

**Sveučilište u Zagrebu**  
**Prehrambeno-biotehnološki fakultet**  
**Preddiplomski studij Nutricionizam**

**Barbara Marić**

7053/N

**USPOREDBA CDC I HR PERCENTILNIH KRIVULJA ZA PROCJENU**  
**UHRANJENOSTI DJECE POMOĆU BLAND-ALTMAN METODE**

**ZAVRŠNI RAD**

**Predmet: Modeliranje i optimiranje u nutricionizmu**

**Mentor: prof. dr.sc. *Jasenka Gajdoš Kljusurić***

**Zagreb, 2017.**

# TEMELJNA DOKUMENTACIJSKA KARTICA

Završni rad

**Sveučilište u Zagrebu**  
**Prehrambeno-biotehnološki fakultet**  
**Preddiplomski studij Nutricionizam**  
**Zavod za procesno inženjerstvo**  
**Laboratorij za mjerenja, regulaciju i automatizaciju**

**Znanstveno područje: Biotehničke znanosti**  
**Znanstveno polje: Nutricionizam**

## **USPOREDBA CDC I HR PERCENTILNIH KRIVULJA ZA PROCJENU UHRANJENOSTI DJECE POMOĆU BLAND-ALTMAN METODE**

***Barbara Marić, 0058206520***

**Sažetak:** Percentilne krivulje služe za procjenu rasta i razvoja djece tako što se djeca rangiraju na percentile i uspoređuju s djecom iste dobi i spola, odnosno referentnom skupinom. CDC krivulje su međunarodno priznate krivulje koje se koriste diljem svijeta, a neke države kao i Hrvatska posjeduju nacionalne krivulje. Cilj istraživanja bio je usporediti HR krivulje sa CDC krivuljama i ustanoviti dali su HR krivulje usklađene sa CDC krivuljama te time i objektivne u kliničkoj primjeni, za procjenu uhranjenosti. Ispitivana skupina su bila djeca iz Zagreba u dobi od 6 do 9 godina, te se na temelju izračunatih vrijednosti indeksa tjelesne mase određivao percentil na obje krivulje *BMI za dob* (CDC i HR). Uhranjenost prema percentilnim vrijednostima iz dviju krivulja uspoređena je prikazom normalne distribucije, frekvencija i primjenom Bland-Altmanove metode. Normalna distribucija prikazivala je odstupanja HR krivulja od CDC krivulja, dok prema Bland-Altman metodi nije bilo značajnih odstupanja i razlika između krivulja što je potvrda kako HR krivulje dobro procjenjuju uhranjenost djece te su rezultati u skladu sa CDC krivuljama.

**Ključne riječi:** Bland-Altman metoda, djeca, indeks tjelesne mase, percentilne krivulje uhranjenost

**Rad sadrži:** 21 stranica, 6 slika, 5 tablica, 21 literaturni navod, 3 priloga

**Jezik izvornika:** hrvatski

**Rad je u tiskanom i elektroničkom obliku pohranjen u knjižnici Prehrambeno-biotehnološkog fakulteta Sveučilišta u Zagrebu, Kačićeva 23, 10 000 Zagreb**

**Mentor:** *prof. dr.sc. Jasenka Gajdoš Kljusurić*

**Pomoć pri izradi:** *prof. dr.sc. Jasenka Gajdoš Kljusurić*

**Datum obrane:** 17. srpnja 2017

## BASIC DOCUMENTATION CARD

Bachelor thesis

**University of Zagreb**  
**Faculty of Food Technology and Biotechnology**  
**Undergraduate studies Nutrition**  
**Department of Process engineering**  
**Laboratory for Measurement, Regulation and Automatisation**

**Scientific area: Biotechnical Sciences**  
**Scientific field: Nutrition**

### **COMPARATION OF CDC AND CRO PERCENTILE GROWTH CHARTS FOR AS- SESSMENT OF NUTRITIONAL STATUS OF CHILDREN USING BLAND-ALTMAN 'S METHOD**

***Barbara Marić, 0058206520***

**Abstract:** Percentile growth charts are used to estimate the growth and development of children by classifying them to percentiles and comparing them with children of the same age and gender, their referral group. CDC growth charts are internationally recognized curves used throughout the world while some countries as well as Croatia have also national curves (CRO). The aim of the study was to compare the CRO growth charts with the CDC growth charts and determine whether the CRO curves are in accordance with the CDC curves and applicable in clinical application for estimation of nutritional status. The examined group were children from Zagreb aged 6 to 9 years old and their body mass index was evaluated by use of CDC and CRO percentile growth charts. Evaluated percentiles were compared using normal distribution of frequencies and by use of Bland-Altman method. The normal distribution showed that the CRO curves differ from the CDC curves, whereas the Bland-Altman method did not show significant deviations and the difference between the curves. This finding confirms the objectivity of the CRO growth charts in the estimation of children's nutritional status.

**Keywords:** Bland-Altman method, body mass index, children, nutritional status, percentile growth curves

**Thesis contains:** 21 pages, 6 figures, 5 tables, 21 references, 3 supplements

**Original in:** Croatian

**Thesis is in printed and electronic form deposited in the library of the Faculty of Food Technology and Biotechnology, University of Zagreb, Kačićeva 23, 10 000 Zagreb**

**Mentor:** *PhD Jasenka Gajdoš Kljusurić, full prof.*

**Technical support and assistance:** *PhD Jasenka Gajdoš Kljusurić, full prof.*

**Defence date:** July 17<sup>th</sup> 2017

## *Sadržaj*

<b>1. UVOD .....</b>	<b>1</b>
<b>2. GLAVNI DIO .....</b>	<b>3</b>
<b>2.1. PROCJENA UHRANJENOSTI DJECE I ADOLESCENATA .....</b>	<b>3</b>
<b>2.2. CDC KRIVULJE.....</b>	<b>6</b>
<b>2.3. HRVATSKE KRIVULJE .....</b>	<b>8</b>
<b>3. METODE RADA.....</b>	<b>9</b>
<b>3.1 ISPITANICI .....</b>	<b>9</b>
<b>3.2 METODE RADA .....</b>	<b>9</b>
3.2.1 Normalna distribucija i distribucija frekvencija.....	9
3.2.2. Bland-Altman metoda .....	10
<b>4. REZULTATI I RASPRAVA .....</b>	<b>11</b>
<b>4.1 NORMALNA DISTRIBUCIJA INDEKSA TJELESNE MASE .....</b>	<b>11</b>
<b>4.2. BLAND-ALTMAN GRAFOVI .....</b>	<b>16</b>
<b>5. ZAKLJUČAK.....</b>	<b>19</b>
<b>6. LITERATURA.....</b>	<b>20</b>
<b>PRILOZI .....</b>	<b>22</b>

