

Doktori értekezés PhD fokozat elnyeréséhez



MÓDSZERFEJLESZTÉS A PREFERENCIA-TÉRKÉPEZÉSBEN

GERE ATTILA

Doktori (Ph.D.) értekezése

Témavezető:

Dr. Sipos László, egyetemi docens

Készült

Budapesti Corvinus Egyetem

Árukezelési és Érzékszervi Minősítési Tanszék

Budapest, 2015

A doktori iskola

megnevezése: Élelmiszertudományi Doktori Iskola

tudományága: Élelmiszertudományok

vezetője: Dr. Felföldi József
egyetemi tanár
Budapesti Corvinus Egyetem, Élelmiszertudományi Kar
Fizika-Automatika Tanszék

Témavezető: Dr. Sipos László
egyetemi docens
Budapesti Corvinus Egyetem, Élelmiszertudományi Kar
Árukezelési és Érzékszervi Minősítési Tanszék

A jelölt a Budapesti Corvinus Egyetem Doktori Szabályzatában előírt valamennyi feltételnek eleget tett, az értekezés műhelyvitájában elhangzott észrevételeket és javaslatokat az értekezés átdolgozásakor figyelembe vette, ezért az értekezés nyilvános vitára bocsátható.

.....
Az iskolavezető jóváhagyása

.....
A témavezető jóváhagyása

A Budapesti Corvinus Egyetem Élettudományi Területi Doktori Tanácsának 2015. december 08 -án kelt határozatában a nyilvános vita lefolytatására az alábbi bíráló Bizottságot jelölte ki:

BÍRÁLÓ BIZOTTSÁG:

Elnöke:

Fodor Péter, DSc

Tagjai:

Lehota József, DSc

Szabóné Dr. Erdélyi Éva, PhD

Zsarnóczay Gabriella, PhD

Kollárné Hunek Klára, CSc

Opponensek:

Baranyai László, PhD

Örsi Ferenc, DSc

Titkár:

Zsomné Muha Viktória, PhD

Tartalomjegyzék

RÖVIDÍTÉSEK JEGYZÉKE	3
1. BEVEZETÉS	5
2. IRODALMI ÁTTEKINTÉS	7
2.1 SKÁLÁZÁS	7
2.1.1. <i>A skálázás elméleti háttere</i>	7
2.1.1.1 A skálázás pszichofizikai folyamata	7
2.1.1.2. A skálák kódolása	8
2.1.1.3. Skálázás vagy értékelés.....	9
2.1.2. <i>A leggyakoribb skálátípusok</i>	10
2.1.2.1 Kategóriaskála	10
2.1.2.2. Vonalskála	13
2.1.2.3. Optimumskála	14
2.1.2.4. Nagyságrendi becslő skálák	16
2.1.2.5. Rangsorolás.....	19
2.1.3. <i>Különleges skálátípusok</i>	20
2.1.3.1. Relatív skálázás.....	20
2.1.3.2. Pozicionáló relatív skálázás	21
2.1.3.3. Motivációs skála	21
2.1.3.4. Megfelelőségi skálák	22
2.2. OPTIMUMSKÁLÁK ELEMZÉSE.....	22
2.2.1. <i>Az optimumskála adatainak szétbontása</i>	24
2.2.2. <i>Penalty analysis</i>	25
2.2.3. <i>A penalty analysis továbbfejlesztése</i>	26
2.3. A PREFERENCIA-TÉRKÉPEZÉS	27
2.3.1. <i>A preferencia-térképezés feltétele és alkalmazása</i>	27
2.3.2. <i>Szakértői bírálatok</i>	28
2.3.3. <i>Fogyasztói bírálatok</i>	30
2.3.4. <i>A preferencia-térképezés folyamata</i>	31
2.3.5. <i>A preferencia-térképezés gyakorlati problémái</i>	33
2.3.5.1. A szakértői panel megbízhatósága	35
2.3.5.2. A vizsgálandó minták száma.....	35
2.3.5.3. A kérdőív hossza.....	35
2.3.5.4. Szegmentálás	36
2.3.5.5. Validálás	37
2.4. SZEMKAMERÁS MÉRÉSEK ÉS A FOGYASZTÓI DÖNTÉSEK	37
2.4.1. <i>A fogyasztói döntést befolyásoló tényezők</i>	37
2.4.2. <i>A szemkamera működési elve</i>	40
2.4.3. <i>Szemkamera alkalmazása élelmiszerek csomagolásának vizsgálatára</i>	45
2.4.4. <i>A fogyasztói döntés vizsgálata</i>	46
3. CÉLKITŰZÉSEK.....	48
4. ANYAGOK ÉS MÓDSZEREK	49
4.1. A KUTATÁS SORÁN FELHASZNÁLT ANYAGOK	49
4.1.1. <i>Csemegekukorica-minták</i>	49
4.1.2. <i>Ízesített ásványvízminták</i>	50
4.1.3. <i>Ízesített kefirmenták</i>	51

4.1.4. Krékeradatok.....	51
4.2. PÁRHUZAMOS FAKTORELEMZÉS	51
4.3. A TUCKER-3-MODELL.....	53
4.5. KATEGÓRIA FŐKOMPONENS-ELEMZÉS	56
4.6. PÁRKORRELÁCIÓS MÓDSZER	58
4.6.1. Egyszerű rendezés	61
4.6.2. Különbségrendezés.....	61
4.6.3. Súlyozásos rendezés	62
4.7. RANGSZÁMKÜLÖNBSEGEK ÖSSZEGE.....	62
4.8. TÚLÉLÉSELEMZÉS.....	66
4.9 A SZEMKAMERÁS MÉRÉS MÓDSZERTANA	68
4.9.1 Vizuális ingerek	68
4.9.2 Résztvevők	69
4.9.3. Szemkamerás mérési módszer	69
4.9.4. Statisztikai elemzés	71
5. EREDMÉNYEK.....	72
5.1. HÁROMSZEMPONTOS MODELLEK ALKALMAZÁSA.....	72
5.1.1. Belső preferencia-térképek megalkotása PARAFAC- és TUCKER 3-módszerekkel	72
5.1.2. Külső preferencia-térképek megalkotása PARAFAC- és Tucker-3-módszerekkel.....	77
5.2. PREFERENCIA-TÉRKÉPEK LÉTREHOZÁSA KATEGÓRIAADATOKBÓL	80
5.2.1. Az általános MDPREF-modell	81
5.2.2. Kategóriaadatokból létrehozott preferencia-térkép	82
5.3. OPTIMUMSKÁLA-ADATOK ÉRTÉKELÉSI MÓDSZEREINEK FEJLESZTÉSE	85
5.3.1. Általánosított párkorrelációs eljárás.....	85
5.3.2. A rangszámkülönbségek összegén alapuló módszer alkalmazása a JAR-változók azonosítására.....	96
5.3.3. Rangszámkülönbségek összege módszer JAR-adatelemző módszerek összehasonlítására.....	100
5.4. A SZEMKAMERÁS MÉRÉSEK EREDMÉNYEI.....	105
5.4.1. Túléléselemzés alkalmazása a döntési idő vizsgálatára	105
5.4.2. A szemmozgás és a döntés közti kapcsolatok.....	108
5.4.3. A választást előrejelző modellek összehasonlítása	115
6. ÚJ TUDOMÁNYOS EREDMÉNYEK.....	122
7. KÖVETKEZTETÉSEK ÉS JAVASLATOK	124
8. ÖSSZEFOGLALÓ	126
9. SUMMARY	127
10. IRODALOMJEGYZÉK.....	128
11. MELLÉKLETEK	139
11.1. NAGYSÁGRENDI BECSLŐ SKÁLÁK KÉRDÉSFELTEVÉSE	139
11.2. SZEMKAMERA TÍPUSOK	141
11.3. A KAISER-MEYER-OLKIN MUTATÓ MEGHATÁROZÁSA	143
12. KÖSZÖNETNYILVÁNÍTÁS	144

Rövidítések jegyzéke

négy lehetőség kötelező választás	<i>four alternative forced choice</i>	4-AFC
Amerikai Gabonakémiai Szövetség	<i>American Association of Cereal Chemists</i>	AACC
felváltva minimalizáló legkisebb négyzetek módszere	<i>alternating least squares</i>	ALS
egyszempontú varianciaanalízis	<i>one-way analysis of variance</i>	ANOVA
megfelelőségi skála	<i>appropriateness scale</i>	AS
Amerikai Anyagtudományi és Ellenőrzési Társaság	<i>American Society for Testing and Materials</i>	ASTM
Quinlan-féle C4.5-ös döntési fák algoritmus	<i>Quinlan's C4.5 decision tree algorithm</i>	C4.5
osztályozási és regressziós fa	<i>classification and regression tree</i>	CART
többszörös választás	<i>check-all-that-apply</i>	CATA
kategória főkomponens elemzés	<i>categorical principal component analysis</i>	CATPCA
véletlen számokkal származtatott SRD eloszlással való összehasonlítás	<i>compare ranks with random numbers</i>	CRRN
kanonikus változó elemzés	<i>canonical variate analysis</i>	CVA
célfüggvényes osztályozási fa	<i>cost-sensitive classification tree</i>	CSCTR
célfüggvényes döntési fák algoritmus	<i>cost-sensitive decision tree</i>	CSMC4
látogatások száma	<i>dwelt count</i>	DC
látogatások hossza	<i>total dwelt duration</i>	DD
motivációs skála	<i>food action rating scale</i>	FACT
fixációk száma	<i>fixation count</i>	FC
fixációk hossza	<i>fixation duration</i>	FD
első fixáció hossza	<i>first fixation duration</i>	FFD
súlyközéppont terület/kerület arány	<i>gravity center area/perimeter</i>	GCAP
általánosított Prokrusztész analízis	<i>generalized Procrustes analysis</i>	GPA
általánosított párkorrelációs módszer	<i>generalized pair-correlation method</i>	GPCM
Hochberg-féle általánosított Tukey 2-próba	<i>Hochberg's generalized Tukey 2</i>	HOCHBERG'S GT2
iteratív elkülönítés 3 algoritmus	<i>iterative dichotomiser 3 algorithm</i>	ID3
nemzetközi szabványosítási testület	<i>international organization for standardization</i>	ISO
optimumskála	<i>just-about-right scale</i>	JAR
Kaplan–Meier eljárás	<i>Kaplan–Meier product–limit estimate</i>	KM
<i>k</i> -legközelebbi szomszédok elvén alapuló klasszifikáció	<i>k-nearest neighbour's algorithm</i>	KNN
címkezett kétirányú becslő skála	<i>labeled affective magnitude scale</i>	LAM
lineáris diszkriminanciaelemzés	<i>linear discriminant analysis</i>	LDA
utolsó fixáció helye	<i>last fixation</i>	LF
címkezett nagyságrendi becslő skála	<i>labelled magnitude estimation scale</i>	LMS
legkisebb szignifikáns differencia	<i>least significant difference</i>	LSD
többszörös adaptív simító görbevonalak	<i>multivariate adaptive regression splines</i>	MARS
többszörös korrespondencia elemzés	<i>multiple correspondence analysis</i>	MCA
többdimenziós preferencia analízis	<i>multidimensional preference mapping</i>	MDPREF
többdimenziós skálázás	<i>multidimensional scaling</i>	MDS
többszörös faktorelemzés	<i>multiple factor analysis</i>	MFA
többrétegű perceptron neurális hálózat	<i>multilayer perceptron neural network</i>	MLP

többszörös lineáris regresszió	<i>multiple linear regression</i>	MLR
multinomiális logisztikus regresszió	<i>multinomial logistic regression</i>	MLoR
naive Bayes féle becslés folytonos változóra	<i>naive Bayes classifier</i>	NBC
lehetőség elemzés	<i>opportunity analysis</i>	OA
lineáris regresszió	<i>ordinary least-squares regression</i>	OLS
kellemesség/kellemetlenség skála	<i>oral pleasantness/unpleasantness scale</i>	OPUS
büntetés szétosztási térkép	<i>penalty allocation map</i>	PAM
párhuzamos faktorok modellje	<i>parallel factor analysis</i>	PARAFAC
főkomponens	<i>principal component</i>	PC
főkomponens elemzés	<i>principal component analysis</i>	PCA
pupilla központú szaruhártya tükröződés	<i>pupil centre corneal reflection</i>	PCCR
párkorrelációs módszer	<i>pair-correlation method</i>	PCM
részleges legkisebb négyzetek elvén alapuló diszkriminanciaelemzés	<i>partial least squares discriminant analysis</i>	PLS-DA
részleges legkisebb négyzetek elvén alapuló regresszió	<i>partial least squares regression</i>	PLS-R
prototype legközelebbi szomszéd elvén alapuló neurális háló	<i>prototype nearest neighbour</i>	PNN
ortogonalizált legkisebb négyzetek elvén alapuló regresszió	<i>orthogonalised partial least squares regression</i>	PO-PLS
külső preferencia-térképezés	<i>preference mapping</i>	PREFMAP
többszörös faktorelemzés alapuló preferencia-térképezés	<i>preference multiple factor analysis</i>	PREFMFA
termék elemző és modellező eszköz módszer	<i>product analysis and modelling tool</i>	PRIMO
radiális alapfüggvényekből álló neurális hálózat	<i>radial basis function neural network</i>	RBF
Ryan-Einot-Gabriel-Welsh-féle F-próba	<i>Ryan-Einot-Gabriel-Welsh F-test</i>	R-E-G-WF
Ryan-Einot-Gabriel-Welsh -féle tartomány-próba	<i>Ryan-Einot-Gabriel-Welsh range test</i>	R-E-G-WQ
ismételt mérések varianciaanalízis	<i>repeated measures analysis of variance</i>	RMANOVA
random döntési fa	<i>random trees</i>	RND
teljesen relatív skálázás	<i>relative scaling</i>	RS
Student-Newman-Keuls-féle próba	<i>Student-Newman-Keuls test</i>	S-N-K
rangsámkülönbségek összege	<i>sum of ranking differences</i>	SRD
hármaskoszinusz	<i>triple cosine</i>	TC
első fixációig eltelt idő	<i>time to first fixation</i>	TTF
változók fontossági értéke	<i>variable importance for the projection</i>	VIP

1. Bevezetés

Az élelmiszerek érzékszervi tulajdonságai nemcsak a termékminőség megítélésében, hanem fogyasztói döntések meghozatalában is kulcsszerepet töltenek be. Ezek alapján a termékek sikeressége nagyban befolyásolható a fogyasztói igényeket és elvárásokat kielégítő termékek fejlesztésével. A termékfejlesztés során alkalmazott érzékszervi minősítés költségghatékony módon a fogyasztók számára elfogadható termék fejlesztését teszi lehetővé, így növelve a sikerességet (Lawless és Heimann, 2010). A termékfejlesztési gyakorlat szerint a piacra újonnan bevezetett termékek 75 %-a nem éri meg az első évfordulóját a polcokon (Kemp *et al.*, 2009).

Az érzékszervi minősítés definícióját a nemzetközi szakirodalomban az Élelmiszertechnológiai Egyesület (*Institute of Food Technology*) úgy definiálja, hogy „*az a tudományterület, amely előidézi, méri, elemzi és értelmezi a termékek által látás, hallás, tapintás, szaglás és ízlelés útján keltett érzeteket*”. A viszonylag fiatal tudományág története a második világháború időszakáig vezethető vissza, amikor felismerték, hogy a fronton harcoló katonák megfelelő minőségű élelemmel történő ellátása kulcsszerepet játszik a katonák moráljának fenntartásában és a csaták, így a háború megnyerésének sikerességében (Meiselman és Schutz, 2003). Az Amerikai Egyesült Államok kormánya által alapított katonai laboratóriumban (*U.S. Army Natick Laboratories*) elsőként alkalmaztak kedveltségre vonatkozó skálákat a fogyasztói elfogadás mérésére. A Natick-ben működő Érzékszervi Laboratórium azóta is vezető szerepet tölt be az érzékszervi minősítéssel kapcsolatos kutatásokban. A kedveltség mérése után a szakértői érzékszervi panelek elterjedését nagyban segítette a profilanalízis módszerének kidolgozása és elterjedése (Kemp *et al.*, 2009). Az egyre növekvő érdeklődés és a sorra megjelenő új módszerek megteremtették az érzékszervi minősítési adatok statisztikai módszerekkel történő elemzésével foglalkozó tudományág, a szenzometria alapjait. A szenzometria egyik legmeghatározóbb szerepe a preferencia-térképezés módszertanának bemutatása volt, amelyben a szakértői bírálócsoport által definiált termékattribútumok és a termékek által leképzett kétdimenziós térben vizsgálható a fogyasztói kedveltséget befolyásoló faktorok szerepe és fontossága.

Az érzékszervi minősítés és a szenzometria napjainkban is dinamikusan fejlődő tudományterületek számtalan kihívással és megválaszolásra váró kérdéssel. A nemzetközi publikációkban elmélyülve egy olyan kirakós képe rajzolódik ki a kezdő kutató szeme előtt, amelyből itt-ott hiányoznak még elemek. Ilyen területek a műszeres és érzékszervi minősítési adatokból képzett multidimenziós preferencia-térképek többszemponatos módszerekkel történő elemzése és értelmezése, valamint a rangsoradatokból képzett preferencia-térképek előállítás.

A modern termékfejlesztés egyre inkább csak a változó fogyasztói igények folyamatos monitorozásával és ennek megfelelő termékek fejlesztésével érhet el eredményeket. Az alkalmazott

érzékszervi minősítési módszerek közül a leginkább elterjedt optimumskálákra alapuló eljárások kutatása az elmúlt néhány évben felerősödött. A megközelítés előnye, hogy közvetlen információ nyerhető a termékek végfelhasználóitól a lehetséges fejlesztési irányokra vonatkozóan az egyes termékattribútumok pontos intenzitásértékeinek finomhangolásához. Az optimumskálák értékelésére azonban még az Amerikai Szabványügyi Testület (*American Society for Testing and Materials*, ASTM) által kiadott szabványban (ASTM MNL-63, 2009) sem adnak egyértelmű iránymutatást. A publikált számos módszer eredményei sok esetben eltéréseket mutatnak vagy ellentmondásban vannak, így elbizonytalanítja a kutatót az eredmények értelmezésével kapcsolatban. A fejlesztett módszerek nem adják meg, hogy mely terméktulajdonságokat milyen sorrendben célszerű megváltoztatni a nagyobb fogyasztói kedveltség elérése érdekében. Ezenfelül a módszerek részletes összehasonlítása sem történt meg, amely megadná, melyik módszer ad pontosabb értékeléseket.

