;
    hucre{i,2} = mu;
    % u.ornek icin bulunan kombinasyon ve
    % kodlayici sayisi hucrede saklanıyor.
end

case_types = unique(data_in);
x = find(isnan(case_types)==1);
case_types(x) = [ ];
[v,bir] = size(case_types);
% v = durum sayısı

diag_comb = [case_types case_types];
triu_comb = combntns(case_types,2);
join_comb = combine(diag_comb, triu_comb);
all_comb = sortrows(join_comb);
% arastirilacak tum kombinasyonlar biraraya getiriliip siralanıyor.

kripp_mat = [ ];
count = 0;

for c=1:v
    for k=c:v
        count = count + 1;
        lookC = int2str(all_comb(count,:));
        % tum kombinasyonlar sirayla alinip string yapiliyor.
        Ock = 0;
        for t=1:N
            forC = int2str(hucre{t});
            % t.hucre alinip string yapiliyor.
            findC = strmatch(lookC, forC);
            % mevcut kombinasyon t.hucrede aranıyor.
            rev_forC = strreverse(forC);
            % t.hucrenin tersi alinıyor.
            find_revC = strmatch(lookC, rev_forC);
            % mevcut kombinasyon t.hucrenin tersinde aranıyor.
            sizeFinds = length(combine(findC, find_revC));
            % tum bulunan ihtimaller sayiliyor.
            if sizeFinds == 0
                Ock_hucre = 0;
            else
                Ock_hucre = sizeFinds /(hucre{t,2}-1);
            end
            Ock = Ock + Ock_hucre;
            % Ock degerleri hesaplanıyor.
        end
        kripp_mat(c,k) = Ock;
        if c~=k
            kripp_mat(k,c) = Ock;
        end
        % hesaplanan Ock degerleri matrise yaziliyor.
    end
    nk = sum(kripp_mat);
    nc = sum(kripp_mat);
    n = sum(nk);

    Do = 0;
    De = 0;
    for c=1:v
        for k=c:v
            Do = Do + (kripp_mat(c,k)*metric(c,k));
            De = De + (nc*c)*nk(k)*metric(c,k);
        end
    end
    KrippAlpha = 1 - (Do/(De/(n-1)));

    fid = fopen('sonuc.txt','a');
    fprintf(fid,' \t %.4f',KrippAlpha);
    fclose(fid);

    function xxx = metric(c,k)
        if c==k
            xxx=0;
        else
            xxx=1;
        end
    %---Krippendorff Uygulamasi Bitti---

```

istatistikleri ve yöntemler arasındaki uyum için çi-
zilen Youden Plot grafikleri ise Medcalc®v11.2
paket programı ile elde edilmiştir.

Benzetim denemelerinde, değerlendirici sayı-
sının 2, 5 ve 7 olduğu 3 durum ile tanı testinin 2, 5,
7 ve 10 kategorili olduğu 4 durum, örnek genişliği-
nin 30, 100 ve 1000 olduğu 3 durumu ile toplam 36
farklı kombinasyon kullanılmıştır. Bu kombinas-
yonlar değerlendirciler arasında hiç uyumun ol-
madığı durum ile uyumun 0.90 olduğu durumlar
için Krippendorff Alpha ve Fleiss Kappa'nın değer-
leri 1000 benzetim denemesi için kaydedilmiş ve
her kombinasyon için ortalama ve standart sapma-
ları hesaplanmıştır. Her iki katsayı için hesaplanan
ortalamlar benzetim denemelerinde tekrar sayısının
1000 olması nedeniyle popülasyon değeri kabul

edilmiş ve hipotez testi ile karşılaştırma yapılmıştır.

BULGULAR

Değerlendirici sayısı 2, 5 ve 7 ($D=2-5-7$) olmak üzere, tanı testi sonuçlarının 2'li, 5'li, 7'li ve 10'lu ($K=2-5-7-10$) ölçümle düzeyleri için beklenen uyumun sıfır ve beklenen uyumun 0.90 olması gereken durumlarda Krippendorff Alpha ve Fleiss Kappa'nın tanımlayıcı istatistikleri örnek genişlikleri 30, 100 ve 1000 için verilmiştir (Tablo 4, 5, 6).