## 1. Uvod

Pretilost je zdravstveno stanje u kojem dolazi do abnormalnog akumuliranja masti u tijelu koja utječe na zdravlje i kvalitetu života pojedinca. Kao prvi i najjednostavniji indikator pretilosti kod odrasle populacije koristi se indeks tjelesne mase (*Body mass index, BMI*) u kojem se u omjer stavljaju tjelesna masa u kilogramima (kg) i kvadrat visine u metrima (m<sup>2</sup>). Pretilima se smatraju osobe čiji je BMI veći ili jednak 30 kg/ m<sup>2</sup> (WHO, 2014).

Prevalencija pretilosti u svijetu raste, te se u razdoblju od 1980. do 2014. godine gotovo udvostručila i prema podacima Svjetske zdravstvene organizacije (World Health Organization – WHO) iz 2014. godine 13% populacije je pretilo od toga 11% muškaraca i 15% žena. Pretilost je ozbiljan globalni problem koji je čak prozvan epidemijom koja ne zahvaća samo odraslu populaciju nego nažalost i djecu i adolescente.

Pretilost kod djece i adolescenata ozbiljan je zdravstveni problem koji ne utječe samo na sadašnje zdravstveno stanje, već i na njegovu budućnost. Komplikacije koje se javljaju uslijed pretilosti kod djece su brojne, poput metaboličkog sindroma, astme, gastrointestinalnih, ortopedskih, te čak i psiholoških komplikacija. U budućnosti djeca koja su pretila imaju čak 80% veći rizik da budu pretila i u odrasloj dobi, te da metabolički sindrom i ostale komplikacije prerastu u kardiovaskularne bolesti ili dijabetes i u konačnici dovode do smanjenja kvalitete i očekivanog trajanja života (Bralić i sur., 2010).

U posljednjih nekoliko godina zabilježen je porast prevalencije pretilosti kod djece i procjenjuje se da je broj djece ispod 5 godina s prekomjernom tjelesnom masom u svijetu preko 42 milijuna (WHO, 2015).

Hrvatska ne zaostaje u odnosu na svjetsku statistiku, te prema podacima Hrvatskog zavoda za javno zdravstvo iz 2017. godine 20,14% odraslih muškaraca i 20,60% odraslih žena u Hrvatskoj smatra se pretilima, 26,4% djece predškolske dobi je prekomjerne tjelesne mase dok ih je 11,2% pretilo zbog čega se Hrvatska nalazi čak na sedmom mjestu u Europi po broju djece s prevelikom tjelesnom masom.

Za procjenu uhranjenosti kod djece najčešće korišteno sredstvo su percentile krivulje. Djeca se na temelju mjerenja antropometrijskih veličina (visina, masa, duljina, opseg glave) rangiraju na odgovarajuće percentile što omogućuje usporedbu s ostalom djecom iste dobi i spola. Postoji više vrsta percentilnih krivulja. Neke od njih se koriste širom svijeta, poput onih od strane Svjetske zdravstvene organizacije ili CDC krivulja izrađenih od strane Američkog centra za kontrolu i prevenciju bolesti. Hrvatska posjeduje vlastite krivulje izrađene na temelju nacionalnih antropometrijskih mjerenja.

Za izradu krivulja potrebno je mjerenje provesti na reprezentativnom uzorku, te je podatke potrebno periodički obnavljati jer u protivnom može doći do neispravnih procjena djece tijekom korištenja krivulje.

Postoji pitanje koja se krivulja treba koristiti pri procjeni uhranjenosti djece, a cilj ovog istraživanja je upravo odrediti dali je bolje koristiti nacionalne hrvatske krivulje ili CDC krivulje u procjeni uhranjenosti djece drugog i trećeg razreda osnovne škole u Zagrebu. Za usporedbu tih dvaju krivulja koristi se Bland-Altman metoda.

## **2. Glavni dio**

### **2.1. PROCJENA UHRANJENOSTI DJECE I ADOLESCENATA**

Na rast i razvoj djeteta utječe niz faktora poput genetike, prehrane, tjelesne aktivnosti, zdravstvenog stanja, okoline itd. zbog čega se ne razvijaju sva djeca istim intenzitetom. Iz tog je razloga teško kod djeteta procijeniti dali je njegova visina ili težina adekvatna i razvija li se dijete sukladno očekivanjima. Rast i razvoj djece osnovni su pokazatelji njihova zdravstvenog stanja, a najčešće korišteni klinički indikator rasta i razvoja su percentilne krivulje koje se koriste u savjetovaništima za zdravu djecu ili u ambulantama za kronične bolesti (Grgurić, 2008).

Pri procjeni djeteta potrebno ga je rangirati na određeni percentil, prema njegovim antropometrijskim veličinama (visina, tjelesna masa, dužina, opseg glave) u odnosu na neki od faktora, primjerice dob. Percentil na kojem se dijete nalazi zatim ga rangira unutar nekog postotka referentne skupine i na taj način ukazuje dali se dijete razvija sukladno očekivanjima ili iskače iz prosjeka. Pri procjeni najprije treba voditi računa o spolu djeteta jer se ne razvijaju dječaci i djevojčice jednakim intenzitetom zbog čega se i krivulje razlikuju prema spolu. Osim spola, važna je djetetova dob pa postoje krivulje za novorođenčad i djecu do 3. godine života i krivulje za djecu i adolescente od 2. do 20. godine života. Primjerice, ako promatramo masa za dob krivulju i dijete prema svojim podacima pripada 25. percentilu, tada kažemo kako 25% referentne populacije ima manju ili jednaku masu, a 75% populacije ima veću tjelesnu masu od ispitivanog djeteta. Također, zdravo dijete uglavnom prati vlastitu krivulju, te svaki veći pomak prema višim ili nižim krivuljama može ukazivati na neki poremećaj. Za posebne potrebe, poput Down sindroma postoje posebne krivulje koje su prilagođene s obzirom na njihove posebitosti.