Az érzékszervi minősítés legújabb iránya azonban minden kétséget kizáróan a szemkamerás mérések alkalmazása, amellyel választ kaphatunk a szemmozgás alapján arra, hogy a fogyasztók miért az adott terméket választották, melyek voltak azok a vizuális attribútumok, amelyek felkeltették a választó érdeklődését. Élelmiszerek esetében csak kevés ilyen jellegű kutatással találkozhatunk, annak ellenére, hogy egy nap folyamán számtalanszor kell élelmiszerekkel kapcsolatos döntéseket hoznunk, akár a boltban, akár a kávéautomatánál, akár az éttermekben. A szemkamerás mérési adatokból történő élelmiszerválasztás előrejelzése egy eddig szenzometria szempontból feltáratlan terület, ami számtalan lehetőséget rejt a termékfejlesztők, a csomagolástervezők, a marketingkutatók és ezáltal az élelmiszeripari cégek számára is.

Doktori munkám során a kirakós hiányzó darabjainak pontos helyére illesztésével a kutatásokban és az ipari gyakorlatokban is jól alkalmazható eljárásokat dolgoztam ki, validáltam és valódi problémákon mutatom be gyakorlati alkalmazhatóságukat élelmiszeripari termékek fejlesztésének segítségével.

2. Irodalmi áttekintés


2.1 Skálázás

2.1.1. A skálázás elméleti háttere

2.1.1.1 A skálázás pszichofizikai folyamata

Életünk során számos alkalommal hozunk döntéseket érzékszervi stimulusok alapján. Ezeket gyakran olyan szituációkban tesszük, amikor egy élelmiszer valamely tulajdonsága túl erős vagy túl gyenge. Főzés közben például lisztet adunk a mártáshoz, ha túl hígnak, és vizet adunk, ha túl sűrűnek találjuk. Ezek az érzetek nem numerikus értékeként jelennek meg, azonban skálák alkalmazásával az érzékszerveken keresztül tudatosult ingerek már átalakíthatóak kvantitatív értékekké, amelyek így felhasználhatóak statisztikai próbákban, modellekben.

A skálázás során tehát az élelmiszer által az agyban kiváltott érzet mértékét szükséges rögzíteni. Arra adható válasz, hogy az adott egyén hogyan reagál az egyes ingerekre (**1. ábra**). Ez a folyamat az ún. pszichofizikai modellen alapszik, amely kimondja, hogy amennyiben egy fizikai stimulus ereje növekszik, úgy az érzet növekedésének mértéke matematikai modellekkel leírható (Lawless és Heimann, 2010). A modellt felhasználva írhatóak le az egyes bírálók által tapasztalt érzetek, azonban az egyének nem egyformán és nem lineárisan érzékelik az ingereket, illetve az ingerek változását. Ebből kifolyólag van szükség az érzeteket leíró modellek létrehozására, amelyek megadják, hogy melyik terméktulajdonságot és milyen mértékben változtassunk annak érdekében, hogy a fogyasztói elfogadást növelni tudjuk.



1. ábra: A skálázás során lejátszódó két folyamat. Az a) folyamat során (inger → válasz) a fiziológiai folyamat a tudatos tapasztalást írja le, míg a b) (inger → érzet → válasz) bemutatja, hogyan alakulnak ki döntéseink egy ingerrel kapcsolatban.

Skálázás során a termékek hasonlóságára és különbözőségére adható válasz és két nagy alkalmazási csoport különíthető el. A szakértői bírálók esetében a bírálóknak részletes ismeretekkel kell rendelkezniük a termékekről, az alkalmazott skálázási technikáról, és megfelelő képzésben kell

részesülniük (ISO 8586:2012). Továbbá a tulajdonságokat konszenzusos megbeszélések során egyértelműen leírják, és minden paneltag közel azonos módon értékeli. A fogyasztói kutatásokban ezzel szemben egyszerű skálákat kell alkalmazni, hogy előzetes ismeretek nélkül is megfelelően és könnyen alkalmazzák azokat. Mivel nincs konszenzusos megbeszélés a fogyasztókkal, ezért ügyelni kell a tulajdonságok közérthető megfogalmazására és arra, hogy mindenki számára egyértelműek legyenek.

2.1.1.2. A skálák kódolása

Mivel a skálázás eredményét matematikai-statisztikai módszerekkel összegzik, elemzik, mérési szintjeik meghatározása kritikus jelentőségű. A **nominális skála** értékei kategóriákat jelölnek, esetleg egyedi azonosítókat jelentenek (például férfi-nő, sorszám, telefonszám, kategória, osztály stb.). A nominális skálán az azonosító értékének önmagában nincs jelentősége, az egyes kategóriák között nincs mennyiség összefüggés, nem lehet azt mondani, hogy az egyik kategóriába tartozó elem nagyobb, több, mint a másikba tartozó. Nominális skálázás esetében bizonyos kategóriákhoz számok rendelhetők, amelyet álváltozó (*dummy variable*) megközelítésnek is neveznek. **Ordinális skálázás** során azonban már feltételezhető egy minőségi sorrend (rangsor) a kódolt változók között például érzékszervi jellemzőik vagy kedveltségük alapján. A rangsorolásból adódóan az alacsonyabb érték magasabb kedveltséget/intenzitást jelöl, amit az adatértékelésnél figyelembe kell venni (Lawless és Heimann, 2010). A harmadik skálázási módszert **intervallumskálázásnak** nevezik, amelyben a számértékek mind a nagyság szerinti viszonyokat megmutatják, mind az eltérés mértékét meghatározzák. A skálaértékek különbségét ebben az esetben már értelmezni lehet. Az érzékszervi minősítésben intervallumskálaként értelmezik a fogyasztói vizsgálatok során legáltalánosabban alkalmazott kilenctagú kategóriaskálát, amely két végpontja a két szélső érték: nem kedvelem – nagyon kedvelem (Lim, 2011). A skálán általánosan alkalmazott kifejezések magyar megnevezései a következők:

1. mindennél jobban elutasítom
2. nagyon nem kedvelem
3. közepesen nem kedvelem
4. kissé nem kedvelem
5. közömbös
6. kissé kedvelem
7. közepesen kedvelem
8. nagyon kedvelem
9. mindennél jobban kedvelem

A skálán adott válaszokat az egyes kifejezésekhez tartozó számértékekkel kódolják, ebből fakadóan az is megadható, hogy két termék kedveltsége között mekkora a különbség (rangsorolásnál csak annyi adható meg, hogy az egyiket jobban kedvelték, mint a másikat). További előnye, hogy az ezen a skálán mért értékek bármely parametrikus módszerrel elemezhetőek (amennyiben a módszer többi feltételének megfelel az adatsor).

A negyedik módszer az ún. **metrikus skála**, amely során a skála egyes értékei között egyenlő a távolság. A metrikus vagy arány skála olyan skála, amelynek abszolút nullpontja van, és rajta bármelyik két intervallum aránya független a mértékegységtől. Az arányskálán végzett mérések adataiból minden statisztikai mutató számítható. Jellemzője, hogy a skálaértékekhez egyetlen tetszőleges szám sem adható hozzá a skála szerkezetének megváltozása (a nullpont eltolódása) nélkül. Ilyen skálát alkalmaznak a hőmérsékletmérések során is (pl.: Kelvin skála), ugyanis reggel lehet kétszer olyan hideg, mint este. Ugyanezt a logikát az érzékszervi minősítésbe átültetve már nehezebb kivitelezni, amely során a bírálóknak relatív számértékeket kell rendelniük érzeteikhez (Schifferstein, 2012). A magasabb rendű skálák minden esetben információvesztés mellett alacsonyabb rendű skálákká alakíthatók, viszont ez fordítva nem megvalósítható. Halmazelméleti példával élve az ordinális skála az arányskála egy részhalmazaként is értelmezhető.

2.1.1.3. Skálázás vagy értékelés

A skálázás folyamatának és gyakorlatának megfelelő ismeretére azért is van szükség mind a bírálatvezető mind a bírálók részéről, hogy megfelelő különbséget tudjanak tenni a skálázás és az értékelés (osztályozás) között. Sok esetben a kategóriaskálákat érzékszervi jellemzők leírására alkalmazzák, azonban előfordulhat olyan alkalmazás, amikor egy skálán belül több érzékszervi jellemzővel próbálnak leírni egy termékattribútumot. A kutatás és fejlesztés során az ilyen skálahasználat nem elfogadható, azonban a minőségellenőrzés során az osztályozás bevett gyakorlat. Az Amerikai Gabonakémiai Szövetség (*American Association of Cereal Chemists*) 1986-ban mutatta be az azóta széles körben elterjedt példát a skálázás és osztályozás közti különbségek szemléltetésére. Egy sütőipari termékeket gyártó cég érzékszervi minősítést végzett termékei ellenőrzése céljából. A képzett érzékszervi bírálók a skálán 10-es értéket adnak a tökéletes állományú terméknek, 8-as értéket a kissé száraz, 6-os értéket a gumis, rugalmas és 4-es értéket a nagyon száraz terméknek. A skála értelmezésekor feltűnik, hogy a rugalmasság és szárazság két egymástól elkülönülő terméktulajdonság, amelyeket külön skálán kellene mérni. Az itt alkalmazott eljárás valójában nem skálázás, hanem minőségi osztályozás. Ennek eredményeit egészen eltérően kell kezelni, azokból gyakoriságértékek számítása lehetséges, átlaguk szórásuk azonban nem értelmezhető, ennél fogva

statisztikai próbákkal sem értékelhető – kivéve a gyakoriságokra vonatkozó próbákat (Lawless és Heimann, 2010). A fenti példán látható, hogy az osztályozás valójában nem valódi skálázási folyamat, vagyis a minőségi osztályozás nem foglal magában semmilyen pszichofizikai tulajdonságot a termékkel kapcsolatban.

2.1.2. A leggyakoribb skálatípusok

2.1.2.1 Kategóriaskála

Legrégebbi skálázási módszer, amely elrendezését tekintve lehet horizontális vagy vertikális. A skála értékei diszkrét értékek, amelyeket jelölhetnek számértékek, szövegdobozok, piktogramok vagy jelölőnégyzetek (**2. ábra**). A kategóriaskálák alkalmazása során egyszerűen értelmezhető kulcsszavakat alkalmaznak a termékjellemző leírására (pl.: sós íz intenzitása), majd a bírálókat ennek a tulajdonságnak ez értékelésére kérik. Az ilyen típusú skálák alkalmazásánál külön figyelmet kell fordítani a skála végpontjainak helyes jelölésére, pl.: “egyáltalán nem édes íz”-től az “intenzív édes íz” (Lawless és Heimann, 2010).

A skála kategóriáinak meghatározása előtt annak típusát kell megadni. A fenti típusok közül választva a leggyakoribb a 7-15-tagú kategóriaskála alkalmazása. Ilyen esetekben lehetőség van a szöveges skálák alkalmazására is, viszont mindig ügyelni kell, hogy a kategóriák leírásainak közei azonosak legyenek. Így elérhető, hogy a kategóriák visszakódolása ne okozzon torzítást az értékelésben. A nemzetközi kutatásokban előfordulnak extrém példák. Winakor és munkatársai 1980-ban például 1-99-ig terjedő kategóriaskálát alkalmaztak különböző textíliák anyagának értékelésére. Ilyen esetekben azonban megfontolandó a vonalskála alkalmazása a túl sok kategória miatt. A kategóriák számának meghatározásakor páros vagy páratlan értékek alkalmazhatók. A páratlan számú kategóriából álló skálák értelmezhetőek úgy is, hogy a „nem tudom” választ megengedjük a bírálóknak, mivel a középső érték mindkét szélsőértéktől azonos távolságra helyezkedik el. A páros számú kategóriák esetében azonban ezt nem engedik meg a bírálóknak, ilyen esetekben mindenképpen dönteni kell, hogy melyik végponthoz van közelebb az érzékelt terméktulajdonság.

A) Intenzitás - értékekkel

1 2 3 4 5 6 7 8 9
gyenge intenzív

B) Intenzitás – feliratokkal

___ nem érzékelhető
___ nyomokban
___ kissé
___ enyhén
___ gyengén
___ mérsékelten
___ határozottan
___ erősen
___ nagyon erősen érzékelhető

C) Referenciától való eltérés

___ nincs különbség
___ nagyon kis különbség
___ kis különbség
___ mérsékelt különbség
___ nagy különbség
___ határozott különbség

D) Intenzitás – jelölőnégyzetekkel


gyenge intenzív

E) Intenzitás – jelölőnégyzetekkel, referenciától való eltérés


kisebb Referencia nagyobb
különbség különbség

F) Kedveltségi skála gyerekeknek, vagy eltérő kultúrák fogyasztói összehasonlításához


nagyon rossz rossz eléggé rossz kicsit rossz nem tudom kicsit jó eléggé jó jó nagyon jó

2. ábra: Kategóriaskála példák. A) egyszerű számokból álló skála intenzitásértékek kifejezésére, B) szöveggel jelölt skála, C) szöveggel jelölt skála a referenciaterméktől való eltérés vizsgálatára, D) egyszerű jelölőnégyzetek alkalmazása intenzitásértékek rögzítésére, E) jelölőnégyzetek a referenciától való eltérés vizsgálatára, F) piktogramok (Lawless és Heymann, 2010 alapján).

A kategóriaskálák nagy előnye a könnyű értelmezhetőség és az egyszerű előállíthatóság. Az adatrögzítés során egyszerű, könnyű adatkódolást biztosítanak. Hátrányuk azonban, hogy a bírálók

hajlamosak értékeléseiket kedvenc számaik alapján meghozni, és ezt esetleg nem tudják elvonatkoztatni a valódi értékeléstől. Ennek a jelenségnek az egyik megoldása a jelölőnégyzetek alkalmazása lehet. Másik igen jelentős probléma az ilyen jellegű skálákkal a végpontok jelölésének jelentése lehet, például az „intenzív édes íz” nem minden termék esetében jelenti ugyanazt. Ez a végpont a vizsgált termékkategória esetében jelenti az intenzív édes ízt vagy pedig a bíráló számára intenzív édes ízt. Természetesen mást fog jelenteni egy cukrászati sütemény értékelésekor, mint csemegekukorica bírálatakor. Megoldást kínálhat, ha előzőleg a panel rögzíti ezeket a pontokat és a vizsgált néhány termékre, esetleg termékcsoporthoz, vagy a bíráló által valaha érzett legintenzívebb ízérzetre korlátozzák. Ilyen esetekben a termékek terméktulajdonságai egymással összehasonlíthatóak, azonban más termékekkel nem összevethetőek az értékek. Például elmondható, hogy ez a péksütemény édesebb, mint sósabb, azonban nem hasonlítható össze a kapott érték a csemegekukoricák édes ízének intenzitásával (Lawless és Heimann, 2010).


A kategóriaskálák egyik speciális esete az ún. többszörös választás (*Check-All-That-Apply*, CATA) típusú skálák. Az érzékszervi minősítésben széles körben alkalmazott technika során a fogyasztói bírálók nem egy tulajdonság intenzitását értékelik, hanem a bírálati lapon több tulajdonság nevét találják. Feladatuk az összes olyan tulajdonság azonosítása és bejelölése, amelyek véleményük szerint jelen vannak a vizsgált termékben (Vidal *et al.*, 2015). A módszerrel egyrésről kivédhetőek a nem megfelelő szókincsből eredő hiányosságok, másrészt a bírálók egy adott tulajdonságcsoporthal dolgoznak, így az adatelemzés egyszerűbbé válik. A legfrissebb kutatások során a kérdőívek eredményeinek reprodukálhatóságát vizsgálták, amely során bebizonyították, hogy az így kapott eredmények jól reprodukálhatóak. Ettől függetlenül a reprodukálhatóság ellenőrzésére az ismétlések hiányában a bootstrapping módszere (véletlenszerű visszatevéses mintavételezés) szintén hatékonynak bizonyult (Ares *et al.*, 2014a). A CATA kérdések kedveltségi kérdésekre történő hatásának vizsgálata során a kutatók arra keresték a választ, hogy a CATA kérdések jelenléte befolyásolja-e a termék kedveltségét. A CATA által felsorolt terméktulajdonságokról azt feltételezték, hogy a fogyasztók értékelésére hatással van, ugyanis nemcsak a termékkel kapcsolatos jó, hanem a rossz tulajdonságokat (hibákat) is fel kell sorolni a megfelelő jellemzéshez. Azonban ennek a hatását több tanulmányban sem tudták bizonyítani, így a CATA kérdések kedveltségi kérdésekkel történő alkalmazása helytálló, és javasolt a komplexebb termékjellemezés eléréséhez (Jaeger és Ares, 2014; Ares és Jaeger, 2015)

2.1.2.2. Vonalskála

Az intenzitásértékek rögzítésére alkalmazott másik skálatípus az ún. vonalskála, amely egy meghatározott hosszúságú vonal két végpontja között elhelyezett jelölővel szemlélteti az adott terméktulajdonság intenzitásának értékét. Az adott jelölés pontos értékét a kezdőponttól számított távolságban fejezik ki. A nyomtatott bírálati lapokon ezt gyakran úgy alkalmazzák, hogy a vonalskála hosszát 9-15 cm-ben határozzák meg, majd a jelölt értéket a zérus ponttól számítva vonalzóval mérve milliméterben adják meg. Az így kapott értékeket ezt követően százalékosan kifejezve adják meg, így transzformálva az adatokat 0 és 100 közé. Az európai gyakorlatban elfogadott elvek alapján a skála bal oldalán szerepel az „alacsonyabb” intenzitásérték, míg a jobb oldalon az „intenzívebb” érték. A tengerentúlon a két végpont gyakran felcserélődik az európai gyakorlathoz képest. Egy másik gyakorlati tapasztalat, hogy általában a tulajdonság nevét leíró végpont a jobb oldalra kerül. Például világos sörök borostyánságra színének bírálatánál a baloldalon a világossárga, míg jobb oldalán a borostyánságra feliratok szerepelnek. A vonalskála tehát egy folytonos skála, ahol egészen érzékenyen kifejezhetőek a termékek közti eltérések. Vonalskála esetében jellemzően csak a két végpontot jelölik szövegesen, más pontot nem. Referenciaanyagok és -minták alkalmazásakor azonban azok helyének jelölése elfogadott. A **3. ábra** mutatja be a leíró érzékszervi vizsgálatok során alkalmazott leggyakoribb skálatípusokat.