Örnek büyülüüğü 30 olduğu durumda değerlendirici sayısı, karar sayısı ve değerlendirciler arasındaki uyumdan Krippendorff Alpha katsayısı ile Fleiss Kappa katsayısı benzer sonuçlar vermiş-
tir. Fakat değerlendirciler arasındaki uyum 0.90

TABLO 4: Örnek büyülüüğü 30 ve beklenen uyumun 0.00 ve 0.90 olduğu durumlarda iki yöntemin tanımlayıcı istatistik tablosu.

		Beklenen Uyum 0,90		Beklenen Uyum 0,00	
		Krippendorff	Fleiss	Krippendorff	Fleiss Kappa
		Alpha	Kappa	Alpha	Fleiss Kappa
N=30		Ortalama	Ortalama	Ortalama	Ortalama
		S.Sapma	S.Sapma	S.Sapma	S.Sapma
D=2-K=2		0,8974	0,8957	0,003525	-0,01336
		± 0,05925	± 0,06024	± 0,1784	± 0,1815
D=2-K=5		0,9004	0,8987	0,001790	-0,01513
		± 0,03053	± 0,03105	± 0,09113	± 0,09268
D=2-K=7		0,8995	0,8978	0,002820	-0,01408
		± 0,02477	± 0,02519	± 0,07327	± 0,07451
D=2-K=10		0,9027	0,8968	0,009757	-0,01543
		± 0,02742	± 0,02085	± 0,06407	± 0,06074
D=5-K=2		0,8965	0,8958	-0,001492	-0,008210
		± 0,01967	± 0,01980	± 0,05644	± 0,05682
D=5-K=5		0,8973	0,8966	-0,00001530	-0,006727
		± 0,01013	± 0,01019	± 0,02905	± 0,02925
D=5-K=7		0,8973	0,8966	-0,001741	-0,008464
		± 0,007715	± 0,007766	± 0,02387	± 0,02403
D=5-K=10		0,9317	0,8971	0,01178	-0,006612
		± 0,02788	± 0,006888	± 0,02536	± 0,01919
D=7-K=2		0,8974	0,8969	-0,001808	-0,006605
		± 0,01314	± 0,01320	± 0,03795	± 0,03814
D=7-K=5		0,8971	0,8966	-0,0003823	-0,005167
		± 0,006680	± 0,006713	± 0,01982	± 0,01992
D=7-K=7		0,8975	0,8970	0,0002912	-0,004489
		± 0,005370	± 0,005396	± 0,01550	± 0,01557
D=7-K=10		0,9451	0,8967	0,01367	-0,005009
		± 0,03050	± 0,004511	± 0,02093	± 0,01309

TABLO 5: Örnek büyülüüğü 100 ve beklenen uyumun 0.00 ve 0.90 olduğu durumlarda iki yöntemin tanımlayıcı istatistik tablosu.