Postoje dvije vrste percentilnih krivulja, standardne i referentne. Standardne krivulje sadrže vrijednosti koje bi djeca u optimalnim uvjetima odrastanja trebala doseći, dok se referentne krivulje odnose na razvoj djece na određenom području i vremenu zbog čega one ne moraju nužno biti maksimalni potencijal koji djeca mogu postići. Za praćenje razvoja trebale bi se koristiti isključivo standardne krivulje, dok se za komparaciju sa referentnom skupinom mogu koristiti referentne krivulje (Grgurić, 2008).

Kao alat za procjenu uhranjenosti djece i adolescenata, odnosno za otkrivanje rizika za razvoj prekomjerne tjelesne mase i pretilosti, koriste se BMI krivulje za dob. Računanje indeksa tjelesne mase, ITM (engl. Body mass index, BMI) je vrlo jednostavna jednadžba u kojoj se u omjer stavljaju tjelesna masa u kilogramima (kg) i tjelesna visina u metrima kvadratnim (m<sup>2</sup>). Međutim, indeks tjelesne mase nije adekvatan pokazatelj pretilosti jer ne uključuje sastav tijela, te je iz tog razloga uz indeks tjelesne mase potrebno provesti daljnja mjerenja poput debljine kožnih nabora ili električne impedance koje omogućuju procjenu udjela masnog tkiva u tijelu.

BMI za dob krivulje koriste se za procjenu djece u dobi od 2 do 20 godina, a osim što su specifične za dob krivulje su specifične za spol. Stupanj uhranjenosti kod djeteta procjenjuje se na temelju percentila na kojem se dijete nalazi prema izmjerenom indeksu tjelesne mase i svojoj dobi i spolu. U tablici 1 je prikazano koje su granice percentila za kategorije uhranjenosti kod djece (Teskera, 2016; CDC, 2015a).

**Tablica 1. Prikaz kategorija uhranjenosti prema ITM za dob krivulji (CDC, 2015b)**

<b>Status</b>	<b>Percentil</b>
<b>Pothranjenost</b>	< 5. percentila
<b>Normalna tjelesna masa</b>	od 5. do 85. percentila
<b>Prekomjerna tjelesna masa</b>	od 85. do 95. percentila
<b>Pretilost</b>	> 95. percentila

Osim nedostataka, BMI za dob krivulje imaju i brojne prednosti zbog kojih su od strane stručnjaka prozване vjerodostojnim alatom u procjeni uhranjenosti djece i adolescenata. Neke od prednosti BMI za dob krivulja su:

- BMI za dob krivulje su jedine krivulje koje obuhvaćaju visinu, težinu i dob u jednom grafu
- krivulje su primjenjive od druge godine života sve do odrasle dobi jer su krivulje sukladne s indeksom za odrasle, te na taj način omogućuju praćenja povezanosti između pretilosti u dječjoj i odrasloj dobi
- BMI za dob ukazuju na rizik od razvitka kroničnih bolesti poput hiperglikemije, visokog tlaka, inzulinske rezistencije (CDC, 2015b).



Procjena uhranjenosti kod djece je izrazito važna jer visoki indeks tjelesne mase (ITM > 30 kg/m<sup>2</sup>) u djetinjstvu i adolescenciji povećava rizik za razvoj pretilosti i kroničnih bolesti u odrasloj dobi. Djeca i adolescenti s ITM vrijednostima iznad 95. percentila (ITM > 30 kg/m<sup>2</sup>) imaju od 62-98% rizika za prekomjernu tjelesnu masu i u odrasloj dobi (Guo i sur., 2002). BMI za dob krivulje su također u korelaciji s kliničkim faktorom za razvoj kardiovaskularnih bolesti poput hiperlipidemije, visokog krvnog tlaka i dijabetesa tipa 2. 60 % djece koja su bila pretila u dobi od 5 do 10 godina imali su prisutan najmanje jedan biokemijski ili klinički rizični faktor za razvoj kardiovaskularnih bolesti, a njih 20% imalo je dva ili više prisutnih faktora (Freedman i sur., 1999).

## 2.2. CDC KRIVULJE

CDC (*Clinical growth charts*) percentilne krivulje ilustriraju distribuciju određenih antropometrijskih veličina djece i koriste se za praćenje rasta i razvoja dojenčadi, djece i adolescenata u SAD-u od 1977. godine. CDC krivulje su stvorene od strane Nacionalnog zdravstvenog centra za statistiku (NCHS), te spadaju u skupinu referentnih krivulja koje služe za procjenu adekvatnosti rasta i razvoja djece u odnosu na referentnu populaciju (CDC, 2010).

Krivulje iz 1977. su u doba kada su izdane imale široku primjenu, te su čak od strane Svjetske zdravstvene organizacije priznate i za internacionalnu primjenu. Međutim uskoro su s većom dostupnošću podataka utvrđeni brojni nedostaci kao što su primjerice nemogućnost procjene ekstrema ispod 5. i iznad 95. percentila i nemogućnost procjene adolescenata iznad 18-ste godine života. Osim toga, krivulje za procjenu novorođenčadi i djece do 3. godine života su zbog ne referentnih podataka smatrane neispravnima. Naime podaci su se za izradu krivulja prikupljali na temelju Fels studije (Fels Longitudinal Growth Study) koja je provedena na novorođenčadi bijele rase iz Ohio-a koja je bila hranjena isključivo dojenačkim formulama, te su mjerenja provedena u neadekvatnim vremenskim intervalima koji su bili nedostadni za procjenu rasta djece. Zbog navedenih nedostataka i dostupnosti novijih nacionalnih mjerenja 2000. godine uvedene su nove krivulje koje su predstavljale bolji klinički alat u procjeni rasta i razvoja djece (Kuczmarski i sur., 2002).