A profilanalízis elterjedése óta a vonalskálákat inkább a szakértői bírálatok során alkalmazzák széles körben. A vonalskálák érzékenységét összevetve a kategóriaskálák és a nagyságrendi becslő skálák érzékenységevel, nem mutatható ki jelentős eltérés (Lawless *et al.*, 2010).


A) Intenzitás – két végpont jelölése




B) Intenzitás – jellemző értékek jelölése




C) Intenzitás – ASTM E-1083 vonalskála




D) Referenciától való eltérés



E) Kedveltségi vonalskála



F) Szabályozható vonalskála



3. ábra: Vonalskála típusok. A) két végpont jelölésével, B) jellemző értékek jelölésével, C) ASTM E-1083 által bemutatott vonalskála, D) vonalskála a referenciától való eltérés vizsgálatára, E) hedonikus vonalskála; F) szabályozható vonalskála (Lawless és Heymann, 2010 alapján).


2.1.2.3. Optimumskála

A nemzetközi irodalomban *Just-About-Right* (JAR) skálaként előforduló optimumskálák alkalmazása széles körben elterjedt az érzékszervi termékfejlesztésben. A JAR-skálák alkalmazásnak egyik fő haszna, hogy közvetlenül megadják, hogy melyik terméktulajdonságot kell megváltoztatni a nagyobb fogyasztói kedveltség eléréséhez. Az ilyen jellegű információ mind termékfejlesztési, mind

marketing szempontból hasznos. Ezen felül az ideálistól való eltérés mérésének ötlete jól modellezi a fogyasztói magatartást is. Gyakori fogyasztói megjegyzés, hogy egy kávé túl erős vagy túl gyenge. Akarva vagy akaratlanul, a fogyasztók döntéseit erősen befolyásolja, hogy mit várnak el egy terméktől érzékszervi szempontból.

A JAR-skálák alkalmazásának egyik kulcseleme a kedveltségi értékekkel való összevetés. Az elemzés végén pontos kép adható arról, hogy a termék mely tulajdonságát milyen irányba kell módosítani (erősíteni, gyengíteni) a magasabb fogyasztói elfogadás elérése érdekében.

A bipoláris JAR-skálák segítségével a bíráló számára ideális intenzitásértéktől való eltérés mértéke határozható meg. A JAR-skálák mindig egy adott terméktulajdonság optimális szintjére kérdeznek rá, amely lehet túl intenzív, nem elég intenzív, és pont jó/ideális. Ezt az ideális szintet nevezik optimumpontnak, illetve a nemzetközi szakirodalomban „*just about right*” vagy „*just right*” pontnak. Bipolárisnak akkor nevezhető egy skála, ha annak végpontjai jelentésüket tekintve egymás ellenpontjai, például „egyáltalán nem édes” és „túl édes”, illetve rendelkeznek egy neutrális, rögzített középponttal (ASTM E456, 2013; ASTM E253-15, 2015). A JAR-skálákról és azok szintjeinek jelentéséről Gacula és munkatársai részletesen értekeznek kutatásukban (Gacula *et al.*, 2007).



4. ábra: Az általánosan alkalmazott öttagú optimumskála és kategóriáinak felirata

A legelterjedtebb JAR-skálák 3, 5, 7 illetve kilenctagúak. A páratlan számú kategória a középső neutrális pont miatt megkövetelt. A **4. ábra** egy általános, öttagú JAR-skálát mutat be. Az érzékszervi termékfejlesztés során jellemzően kedveltségre vonatkozó kérdésekkel együtt jelenik meg, ugyanis a két skálatípusból kapott eredmények összevetése segítségével a termékfejlesztési irányok illetve új termékek bevezetésének irányai jól meghatározhatóak. JAR-skálákat eddig széles körben alkalmaztak a nemzetközi szakirodalomban például paradicsomszósok (Popper és Gibes, 2004), mazsolából készített lekvárok (Rababah *et al.*, 2012), probiotikus Petit Suisse sajtok (Esmerino *et al.*, 2013), egzotikus gyümölcsökből készült gyümölcslevek (Freitas és Mattietto, 2013), mangónektárok (Cadena és Bolini, 2012), húsok (Chan *et al.*, 2013), Bulgogi (tradicionális koreai sült húsféle) (Hong *et al.*, 2011) és gyümölcslekeverékek (Lawless *et al.*, 2013) fejlesztésének

optimalizálására. Gyakori alkalmazása ellenére azonban használata körültekintést igényel, mivel több feltételnek is eleget kell tenni:

- (1) A fogyasztóknak tisztában kell lenniük a skála típusával és használatával.
- (2) A végpontokat helyesen kell megválasztani, azok egymás pontos ellentétei legyenek (Lawless és Heimann, 2010).
- (3) Jelenleg nincs határozott bizonyíték arra vonatkozóan, hogy a JAR-skálák alkalmazásával elérhető az optimális termék (Epler *et al.*, 1998). Többen is rámutattak arra, hogy a kérdőívben szereplő JAR-kérdések maguk is hatással vannak a termék kedveltségére (Earthy, MacFie, és Hedderley 1997; Popper *et al.* 2004).
- (4) Néhány kutató nem ajánlja a JAR-skálák alkalmazását, amit azzal indokolnak, hogy a válaszadás során egyszerre kell preferenciával és intenzitásokkal kapcsolatos választ adni/kifejezni egy értékben (Stone és Sidel, 2004). A fentiekkel ellentétben azonban a kutatók pozitív eredményeket jelentenek a JAR-skálák alkalmazásakor.
- (5) A JAR-skálák alkalmazása nem ad választ arra a kérdésre, hogy milyen mértékben kell a terméket megváltoztatni az optimális termékszint és a legmagasabb kedveltség eléréséhez.
- (6) Kizárólag olyan terméktulajdonságoknál működik a módszer, amelyeknek van optimális szintje. Amennyiben egy tulajdonságot akkor kedvelnek a fogyasztók, ha minél több van belőle a termékben (minél pirosabb eper vagy paradicsom), akkor a módszer nem alkalmazható. Ugyanez igaz azokra a tulajdonságokra is, amelyek jelenléte nemkívánatos (mellékízek).
- (7) A fogyasztóknak felszolgált minta mennyisége befolyásolhatja az eredményeket. Sütemények, édesipari termékek esetében előfordulhat, hogy kis mennyiségben bizonyos terméktulajdonságok optimálisnak tűnnek, azonban nagyobb (fogyasztási) adagokban már nem (tejszínhab, krémek).

A JAR-skálákkal kapcsolatos problémákat van Trijp és munkatársai részletesen bemutatják (van Trijp *et al.*, 2007). Lesniaszkas és Carr (egy JAR-adatelemző munkacsoport tagjaiként) az alábbi három kérdést fogalmazták meg, amelyekre a JAR-adatelemzésnek választ kell adnia (Popper és Gibes, 2004):

- (1) Vannak olyan termékek, amelyek közelebb helyezkednek el az optimum ponthoz, mint a többi?
- (2) Ha a termék nem optimális, akkor melyik tulajdonságát és milyen irányba kell módosítani?
- (3) Milyen mértékben hat a kedveltségre, ha egy termék nem optimális?


2.1.2.4. Nagyságrendi becslő skálák

A nagyságrendi becslés valójában pszichofizikai folyamat, amelyet a skálázás során használnak fel. A nagyságrendi becslő skálákat széles körben alkalmazzák a pszichofizikai kutatásokban. A skálázási folyamat során a bírálók a tulajdonság nagyságához egy becsült számértéket rendelnek, azonban megkötés, hogy az egyes termékek intenzitásértékeit úgy kell megadni, hogy azok nagyságrendileg tükrözzék az érzékelt intenzitáskülönbséget. Ezek alapján az egyes termékekre adott értékek az érzetek közti különbségeket nagyságrendekben fejezik ki. Például,


amennyiben az „A” jelű kávé édes ízének intenzitását 20-as értékkel írja le a bíráló, és a „B” jelű terméket kétszer olyan édesnek érzékeli, úgy a „B” jelű termékre 40-es értékelést kell adnia. A fentiek alapján tehát kritikus fontosságú a bírálókkal a tesztfolyamat és a skála használatának magas szintű ismerete. A termékjellemzők intenzitásértékei, a kedveltség és a fogyasztói elfogadás is sikeresen értékelhető a módszerrel (ISO 11056:1999).

A nagyságrendi becslő skálák alkalmazása különösen akkor lehet előnyös, amikor a bírálók száma és a képzésre rendelkezésre álló idő korlátozott. A módszert egyszeri képzést követően a bírálók számos minta és tulajdonság értékelésére is képesek alkalmazni minimális kiegészítő képzéssel. A nagyságrendi becslő skálák egyik nagy előnye, hogy a „véghatások” nem jelennek meg alkalmazásakor. Véghatásnak azt a jelenséget nevezzük, amikor a bírálók nem ismerik egy adott tulajdonság végpontjához tartozó inger mértékét. Például a „csípős íz” mérése során a 100-as értékkel jelölt „intenzív csípős íz” végpont mellé nincs társítva referencia minta, így a bírálók számára eltérően fog megjelenni ez az érték. A nagyságrendi becslő skálák esetében alkalmazott kérdésfeltevés az **M11.1 mellékletben** szerepel.

A nagyságrendi becslő skálák fejlesztésének egyik fontos lépcsője a Green és munkatársai által 1993-ban bemutatott címkézett nagyságrendi becslő skálák (*labelled magnitude estimation scales*, LMS) (Green *et al.*, 1993). Ebben a változatban a skála egyes pontjait címkékkel látják el a megfelelő értékelés segítése céljából. Az **5. ábra** mutatja be a címkézett nagyságrendi becslő skálák egyik példáját, ahol jól láthatóak az egyes lépcsők a skála címkéi által jelölt szintek között. A címkézett kétirányú becslő (*labeled affective magnitude scale*, LAM) skálák fogyasztói vizsgálatokban alkalmazott változatát mutatja be a **6. ábra**, amelyen látható, hogy a középpontból kiindulóan a nagyságrendi becslés a kedveltség és az elutasítás irányába is terjed (Schutz és Cardello, 2001). Ennek az egyik változata a kellemesség/kellemetlenség skála (*oral pleasantness/unpleasantness scale*, OPUS), amely a kedveltséget alakítja át kellemességre, illetve kellemetlenségre (Guest *et al.*, 2007). Itt a fogyasztóknak azt kell elmondaniuk, hogy az adott tulajdonság mennyire kellemes/kellemetlen számukra.



5. ábra: Címkezett nagyságrendi becslő skála (*labelled magnitude estimation scale*, LMS).



6. ábra: Címkézett kétirányú becslő (*labelled affective magnitude scale, LAM*) és a kellemesség/kellemetlenség skála (*oral pleasantness/unpleasantness scale, OPUS*) összevetése.

2.1.2.5. Rangsorolás

A rangsorolás az egyik legegyszerűbb és legkönnyebben végrehajtható skálázási feladat. Rangsoroláskor egyszerűen egy megadott terméktulajdonság alapján sorba kell rendezni a mintákat. Képzett panel esetén egy terméktulajdonság intenzitásának erőssége alapján, míg a fogyasztói bírálatoknál a kedveltség alapján kell ezt megtenni (ISO 8587:2006). A feladat több mintával is végrehajtható jelentős fáradtság nélkül (akár 6-8 minta). A legegyszerűbb kiértékelési módszer a rangszámok összegének meghatározása, itt azonban ügyelni kell az eredmények értelmezése során arra, hogy a legalacsonyabb rangszámösszeggel rendelkező minta kapja a legjobb értékelést. Az adatok ordinális jellege miatt azonban nem értékelhetők az olyan, általánosan alkalmazott paraméteres próbák segítségével, amelyek az adatok normál eloszlását feltételezik. Emellett a rangsor adatok átlagának és szórásának értelmezése is körültekintést igényel, Ezek miatt csak nemparaméteres próbákkal értékelhetők ki a rangsorolás során kapott eredmények. Ezek a próbák nem igénylik a normál eloszlás meglétét, továbbá az átlag és szórás helyett algoritmusukban a mediánt és móduzt alkalmazzák. Egy minta vagy két összefüggő (párosítható) minta esetében a Wilcoxon-féle előjeles rangpróba alkalmazása javasolt az egy- illetve kétmintás t -próba helyett. Két független minta összevetésére a Mann-Whitney-féle U-próba alkalmazandó a kétmintás t -próba helyett, kettőnél több független minta összevetésére a Kruskal-Wallis-féle H-próba a megfelelő a paraméteres varianciaanalízis kiváltására, illetve kettőnél több összefüggő (párosított) minta értékelésére a Friedman-próba javasolt az ismételt méréses varianciaanalízis helyett (Conover, 1999). Az érzékszervi minősítésben az MSZ ISO 8587:2014 szabvány részletezi a rangsorolások módszerek eredményeinek kiértékelésénél javasolt statisztikai módszereket (ISO 8587:2006) (1. táblázat).

1. táblázat: Az MSZ ISO 8587:2014 által javasolt módszerek rangsorolások kiértékelésére (Forrás: ISO 8587:2006).

Vizsgálati cél	Bírálok képzettsége	Bírálok száma	Statistikai módszer		
			Összehasonlítás ismert sorrendhez	Ismeretlen termék sorrend (termék összehasonlítás)	
				2 termék	> 2 termék
Egyéni teljesítményének értékelése	Kiválasztott bírálók vagy szakértők	Korlátlan	Spearman- vagy Kendall-próba	Előjel-próba	Friedman-próba
Csoport teljesítményének értékelése	Kiválasztott bírálók vagy szakértők	Lehetőleg 12-15 fő	Page-próba		
Termék értékelése leíró szempont alapján	Kiválasztott bírálók vagy szakértők	Lehetőleg 12-15 fő			
Termék értékelése kedveltség alapján	Fogyasztók	Minimum 60 fogyasztói típus csoportonként (cellánként és szegmensenként)			

A rangsorolás azonban egyszerűségéből fakadóan információszegény eredményt ad, ugyanis a minták közti távolságokat nem fejezi ki, csak azt, hogy az egyik terméket jobban kedvelték a másikinál, azonban nem adja meg, hogy mennyivel jobban. Az olimpiai helyezések jól példázzák ezt az információszegénységet, mivel az aranyérem és az ezüstérem nem fejezi ki, hogy két futó között mindössze 0,1 s vagy 5 s időkülönbség volt-e. Mindezeket figyelembe véve a rangsorolás jól alkalmazható az érzékszervi vizsgálati kérdőívek végén a fogyasztói preferencia stabilitásának vizsgálatára, mivel a kedveltségi adatokhoz igazodó eredményt kell mutatnia stabil preferencia esetén (Gere *et al.*, 2014b).

2.1.3. Különleges skálatípusok

2.1.3.1. Relatív skálázás

A teljesen relatív skálázás (*relative scaling*) módszerét Gay és Mead fejlesztették ki (Gay és Mead, 1992). A folyamat során a fogyasztók az összes értékelendő termék közül kiválasztják a leginkább kedveltet (jobb oldali végpont) és a legkevésbé kedveltet (bal oldali végpont), majd a többi terméket ezek között értékelik, hasonlóan a rangsoroláshoz. A módszer a rangsoroláshoz hasonlóan érzéketlen a termékek közti különbségek mértékére, illetve nem adja meg azt sem, hogy az első és utolsó termék globálisan mennyire kedvelt/nem kedvelt.

Előnye, hogy minden válaszadó a saját maga által létrehozott tartományban tudja értékelni a mintákat, így a végponthatás nem jelentkezik, ugyanis a leginkább kedvelt és legkevésbé kedvelt

terméket is definiálja a bíráló saját magának. További hátránya, hogy csak a termékek relatív pozícióját adja meg (a többihez képest ezt jobban kedvelem).

2.1.3.2. Pozícionáló relatív skálázás

A skálázási módszerek általában nem engedik meg, hogy a bíráló megváltoztassa véleményét a skálázás során. Erre egy ellenpélda az 1998-ban először bemutatott „rangértékelés” (Park *et al.*, 2004). A módszert később Cordinnier és Delwiche találóan pozícionáló relatív skálázásnak nevezte (Cordonnier és Delwiche, 2008). A folyamat során a bírálók elé egy asztalon kinyomtatva elhelyeznek egy nagyméretű kategóriaskálát. A bírálat során a termékeket el kell helyezni egyesével a skálán. Itt azonban lehetőség van a sorrendek megcserélésére, eltolására. A kötések is megengedhetők a rangsorban, vagyis két vagy több terméket is lehet ugyanarra a pontra helyezni, ha a fogyasztó nem talál köztük különbséget a vizsgált tulajdonság alapján.

Kutatásaik során a fejlesztők megállapították, hogy a relatív skálázás más módszerekhez képest kevesebb bírálóval is már ki tud mutatni szignifikáns eredményt, azonban a folyamat akár kétszer annyi időt is igénybe vehet (Lawless és Heimann, 2010). A módszer hátránya továbbá, hogy egyszerre csak egy tulajdonságot értékelhetnek a bírálók, így minden tulajdonságnál a folyamatot újra kell kezdeni. Emiatt elsősorban fogyasztói bírálatok során, a kedveltségre vonatkozó kérdések megválaszolására alkalmazandó (O'Mahony *et al.*, 2004). Az értékelés megváltoztatásának további hátrányai a megnövekedett bírálati idő miatti bírálói kifáradás, illetve az ízathordás jelensége is, amely jelentősen befolyásolhatja a bírálók értékelését. Napjainkban a különböző érzékszervi célszoftverekben beállítható egy funkció, amely megengedi a minták értékelésének utólagos módosítását, azonban ennek előnyei és hátrányai még nem bizonyítottak.