		Beklenen Uyum 0,90		Beklenen Uyum 0,00	
		Krippendorff	Fleiss	Krippendorff	Fleiss Kappa
		Alpha	Kappa	Alpha	Fleiss Kappa
N=100		Ortalama	Ortalama	Ortalama	Ortalama
		S.Sapma	S.Sapma	S.Sapma	S.Sapma
D=2-K=2		0,8979	0,8974	-0,002811	-0,007852
		± 0,03153	± 0,03169	± 0,1032	± 0,1037
D=2-K=5		0,8990	0,8985	0,002711	-0,002303
		± 0,01540	± 0,01547	± 0,05087	± 0,05112
D=2-K=7		0,8991	0,8986	0,001118	-0,003902
		± 0,01224	± 0,01230	± 0,04200	± 0,04221
D=2-K=10		0,9042	0,8989	0,008143	-0,0008549
		± 0,01444	± 0,01059	± 0,01122	± 0,01052
D=5-K=2		0,8990	0,8988	-0,0008063	-0,002814
		± 0,01020	± 0,01021	± 0,03099	± 0,03105
D=5-K=5		0,8994	0,8992	0,0008289	-0,001173
		± 0,005124	± 0,005133	± 0,01607	± 0,01610
D=5-K=7		0,8975	0,8968	-0,0001023	-0,002108
		± 0,007390	± 0,007440	± 0,01310	± 0,01313
D=5-K=10		0,9328	0,8992	0,01178	-0,006612
		± 0,01585	± 0,003442	± 0,02536	± 0,01919
D=7-K=2		0,8991	0,8989	-0,0002343	-0,001663
		± 0,006876	± 0,006886	± 0,02192	± 0,02195
D=7-K=5		0,8992	0,8991	0,0002131	-0,001217
		± 0,003605	± 0,003610	± 0,01124	± 0,01126
D=7-K=7		0,8994	0,8992	-0,00005720	-0,001488
		± 0,002989	± 0,002996	± 0,009090	± 0,009105
D=7-K=10		0,9455	0,8999	0,01411	-0,001156
		± 0,005126	± 0,0007450	± 0,01183	± 0,007254

TABLO 6: Örnek büyülüğu 1000 ve beklenen uyumun 0.00 ve 0.90 olduğu durumlarda iki yöntemin tanımlayıcı istatistik tablosu.

	Beklenen Uyum 0,90		Beklenen Uyum 0,00	
	Krippendorff	Fleiss	Krippendorff	Fleiss Kappa
	Alpha	Kappa	Alpha	Ortalama S.Sapma
N=1000	Ortalama S.Sapma	Ortalama S.Sapma	Ortalama S.Sapma	Ortalama S.Sapma
D=2-K=2	0,8994 ± 0,01025	0,8993 ± 0,01026	-0,001485 ± 0,03102	-0,001984 ± 0,03104
D=2-K=5	0,8997 ± 0,005013	0,8997 ± 0,005016	0,0008283 ± 0,01585	0,0003283 ± 0,01586
D=2-K=7	0,8991 ± 0,01224	0,8986 ± 0,01230	0,0002834 ± 0,01270	-0,0002169 ± 0,01271