Konstruirane su nove krivulje koje se dijele prema dobi i spolu, pa tako razlikujemo krivulje za novorođenčad do 3. godine života i djecu i adolescente od 2 do 20 godina. Svaki graf sadrži 9 percentila (3., 5., 10., 25., 50., 90., 95. i 97.), odnosno postoje krivulje sa 3. i 97. percentilom i krivulje sa 5. i 95. percentilom. Izuzetak je BMI za dob krivulja koja sadrži dodatni 85. percentil koji predstavlja tzv. cutoff vrijednost koja ukazuje na rizik od prekomjerne tjelesne mase i pretilosti kod djece i adolescenata. BMI za dob krivulje su uvedene umjesto masa za staturu krivulja iz 1977. godine, te je njihova namjena procjena uhranjenosti djece od 2. godine nadalje i omogućuju rano otkrivanje rizika pretilosti kod djece (CDC, 2015a).

Ukupno postoji 14 krivulja za djevojčice i dječake, te dvije dodatne krivulje za djecu od 2 do 5 godina pregled krivulja prikazan je u tablici 2.

**Tablica 2.** Pregled CDC krivulja (Teskera, 2016)

<b>DOB I SPOL</b>	<b>VRSTA KRIVULJE</b>
<b>dječaci, od rođenja do 36 mjeseci</b>	masa za dob
	dužina za dob
	masa za dužinu
	opseg glave za dob
<b>djevojčice, od rođenja do 36 mjeseci</b>	masa za dob
	dužina za dob
	masa za dužinu
	opseg glave za dob
<b>dječaci, 2-20 godina</b>	masa za dob
	visina za dob
	BMI za dob
<b>djevojčice, 2-20 godina</b>	masa za dob
	visina za dob
	BMI za dob
<b>dječaci, 2-5 godina</b>	masa za visinu
<b>djevojčice, 2-5 godina</b>	masa za visinu

CDC krivulje rasta nisu namijenjene za samostalnu primjenu, već su konstruirane kao alat koji može pridonijeti sveukupnoj kliničkoj slici promatranog djeteta. Prvenstveno je potrebno provesti adekvatno mjerenje antropometrijskih veličina kod djeteta prema kojima ih se rangira na odgovarajući percentil referentne populacije i omogućuje rano otkrivanje potencijalnih zdravstvenih problema. Primjerice, opseg glave za dob krivulje se koriste kod novorođenčadi i djece do 3. godine života i omogućuju praćenje razvoja mozga, dok dužina za dob krivulje omogućuju praćenje rasta kod djece. CDC krivulje su jednostavne za korištenje i dostupne su na internetu širokoj populaciji što znači da nisu namijenjene samo za primjenu u ambulantama, već se njima mogu koristiti i sami roditelji. (CDC, 2015b).

### **2.3. HRVATSKE KRIVULJE**

Prva nacionalna mjerenja u Hrvatskoj su provedena u razdoblju od 1980-1984. godine, te su prema tim podacima izrađene krivulje rasta za djecu od 6 do 19 godina. Međutim, zbog procjene zastarjelosti podataka dobivenih u studiji iz 1980. godine, sastavljena je grupa stručnjaka Vesna Jureša, Vera Musil i Mirjana Kujundžić Tiljak sa Nastavnog zavoda za javno zdravstvo Dr. Andrija Štampar. Mjerenja su provedena u osnovnim i srednjim školama na području cijele Hrvatske u razdoblju od 2006 do 2008. godine, a ciljna skupina su bila djeca u dobi od 6.5 do 18.5 godina. Na temelju upitnika i sistematskih pregleda prikupljeni su podaci o tjelesnoj masi i visini, te su uspoređeni s podacima iz 1980. godine i uočen je trend porasta tjelesne mase i tjelesne visine kod djece u posljednjih 20 godina. Nove krivulje predstavljaju bolji alat u procjeni rasta i razvoja djece od krivulja iz osamdesetih godina (Jureša, 2011). Međutim, Hrvatska nema nacionalne krivulje rasta za predškolsku djecu, no prihvaćeno je korištenje krivulja Svjetske zdravstvene organizacije – WHO krivulja. Ministarstvo zdravstva je donijelo odluku o uvođenju zdravstvenih iskaznica za svu novorođenu djecu putem kojih je usvojena primjena novih antropometrijskih standarda, te niza predradnji za primjenu WHO krivulja (Grgurić, 2008).

Iznimno je važno periodički obnavljati nacionalna mjerenja jer u protivnom zastarjele i ne referentne krivulje nemaju svoju namjenu, pa čak i mogu utjecati na krivu procjenu djetetova razvoja (HZJZ, 2014). Također, izrada nacionalnih krivulja i njihova upotreba ima prednosti pred onim internacionalnim jer su okolišni uvjeti u državama ipak različiti (Jureša, 2011).

### **3. Metode rada**

#### **3.1 ISPITANICI**

Ispitanici u ovom istraživanju bili su dječaci i djevojčice prvih i drugih razreda osnovne škole u Zagrebu. Ukupni broj ispitanika iznosio je 60, od kojeg su bile 31 djevojčica i 29 dječaka u dobi od 6 do 9 godina. Podaci o datumu rođenja, tjelesnoj visini i tjelesnoj masi prikupljali su se u prvim i drugim razredima pod suglasnošću ravnatelja i roditelja u 2013/14. školskoj godini. Iz prikupljenih vrijednosti izračunat je indeks tjelesne mase za svako dijete. Podaci za percentilne vrijednosti iz HR krivulja preuzeti su iz dijela istraživanja Zavoda za javno zdravstvo Dubrovačko-neretvanske županije, koja koristi navedene krivulje.

#### **3.2 METODE RADA**

Za procjenu uhranjenosti djece koristile su se dvije vrste percentilnih krivulja: CDC krivulje (prilog 1 i 2) i HR krivulje (prilog 3 ) u kojima su se djeca rangirala na odgovarajući percentil prema vrijednosti indeksa tjelesna mase, te s obzirom na svoju dob i spol. Sve korištene krivulje su referente.