2.1.3.3. Motivációs skála

Magatartápszichológiai szempontok alapján működő módszer a motivációs skála (*food action rating scale*, FACT), amelyet 1964-ben Schutz fejlesztett ki (Schutz, 1964). A skála az adott terméktulajdonság által kiváltott attitűdöket és a fogyasztási gyakoriságot egyszerre kezeli további motivációkra irányuló kifejezésekkel. Az eredmény egy viselkedésorientált értékelés, amelyről megismerhető a fogyasztó várható reakciója. Noha Schutz munkájában kifejti, hogy a FACT-skála és az általános kedveltségi skála nem azonos szempontok alapján vizsgálja a kedveltséget, és ezért eltérő eredmények várhatóak, későbbi kutatások során a két skála között szignifikáns pozitív korrelációt mutattak ki.

A skála pontjai Schutz alapján a következők:

- minden körülmények között megenném
- nagyon gyakran fogyasztanám
- gyakran fogyasztanám
- tetszik és megenném
- megenném, ha előttem lenne, de nem mennék el érte a boltba
- nem igazán tetszik, de alkalmanként megenném
- nem igazán fogyasztanám
- csak akkor enném meg, ha nem lenne más étel az asztalon
- csak akkor enném meg, ha kényszerítenének

2.1.3.4. Megfelelőségi skálák

Későbbi munkája során Schutz a skálázás körülményeit vizsgálva alkotta meg a megfelelőségi skálákat (*appropriateness scales*). Ezek segítségével megbecsülhető az élelmiszerek kedveltségével kapcsolatos körülmények hatása is (Schutz, 1995). Például, a fogyasztók nagy hányada általában kedveli a pizzát, azonban reggel 8 órakor, reggeli helyett fogyasztva ez a kedveltség csökken, mivel ez az időpont nem a legmegfelelőbb a pizza fogyasztására legtöbbjük számára (Lawless és Heimann, 2010).

A megfelelőségre vonatkozó kérdések az élelmiszerre és annak fogyasztási jellemzőire is vonatkoznak, például „általában reggeliként fogyasztom”. A skálák tartománya 1-től 7-ig terjed, ahol az 1-es érték a „soha”, míg a 7-es érték a „mindig” végpontokat jelölik (Schutz, 1995). Elrendezése a könnyebb értelmezhetőség miatt lehet mátrix vagy rács. Cardello és Schutz kutatásukban összehasonlították a kilenctagú kedveltségi skála és a megfelelőségi skála eredményeit, amelyben rávilágítottak, hogy azonos kedveltségi termékek különböző szituációkban erősen eltérő megfelelőségi értékeket kaptak (Cardello és Schutz, 1996). Cardello és Schutz eredményei is megerősítik, hogy a két skála között határozott különbségek vannak, tehát a fogyasztói kérdőívekben ezek egymást nem váltják ki, együtt többletinformáció nyerhető a termék megfelelő fogyasztási körülményeiről. Ezek mellett azonban különös tekintettel kell lenni a fogyasztói kérdőívek hosszára is.

2.2. Optimumskálák elemzése

Az optimumskálák (*just-about-right*, JAR) elemzésének egyik fő célja a vizsgált termékek erősségeinek/gyengeségeinek feltárása és annak meghatározása, hogy mely érzékszervi terméktulajdonság intenzitását kell növelni vagy csökkenteni a termékfejlesztés során, hogy magasabb fogyasztói elfogadást érjen el a termék. Az érzékszervi minősítésben a JAR-skálákat gyakran képzetlen fogyasztói bírálókkal alkalmazzák, hogy véleményük alapján formálják a

termékeket azok gyengeségei/erősségei alapján. Ilyen esetekben azonban a JAR-skálák mellett a termékekre vonatkozó kedveltségi pontszámokat is rögzíteni kell a kérdőívben, így a JAR-változók kedveltségre gyakorolt hatása megismerhető.

A JAR-skálákon mért adatok feldolgozása a skálák bipoláris jellege miatt eltérő a legtöbb skáláétól. Éppen ezért a kutatók számos módszert dolgoztak ki az elmúlt években, hogy minél több információt nyerjenek ki a JAR-skálákból a termékekre vonatkozóan. A nemzetközi szakirodalomban több módszert is bemutatnak a JAR-adatok elemzésére, amelyek két nagy csoportra oszthatóak.


Az első csoportba azok a módszerek tartoznak, amelyek nem veszik figyelembe a kedveltségi értékeket, vagyis a termékek összehasonlítása kizárólag a JAR-értékeik alapján történik. Ilyenek például a grafikus módszerek (adatok megjelenítése oszlopdiagramokon, illetve grafikus skálázás), a százalékos eltérések számítása egy adott referenciaterméktől és/vagy JAR-szinttől, átlagok számítása és összevetése, átlagok iránya vagy az átlagok abszolút szórása, egymintás *t*-próba, többváltozós matematikai-statisztikai módszerek (biplotok, korrelációelemzés, főkomponens-elemzés stb.) (ASTM MNL-63, 2009), χ^2 -próba (termékek JAR-eloszlásának összehasonlítására), Cochran-Mantel-Haenszel-próba (Best *et al.*, 2014), Stuart-Maxwell-próba, McNemar-próba, Student-féle *t*-próba és varianciaanalízis (*analysis of variance*, ANOVA) (ASTM MNL-63, 2009), proporcionális esély/veszély modellek (*proportional odds/hazards models*) (Meullenet *et al.*, 2007), Thurston-féle ideális pont modellezés (Goerlitz és Delwiche, 2004) és a jel-zaj arány modell (*signal to noise ratio model*, SNR) (Gacula *et al.*, 2007).

A második csoportba azok a módszerek tartoznak, amelyek figyelembe veszik a kedveltségi értékeket, mint például a széles körben alkalmazott *penalty analysis* módszere, a *penalty analysis* különböző módosításai, lehetőségelemzés (*opportunity analysis*), termékelemző és modellezőeszköz-módszer (*product analysis and modelling tool*, PRIMO) (ASTM MNL-63, 2009), bootstrappelt *penalty analysis* (Meullenet *et al.*, 2007), lineáris regresszió (*ordinary least-squares regression* OLS) (Plaehn és Horne, 2011), χ^2 -próba (annak meghatározására, hogy azok a fogyasztók akik nem optimálisnak (JAR) értékelték a terméket, alacsonyabb kedveltségi pontszámot adtak-e a terméknek), Spearman-féle rangkorrelációs együttható, többszörös lineáris regresszió (*multiple linear regression*, MLR) (ASTM MNL-63, 2009), többváltozós adaptív simító görbevonalak (*multivariate adaptive regression splines*, MARS) (Meullenet *et al.*, 2007), részleges legkisebb négyzetek elvén alapuló regresszió (*partial least squares regression*, PLS-R) álváltozókkal (Xiong és Meullenet, 2006), kanonikusváltozó-elemzés (*canonical variate analysis*, CVA) (Popper és Gibes, 2004) és az

általánosított párkorrelációs módszer (*generalized pair-correlation method*, GPCM) (Héberger és Rajkó, 2002; Gere *et al.*, 2015).

2.2.1. Az optimumskála adatának szétbontása

Az eddigieken felül a második csoport további két részre osztható az alapján, hogy milyen módon számítják a JAR-változók hatását a kedveltségre. Az egyik megközelítés szerint a JAR-változókat változtatás nélkül bevonják az adatelemzésbe, míg a másik szerint az adatelemzés megkezdése előtt két részre kell bontani azokat a két végpont alapján. Tehát a skála alacsonyabb értékei a „túl gyenge”, míg a magasabb értékei a „túl erős” változókat fogják alkotni. A nem szétbontott JAR-adatelemzés során nemlineáris módszerek alkalmazhatóak, mivel a bipoláris JAR-skálák eredményei nem lineárisak. Ennek oka, hogy a „pont jó” érték minden esetben a legmagasabb kedveltségi értéket kell, hogy kapja, amely egy „háztető”-re emlékeztető alakot kölcsönöz, amennyiben az egyes kategóriákhoz tartozó gyakoriságok össze vannak kötve (7. ábra). A kétirányú skála azonban általában nem követi a normál eloszlást. Ezért javasolja több szerző is a skálák szétbontását a középső pontjuk mentén, így egy JAR-változóból előállítható két új változó, amelyek közül egyik csak a „túl gyenge” tartományt, míg a másik csak a skála „túl erős” tartományát tartalmazza. A folyamatot egyirányúsításnak is nevezik, azonban így azok a fogyasztók, akik a terméket „pont jó”-nak ítélték, kikerülnek az adatelemzésből.



7. ábra: A JAR-skálák bipoláris, nemlineáris jellegét szemléltető „háztető” alak az édes íz példáján bemutatva.

A bipoláris skálák unipolárisra transzformálására Xiong és Meullenet 2006-ban bemutatták az ún. dummy változó módszert, amelyet ezt követően széles körben alkalmaztak JAR-adatok elemzése


során (2. táblázat) (Xiong és Meullenet, 2006). Az átalakítások során a JAR-tulajdonság után szereplő + jel a túl erős oldalt, a – jel a túl gyenge oldalt jelöli.

2. táblázat: Az egy (Utóíz), illetve a két (Édes íz-; Édes íz+) dummy változóba kódolás folyamata egy öttagú JAR-skála esetében Xiong és Meullenet alapján (Xiong és Meullenet, 2006).

Eredeti JAR-értékek (öttagú JAR-skála)	Utóíz	Édes íz+	Édes íz-
1 – túl gyenge	-2	-2	0
2 – kissé gyenge	-1	-1	0
3 – pont jó, JAR	0	0	0
4 – kissé erős	1	0	1
5 – túl erős	2	0	2

2.2.2. Penalty analysis

A bemutatott módszerek közül a penalty analysis módszerét alkalmazzák a legelterjedtebben JAR-adatok elemzésére. A penalty analysis három fő lépésből áll. Az első lépésben a JAR-adatok szintjeit (az alkalmazott JAR-skálától függően ez lehet 3-, 5-, 7- vagy 9-tagú) három csoportba sűrítik. A JAR-skálától függetlenül a középső pont kerül a „pont jó” (JAR) csoportba, majd az ennél kisebb kategóriaértékek összevonásával állítják elő a „túl kevés”, az ennél nagyobb értékekből pedig a „túl erős” csoportokat. Egy öttagú JAR-skálánál ezt úgy teszik meg, hogy az 1 és 2 tagok adják a „túl kevés”, a 3 a „pont jó”, a 4 és 5 pedig a „túl erős” kategóriákat (8. ábra).



8. ábra: Az öttagú JAR-skála háromtagúvá sűrítése. Az 1 és 2 tagok, a 3. tag, illetve a 4 és 5 tagok alkotják (balra) az újonnan létrehozott három tagot (jobbra).

Ezt követően mindhárom csoportra kiszámítják a csoportok átlagos kedveltségi pontszámait. A büntetések (*penalties*) kiszámítása során pedig a két nem JAR-csoport átlagát kivonják a JAR-csoport átlagos kedveltségi értékeiből. Ezzel valójában azt lehet megadni, hogy mekkora kedveltségi

értéket veszített a termék azáltal, hogy a fogyasztók egy tulajdonságát túl erősnek vagy túl gyengének találták. A kapott különbségek az ún. „*mean drop*” ábrán ábrázolhatóak. A pontdiagramban a különbségeket a kategóriában szereplő fogyasztók százalékos számával szemben ábrázolják. Minél fontosabb egy tulajdonság (magas *mean drop* érték) és minél több fogyasztó gondolja, hogy az túl erős vagy gyenge (magas fogyasztói százaléérték), annál inkább a jobb felső kvadránsba kerül a pont. Ezek alapján tehát a jobb felső kvadránsban szereplő tulajdonság megváltoztatása magasabb fogyasztói elfogadást eredményezhet.

2.2.3. A *penalty analysis* továbbfejlesztése

Az utóbbi néhány évben több publikáció is megjelent a *penalty analysis* fejlesztési lehetőségeiről. Plaehn és Horne egy regresszió alapuló módszert mutatott be, amellyel pontosabban tudták becsülni a JAR-változók *mean drop* értékeinek szignifikanciáját (Plaehn és Horne, 2008). Módszerükkel regressziós modellt állítottak fel a JAR-adatok és a becsülni kívánt változó (kedveltség) között. A regressziós modell alkalmazása miatt a JAR-változókat egyirányúsították álváltozók kialakításával. A regressziós egyenletből a JAR-változók fontossága súlyozottan is kifejezhető. A súlyozás azon fogyasztók számával történik, akik az adott tulajdonságot túl gyengének, vagy túl erősnek találták. Kutatásukban a regressziós egyenlettel kapott regressziós koefficiensek szignifikanciájának vizsgálatát több módszerrel is megtették. Eredményeikben bemutatják, hogy a szignifikanciát tesztelő módszerek közül a Jackknife- és a bootstrap-módszerek erős egyetértést mutattak. Azonban ez a két módszer inkább a nem-modell alapú, leíró megközelítés esetében előnyösebb, ugyanis eredményeikben bizonyították, hogy a modell alapú optimumskála-elemzés során a paraméteres eljárás pontosabb eredményeket adott.

Plaehn a *mean drop* értékek becslésének pontosítására bemutatta a büntetésszétosztási térkép (*penalty allocation map*, PAM) módszerét (Plaehn, 2013). A létrehozott módszer a külső preferencia-térképezéshez hasonló elven, az eredményeket egyben, aggregáltan adja meg. A tradicionális *penalty analysis*-szel szemben a PAM az összes termék összes terméktulajdonságát egyszerre vizsgálja, amely jelentősen lerövidíti az elemzési időt, és megkönnyíti a termékek összehasonlíthatóságát. A JAR- és kedveltség értékeket bírálónként modellezi osztályozási és regressziós fák (*classification and regression trees*, CART) módszerrel, amely egy nemparaméteres osztályozási eljárás (Lori és Oded, 2008). Ebből fakadóan tökéletesen alkalmas a nem normális eloszlású bipoláris JAR-adatok elemzésére. Az eredményei alapján két változó is elegendőnek bizonyult a kedveltség megfelelő modellezéséhez. A determinációs együtthatók alapján történt modellfinomítás után a modellek illeszkedése kiemelkedően jónak bizonyult. A büntetőpontokat (*penalty*) első lépésben személyenként

számítja a CART-modellekkel, majd aggregálja azokat. Az így kapott összesített büntetőpontok alacsonyabb értékűnek adódtak, mint a penalty analysis során kapott értékek. Emellett 60 %-kal kevesebb érték adódott szignifikánsnak, mint a tradicionális penalty analysis során. A PAM büntetőpontok továbbá a szerző leírása szerint sokkal „hihetőbbnek/elfogadhatóbbnak” tűntek. A Monte-Carlo-szimulációval végzett keresztellenőrzés során is meggyőző eredményeket kapott a szerző. A Monte-Carlo szimuláció az adatsor eloszlásának meghatározása után az adott eloszlást követő véletlenszámokat generál. Mindezek ellenére a PAM módszere nagyon hasonló limitációkkal jellemezhető, mint a külső preferencia-térképezés. Futtatása minimum hat, de inkább tíz termékkel ajánlott a feltételek teljesítéséhez. Emellett a termékeknek megfelelő diverzitást is kell hordozniuk, illetve ebből fakadóan a számítás is idő- és teljesítményigényes (Plaehn, 2013).

Pagès és munkatársai többszörös korrespondencia elemzést (*multiple correspondence analysis*, MCA) módszert alkalmaztak a *mean drop* értékek bizonytalanságának ábrázolására (Pages *et al.*, 2014). Az MCA egy olyan exploratív többváltozós technika, amely az asszociáció kapcsolat vizuális elemzése érdekében egy kontingencia tábla adatait grafikus ábrává konvertálja. Megközelítésük során a penalty analysis eredményeinek bizonytalanságát kívánták hatékonyabban ábrázolni konfidenciasávok megjelenítésével. Az adatokat úgy rögzítették, hogy az adattábla soraiban egy termék egy fogyasztó által értékelt eredményei szerepeltek, az oszlopokban pedig a JAR-változók, a termékek, illetve a fogyasztók azonosítói és a kedveltségi értékek. A JAR- és kedveltségi adatok közti modellezést egyszempontú varianciaanalízissel végezték el, majd ezt bővítették a fogyasztók és a termékek faktoraival. Az MCA-elemzés során a fogyasztókat és a termékeket tartalmazó változók „*supplementary*” változókként szerepeltek az adatelemzésben. Az alkalmazott MCA kiválóan alkalmas az ilyen, több típusú változókat tartalmazó adattáblák elemzésére. Továbbá a módszer szintén megengedi a több termék egy elemzésben történő felhasználását, amely a stabilitás (a kapott konfidenciaintervallumok kisebbnek adódtak), illetve az eredmények értelmezése szempontjából is előnyös. Az MCA további előnye, hogy a kapott kétdimenziós ábrán együttesen vizsgálhatóak a JAR-változók, a kedveltség, valamint a termékek és a fogyasztók közti kapcsolatok és összefüggések.

2.3. A preferencia-térképezés

2.3.1. A preferencia-térképezés feltétele és alkalmazása

A fogyasztói igényeknek/kedveltségeknek megfelelő érzékszervileg optimális termék létrehozása és folyamatos fejlesztése óriási kihívások elé állítja az élelmiszeripar szereplőit. A preferencia-térképezés megmutatja, hogy mely termékek a leginkább és a legkevésbé kedveltek. Rámutat arra, hogy a termék hol helyezkedik el a versenytársak termékeihez képest. A kutatás-

fejlesztésben nem csak a már meglévő termékek fejlesztésében nyújthat segítséget, hanem olyan hiányokra, résekre mutathat rá, amelyek alapján új termékek létrehozására nyílik lehetőség, illetve azonosítja az ígéretes, betöltetlen piaci lehetőségeket/helyeket („*niche*”). Segítségével jellemezhetők a különböző fogyasztói szegmensek a demográfiai tényezők, szokások és attitűdök vonatkozásában. A szakértőkkel elvégzett érzékszervi tesztek megmutatják, hogy mely érzékszervi attribútumok jellemzik a legjobban és a legkevésbé kedvelt mintákat, azaz melyek a kedveltség vagy az elutasítás mozgatórugói. Ezek segítségével egyértelműen meghatározható, hogy miben kellene megváltoztatni a terméket ahhoz, hogy jobban megfeleljen a célcsoport igényeinek (Næs *et al.*, 2010).