D=2-K=10	0,9042 ± 0,01444	0,8989 ± 0,01059	0,01000 ± 0,03629	-0,003341 ± 0,03396
D=5-K=2	0,9000 ± 0,001241	0,8999 ± 0,001241	-0,0003415 ± 0,009957	-0,0005414 ± 0,009958
D=5-K=5	0,8973 ± 0,01013	0,8966 ± 0,01019	0,0001190 ± 0,005035	-0,00008140 ± 0,005036
D=5-K=7	0,8999 ± 0,0009172	0,8999 ± 0,0009154	-0,00006020 ± 0,004103	-0,0002602 ± 0,004105
D=5-K=10	0,9329 ± 0,004888	0,9000 ± 0,001059	0,01148 ± 0,004472	-0,00006780 ± 0,003238
D=7-K=2	0,9000 ± 0,002214	0,9000 ± 0,002212	-0,0005548 ± 0,006781	-0,0006989 ± 0,006782
D=7-K=5	0,9000 ± 0,001115	0,8999 ± 0,001116	-0,00001440 ± 0,003424	-0,0001578 ± 0,003425
D=7-K=7	0,8999 ± 0,0009172	0,8999 ± 0,0009154	-0,000009020 ± 0,002807	-0,0002323 ± 0,002811
D=7-K=10	0,9455 ± 0,005126	0,8999 ± 0,0007450	0,01344 ± 0,003627	-0,00002250 ± 0,002273

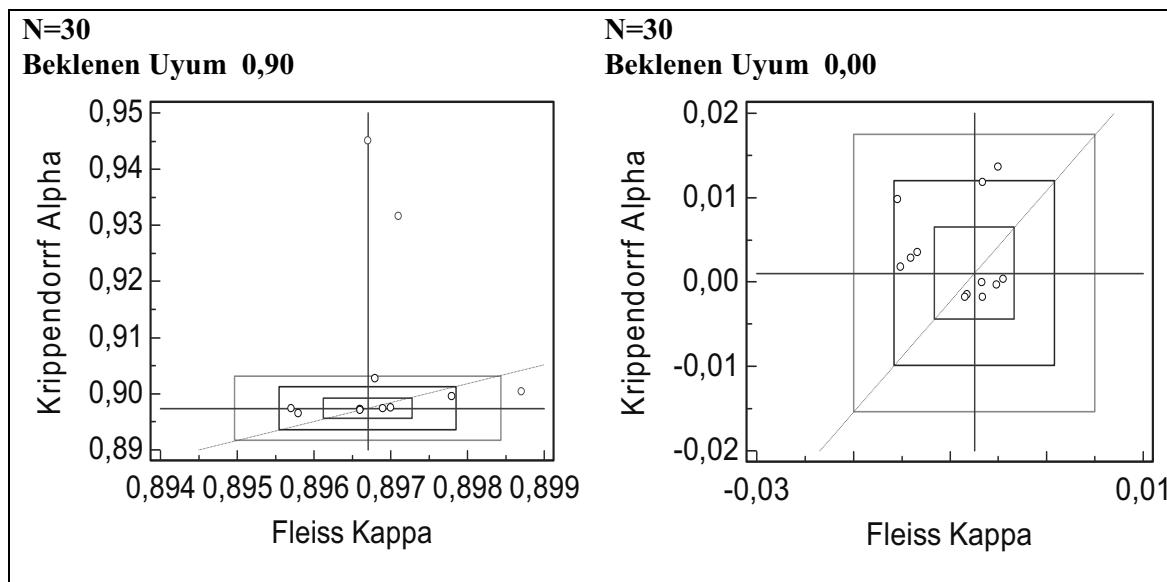
çıkması beklenen durumda, değerlendirmeli artışından ve tanı testinin kategorisi sayısının 10'a çıkma durumunda Krippendorff Alpha katsayısının etkilendiği ve Fleiss Kappa'ya göre arttığı gözlenmektedir.

Örnek büyülüğünün 100 olduğu durumda Krippendorff Alpha katsayı ile Fleiss Kappa katsayı benzer sonuçlar vermiştir. Fakat değerlendirmeler arasındaki uyumun 0.90 olması beklenen durumda, değerlendirmeli sayısının ve tanı testi kategorisinin birlikte artmasının Krippendorff Alpha katsayıını etkilediği ve Fleiss Kappa'yı ise etkilemediği gözlenmektedir.

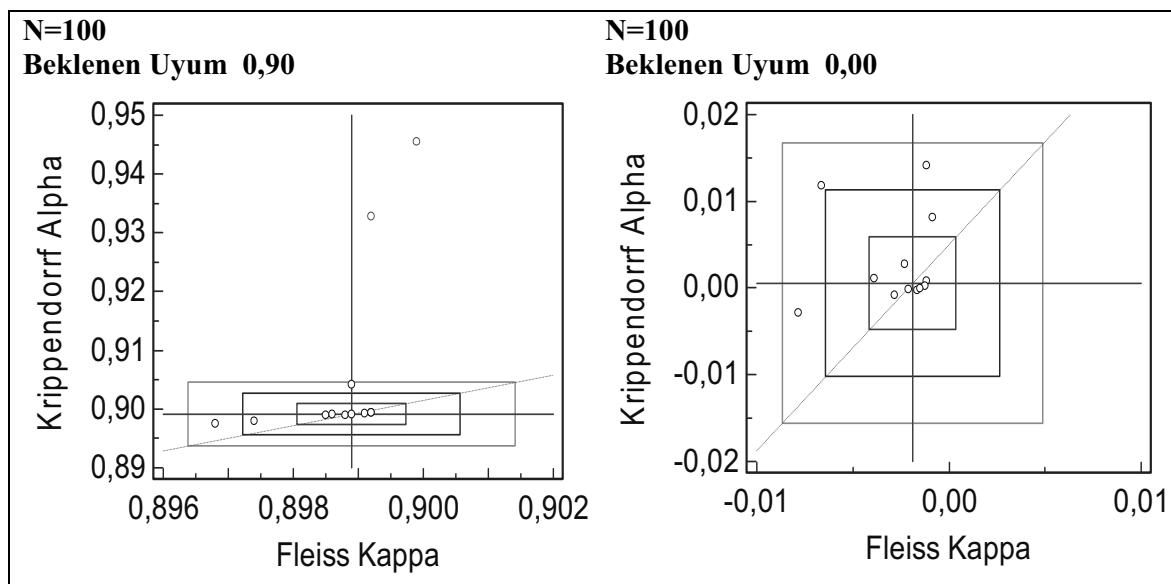
Örnek büyülüğü 1000 olduğu durumda da sonuçların 30 ve 100 olduğu duruma oldukça yakın bulunduğu gözlenmiştir. Ayrıca örnek büyülüklere göre her iki yöntemin uyumluluklarının görsel gösterimi beklenen uyumların 0.00 ve 0.90 olduğu durumlarda 1SD, 2SD ve 3SD alanları için Youden Plot grafiği ile sunulmuştur (Şekil 1, 2, 3). Grafikler incelendiğinde Krippendorff Alpha değeri D=5, K=10 ve D=7, K=10 durumlarının 3SD sınırları dışında kaldığı görülmektedir.