##### **3.2.1 Normalna distribucija i distribucija frekvencija**

Normalna distribucija je zvonkolika krivulja koja svoju primjenu pronalazi u brojnim situacijama za prikaz podataka. Tjeme funkcije određeno je aritmetičkom sredinom svih podataka, dok standardna devijacija određuje raširenost krivulje. Najmanji postotak podataka nalazi se na rubovima krivulje, a najveći u sredini u području aritmetičke sredine. Ukupna površina ispod krivulje iznosi jedan ili 100%. Oblik distribucije omogućuje nam interpretaciju rezultata, a svaka krivulja se definira momentima prvog, drugog, trećeg i četvrtog reda.

Distribucija frekvencija je raspodjela podataka mjerene veličine što je u ovom radu indeks tjelesne mase osnovnoškolaca. Visina krivulje određena je koncentracijom podataka, odnosno frekvencijom podataka unutar raspona (Zrno, 2011).

### 3.2.2. Bland-Altman metoda

Prilikom uvođenja nove ili alternativne metode mjerenja u kliničkim ispitivanjima potrebno je usporediti slaganje nove s već postojećom metodom kako bi se ispitala njezina adekvatnost. U slučaju da je prisutna visoka razina ne slaganja, nova metoda smatra se neadekvatnom zamjernom i neće biti primijenjena (Bland i Altman, 1986).

Koeficijent korelacije ( $r$ ) je često korištena statistička tehnika koja pokazuje linearnu vezu između dvije skupine podataka, ali ne smatra se dovoljno preciznom i relevantnom za usporedbi dviju metoda jer su podaci smješteni u blizini ili na regresijskom pravcu zbog čega je teško procijeniti njihovo međusobno slaganje (Giavarina, 2015). Nadalje, koeficijent korelacije nije adekvatna metoda za usporedbu metoda koje mjere istu veličinu jer visoka korelacija za usporedbu dvaju istih veličina nije ista kao i visoka korelacija za veličine koje se odnose na dva različita parametra. Zbog toga često metode koje se već vizualno slabo slažu mogu često imati vrlo visoke koeficijente korelacije, te se koeficijent korelacije ne smatra mjerilom sporazuma dviju metoda mjerenja, već mjerom udruživanja dviju veličina (Bland i Altman, 1983).

1983. godine J. Martin Bland i Douglas G. Altman predstavili su metodu koja grafički prikazuje kvantifikaciju razlika između mjerenih podataka dviju metoda, te omogućuje njihovu jednostavniju usporedbu. Budući da mjerenja dvaju metoda vrlo vjerojatno neće biti u potpunosti identična i uvijek će neka razlika postojati, Bland-Altman prezentirali su metodu koja omogućuje utvrđivanje veličine razlike. Kada je razlika prevelika, odnosno nalazi se iznad postavljenog limita, tada smatramo metodu neadekvatnom. Limit je unaprijed određena vrijednost koja se računa kao srednja vrijednost svih razlika  $\pm 1,96x$  standardna devijacija. Razlike dvaju mjerenja prikazane su u grafu u odnosu na svoju srednju vrijednost, koja se smatra relevantnom uslijed nepoznavanja točne vrijednosti veličine koje mjerimo. Očekivanja su da se unutar postavljenih limita nalazi 95% razlika između podataka koje smatramo prihvatljivima. U slučaju da su razlike u većoj mjeri smještene izvan postavljenih granica, tada metodu ne smatramo adekvatnom tj. primjenjivom jer može utjecati na povećanje ili smanjenje vrijednosti mjerenja u usporedbi s već afirmiranom metodom (Blan i Altman, 1999).

## 4. Rezultati i rasprava

Rezultati su prikazani pomoću dva tipa grafova, pomoću normalne distribucije i Bland-Altman grafova.

Prvih niz grafova (1-3) prikazuje normalnu distribuciju BMI vrijednosti za svu djecu, te posebno za djevojčice i dječake, ovisno o korištenoj percentilnoj krivulji (CDC ili HR). Za svaku krivulju izračunati su i momenti koji omogućuju njihovu usporedbu.

Drugi niz (4-6) su Bland-Altman grafovi koji omogućuju usporedbu podudarnosti dviju vrsta percentilnih krivulja za procjenu uhranjenosti djece.


### 4.1 NORMALNA DISTRIBUCIJA INDEKSA TJELESNE MASE

Normalna ili Gaussova distribucija je najčešći oblik distribucije frekvencija podataka kontinuiranih varijabli (varijable koje mogu poprimiti bilo koju vrijednost između specifičnih vrijednosti). Većina vrijednosti takve varijable grupirana je oko područja njihove srednje vrijednosti jer uzastopnim mjerenjem jedne varijable postoji tendencija postizanja jednakog rezultata. Kontinuirana krivulja stoga ima oblik zvona u kojoj je najveći broj vrijednost grupiran oko srednjih razreda, tj. oko aritmetičke sredine  $\pm$  odstupanja standardne devijacije. Zbog toga je za izradu normalne distribucije podataka potrebno poznavati osnovne parametre - aritmetičku sredinu i standardnu devijaciju. Oblik krivulje omogućuje nam interpretaciju rezultata, te je moguće izračunati postotke podataka koji se nalaze u određenim intervalima ispod krivulje:


- u intervalu  $\bar{x} \pm 1s$  nalazi se 68.26% podataka,
- u intervalu  $\bar{x} \pm 2s$  nalazi se 95.46% podataka,
- u intervalu  $\bar{x} \pm 3s$  nalazi se 99.72% podataka (Zrno, 2011).

Ako aritmetičkoj sredini svih podataka dodamo jednu standardnu devijaciju (+1s), tada je obuhvaćeno 68% površine ispod krivulje, odnosno obuhvaćeno je 68,26% rezultata. Dodatkom dvije standardne devijacije (+2s) obuhvaćamo 95,44% podataka, a s tri standardne devijacije (+3s) skoro svi podaci su obuhvaćeni, točnije 99,73% podataka. Ne mogu se obuhvatiti svi podaci (100%) jer se krivulja distribucije asimptotski približava apscisi i nikada ju ne siječe.

Na slikama (1-3) su prikazane krivulje distribucije frekvencija za vrijednosti indeksa tjelesne mase (ITM).




**Slika 1.** Normalna distribucija *ITM* za *dob*, za cijelu promatrano skupinu



**Slika 2.** Normalna distribucija *ITM* za *dob*, za djevojčice





**Slika 3.** Normalna distribucija *ITM za dob*, za dječake

Iz prikaza distribucije frekvencije percentila vidljivo je kako hrvatske krivulje odstupaju od CDC krivulja. Međutim, računanje momenata za krivulje omogućuje nam njihovu usporedbu i interpretaciju.