A preferencia-térképezés során a termékek érzékszervi jellemzői és a fogyasztói kedveltség (preferencia) értékei közötti összefüggések megállapítása a cél. A preferencia-térképezés eredményei jól alkalmazhatók a termékfejlesztésben és marketingben egyaránt, mivel használatával megadható, hogy a fogyasztók miért kedvelnek bizonyos termékeket, illetve hogy miért utasítják el azokat. Emellett a módszer választ ad arra is, hogy a vizsgált terméket miért kedvelik/utasítják el a versenytárs termékekhez képest. A preferencia-térképezés eredményeinek feldolgozása során a fentiek mellett (elegendő számú megkérdezett esetén) egyedi fogyasztói jellemzőkkel rendelkező fogyasztói csoportok (szegmensek, klaszterek) is lehatárolhatóak, így az egyes termékek célcsoportjai is azonosíthatóak preferenciáik alapján. A preferencia-térképezéshez tehát a két legfontosabb szükséges adathalmaz a vizsgált termékek szakértői és fogyasztói érzékszervi bírálók által értékelt adatai mátrixokba rendezve.

2.3.2. Szakértői bírálatok

A szakértői bírálat során fontos megemlíteni, hogy a bírálók – hasonlóan a műszeres mérésekhez – analitikai feladatokat végeznek. A szakértői bírálat során tehát a bírálók nem preferenciáikat, kedveltségüket fejezik ki, hanem sokkal inkább a termék tulajdonságainak intenzitásait értékelik. Ebből fakadóan a szakértői bírálóknak a bírálatok megkezdése előtt megfelelő képzésben kell részesülniük (ISO 8586:2012), amely során kalibrációjuk megtörténik. A képzés során a hat alapízre (édes, sós, savanyú, keserű, fém és umami (Na-glutamát)) ízérzékenységüket, és ízfelismerő képességeiket is meg kell vizsgálni (ISO 3972:2011). Ízlelő képességeik mellett színlátásukat (ISO 8586:2012), szaglókéességüket (ISO 5496:2006) és speciális esetekben tapintásukat és hallásukat is tesztelni kell az elvégzendő feladathoz igazodóan.

A panel tagjai képzésüknek köszönhetően ismerik az alkalmazott módszertant és az értékelő skálákat (lásd. 2.1.2. bekezdés). Noha napjainkban a számítógépek elterjedésének köszönhetően nem kell külön képezni a bírálókat a számítógépek használatára, azonban a speciális érzékszervi

célszoftverek működésével és felhasználói szintű ismeretével rendelkeznie kell a bírálóknak. A bírálatok során előforduló esetleges referenciatermékeket/anyagokat ismerniük, használniuk és azonos módon értékelniük kell. Az eddigiek mellett a szakértői bírálókkal végzett bírálatok során törekedni kell a szubjektivitás kizárására, hogy megfelelően objektív eredmények szülessenek. A szakértői bírálatokat jellemzően 8-12 fővel hajtják végre megfelelő laboratóriumi körülmények között (ISO 8589:2007) legalább két, de inkább három ismételtsben. A fentieket követve és betartva a szakértői bírálat végeredménye a vizsgált termékek (N) és azok terméktulajdonságainak (K) intenzitásértékei bírálónként (L) (9. ábra). Az eredmények megjelenítésekor azonban célszerű átlagokat számítani az értékelésekből.



9. ábra: A szakértői bírálat adatstruktúrájának felépítése.

A szakértői bírálatok másik sarkalatos pontja a bírálat elvégzése és az adatbegyűjtés után következik. A bírálók teljesítményének monitorozása napjainkban ugyanannyira elvárt az egyes kutatások során, mint a műszeres mérések esetében a megfelelő kalibrálás. A bírálók teljesítményét különböző szempontok alapján kell figyelemmel kísérni, amelyek során ki kell térni a bírálói panel egészének konszenzusára, a bírálók ismételőképességére és a bírálók megkülönböztető képességére (ISO 11132:2012).

A panel konszenzusának vizsgálata során arról kell megbizonyosodni, hogy a panel tagjai mennyire értékelik az egyes termékeket azonos módon, hol vannak azok a területek, ahol fejleszteni kell a panel egyetértését. Az így kapott eredmények segítenek csökkenteni a szórást a paneltagok között, és biztosítják, hogy a bírálat eredményei megbízhatóak legyenek. A konszenzus vizsgálata során az egyik gyakran megjelenő probléma, amikor egyes bírálók az alkalmazott skála végpontjait felcserélik, így a többiekhez képest éppen ellenkezőleg értékelik a mintákat.

A bírálók ismételőképességének vizsgálata egybevág a műszeres mérések során használt ismételőképesség fogalmával, ugyanis a szakértői érzékszervi bírálatokon is elvárt a konzekvens, azonos értékelés. Természetesen a humán bírálók az ismétlések során mindig nagyobb szórást mutatnak, mint a műszerek, azonban a panelre jellemző (attól elvárt) szórásértékeken belül kell mozogniuk (ISO 11132:2012).

A bírálók elkülönítő képességének vizsgálata során a kérdés az, hogy a panel tagjai tudtak-e különbséget tenni az egyes termékek között a vizsgált tulajdonságok alapján. A paneltagok képességeit itt egymáshoz kell viszonyítani, és azokat a bírálókat kell megtalálni, akiknek egy-egy tulajdonság megfelelő bírálatához további képzésre van szükségük.

A szakértői bírálói panelek teljesítményét az ISO 11132:2012 szabvány alapján lehet számítani, azonban a szakirodalomban számos egyéb módszer és programcsomag is megjelent (MAM-CAP, PanelCheck, Quali-Sens, Fizz, Compusense, Senstools, SenPaq stb.).

2.3.3. Fogyasztói bírálatok

A szakértői tesztekkel ellentétben a fogyasztói bírálat során viszont kizárólag a termékkel/terméktulajdonsággal kapcsolatos kedveltségre, preferenciára vonatkozó kérdéseket kapnak a bírálók. További, hasonló kérdések vonatkozhatnak a vásárlási hajlandóságra, illetve az elfogadásra is. Fogyasztói bírálók esetében kifejezetten kerülendő a termékkel kapcsolatos előzetes ismeret, mivel ez befolyásolhatja az értékelést. Kutatások bizonyították a márka hatását a fogyasztói észlelésre (Szőke *et al.*, 2012). Mivel nem rendelkeznek a fogyasztói bírálók előzetes ismeretekkel sem a termékekkel, sem a módszertanokkal kapcsolatban, ezért különös gondot kell fordítani a megfelelő fogyasztói kérdőívek összeállítására. A megfelelő skálatípusok kiválasztása során segítség adható piktogramok, illetve skálafeliratok formájában, amelyet a nemzetközi szabványok is javasolnak (10. ábra).

1. Mennyire kedveled a megkóstolt termékeket?

									
	Nem kedvelem								Nagyon kedvelem
871	☐	☐	☐	☐	☐	☐	☐	☐	☐
621	☐	☐	☐	☐	☐	☐	☐	☐	☐
471	☐	☐	☐	☐	☐	☐	☐	☐	☐


10. ábra: Fogyasztói kedveltségi kérdőív piktogramokkal kiegészítve.

Ezekén túl ügyelni kell arra is, hogy megfelelő információt kapjanak a bírálók a bírálat előtt arról, hogy milyen típusú skálán kell értékelniük. Ez különösen igaz az optimumskálákra. A fogyasztói kutatások során nem ritka, hogy egy kérdőívben belül nem csak egy típusú skálát alkalmaznak (pl. termékfejlesztés során a penalty analysis-ben). Ilyen esetekben célszerű figyelmeztetni a fogyasztókat, hogy új típusú skála következik a kérdőívben.

Az egyszerűsített és jól elmagyarázott skálák mellett szem előtt kell tartani, hogy képzés és gyakorlás hiányában a fogyasztói bírálók jóval hamarabb elfáradhatnak, elveszíthetik érdeklődésüket.

Emiatt a kérdőívek hosszát és a minták számát úgy kell meghatározni, hogy minden kérdést és mintát meg tudjanak válaszolni és értékelni tudjanak érzékszervi kifáradás nélkül. Ökölszabályként alkalmazandó, hogy minél kevesebb mintát minél kevesebb kérdéssel értékeljenek. Az egyszerre értékelhető minták száma maximum hat legyen. Ha ennél több mintát kell értékelni, akkor érdemes több blokkot alkalmazni. A szakértői bírálatokkal szembeni következő nagy eltérés, hogy a fogyasztói tesztek tervezésekor nagy létszámmal kell dolgozni. Næs minimum 60 főt javasol az érzékszervi vizsgálatokban, azonban a nemzetközi szakirodalomban ez a szám 100 fő körüli (Næs *et al.*, 2010). A létszámon kívül további figyelmet kell fordítani a megfelelő célcsoportra, és a reprezentatív mintavételre is, mivel a nem megfelelően kiválasztott fogyasztói minta félrevezető eredményeket adhat.


A preferencia-térképezés során a fogyasztói vizsgálatok eredménye egy $L \times M$ -es mátrix, ahol a mátrix soraiban a minták (N), míg a mátrix oszlopaiban a fogyasztók (M) szerepelnek (**11. ábra**).



11. ábra: A fogyasztói bírálat adatstruktúrájának felépítése

2.3.4. A preferencia-térképezés folyamata

A preferenciamódszer lényege, hogy matematikai összefüggést határoz meg egy adott termékcsoportra alkalmazott nagy létszámú laikus (*naïve*) fogyasztó által végzett kedveltségvizsgálat és egy kis létszámú szakértői bíráló csoport által végzett érzékszervi vizsgálat között (Yenket *et al.*, 2011a) (**12. ábra**). Kleef és munkatársai tanulmányukban összefoglalóan megállapítják, hogy míg a belső preferencia-térképezés a marketing szakembereknek, addig a külső preferencia-térképezés a termékfejlesztőknek segít a termékoptimalizálásában (van Kleef *et al.*, 2006).



12. ábra: A preferencia-térképezés elméleti váza

A belső preferencia-térképezés célja létrehozni egy többdimenziós teret, amely a termékek közti különbségeket reprezentálja a fogyasztói kedveltségvizsgálatok eredményei alapján. A belső preferencia-térképezést Chang és Carroll fejlesztette ki 1969-ben, és többdimenziós preferencia-analízisnek (*multidimensional preference mapping*, MDPREF) nevezte el (Yenket *et al.*, 2011a). Az eredeti MDPREF algoritmus többdimenziós skálázáson (*multidimensional scaling*, MDS) alapult, ám nem sokkal később a jóval népszerűbb főkomponensanalízisen (*principal component analysis*, PCA) alapuló változat terjedt el (Ares *et al.*, 2006; Felberg *et al.*, 2010). A PCA egy olyan dimenziócsökkentő eljárás, amely célja, hogy a változók számának csökkentés során azok információtartalmát minél jobban megtartsa. A fogyasztói kedveltségadatokon futtatott PCA első néhány főkomponense alapján állítjuk elő a preferencia-térképeket. A belső preferencia-térképen a fogyasztók preferenciája egy-egy vektorként jelenik meg. Egy adott vektor iránya megmutatja, hogy a bíráló mely terméket vagy termékeket részesítette előnyben. A vektorok hossza pedig arra utal, hogy a bíráló mennyire rendelkezett határozott preferenciával a termékekkel kapcsolatban (Guinard *et al.*, 2001).

A külső preferencia-térképezés során a szakértői bírálatok dimenzióinak számát csökkentjük néhány komponensre – minden egyes komponens lényegében néhány terméktulajdonság információtartalmát hordozza – majd ezt követi a fogyasztói adatoknak a komponenseket magyarázó regressziója (Yenket *et al.*, 2011a). A külső preferencia-térkép megalkotásához a kutatók számos statisztikai módszert alkalmaztak. Az első külső preferencia-térképet Carroll 1972-ben alkotta meg, aki MDS alapján dolgozott, majd a módszert preferencia-térképezésnek (*preference mapping*, PREFMAP) nevezte el (Carroll, 1972). Meulman és munkatársai 1986-ban a PREFMAP algoritmust kiegészítették azzal, hogy a fogyasztói adatokat illesztették egy vektormodellre PCA segítségével (Meulman *et al.*, 1986).

A következő mérföldkő során PCA-val csökkentették a leíró érzékszervi tulajdonságok dimenziószámát. A komponensek szkórértékeit a PCA a leíró érzékszervi adatokból és fogyasztói kedveltségi adatokból számította. Ezt követően vektor, körkörös, elliptikus vagy négyzetes modellel illesztette a fogyasztókat reprezentáló szkór értékeket a leíró érzékszervi adatokból származó szkór értékeire. A fogyasztói vektorokat jelenítették meg kétdimenziós ábrákon, amelyet szintén PREFMAP-nek neveztek el (Carbonell *et al.*, 2008). Ez az eljárás a változók számát csökkenti minimális információvesztés mellett, ezért akkor javasolt, ha a változók száma magas. A módszer legnagyobb előnye, hogy mindegyik komponens a sajátérték sorrendjében ábrázolja és magyarázza a megfigyelt változók varianciáját, ahol az első faktor magyarázza a legnagyobb részt, míg a többi

faktor csökkenő mértékben járul hozzá az összvarianciához. A kanonikusváltozó-elemzés (*canonical variate analysis*, CVA) (Hein *et al.*, 2009) és a Prokrusztész analízis (*generalized procrustes analysis*, GPA) (Nestrud és Lawless, 2008) úgy hajtja végre a dimenziócsökkentést, hogy a fogyasztói preferenciákat a saját komponens szkórjaikra regresszálja, amely szintén külső preferencia-térképet eredményez. A részleges legkisebb négyzetek elvén alapuló regresszió (*partial least squares regression*, PLS-R) módszerét szintén alkalmazták preferencia-térképek létrehozására a leíró érzékszervi adatok és a fogyasztói adatok regressziójával (Sveinsdóttir *et al.*, 2009; Michon *et al.*, 2010). A PLS-R modell szimultán dekompozíciót végez a leíró érzékszervi adatok és a fogyasztói adatok között, hogy maximalizálja a két mátrix közti kovarianciát. Ezzel szemben a PCA-módszerrel készített preferencia-térképek a leíró érzékszervi adatokat tartalmazó mátrix varianciájának maximalizálásával készülnek. A leggyakrabban PLS-R1-et alkalmaznak az érzékszervi kutatásokban, amelyben az *y* adatmátrix csupán egy változóból áll, a fogyasztói kedveltségi adatokból (Tang *et al.*, 2000; Kühn és Thybo, 2001). A többtényezős statisztikai módszerek erre a célra jól használhatók, mivel becslést és értelmezést is adnak az adatokhoz (NAES *et al.*, 2010).

Preferencia-térképezést eddig számos terméken végeztek a nemzetközi irodalom alapján, a teljesség igénye nélkül: almára (Kühn és Thybo, 2001), lager sörökre (Guinard *et al.*, 2001), almalevelekre (Kato *et al.*, 2003), müzliszeletre (Hein *et al.*, 2008), sült csirkére (Arditti, 1997), instant kávéra (Geel *et al.*, 2005), Cheddar sajtokra (Murray és Delahunty, 2000), illetve tortilla chipsre (Meullenet *et al.*, 2003). A 2010 és 2015 között publikált preferencia-térképezéssel foglalkozó nemzetközi kutatásokat a 3. táblázat tartalmazza.

2.3.5. A preferencia-térképezés gyakorlati problémái

Az ipari gyakorlatban az idő nyomása és a kutatás rendelkezésére álló szűkülő források nagymértékben befolyásolják egy-egy termékkel kapcsolatban a piacelemzést, fejlesztést. A tendencia egyértelmű, a nagymintás reprezentatív kutatásokat egyre inkább felváltják a kevesebb erőforrást igénylő, gyorsabban és gazdaságosabban elvégezhető kisebb mintás piackutatási technikák és módszerek. Ezt támasztják alá a különböző újonnan fejlesztett gyors profilmódszerek: Flash Profile, Ultra Flash Profile, Napping, stb. (Valera és Ares, 2014). Ennek eredménye, hogy néhány tíz fogyasztó dönt akár több tízezer főt érintő termékmódosításról, vagy regionálisan bevezetésre kerülő új termék sorsáról.

3. táblázat: A 2010 és 2015 között publikált preferencia-térképezéssel foglalkozó nemzetközi kutatások.