TARTIŞMA

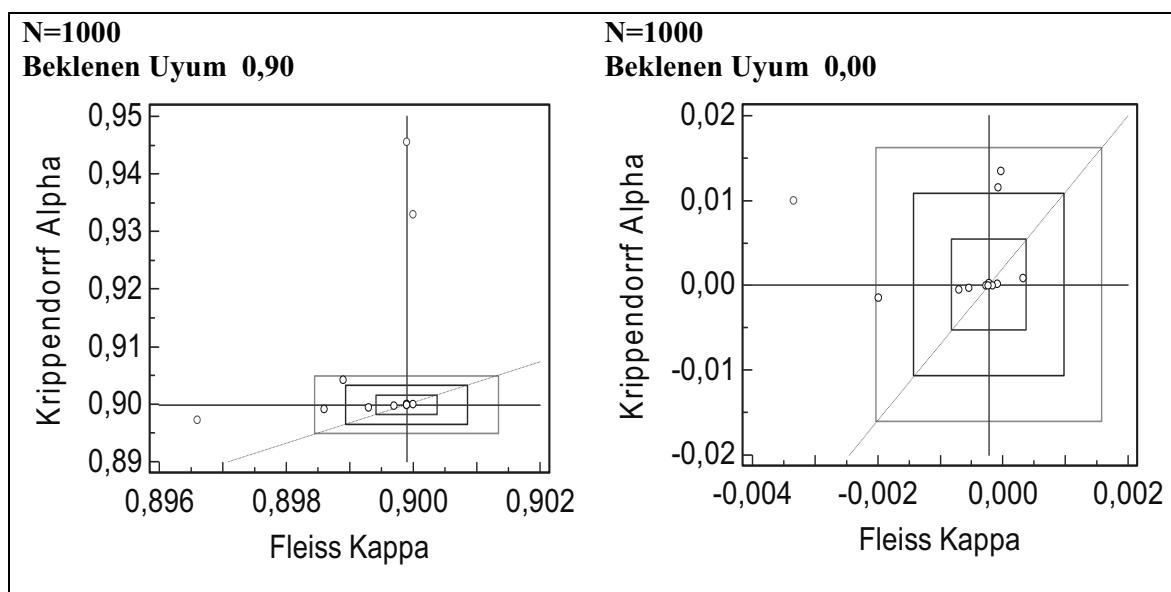
Değerlendirmeler arasındaki uyum hesaplanırken değerlendirmeli sayı, tanı testinin alt kategorileri



ŞEKİL 1: Örnek büyülüği 30 olduğu durumda oluşturulan Youden Plot grafiksel gösterimi.



ŞEKİL 2: Örnek büyüklüğü 100 olduğu durumda oluşturulan Youden Plot grafiksel gösterimi.



ŞEKİL 3: Örnek büyüklüğü 1000 olduğu durumda oluşturulan Youden Plot grafiksel gösterimi.