Prvi i drugi moment definirani su aritmetičkom sredinom i standardnom devijacijom svih podataka i smatraju se osnovnim parametrima u definiranju distribucije. Aritmetička sredina ( $M1$ ) određuje tjeme svake krivulje, dok standardna devijacije ( $M2$ ) označava mjeru odstupanja pojedinih podataka u nizu od njihove srednje vrijednosti i time definira raspršenost krivulje (Zrno, 2011).

Moment trećeg reda ( $M3$ ) ili koeficijent asimetrije može poprimiti negativne i pozitivne vrijednosti. Kada je treći moment pozitivan ( $M3 > 0$ ) krivulja je pozitivno asimetrična, tj. pomaknuta je u desnu stranu. Ukoliko je moment negativan ( $M3 < 0$ ) krivulja je pomaknuta u lijevo i negativno je asimetrična. Moment trećeg reda može poprimiti i točno vrijednost 0, te tada kažemo da je krivulja simetrična jer se sa svake strane krivulje nalazi jednak broj podataka.

Moment četvrtog reda ( $M4$ ) je mjera spljoštenosti krivulje. U slučaju da je vrijednost četvrtog momenta veća od nula ( $M4 > 0$ ) kažemo da je krivulja izdužena u visinu – šiljasta. Kada je vrijednost momenta manja od nule ( $M4 < 0$ ) tada je krivulja spljoštena.

**Tablica 3.** Momenti za krivulje distribucije percentila dviju vrsta krivulja (CDC i HR)

<b>CIJELA SKUPINA</b>	<b>M1</b>	<b>M2</b>	<b>M3</b>	<b>M4</b>
<b>CDC</b>	47,4	28,1	0,17	-1,13
<b>HR</b>	37	24,8	0,63	-0,43

Izračunati momenti dokazuju kako razlika između krivulja postoji, ali razlika je mala. Moment trećeg reda za CDC krivulje iznosi 0,17 što se smatra zanemarivom asimetrijom jer je vrijednost unutar raspona od 0-0,25. Hrvatska krivulja je također pozitivno asimetrična, ali prisutna je srednja asimetričnost što bi značilo da je manji broj djece smješteno na vrijednostima viših percentila. Vrijednosti momenta četvrtog reda za obje krivulje manje su od 0 što znači da su obje krivulje spljoštene.

**Tablica 4.** Momenti za HR i CDC krivulje za djevojčice

<b>DJEVOJČICE</b>	<b>M1</b>	<b>M2</b>	<b>M3</b>	<b>M4</b>
<b>CDC</b>	47,7	30,7	0,19	-1,43
<b>HR</b>	41	26,8	0,39	-0,87

Prema vrijednostima momenata za krivulje koje prikazuju distribucije frekvencija percentila za djevojčice ukazuju na slične razlike. Obje su krivulje spljoštene jer su vrijednosti četvrtog momenta ispod 0. Asimetričnost je prisutna kod obje krivulje, a HR krivulja je više pomaknuta u desnu stranu jer je više djece smješteno na niže percentile nego je to prema CDC krivuljama.

**Tablica 5.** Momenti za HR i CDC krivulje za dječake

<b>DJEČACI</b>	<b>M1</b>	<b>M2</b>	<b>M3</b>	<b>M4</b>
<b>CDC</b>	47	25,6	0,09	-0,85
<b>HR</b>	32,8	22,2	0,83	0,07

Vrijednost momenta prvog reda za sve tri HR krivulje manja je od vrijednosti CDC krivulja što također ukazuje na manji broj pretile djece nego što to ističu CDC krivulje. Srednja vrijednost označava vrijednost oko koje se većina podataka ima tendenciju grupirati. Vrijednost momenta četverog reda za HR krivulju za dječake ukazuje na izduženi oblik jer je vrijednost iznad 0, dok je za CDC krivulju i dalje vrijednost ispod 0 što označava spljoštenost krivulje.


Uspoređujući HR krivulje za dječake i djevojčice vidljivo je prema momentu prvog reda da su djevojčice smještene na više percentile od dječaka, odnosno srednja vrijednost percentila za djevojčice iznosi 41, dok za dječake iznosi 32,8. Takvi rezultati posljedica su intenzivnijeg rasta dječaka u visinu u odnosu na djevojčice, zbog čega je indeks tjelesne mase nešto niži i dječaci su smješteni u prosjeku na niže percentile. Prema istraživanju iz 2012. godine 50. percentil odgovarao je visini od 180,4 cm za osamnaestogodišnjih dječaka, a za osamnaestogodišnju djevojčicu je odgovarao visini od 166,49 cm (Jureša i sur., 2012).

Razlike između krivulja su male, ali ipak postoje što je posljedica utjecaja okoliša odnosno nacionalnih razlika. Također, indeks tjelesne mase (ITM) ne uzima u obzir stastav tijela (udio masnog tkiva i nemasne mase), već samo tjelesnu masu i tjelesnu visinu (Vezilić, 2014). To bi značilo da su djeca iz Hrvatske vjerojatno viša i teža od djece u Americi koja su činila referentnu skupinu za izradu CDC krivulja, zbog čega je i veći broj djece prema HR krivulja smješten na nižim percentilima u odnosu na CDC krivulje.


U Hrvatskoj je prema posljednjim istraživanjima prisutan sekularni trend rasta prema kojem su djeca i adolescenti u dobi od 6,5 do 18,5 godina i viša i teža od svojih vršnjaka prije 22 godine. Pojam sekularnog rasta označava progresivni porast visine i tjelesne mase, odnosno ranije sazrijevanje koje je prisutno tijekom nekoliko generacija, te na njega imaju utjecaj spol, dob, rasa, etička pripadnost, socio-ekonomski status itd. Zbog različitih utjecaja prisutne su i razlike u sekularnim trendovima rasta između zemljopisnih područja (Bralić, 2008). Prema istraživanju iz 2008. godine dječaci u dobi od 7 godina su 2,7 cm viši od dječaka iz 1984. godine, a djevojčice su više od svojih vršnjakinja za 2,5 cm. (Jureša i sur., 2012).