Szerző	Folyóirat	Termék	Módszer	Fogyasztók létszáma
Felberg <i>et al.</i> , 2010	Journal of Sensory Studies	szója-kávéital	MDPREF	60
Allgeyer <i>et al.</i> , 2010	Journal of Food Science	joghurtital	MDPREF, PREFMAP	110
Ares <i>et al.</i> , 2010a	Journal of Sensory Studies	csokoládés tejes desszert	PREFMAP	70
Ares <i>et al.</i> , 2010b	Food Quality and Preference	tejalapú desszertek	MDPREF, PREFMAP	80
Biasoto <i>et al.</i> , 2014	Food Research International	vörösborok	MDPREF	120
Bonany <i>et al.</i> , 2014	Food Quality and Preference	alma	PREFMAP	110
Cadena <i>et al.</i> , 2012	Journal of Dairy Science	csökkentett zsír és cukortartalmú jégkrém	PREFMAP	117
Cadena <i>et al.</i> , 2013	Food Research International	mangó nektár	PLS-R	120
Cannata <i>et al.</i> , 2010	Meat Science	szárazon pácolt sonka	MDPREF	201
Causse <i>et al.</i> , 2010	Journal of Food Science	paradicsom	PREFMAP	806
Delgado <i>et al.</i> , 2013	Food Research International	extra szűz olívaolaj	MDPREF	212
Dinnella <i>et al.</i> , 2011	Appetite	37 különböző termék	MDPREF	77
Dooley <i>et al.</i> , 2010	Food Quality and Preference	vaníliás jégkrém	PREFMAP	80
Gallina Toschi <i>et al.</i> , 2012	Journal of the Science of Food and Agriculture	joghurt	PREFMAP	60
Gatti <i>et al.</i> , 2011	Journal of Food Quality	alma	MDPREF	154
Gere <i>et al.</i> , 2014a	Journal of the Science of Food and Agriculture	csemegekukorica	PARAFAC, Tucker-3	60
Gere <i>et al.</i> , 2014b	Journal of Chemometrics	ízesített kefir	CATPCA, MDPREF	61
Hassine <i>et al.</i> , 2015	European Journal of Lipid Science and Technology	olívaolaj	PREFMAP	3700
Janzantti <i>et al.</i> , 2011	Journal of Sensory Studies	gyümölcsle	MDPREF	101
Jorge <i>et al.</i> , 2015	Meat Science	mortadella felvágott	PARAFAC	86
Lee <i>et al.</i> , 2012	Journal of Food Science	olajbogyó	MDPREF, PLS-R	104
Mâge <i>et al.</i> , 2012	Food Quality and Preference	málna lekvár	PO-PLS	114
Malherbe <i>et al.</i> , 2013	Journal of the Science of Food and Agriculture	bor	PCR	98
Neely <i>et al.</i> , 2010a	Journal of Sensory Studies	szója alapú extrudált snack	MDPREF	139
Neely <i>et al.</i> , 2010b	Journal of Food Science	szója alapú extrudált snack	PREFMAP	72
Nunes <i>et al.</i> , 2011	Journal of Sensory Studies	hamburger és sütemény	PARAFAC	50
Nunes <i>et al.</i> , 2012	Journal of Sensory Studies	szőlőlé	PARAFAC	100
Parente <i>et al.</i> , 2011	Journal of Sensory Studies	öregedés elleni krém	PREFMAP	69
Piqueras-Fiszman <i>et al.</i> , 2011	Journal of Sensory Studies	mobiltelefon és karóra	MFA	282
Rocha <i>et al.</i> , 2013a	Journal of the Science of Food and Agriculture	koktélpáradicsom	Corr. Anal.	110
Rocha <i>et al.</i> , 2013b	Food Research International	koktélpáradicsom	PREFMAP	80
Sinesio <i>et al.</i> , 2010	Journal of Food Science	paradicsom	MDPREF	179
Teillet <i>et al.</i> , 2010	Journal of Sensory Studies	palackozott és csapvíz	MDS	389
Torri <i>et al.</i> , 2013	Journal of the Science of Food and Agriculture	vörösbor	PREFMAP	189
Valli <i>et al.</i> , 2014	Journal of the Science of Food and Agriculture	extra szűz olívaolaj	PREFMAP	272
Varela <i>et al.</i> , 2014	Food Quality and Preference	kávé	MDPREF	161
Villamor <i>et al.</i> , 2013	Journal of Food Science	málna	PLS-R	205
Worch <i>et al.</i> , 2012	Food Quality and Preference	croissant	Ideal Map	151
Worch, 2013	Food Quality and Preference	leves	PrefMFA	109
Yenket <i>et al.</i> , 2011b	Journal of Sensory Studies	tej	MDPREF, CVA, GPA, PCA, PLS-R1, PLS-R2	115

2.3.5.1. A szakértői panel megbízhatósága

A preferencia-térképezésnél különösen fontos, hogy a szakértői bírálatokat nagy megbízhatóságú panel végezze, mivel a preferencia-térkép a profilanalízis eredményekből az egyes bírálati átlagokat használja. Ezért fontos az alapképzést követő szelekció és a költséges, több hónapon keresztül tartó a nemzetközi szabványoknak megfelelő (ISO 8586:2012) panelteljesítmény monitorozása (ISO 11132:2012), szoftverekbe integrált panelteljesítményt mérő módszerek segítségével (FIZZ, Compusense). Külön célszoftverrel (PanelCheck) (Næs *et al.*, 2010), vagy egyéb módszerekkel is elvégezhető a panel ellenőrzése (súlyközéppont terület/kerület arányon alapuló (*gravity center area/perimeter*, GCAP) módszer (Kollár-Hunek *et al.*, 2008), rangszámkülönbségek összege (*sum of ranking differences*, SRD) (Héberger és Kollár-Hunek, 2011)), ami így megalapozott termékspecifikus képzést tesz lehetővé. A termékspecifikus képzéseket célszerű kiegészíteni validált referenciaanyagokkal, vagy aromalexikon-képzésekkel, így az egyes tulajdonságok szórása jelentősen lecsökkenthető.

2.3.5.2. A vizsgálandó minták száma

Amikor a preferencia-térképezési tanulmányokban a vizsgálandó minták számát megállapítják, akkor minden esetben kompromisszumot kell hozni a becsült modellek elvárt statisztikai biztonsága és az adatok megbízhatóságának szükségessége között. A legfőbb problémát az a tény jelenti, hogy a fogyasztók hány mintát tudnak tesztelni, amellet, hogy megbízható adatokat adjanak. Az öt alatti mintaszám az egyedi regressziós modellek becslésekor a statisztikai megbízhatóság sérülése miatt nem javasolt (Næs *et al.*, 2010).

2.3.5.3. A kérdőív hossza

A kérdőív hossza, a skálák számának változása, a skálákon belül a kategóriák száma és jelölése befolyásolhatja a fogyasztók kedveltségi értékeit (ISO 6658:2005). A nemzetközi szabványosítási testület (*International Organization for Standardization*, ISO) rangsorolós módszerekkel végzett érzékszervi kutatásokkal kapcsolatban meghatározza, hogy a skálának 3-11 beosztásúnak kell lennie (ISO 8587:2006). Több kutatásban is megfigyelték, hogy ha a skálák páratlan beosztásúak, a bírálók hajlamosak a középső értéket választani (Costell *et al.*, 2010).

A kérdőív legyen felhasználóbarát, rövid, azonos jelölésű és beosztású skálákat tartalmazzon. Érdekes mindenki által könnyen értelmezhető piktogramokat alkalmazni a motiváció fenntartása érdekében (Chen *et al.*, 1996). A fogyasztók számát illetően a legtöbb esetben 60-150 számú fogyasztóval végzik a vizsgálatokat. Általános tapasztalat szerint ez elegendő a megfelelő megbízhatóságú adatokhoz, amelyek elengedhetetlenek a statisztikai modellek futtatásához. A

fogyasztókat mindig úgy kell kiválasztani, hogy a tanulmányozni kívánt populációt reprezentálják, például egy bizonyos korcsoportot, az egész országot vagy csak egy várost (Næs *et al.*, 2010).

2.3.5.4. Szegmentálás

Az ipari gyakorlatban ismételten előfordul, hogy a preferencia-térképeken a szegmensek nem válnak szét egymástól, a vektorok teljesen fedik egymást, így az adatok szinguláris mátrixba esnek. Ennek egyik oka az lehet, hogy a termékek érzékszervileg nagyon hasonlóak, vagy a fogyasztók nagyon hasonló ízléssel rendelkeznek, esetleg rossz a mintavétel vagy rossz a szegmentációs módszer, szegmentációs ismerv.

A szegmentációs módszerek közül a particionáló módszerek az elterjedtek, emellett ismeretes a szegmentálásnak másik két módszere: az átfedéses (*overlapping*) és lágy (*fuzzy*) szegmenseket létrehozó módszerek. Az ipari gyakorlatban bevett általánosan elterjedt hagyományos szegmentációs ismerv a szocio-demográfiai (nem, lakhely, iskolai végzettség, jövedelem) és a fogyasztói szokásokra, vásárlási/fogyasztói gyakoriságokra alapozott szegmentáció. Az ipari gyakorlatban a leggyakrabban a legkisebb szignifikáns differenciák (*least significant difference*, LSD) páros összehasonlítás módszerét alkalmazzák/igénylik, azonban mind a fogyasztói, mind a szakértői érzékszervi eredményeket befolyásolhatják a *post-hoc* páros próbák ereje. Növekvő sorrendben: LSD, Bonferoni, Sidak, Scheffe, Ryan-Einot-Gabriel-Welsh-féle F-próba (*Ryan-Einot-Gabriel-Welsh F test*, R-E-G-WF), Ryan-Einot-Gabriel-Welsh-féle tartománypróba (*Ryan-Einot-Gabriel-Welsh range test*, R-E-G-WQ), Student-Newman-Keuls-féle próba (*Student-Newman-Keuls test*, S-N-K), Tukey-próba, Tukey-féle b-próba, Duncan-féle próba, Hochberg-féle általánosított Tukey 2-próba (*Hochberg's generalized Tukey 2*, Hochberg's GT2), Gabriel-féle próba stb. (Sajtos és Mitev, 2007).

A tapasztalat szerint 2 vagy 3 főkomponens (*principal component*, PC) rendszerint elegendő az érzékszervi és a fogyasztói adatok legfontosabb változásainak leírására (Rødbotten *et al.*, 2009). Tenenhaus és munkatársai szerint tipikus, hogy az első két főkomponensen alapul a preferencia-térképezés, különösen akkor, ha a PC1 és PC2 által magyarázott varianciarányad nagyobb mint 90 százalék (Tenenhaus *et al.*, 2005). Amennyiben a kutató túl kevés faktort választ, úgy több fontos dimenzió kimaradhat az elemzésből, viszont ha túl sokat, akkor az elemzés válhat túlzottan bonyolulttá. Az optimális főkomponensszám meghatározására elsősorban a magyarázott varianciamódszert alkalmazzák (hegyomlás diagram vagy *scree-plot*), de ismeretesebb további módszerek: Kaiser-kritérium, maximum-likelihood módszer, kétfelé osztás megbízhatóságán alapuló meghatározás és a sajátértékek statisztikai szignifikanciájának meghatározása (Sajtos és Mitev, 2007; Næs *et al.*, 2010).

2.3.5.5. Validálás

Elsődlegesen a validált referenciaanyagokon alapuló termékspecifikus tesztek mellett a panelmonitoring nemzetközi módszereinek és szoftvereinek alkalmazásával elérhető, hogy a képzett panel tagjai egyetértsenek, illetve jó ismétlő- és megkülönböztető képességgel rendelkezzenek. Másodlagosan a szinguláris mátrixba eső adatok okainak kiküszöbölésével az egymástól lehatárolható fogyasztói szegmensek külső és belső preferencia-térképe megalkotható. Fontos azonban azt felismerni, hogy mint minden prediktív módszer, így a preferencia-térképezés is igényli az ismételt párhuzamos vizsgálatokat a modell felállításához. Egy jól definiált rendszer ugyanakkor lehetővé teszi, hogy egy új termék fejlesztésekor a költséges és időigényes fogyasztói teszteket bizonyos mértékig kiváltsuk. A módszer alkalmazásához tudni kell, hogy minden preferencia-térkép specifikus az adott termékre, régióra és időszakra, így bizonyos gyakorisággal validálni kell azt. Különböző időpontokban hasonló vizsgálatok lefolytatásával a probléma kiküszöbölhető.

2.4. Szemkamerás mérések és a fogyasztói döntések

2.4.1. A fogyasztói döntést befolyásoló tényezők

Az ételmiszer-választás egy többszörösen összetett folyamat, amelyet – annak ellenére, hogy mindennapi tevékenység – számos tényező befolyásol. Ezek a befolyásoló tényezők mind külön-külön tudományterületek részét képezik, aminek eredményeképpen ezek a tudományterületek önmagukban csak egy kis részét tudják megválaszolni azoknak a kérdéseknek, hogy „ki”, „mikor”, „mit”, „miért” és „hol” fogyaszt/vásárol.

A biológia (pl.: energiaszükséglet), fiziológia (pl.: emésztési mechanizmusok) valamint a motivációs és döntési pszichológia (pl.: indítékok) mind a „miért” kérdést válaszolják meg, annak tudatában, hogy a kérdést további faktorok is befolyásolhatják. A „ki” kérdésre szintén a biológia (pl.: genetikai jellemzők, nem), a szociológia (pl.: kultúra, hagyományok) és a fejlődési– illetve mentálpszichológia kutatói keresik a választ. Az érzékszervi minősítés, az ételmiszer-tudományok (pl.: ételmiszer-kémia, táplálkozástudomány), a marketing (pl.: fogyasztói viselkedés), a tanulási pszichológia (pl.: elvárások) és a közgazdaságtan (pl.: ár, haszon) a „mit” kérdésre adhatnak választ. Végül, de nem utolsósorban, a „hol” és „mikor” kérdéseket a biológia és a fiziológia (pl.: éhség, szomjúság, teltségérzet), a közgazdaságtan (pl.: elérhetőség, költségvetés), a szociológia (pl.: kulturális jellemzők), a marketing (pl.: reklámok és hozzáférhetőség), a fogyasztói tudományok (pl.: attitűdök) és a döntési pszichológia (pl.: szituációs hatások) válaszolhatják meg (Köster, 2009). Köster a tudományterületek szerepének meghatározásán túl a választást befolyásoló tényezőket a következő hat csoportba sorolta: belső termékjellemzők, biológiai és fizikai faktorok, pszichológiai faktorok,

helyzeti faktorok, szocio-kulturális faktorok és külső terméktulajdonságok, amelyek kapcsolatát a **13. ábra** szemlélteti (Köster, 2009).

Mela 1999-ben megjelent munkájában az étel-miszer-választás és -bevitel humán tényezőit vizsgálva megállapította, hogy a fent említett tudományterületek mind csak részben válaszolják meg a fő kérdést, minden esetben a fő hangsúly kissé eltolódik. Az egyetlen tudományterület, amely számára a „ki”, „mikor”, „mit”, „miért” és „hol” fogyaszt/vásárol a központi kérdések, az a fogyasztói érzékszervi minősítés területe (Mela, 1999).



13. ábra: A fogyasztói döntésre ható tényezők és azok kapcsolatai (Köster, 2009 alapján).

Noha több szerző is az élelmiszerek ízét azonosítja az étel-miszer-fogyasztást leginkább befolyásoló tényezőként (Glanz *et al.*, 1998), a legtöbb esetben az étel-miszerrel történő első érzékszervi találkozási pont a szemrevételezés, vagyis annak külleme (Wadhera és Capaldi-Phillips, 2014). Több nemzetközi publikáció is foglalkozott a döntéshozatalban jelentős szerepet játszó pszichológiai és/vagy gazdasági tényezőkkel (Towal *et al.*, 2013), azonban az élelmiszerek külleme bizonyult a legfontosabb érzékszervi szempontnak a választás meghozatalában. Valójában az étel-miszer pusztán látványa előidézhetheti az elfogyasztása iránti vágyat (Marcelino *et al.*, 2001). Ezen okokból kifolyólag a fogyasztói döntés meghozatalában az íznel és illatnál nagyságrendekkel

fontosabb szerepet tölt be az élelmiszer külleme. A küllem alapján határozhatók meg az élelmiszer ízével és illatával kapcsolatos elvárások, amelyek közvetlen szerepet játszanak az élelmiszer kedveltségében és elfogyasztásában (Hurling és Shepherd, 2003). Az élelmiszerfogyasztásra több vizuális tényező együttesen hat, amelyeket Wadhera és munkatársai a következő pontokra bontják (Wadhera és Capaldi-Phillips, 2014):

Láthatóság. Deng és Srinivasan egy 2013-ban megjelent kutatásukban bizonyították, hogy az átlátszó csomagolásban felszolgált élénk, többszínű termékből (színes reggelizőpehely) többet fogyasztottak a résztvevők, mint az opálos, kevésbé átlátszó csomagolásban felszolgált azonos termékből. Ezzel szemben zöldségek esetében többet fogyasztottak az opálos, kevésbé átlátszó csomagolású termékekből, mint a teljesen átlátszóból. A szerzők megállapításai alapján a kevésbé ízletes termékek (zöldségek) átlátszó csomagolásban történő felszolgálásával azok jobban kiemelkednek környezetükből, így jobban felhívják magukra a figyelmet, amely a fogyasztott mennyiség csökkenését okozta (Deng és Srinivasan, 2013).

Szín. Nemcsak az élelmiszer színe befolyásolhatja az elfogyasztott mennyiséget, illetve a kedveltséget, hanem a tányér vagy tál, amiben az élelmiszert felszolgálják a fogyasztóknak. Például a fehér tányéron, rózsaszín színezetű élelmiszert a fogyasztók ízletesebbnek és édesebbnek találták, mint ugyanazt a terméket fekete tányéron felszolgálva (Piqueras-Fiszman *et al.*, 2012). Hasonlóan az eddigiekhez, a piros csészében felszolgált forró csokoládét jobban kedvelték a fogyasztók mint a fehér csészében felszolgált (Piqueras-Fiszman *et al.*, 2012), illetve a kék poharakban felszolgált italok jobban oltották a fogyasztók szomját mint a piros, zöld vagy sárga színű poharakban felszolgált azonos italok (Guéguen, 2003).

Választék. Az élelmiszer-fogyasztást és –választást a különböző küllemű, ízű és illatú termékek együttes jelenléte szintén erősen befolyásolhatja. A nagyobb élelmiszer-választék emellett az energiabevitelt is megnöveli. A főtt tészta és darabolt zöldségek külön-külön történő felszolgálása magasabb energiabevittel társult, mint amikor összekeverve szolgálták fel a résztvevőknek (Levitsky *et al.*, 2012). A szerzők emellett megállapították, hogy az élelmiszeradagot több kisebb adagra bontva megnő az energiabevitel, amely az elfogyasztható élelmiszer választékának növekedésével magyarázható.

Az adagok mérete. A kutatások résztvevői általában a nagyobb adagokat jobban kedvelik és nagyobb vágyat éreznek az elfogyasztásukra, mint a kisebb adagok esetében (Burger *et al.*, 2011). Ezen felül a résztvevők nagyobb mennyiséget is fogyasztanak a nagyobb mennyiségben felszolgált ételből. Laboratóriumi körülmények között és valós szituációkban vizsgált gyerekek és felnőttek is

több ropogtatni valót, italt, szendvicset és téstát fogyasztottak, amikor nagyobb adagokban szolgálták fel azokat (Rolls *et al.*, 2007).