ve örnek büyüğünün etkisi sık tartışılan bir konudur. Bu çalışmada her iki yöntemin de örnek büyüğünden etkilenmediği saptanmıştır.

Örnek büyüğünün 30'dan 100'e ve hatta 1000 çıkması durumunda bile değerlendirciler arasındaki uyumun tahmininde değişiklik olmamıştır. Fakat değerlendirciler arasındaki uyumun 0.90 çıkması beklenen durumda, değerlendirci sayısı-

nin en az 5 ve tanı testinin kategorisi sayısının 10'a çıkma durumunda Krippendorff Alpha katsayısının beklenen değerin (0,90) daha büyük tahminler yaptığı gözlenmiştir. Bu dezavantajının yanında literatürde Krippendorff Alpha katsayı eksik verilerde de kullanılabildiği için değerlendirciler arasındaki uyum hesaplamasında önemli bir yere sahip olduğu bildirilmektedir.^{12,13}

SONUÇ

Değerlendiriciler arasındaki uyum hesaplanırken kullanılan Krippendorff Alpha ve Fleiss kappa istatistikleri üzerinde durulan özelliğin örnek büyüğünden etkilenmemekle birlikte Krippendorff Alpha katsayısı değerlendirici sayısı ve tanı testi-

nin kategori sayısından etkilenmekte ve bekleneneden daha yüksek tahminlerde bulmaktadır. Bunun yanında Krippendorff Alpha katsayı eksik verilerde de kullanılamıyor olması özelliği bu çalışmada dikkate alınmamıştır. Bu konu bir sonraki çalışmada ele alınacaktır.

KAYNAKLAR

- Conaway RC. Latent class analysis. In: Armitage P, Colton T. Encyclopedia of Biostatistics. 2nd ed. New York; John Wiley & Sons: 2005. p.2730-3.
- Uebersax JS, Grove WM. Latent class analysis of diagnostic agreement. Stat Med 1990;9(5):559-72.
- Cohen J. A coefficient of agreement for nominal scales. Educational and psychological measurement. 1990;20(1):37-46.
- Shoukri M. Measures of 2x2 association and agreement of cross-classified data. Samar Haddad. Measures of Interobserver Agreement. 1st ed. New York: Chapman & Hall/Crc; 2004. p.25-7.
- Peyré SE, Peyré CG, Hagen JA, Sullivan ME. Reliability of a procedural checklist as a high-stakes measurement of advanced technical skill. Am J Surg 2010;199(1):110-4.
- Ersland K, Kvaløy JT, Styr BM, Helland EB, Espeland A. Do radiologists agree on the quality of computed tomography enterography? J Med Imaging Radiat Oncol 2009;53(4):353-60.
- Wadsten MA, Sayed-Noor AS, Sjödén GO, Svensson O, Buttazzoni GG. The Buttazzoni classification of distal radial fractures in adults: interobserver and intraobserver reliability. Hand (NY) 2009;4(3):283-8.
- Haderlein T, Riedhammer K, Nöth E, Toy H, Schuster M, Eysholdt U, et al. Application of automatic speech recognition to quantitative assessment of tracheoesophageal speech with different signal quality. Folia Phoniatr Logop 2009;61(1):12-7.
- Dedouit F, Bindel S, Gainza D, Blanc A, Joffre F, Rougé D, et al. Application of the Iscan method to two- and three-dimensional imaging of the sternal end of the right fourth rib. J Forensic Sci 2008;53(2):288-95.
- Fleiss JL. Measuring nominal scale agreement among many raters. Psychological Bulletin. 1971;76(5):378-82.
- Krippendorff K. Reliability. In: Seawell MH, Hoffman CA, Selhort J, eds. Content Analysis, an Introduction to its Methodology, 2nd ed. California. Sage Publications; 2004. p.211-56.
- Krippendorff K. Reliability in content analysis some common misconceptions and recommendations. Human Communication Research 2004;30(3):411-33.
- Hayes AF, Krippendorff K. Answering the call for a standard reliability measure for coding data. Communication Methods and Measures 2007;1(1):77-89.