Na temelju normalnih distribucija za krivulje i dobivenih rezultata momenata vidljivo je kako razlike u krivuljama postoje, ali ne dobivamo konkretan odgovor koje krivulje su adekvatnije u primjeni procjene uhranjenosti djece u Hrvatskoj. Odgovor na to pitanje može dati Bland-Altman metoda koja služi za procjenu slaganja dvije skupine mjerenja, uključujući i njihove pogreške (Hanneman, 2008).


## 4.2. BLAND-ALTMAN GRAFOVI



**Slika 4.** Bland-Altman graf za CDC i HR krivulje za parametar *BMI za dob*



**Slika 5.** Bland-Altman graf za CDC i HR *BMI za dob* krivulje za djevojčice



**Slika 6.** Bland-Altman graf za CDC i HR *BMI za dob* krivulje za dječake

Bland-Altmanova metoda nam grafički omogućuje prikaz razlike percentila za vrijednosti indeksa tjelesne mase sa dvije vrste krivulja (CDC i HR) iz kojeg je moguće očitati koliki postotak podataka odstupa od dozvoljenih granica prihvatljivosti i adekvatnost primjene određene krivulje za procjenu uhranjenosti djece.

Prema Bland-Altman metodi očekuje se kako 95% podataka ulazi unutar granica vrijednosti  $\pm 1,96$  standardnih devijacija od srednje vrijednosti svih podataka, u ovom slučaju razlike percentila očitanih sa CDC i HR krivulja za osnovnoškolsku djecu. Ostalih 5% podataka koji se mogu naći izvan granica dobivenog raspona smatra se prihvatljivim razlikama i neće utjecati na ocjenu adekvatnosti, točnije slaganja dviju krivulja (Myles, 2007).

Bland-Altman grafovi nam također omogućuju određivanje pristranosti i stupnja rasipanja podataka. Ako je jedna mjerna metoda prihvaćena kao precizna i točna, čime predstavlja tzv. "zlatni standard", a postoji pristranost tada će druga metoda mjerenja ili procjene dati drugačiju sredinu. Rasipanje podataka pojavljuje se uslijed pogreške u mjerenju koja odgovara stalnom odstupanju od točne vrijednosti (Smith i sur., 2010).

Na slici 4. je prikazan Bland-Altman graf koji prikazuje raspodjelu razlika između vrijednosti percentila očitanih sa CDC i HR krivulja za parametar BMI za dob. Vidljivo je kako većih rasipanja nema jer samo jedna točka na grafu odstupa izvan dozvoljenih granica na što je unutar prihvatljivih 5%. Sve vrijednosti koje se nalaze izvan crvenih isprekidanih linija nazivamo tzv. outlier i očekuje se kako će 2-5% podataka biti takvih jer je nemoguće da se mjerenja pomoću dviju metoda poklapaju u potpunosti (Vezilić i sur., 2014). U ovom slučaju broj izmjerene djece iznosi 60, što znači da 3 točke mogu odstupati izvan granica raspona, a da pritom možemo smatrati da razlike između krivulja neće utjecati na procjenu uhranjenosti. Odnosno, tada kažemo da nema značajnih odstupanja između percentilnih vrijednosti očitanih sa CDC i HR krivulja što potvrđuje njihovu usklađenost.

Na slikama 5. i 6. prikazani su Bland-Altman grafovi posebno za dječake i djevojčice. Grafovi potvrđuju rezultate dobivene u slici 4. jer nema značajnih odstupanja, odnosno rasipanja izvan granica sličnosti.

U gore izračunatim distribucijama frekvencija očitanih percentila dobiveni su rezultati koji ukazuju na postojanje manjih razlika između krivulja, ali nedovoljno ukazuju na adekvatnost primjene krivulja u ocjeni uhranjenosti i njihovo međusobno slaganje. Bland-Altman nam je stoga dao odgovor o slaganju CDC i HR krivulja i potvrdio kako su prethodno uočene razlike posljedica razlike u rastu dječaka i djevojčica, odnosno posljedica sekularnog trenda prisutnog u Hrvatskoj, te kako one neće značajno utjecati na mjerenja koja će se provoditi.

Pretilost je danas rastući problem u društvu od kojeg prema podacima Svjetske zdravstvene organizacije (WHO, 2014) većina stanovništva živi u državama u kojima pretilost ubija više ljudi nego pothranjenost. Zbog toga se uvodi sve više nacionalnih planova za prevenciju i liječenje pretilosti. U Hrvatskoj je 2006. godine Ministarstvo obitelji, branitelja i međugeneracijske solidarnosti RH uvelo plan za promicanje zdravijeg načina života kod djece i mladih. Prevencija pretilosti kod djece od izuzetne je važnosti jer ima za posljedicu pojavu pretilosti i kroničnih oboljenja u kasnijoj životnoj dobi (Škerija i sur., 2008).

Iz zabrinjavajućih statističkih podataka i posljedica pretilosti na zdravlje djece i odraslih, potvrđujemo važnost redovitog praćenja statusa uhranjenosti djece tijekom njihovog razvoja.

## 5. Zaključak

Cilj ovog rada bio je ustanoviti slaganje HR krivulja sa međunarodno priznatim CDC krivuljama razvijenih u američkom Nacionalnom centru za zdravstvenu statistiku (NCHS), te dobiti odgovor dali HR krivulje mogu biti adekvatna zamjena CDC krivulja u procjeni djece u Hrvatskoj.

Kako bi se dobio odgovor na pitanje korištene su dvije metode za usporedbu tih dviju krivulja – normalna distribucija i Bland-Altman metoda.

Na temelju rezultata dobivenih distribucijom frekvencija percentilnih vrijednosti očitanih sa krivulja ustanovljeno je blago odstupanje HR od CDC krivulja. Pomoću momenata za obje krivulje distribucije vidljivo je kako razlike nisu drastične, ali ipak postoje. Pitanje je zbog čega je veći broj djece prema HR krivuljama smješten na nižim vrijednostima percentila, odnosno zbog čega je broj pretile djece manji u odnosu na očitane percentile sa CDC krivulja?