Folyadékok mennyisége. A gyermekek és felnőttek is hajlamosak a folyadékok mennyiségét a poharak magasságával arányosan becsülni (Raghubir és Krishna, 1999). Kutatásaik során bemutatták, hogy a résztvevők több folyadékot töltöttek a szélesebb, de alacsonyabb, mint a magasabb, de vékonyabb kialakítású poharakba. A jelenséget azzal magyarázták, hogy nagyobb jelentőséget tulajdonítottak a résztvevők a magasságnak, mint a szélességnek a folyadékok mennyiségének becslésekor.

Alak és a felület mérete. Ahogy a fenti kutatások is bizonyították, az élelmiszerek alakja befolyásolhatja az érzékelt mennyiséget. Krider és munkatársai egyetemi hallgatókat kértek meg, hogy becsüljék meg, hogy a kerek vagy a négyszögletű pizza a nagyobb. A résztvevők több mint 70 %-a érzékelte a négyszögletű pizzát nagyobbabbnak mint a kerekét, holott területük azonos volt (Krider *et al.*, 2001). Hasonlóan a fentiekhez, a szeletelt élelmiszerek alakja is befolyásolhatja a mennyiséget. Wada és munkatársai bemutatták, hogy a résztvevők túlbecsülték a vékony csíkokra vágott élelmiszerek tömegét, ám a kockákra vágott élelmiszerek tömegét pontosan meg tudták határozni (Wada *et al.*, 2007).

Darabszám. A bemutatott élelmiszerek száma szintén befolyásolhatja a mennyiséggel kapcsolatos érzetet. Egy marketingkutatás keretein belül azonos mennyiségű peracet csomagoltak egy olyan csomagolásba, amelyen 15 perac volt látható, illetve egy olyanba, amelyre csak három peracet rajzoltak. A résztvevők a vizuális ingerek hatására nagyobb mennyiségűnek ítélték a tizenöt peracet ábrázoló csomagolás tartalmát mint a másikat, annak ellenére, hogy az azonos mennyiséget tartalmazott (Madzharov és Block, 2010).

A fenti kutatások mind bizonyítják a vizuális jellemzők fontosságát, amelyet Imram úgy ír le szemléletesen, hogy: „*az első kóstolás mindig a szemekkel történik*”, amely során felidézük az elvárásainkat, emlékeinket és érzelmeinket (Imram, 1999). Következésképpen, a vizuális érzékelés a teljes ételminőség-érzékelésének egyik alapvető összetevője, ami szignifikánsan befolyásolja az ételminőség-választást (Jaros *et al.*, 2000; van der Laan *et al.*, 2011). Az elvárásokat és asszociációkat a vizuális tényezők mozgósítják, ennél fogva a vásárlók szemmozgásának elemzése elősegítheti a fogyasztói döntési mechanizmusok feltárását, megértését.

2.4.2. A szemkamera működési elve

A szemkamerás mérések alatt azokat a technikákat és mérési módszereket értik, amelyekkel a szem mozgása mérhető. A szemkamera története 1879-ig nyúlik vissza, amikor Louis Emile Javal

francia szemész orvos megfigyelte, hogy páciensei olvasás közben nem egyenletesen haladva olvasnak, hanem néhány szón elidőzik tekintetük (fixáció), néhányon pedig gyorsan átsiklanak (szakkádok), ami megteremtette az 1900-as évek elején a szemmozgás tanulmányozása iránti igényt. Edmund Huey építette az első műszert, amely képes volt követni a szemmozgást, majd kiadta „*The Psychology and Pedagogy of Reading*” című könyvét 1908-ban, amely az első ilyen jellegű publikáció. A Huey által épített készülék óta a szemkamerák alkalmazása az olvasási mintázatok területéről elterjedve számos helyre eljutott.

Az emberi látás a fényképezőgépek működéséhez hasonló elven működik. A szem fő része a szemgolyó, de a látószervhez szervesen hozzátartoznak a szemidegek és a folytatásukba eső idegpályák, valamint a szem járulékos szervei. Az emberi szem két részből álló gyűjtőlencse típusú objektívvel rendelkezik. A külső a szaruhártya, a belső a szemlencse. A szivárványhártya, amely a szem színét is meghatározza, a szembe lépő fény mennyiségét csökkenti. A szivárványhártya nyílása a pupilla, amelynek átmérője a fényerősségtől függően változik, a fényrekesz szerepét tölti be. A belépő fénysugarak áthaladnak az üvegtesten és a recehártyára (retina) fókuszálódnak. Ezután a központi idegrendszer közreműködésével alakul ki a kép (Réthelyi és Szentágothai, 2013). A szemben a fényérzékeny terület nem mindenhol egyforma. Az egyedfejlődés során az emberi szemnek alkalmazkodnia kellett a nappali és az éjszakai fényhez is, illetve ezek gyors váltakozásához. Emiatt alakult ki, hogy a látótér csak kisebb területén ad éles képet (foveális terület), míg a látótér nagyobb része jobban adaptálódott a kevés fényhez (perifériás látás), így ezen a területen a mozgásokat, kontrasztbeli eltéréseket érzékeli a szem. Az ezen a területen képzett kép életlen, és színekben szegény. A kettő közt helyezkedik el egy átmeneti terület, az ún. parafoveális terület. A két fő terület közti eltérésekért a szemben található fotoreceptorok felelősek, a pálcikák és a csapok (Ganong, 1990). A pálcikák az alacsonyabb intenzitású fényre is érzékenyek, az erősebb fényingert igénylő csapok a színlátást és az éles látást szolgálják. Az ún. sárgafoltban levő látógödörben csak tömötten egymás mellé rendeződött csapok vannak, ez az éleslátás helye.


Az emberi látómező nagyjából 200°-os szöget zár be, amely három fő részre osztható: éleslátás területe, parafoveális terület és perifériás terület. A szemmozgásadatokat rögzítése a foveális, vagyis éleslátás helyére korlátozódik, amely a teljes látótér kevesebb mint 8 %-át teszi ki. Ennek ellenére az itt rögzített információ az agynak küldött teljes információmennyiség mintegy felét teszi ki. A szemmozgás során három fő folyamat zajlik le:

1. A szemlélőt érdeklő, érintő információnak az éleslátás mezejébe kell esnie. Ezt fixációkkal és szakkádokkal éri el a szem. Fixációnak nevezik azokat a szüneteket, amikor a szem elidőz egy adott területen, szakkádoknak pedig a fixációk közti gyors mozgást.

2. A látottak folyamatos követése. A szemnek képesnek kell lennie az előtte lassan mozgó tárgyak követésére a fej megmozdítása nélkül. Ezt lassú szemmozgásnak (vagy lassú követésnek) nevezik.
3. A retinára eső kép elhalványulásának megakadályozása. Az erre szolgáló apró mozdulatokat mikroszakadásoknak nevezik, amelyek hiánya esetén a tekintet fixációja után rövid idő alatt a tárgyak elhalványulnának, sőt akár teljesen el is tűnnének.

A szemkamerák működésének folyamata technikai oldalról nézve két részre bontható: a szemmozgás rögzítése és annak a felhasználó számára értelmezhető módon történő prezentációja alapján.

A szemmozgás rögzítését a legelterjedtebben a pupilla központú szaruhártya tükröződés (*pupil centre corneal reflection*, PCCR) elvén teszik meg a szemkamera gyártói (**14. ábra**). Az orvosi alkalmazásokkal szemben ez a módszer nem invazív, nem igényel komoly előkészületeket, és szinte bárhol alkalmazhatóvá teszi a technikát. Lényege, hogy egy fényforrás segítségével a szemről visszaverődő reflexiót hoznak létre a szaruhártyán és a pupillán, amelyet egy kamera segítségével rögzítenek. A reflexió helye alapján egy vektor számítható, amely megadja a pillantás irányát. A Tobii® (Tobii AB, Danderyd, Svédország) szemkamerák közeli infravörös megvilágítást alkalmaznak a reflexió kiváltására, majd két szenzor segítségével rögzítik a visszavert fényt. Az így kapott adatokból képfeldolgozási és fiziológiai 3D algoritmusok segítségével modellezik a szemet, illetve a szem térbeli elhelyezkedését, így a pillantás pontos helyét is.



14. ábra: A pupillaközpontú szaruhártya-tükröződési módszer működési elve (Guestrin és Eizenman, 2006 alapján).

A pupilla megvilágítása két eltérő elv alapján történhet: világospupilla-módszer és sötétpupilla-módszer. A két megközelítés lényege, hogy minél nagyobb kontrasztot hozzanak létre a szivárványhártya és a pupilla között, amit nagymértékben befolyásolnak a környezeti adottságok, és emiatt vált szükségessé a két módszer kifejlesztése.

A világospupilla-módszer alkalmazása akkor javasolt, ha az infravörös fényforrás a kamera optikai tengelyével egybeesik, mivel ilyenkor a pupilla világosabbá válik, mint a szivárványhártya. Ennek az az oka, hogy a retinából visszavert fény közvetlenül a kamerába irányul. A jelenség azonos a fényképezéskor előforduló vörös szem effektushoz. Éppen ezért a módszert inkább sötétebb környezetben ajánlott alkalmazni, kültéri vagy jó megvilágítású helyszíneken azonban nem. Mivel a rendszer a pupillát világosabbnak érzékeli, mint a szivárványhártyát, ezért a külső zavaró hatásokat jobban tolerálja. Ilyen hatások lehetnek a sötét színű szempillafesték, vagy szemhéjfesték. Hasonló okokból kifolyólag világos, kékszemű résztvevők esetében a világospupilla-módszer javasolt alkalmazni.

A sötétpupilla-módszer ezzel szemben akkor alkalmazható, ha az infravörös fényforrás a kamerától távolabb helyezkedik el, mivel ilyen esetekben a pupilla sötétebb színezetű lesz mint a szivárványhártya. A módszert inkább a normál megvilágítású belső helyszíneken vagy kültéri vizsgálatoknál célszerű alkalmazni. A pupilla sötétebb árnyalata miatt a fent említett zavaró hatások ebben az esetben jobban befolyásolhatják a mérést, mint a világospupilla-módszer esetében. A gyártók ezt a módszert javasolják a sötétebb (pl.: barna) szemű résztvevők vizsgálatakor. A szemkamera gyártói általában mindkét módszert integrálják termékeikbe, azonban az már termékfüggő, hogy a felhasználónak kell-e kiválasztani a megfelelő módszert, vagy a beépített vezérlő szoftver határozza meg, hogy melyiket érdemes használni az adott szituációban, helyszínen.

A PCCR-elven működő szemkamerákat két további nagy csoportra bonthatjuk: statikus (azaz helyhez kötött) (melléklet, **M11.2.1 ábra**) vagy dinamikus (azaz viselhető, hordható) (melléklet, **M11.2.2 ábra**). A kettő közti legnagyobb különbség elhelyezkedésükből fakad. A statikus szemkamerákat egy megjelenítő eszközhöz csatlakoztatják (pl.: monitor, televízió, (melléklet, **M11.2.3 ábra**)), így a résztvevő a megjelenítőn látottakat vizsgálja, nincs közvetlen kontaktus közte és a szemkamera között. A dinamikus szemkamerákat szemüveggé kell viselnie a résztvevőknek a vizsgálat során.

A statikus szemkamerákat fix elhelyezésük miatt jellemzően olyan kutatásokban alkalmazzák, amikor a vizsgálandó stimulus egyszerűen megjeleníthető egy monitoron (képek, weblapok, videók) (**15. ábra**). A legújabb alkalmazások között szerepel az okostelefonokon, illetve tableteken történő

alkalmazás (melléklet, **M11.2.4 ábra**). Mivel nincs közvetlen kontaktus a résztvevővel, a résztvevők könnyebben és hamarabb megfélekedhetnek arról, hogy szemmozgásukat rögzítik, így természetesebben viselkednek. Hátránya azonban, hogy a résztvevők csak a szemkamera rögzítési szögén belül, kis mértékben mozgathatják fejüket a megfelelő rögzítési minőségért. Ez azonban az adatelemzést nagymértékben megkönnyíti, ugyanis minden résztvevő azonos stimulust vizsgál, így könnyen összehasonlíthatóvá válik szemmozgásuk és viselkedésük, az adatelemzés automatizálható.

A dinamikus szemkamerát ezzel szemben inkább laboratóriumon kívüli kutatásokban alkalmazzák sikerrel, vagyis amikor a résztvevő közvetlen kapcsolatba kerül a vizsgálandó termékkel, kézbe veszi, boltban barangol, polcelrendezést vizsgál. A technika egyik hátránya, hogy a viselés miatt közvetlen kapcsolatban van a szemkamera a résztvevőkkel, így hosszabb időre van szükség, hogy megszokják jelenlétét. Emiatt azonban nagy szabadságot is biztosít a résztvevőknek, szabadon mozoghatnak. A kutatások során így jobban vizsgálható az egyén termékkel szemben tanúsított magatartása (melyik oldalát nézi meg először, mi alapján választ eltérő termékek közül). Azonban ez a nagyfokú szabadság az adatelemzést jelentősen megnehezíti, a résztvevők eltérő képi anyagot generálnak eltérő fejmozgásuk miatt. Így minden felvételt egyesével kell megvizsgálni, majd ezek alapján levonni a következtetéseket (Bojko, 2013).



15. ábra: Tobii X2-60 szemkamera (Forrás: Saját felvétel).

A szemkamerákat kialakításuk mellett azok mintavételi frekvenciái is megkülönböztetik egymástól. A mintavételi frekvenciát Hertz-ben (Hz) adják meg a gyártók, amely azt jelenti, hogy a szemkamera másodpercenként hányszor rögzíti a résztvevő szemmozgás adatait. Ezek alapján egy 60 Hz-es berendezés másodpercenként hatvenszor rögzíti az adatokat. A piacon előforduló szemkamerák általában 30 és 2000 Hz közötti mintavételre képesek. A mintavételi gyakoriság kiválasztása minden esetben feladatfüggő. Amennyiben a kutató arra kíváncsi, hogy a résztvevők hova néznek egy adott képen, videón vagy honlapon, úgy a 25-150 Hz mintavételű berendezések használata javasolt, ugyanis a magasabb mintavételű készülékek nem adnak többletinformációt az ilyen jellegű kérdések megválaszolásában. Azonban, ha a kutatás például olvasási zavarok feltárására irányul (pl.:

diszlexia szűrés), úgy a nagyobb mintavételű műszerek alkalmazása nélkülözhetetlen. Az ilyen, nagyobb mintavételű szemkamerák képesek a szakkádok és mikroszemmozgások rögzítésére is (Bojko, 2013).

2.4.3. Szemkamera alkalmazása élelmiszerek csomagolásának vizsgálatára

Szemkamerás méréseket széles körben alkalmaznak élelmiszerek csomagolásának és címkéinek értékelésére (Bialkova és van Trijp, 2011; Ares *et al.*, 2013, 2014b; Rebollar *et al.*, 2015), illetve tápérték-táblázatok vizsgálatára (Graham *et al.*, 2012). Az ilyen kutatások során a résztvevők a termékeket címkéik alapján vizsgálják és értékelik. Ares és munkatársai 2013-ban arra keresték a választ, hogy a fogyasztók hogyan gyűjtik be az információt az élelmiszerek címkéiről (Ares *et al.*, 2013). Noha a kutatás során alkalmazott címkék grafikai felépítése és információtartalma eltérő volt, a résztvevők többsége négy területre fókuszált: a termék képe, a márka, az összetevők listája és a tápérték-információ. Az eredettel, súllyal, gyártóval és lejáratival kapcsolatos információra szignifikánsan kevesebb időt fordítottak, amikor a vásárlási hajlandósággal és a termékek egészségességével kapcsolatos kérdésekre válaszoltak. A szemkamerás mérések során megállapították, hogy a címkék kialakítása és a fogyasztók által megválaszolendő feladatok csak kismértékben befolyásolták azt, hogy mennyi figyelmet szenteltek a címkéken feltüntetett egyes információknak.

Graham és munkatársai 2012-ben közölt áttekintő munkájukban a szemkamerás mérésekről és a tápanyag-táblázatok használatáról részletesen értekeznek (Graham *et al.*, 2012). Kitérnek arra, hogy noha a tápanyag-táblázatokkal kapcsolatos szemkamerás kutatások száma limitált, az alábbi szempontok figyelembevételével a fogyasztók könnyebben tájékozódnak a címkén:

- a tápanyag-táblázatokat középpontba kell helyezni,
- a tápanyag-összetevőket egészségi hatásuk alapján csökkenő sorrendben kell felsorolni,
- a tápanyag-táblázat körüli területet letisztulttá kell tenni,
- a táblázat emelkedjen ki a címkéből (szín, kontraszthatás),
- a megnövelt táblázat több figyelmet kap,
- egyszerű megjelenítés és fogalmazás szükséges a jobb megértéshez.

Bialkova és van Trijp megállapították, hogy szemkamerás mérési módszerek segítségével megválaszolható számos, a fogyasztói figyelemmel és döntéshozattal kapcsolatos kérdés (Bialkova és van Trijp, 2011). Kutatásuk során egy olyan módszert dolgoztak ki, amellyel az élelmiszerek címkéin feltüntetett információk szerepét lehet hatékonyan vizsgálni a fogyasztói döntéshozatalban. A kísérletterv felépítésének köszönhetően (egyedeken belüli elrendezés, *within-subject design*) már kis létszámú válaszadás és egyszerű választási helyzet (két alternatíva) esetén is hasznos információ

nyerhető. Eredményeik során bizonyították, hogy a figyelem a csomagoláson leginkább kitűnő információ felé irányul, amely különösen igaz akkor, ha az adott információ a vásárlási céllal egybevágh. A sorozatos döntési szituációk miatt a résztvevők figyelme a feladat előrehaladtával egyre csökkent, amelynek okai közt lehet a fáradtság vagy a feladathoz való adaptáció is, illetve a végső döntést a megfigyelt információ erősen befolyásolta (Bialkova és van Trijp, 2011). Hasonló kutatást végzett Gofman munkatársaival 2009-ben, amelyben szemkamerát alkalmazva keresték a választ arra a kérdésre, hogy hogyan is néznek a fogyasztók az egyes termékcsomagolásokra. Eredményeik alapján megállapították, hogy a résztvevők több időt szentelnek a csomagolásokon található grafikai elemeknek, mint a címkének, illetve a szöveges információnak (Gofman *et al.*, 2009).