Objektivniji odgovor na pitanje dala nam je Bland-Altman metoda koja služi za usporedbu dvije skupine mjerenja prilikom uvođenja nove metode kao zamjene za već postojeću metodu. U ovom slučaju CDC krivulje koje su međunarodno priznate zamjenjuju se HR krivuljama u kliničkoj procjeni rasta i razvoja djece u Hrvatskoj. Prema rezultatima Bland-Altman prikaza ustanovljeno je kako ne postoje značajna odstupanja HR od CDC krivulja jer se veći broj razlika podataka nalazio unutar granica raspona slaganja. Zbog toga zaključujemo da HR krivulje neće utjecati na podcjenjivanje broja pretile djece, te se pretpostavlja kako su takvi rezultati posljedica sekularnog trenda rasta djece u Hrvatskoj što znači da su djeca u prosjeku viša od djece u Americi što je ujedno i posljedica utjecaja različitih okolišnih uvjeta života.

Stoga se za procjenu uhranjenosti djece mogu koristiti i HR i CDC krivulje, ali je ipak uvijek poželjno koristiti nacionalne krivulje, ako su one dostupne, zbog utjecaja okoliša i nacionalnih razlika između država na rast i razvoj djece.

## 6. Literatura

Bland, J.M., Altman, D.G. (1983) Measurement in Medicine: the Analysis of Method Comparison Studies. *The Statistician* **32**: 307-317.

Bland, J.M., Altman, D.G. (1986) Statistical methods for assessing agreement between two methods of clinical measurement. *Lancet* **327**: 307-310.

Bralić, I. (2008) Sekularne promjene rasta i razvoja. *Paediatrica Croatica* **52**: 25-35.

Bralić, I., Jovančević, M., Predavec, S., Grgurić, J. (2010) Pretilost djece – novo područje multidisciplinarnog preventivnog programa. *Paediatrica Croatica* **54**: 25-34.

Centers for disease control and prevention - CDC (2010). Growth charts, <<https://www.cdc.gov/growthcharts/index.htm>>. Pristupljeno 12. ožujka 2017.

Centers for disease control and prevention - CDC (2015a). Child and teen BMI, <[https://www.cdc.gov/healthyweight/assessing/bmi/childrens\\_bmi/about\\_childrens\\_bmi.html](https://www.cdc.gov/healthyweight/assessing/bmi/childrens_bmi/about_childrens_bmi.html)>. Pristupljeno 10. ožujka 2017.

Centers for disease control and prevention – CDC (2015b). Growth charts, <<https://www.cdc.gov/nccdphp/dnpa/growthcharts/training/modules/module1/text/module1print.pdf>>. Pristupljeno 10. ožujka 2017.

Giavarina, D. (2015) Understanding Bland Altman analysis. *Biochemia medica* **25**: (2), 141-151.

Guo, S.S., Wu, W., Chumlea, W.C., Roche A.F. (2002) Predicting overweight and obesity in adulthood from body mass index in childhood and adolescence. *The American Journal of Clinical Nutrition* **76**: 653-658.

Hanneman, S.K. (2008) Design, analysis and interpretation of method-comparison studies. *AACN Advanced Critical Care* **19**: (2), 223–234.

Hrvatski zavod za javno zdravstvo (2017). Odjel za prehranu, tjelesnu aktivnost i prevenciju debljine, <<https://www.hzjz.hr/sluzba-promicanje-zdravlja/odjel-za-prevenciju-debljine/>>. Pristupljeno 12. ožujka 2017.

Jureša, V., Musil, V., Tiljak, K.M. (2012) Growth Charts for Croatian School Children and



Secular Trends in Past Twenty years. *Collegium Antropologicum* **36**: 47-57.

Kuczmarski, R.J., Ogden C. L., Guo S. S., Grummer-Strawn L. M., Flegal K.M., Mei Z., Wei R., Curtin L. R., Roche A. F., Johnson C. L. (2002) 2002 CDC Growth charts for the United States: methods and development. *Vital and health statistics* **11**: 246.

Myles, P.S., Cui, J. (2007) Using the Bland-Altman method to measure agreement with repeated measures. *British Journal of Anaesthesia* **99**: 309-311.

Smith, M.W., Ma, J., Stafford, R.S. (2010) Bar charts enhance Bland-Altman plots when value ranges are limited. *Journal of Clinical Epidemiology* **63**: 180-184.

Šekerija, M., Ajduković, D., Poljičanin, T. (2008) Debljina mladih – problem današnjice ili budućnost. *Hrvatski časopis za javno zdravstvo* **4**: br.16.

Teskera M. (2016) Procjena nutritivnog statusa djece primjenom različitih percentilnih krivulja i Bland Altman metode. Diplomski rad, Prehrambeno-biotehnološki fakultet, Zagreb.

Vezilić, M., Brazdičić, E., Gajdoš Kljusurić, J., Čale-Mratović, M. (2014) Use of Bland-Altman plots in evaluation of stature-, weight- and BMI-for-age percentiles for anthropometric measures of pupils attending an extended stay in school . *Proceedings - 8<sup>th</sup> International Congress of Food Technologists, Biotechnologists and Nutritionists*, 198-203.

World Health Organization – WHO (2014). Obesity and overweight, <<http://www.who.int/mediacentre/factsheets/fs311/en/>>. Pristupljeno 11. ožujka 2017.

World Health Organization – WHO (2015). Childhood overweight and obesity, <<http://www.who.int/dietphysicalactivity/childhood/en/>>. Pristupljeno 11. ožujka 2017.

Zrno, Ž. (2011) Neke primjene normalne (Gaussove) distribucije. Zbornik radova Međimurskog veleučilišta u Čakovcu 2 (2): 129-143.





**Prilog 3.** Za korištenje HR krivulja nužno je imati suglasnost autora: Jureša, V., Musil, V., Tiljak, K.M. (2012) Growth Charts for Croatian School Children and Secular Trends in Past Twenty years. *Collegium Antropologicum* **36**: 47-57.

Izjava o izvornosti

*Izjavljujem da je moj završni rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristila drugim izvorima, osim onih koji su u njemu navedeni.*

A handwritten signature in blue ink is written over a horizontal line. The signature is stylized and appears to be 'B. Kocić'.