2.4.4. A fogyasztói döntés vizsgálata

A marketing szakemberek számára ismert mondás szerint, ha nem látszik egy termék, nem is lehet eladni azt. Mivel az étel- és italválasztás a táplálkozási viselkedés egyik legfontosabb jellemzője, a szemkamera alkalmazásának egyik ígéretes területe a szemmozgás és étel- és italválasztás közti összefüggések feltárása. Ebből fakad az a kutatási kérdés, hogy a választás, pontosabban az étel- és italválasztás, milyen kapcsolatban áll a termékek tulajdonságaival és a vizuális figyelemmel. Különböző kutatások bizonyították, hogy több szemmozgást leíró paraméter is összefüggésben áll a fogyasztói választással. Egy friss összefoglaló cikkben Orquin és Mueller Loose a szemmozgás döntési folyamatokban betöltött szerepét tárja fel (Orquin és Mueller Loose, 2013). Cikkükben rávilágítanak, hogy a fogyasztók figyelme fontos szerepet játszik a döntéshozatalban. Több, szemkamerával folytatott kutatás eredményét feldolgozva arra a következtetésre jutottak, hogy a résztvevők általában többször fixálnak a választott termékre, illetve hosszabb ideig nézik a választott terméket. Emellett az alábbi három lehetséges mechanizmust is azonosították: kitettség hatás, a döntési lehetőségek redukálása a fixált alternatívákra, a fixált alternatívák megnövekedett befolyása. Ezeken felül kitérnek arra is, hogy a résztvevők nagy valószínűséggel azt a terméket választják, amelyre az első fixáció esett, illetve az utoljára fixált alternatíva erős kapcsolatban áll a választottal.

Noha a választás és a szemmozgás közti korrelációt sok publikáció tárgyalja, csak néhány tanulmány foglalkozott az étel- és italválasztással, illetve azzal, hogy a szemmozgás vajon általános-e a különböző étel- és ital-kategóriák között. Reutskaja és munkatársai három döntési modellt hasonlítottak össze szemkamerás mérési adatok felhasználásával (Reutskaja *et al.*, 2011). Kutatásukban éhes résztvevőknek sokszempontos (multialternatív) választási szituációban chips termékeket mutattak be. Az eredmények alapján a résztvevők jól optimálták döntéseiket egy adott célcsoportra. Emellett természetesen a választott termék keresési folyamata véletlenszerű volt.

Továbbá az eredmények rávilágítottak, hogy a döntéshozók megállási szabályokat alkalmaztak, amelyek az optimális keresés elemei alapján állították meg a keresési folyamatot. Krajbich és Rangel megállapították, hogy a multialternatív drift-diffusion modell mennyiségileg pontosan leírja a választás, a reakcióidő és a vizuális fixáció közti kapcsolatot (Krajbich és Rangel, 2011). Kutatásukban egy három alternatívából álló döntési szituációban vizsgálták a résztvevők szemmozgását.

Jantathai és munkatársai munkájuk során azt vizsgálták, milyen hatása van az élelmiszerek színének a szemmozgásra (Jantathai *et al.*, 2013). Egy további kutatási kérdésükben pedig a szemmozgás és választás közti összefüggésekre keresték a választ. Szignifikáns pozitív korrelációt azonosítottak két szemkamerával mérhető paraméter (fixációk száma és a látogatások hossza) és a választott alternatíva között. Eredményeik alapján a fixációk száma és a látogatások hossza felhasználható akár a fogyasztói döntések előrejelzésére is.

Ares és munkatársai 2014-ben a racionális és intuitív gondolkodási sémák élelmiszer-választásra vonatkozó hatását vizsgálták (Ares *et al.*, 2014b). Eredményeik alátámasztották, hogy a gondolkodási mód szignifikánsan befolyásolja az információfeldolgozást, így a választást is.

Egy közelmúltban publikált kutatás közelebbről is megvizsgálta az első fixáció és a fogyasztói választás kapcsolatát (van der Laan *et al.*, 2015). Eredményeik alapján az első fixáció helye (az első alkalommal fixált termék) nem állt szignifikáns összefüggésben a választással. Ezek alapján kijelentették, hogy az első fixáció mérése nem szolgáltat többletinformációt a szemkamerás vizsgálatok során. A kutatás eredményeinek megvitatásához azonban figyelembe kell venni, hogy vizsgálataik során bináris döntési szituációt alkalmaztak. Összetettebb vizsgálatok során az első fixáció szerepe jóval határozottabb is lehet, amelynek meghatározásához további vizsgálatok szükségesek. A tanulmány egy további érdekes megállapítása, hogy a teljes fixációs időtartamot főleg a döntési cél határozta meg, vagyis nem a preferencia.

A nemzetközi szakirodalom részletes áttekintése alapján megállapítható, hogy a kutatások fókuszra elkerülte azt a kérdést, hogy a szemmozgás és élelmiszer-választás közti összefüggések mennyire tekinthetők állandónak különböző termékkategóriák között?

A fogyasztói döntések mellett az egészségesség érzékelésére is sikeresen alkalmaztak szemkamerás méréseket. Halakból készült készételeket vizsgáltak a fogyasztók a Mitterer-Daltoé és munkatársai által közölt kutatásban, amelyben az alábbi egészségességi sorrendet állapították meg a fogyasztói megítélés alapján: halfilé (legegészségesebb) > halból készült hamburger > rántott halfalatkak (legkevésbé egészséges) (Mitterer-Daltoé *et al.*, 2014).

3. Célkitűzések

Doktori dolgozatom fő célkitűzései olyan új módszerek fejlesztése az élelmiszertermékek preferencia-térképezésének gyakorlatában, amelyekkel: 1) részletesebb, 2) a gyakorlatban is jól alkalmazható módszerkiválasztásra vonatkozó, 3) szemkamerát integráló komplex eredmények kaphatóak. A fő célkitűzésekhez kapcsolódó kutatási célkitűzéseket az alábbiakban mutatom be.

1. A részletesebb preferencia-térképek megalkotásánál célkitűzéseim voltak:

- 1.1. A részletesebb preferencia-térképek létrehozásának céljából több adatmátrix szimultán háromszempontos elemzési eredményeinek integrálása különböző statisztikai modellekkel.
- 1.2. Annak a gyakorlati kihívásnak a statisztikai megoldása, hogy fogyasztói rangsoradatokból preferencia-térképek építhetők legyenek.

2. A gyakorlatban is jól alkalmazható statisztikai módszer kiválasztásával kapcsolatos célkitűzéseim voltak:

- 2.1. Az általánosan alkalmazott optimumskálák (JAR-skálák) elemzésére az eddigieknél hatékonyabban alkalmazható módszer megfogalmazása és megvalósítása, valamint ennek új és könnyen értelmezhető vizualizációja.
- 2.2. A JAR-elemzésre alkalmazható statisztikai módszerek szignifikáns rangsorolásának elméleti és gyakorlati megvalósítása.
- 2.3. Termékoptimalizálás a JAR-változók kedveltségre gyakorolt hatásának meghatározására és rangsorolásuk JAR-adatelemzésre alkalmazott statisztikai módszerek együttes integrálásával.

3. Szemkamera integrálásával kapcsolatos célkitűzéseim voltak:

- 3.1. A szemkamera szemmozgást rögzítő változói alapján a döntési idő vizsgálatának újszerű megközelítése.
- 3.2. A szemkamera szemmozgást leíró változóinak felhasználása a fogyasztói döntéshozás jobb megismeréséhez élelmiszer-termékcsoportok vizsgálatával. A fogyasztói döntést legpontosabban előrejelző statisztikai modellek meghatározása.
- 3.3. Az *utolsó fixáció helye* alapján történő fogyasztói választás előrejelzésénél pontosabb előrejelzés megvalósítása statisztikai módszerkombinációk segítségével.

4. Anyagok és módszerek

4.1. A kutatás során felhasznált anyagok

Munkám során több különböző termék érzékszervi vizsgálatát végeztem el, hogy megfelelő bemenő adathalmazt biztosítsak az alkalmazott egy- és többváltozós statisztikai módszerek számára. A vizsgálatok megtervezésekor és végrehajtásakor a jó érzékszervi gyakorlat (*good sensory practice*, GSP) elemeit betartva jártam el. Kilcast ajánlásait megfogadva a mintamennyiségeket mindig azonos személy, azonos digitális mérlegen mérte ki (Kilcast, 2010). A bírálatok között a bírálók semleges ízű szénsavmentes ásványvizet használtak ízsemlegesítésre (Sipos *et al.*, 2012). A mintákat minden esetben nem nullával kezdődő háromjegyű véletlenszámokkal kódoltam kiegyenlített blokk elrendezést követve (ISO 6658:2005). Az érzékszervi teszteket minden esetben az ISO 8589:2007 szabvány szerinti standardizált helyiségben, a Budapest Corvinus Egyetem Érzékszervi Minősítő Laboratóriumában hajtottam végre (ISO 8589:2007).

A szakértői bírálatok során a panel a laboratórium szakértőiből állt, ahol a tagok részesültek az ISO 8586:2012 szabvány által előírt képzésben (ISO 8586:2012). A vizsgálatokat az adatok megbízhatósága miatt kétszer végeztem el, a bíráló panel minimum tíz főből állt. A profilanalízis megtervezését, végrehajtását és az eredmények értékelését a vonatkozó szabvány előírásai alapján hajtottam végre (ISO 11035:1994).

Næs minimum 60 főt javasol fogyasztói tesztekhez, amelyet minden vizsgálat során betartottam (Næs *et al.*, 2010). A fogyasztói bírálatok során kedveltségi és optimumskálákat is felhasználtam a különböző kutatásokban. A fogyasztók kedveltségi értékeléseiket kilenctagú kategóriaskálán rögzítették (1 – nem kedvelem, 9 – nagyon kedvelem) (ISO 4121:2003), valamint öttagú optimumskálákat alkalmaztunk (1 – nem elég intenzív, 3 – pont jó, 5 – túl intenzív). A fogyasztók a kérdőívek kitöltéséhez előzetesen instrukciókat kaptak.

4.1.1. Csemegekukorica-minták

Nyolc különböző, hazánkban is termesztett csemegekukorica mintát alkalmaztam a kutatás során (4. táblázat). A blansírozott, fagyasztott mintákat 1 kg-os kiszerelésben a MIRELITE MIRSA Zrt. biztosította a kutatáshoz. Az UPOV (*International Union for Protection of New Varieties of Plants*) előírásai alapján megkülönböztethetőek normálédes (su1), növelt cukortartalmú (se) és szuperédes (sh2) fajtákat (CPVO, 2010).

4. táblázat: A felhasznált csemegekukorica minták.

Minta/tulajdonság	Érés	Édesség	Csőhosszúság	Szemek sárga szín intenzitása
GSS 8529	közép	szuper (sh2)	közepes-hosszú	közepes-sötét
Jumbo	közép	normál (su1)	hosszú	közepes-sötét
Legend	korai	normál (su1)	közepes-hosszú	közepes
Madonna	korai	normál (su1)	közepes	közepes
Overland	késői	szuper (sh2)	közepes-hosszú	közepes
Rebecca	közép	szuper (sh2)	hosszú	világos-közepes
Spirit	korai	normál (su1)	rövid-közepes	közepes
Turbo	közép	normál (su1)	hosszú	közepes

A csemegekukorica biológiai minta, így az ebből eredő heterogenitás a kutatás során is jelen volt. Annak érdekében, hogy ezt a hatást a minimálisra csökkentsem, a jó érzékszervi gyakorlat elemeit szem előtt tartva végeztem el a mintaelőkészítést. A mélyfagyasztott (-18 °C-on tárolt) minták előkészítése azonos paraméterek mellett zajlott (főzési idő, mintamennyiség, az edényzet anyaga és gyártója, a tűzhely mérete és gyártója stb.). A mintákat a fagyasztóból kivéve azonnal forrásban lévő vízbe tettem, majd 300 s ideig főztem. A fajtákat külön-külön 5 literes edényekben készítettem elő az ízathordás megelőzésére. A 300 s letelte után rozsdamentes acélszűrővel szűrtem a mintákat. Minden edényhez dedikált szűrő tartozott. A mintákat általános fogyasztási hőmérsékleten (45 °C) üvegtálakban (0,3 liter) szolgáltam fel a bírálóknak (100 g/fő).

A szakértői bírálat során a bírálók 100 pontos, folytonosnak tekinthető skálát alkalmaztak a következő terméktulajdonságok értékelésére: sárga szín, árnyalat, szemméret, szemméret egyenetlensége, frissesség, illatintenzitás, főttkukorica illat, édes illat, állomány, lédűsság, héj rághatósága, zsengesség, globális ízintenzitás, édes íz, sós íz utóíz és utóíz leírása.

Összesen 60 fő fogyasztó vett részt a kutatásban, akik az alábbi tulajdonságok alapján értékelték a mintákat: küllem, illat, íz és állomány kedveltsége. A fogyasztók válogatása a következők alapján történt: 56 % férfi és 44 % nő, 18 és 50 év közöttiek. A résztvevők átlagosan havonta egyszer legalább fogyasztanak csemegekukorica terméket.

4.1.2. Ízesített ásványvízminták

A kutatás során egy mangó-passiógyümölcs ízesítésű ízesített ásványvíz termék prototípusát értékelték a fogyasztói bírálók (117 fő). A mintákat azonos körülmények között (10 °C-on) tároltam, majd a vizsgálat megkezdése előtt 200 cm³ űrtartalmú műanyag poharakba töltöttem (180 cm³/fő). A minták felszolgálása végül fogyasztási hőmérsékleten (15 °C) történt, amelyet szigorúan ellenőriztem a vizsgálat során. A fogyasztók kiválasztása a következők alapján történt: 60%/40% férfi/nő, 18 és 30 év közöttiek, rendszeresen fogyasztanak ízesített ásványvízterméket. A fogyasztói bírálók általános

kedveltségértékeinek rögzítése mellett az alábbi tulajdonságokat vizsgálták optimumskálákon: szín, illat, gyümölcsíz, szénsavasság, édes íz, savanyú íz, keserű íz és utóíz-intenzitás.

4.1.3. Ízesített kefirmenták

A kutatás során három különböző ízesítésű (szőlő, ribizli, alma) kefirmenta két eltérő ízesítési koncentrációját használtam fel, így összesen hat terméket értékelt a 61 fős fogyasztói bíráló panel. A kutatás során a kisebb aromakonzentráció „A” jelzést, a nagyobb koncentráció „B” jelzést kapott. A mintákat azonos körülmények között (4 °C-on) tároltam, majd a vizsgálat megkezdése előtt a hűtőszekrényből kivéve azonnal 200 cm³ űrtartalmú műanyag poharakba töltöttem (150 cm³/fő). A minták felszolgálása végül fogyasztási hőmérsékleten (15 °C) történt, amelyet szigorúan ellenőriztem a vizsgálat során. A fogyasztók toborzása a következők alapján történt: 60%/40 % férfi/nő 18 és 30 év közöttiek, többségük rendszeresen fogyaszt ízesített kefirterméket. A fogyasztói bírálók kedveltségértékeinek rögzítése (általános kedveltség, szín kedveltsége, íz kedveltsége és illat kedveltsége) mellett az alábbi tulajdonságokat értékelték optimumskálákon: állomány, illat, kefiríz és gyümölcsíz. A kutatás során ezen felül kedveltség alapján sorba kellett rendezni a mintákat, és meg kellett becsülni a minták ízesítését, amit a háromjegyű véletlenszámmal történő kódolás miatt nem ismertek a fogyasztók.

4.1.4. Krékeradatok

A nemzetközi szakirodalommal történő könnyebb összehasonlíthatóság miatt a kutatások során az Amerikai Anyagtudományi és Ellenőrzési Társaság (*American Society for Testing and Materials*, ASTM) által kiadott optimumskálákkal foglalkozó szabványban felhasznált adatokon alkalmaztam módszereket (ASTM MNL-63, 2009). Az adathalmazt az ASTM Titkárságáról, Lori Rothman-tól kaptam meg további elemzésre. Az adathalmaz öt termék értékelését tartalmazza, amelyben 117 fogyasztót kérdeztek meg. A fogyasztói bírálók általánoskedveltség-értékeinek rögzítése mellett az alábbi tulajdonságokat értékelték optimumskálákon: méret, szín, általános ízintenzitás, sós íz intenzitása, vastagság és ragadósság. Az eredményeket a 170-es kódolású termék mentén mutatom be.

4.2. Párhuzamos faktorelemzés

A párhuzamos faktorok modellje (*parallel factor analysis*, PARAFAC) módszert Harshman dolgozta ki az arányos profilok (*proportional profiles*) elméletből (Harshman, 1970). A PARAFAC-algoritmussal történő elemzés előtt az adatokat két fázisban készítjük elő annak érdekében, hogy a

nemkívánatos konstansokat eltüntessük. Az első fázisban a 3 dimenziós mátrixot kell átdarabolni kétdimenziós mátrixszá a megfelelő nézetből történő metszeteket használva. Ezután következik az adatok centrálása és skálázása. A centrálást (átlag kivonása az adatsorból) változónként végezzük, majd egységnyi hosszra skálázzuk (teljes szórással való osztás) a tulajdonságokat a termékek mentén az 1. és 2. egyenletek alapján (Kroonenberg *et al.*, 2009):

$$\mathbf{x}_{ijk}^{(\text{cent})} = \mathbf{x}_{ijk} - \bar{\mathbf{x}}_{\cdot jk}, \text{ ahol } \bar{\mathbf{x}}_{\cdot jk} = \frac{\sum_{i=1}^n \mathbf{x}_{ijk}}{n}, \quad 1. \text{ egyenlet}$$

$$\mathbf{x}_{ijk}^{(\text{scale})} = \frac{\mathbf{x}_{ijk}}{s_i}, \text{ ahol } s_i = \sqrt{\sum_{j=1}^m \sum_{k=1}^p \frac{(\mathbf{x}_{ijk} - \bar{\mathbf{x}}_{\cdot jk})^2}{m \cdot p}} \quad 2. \text{ egyenlet}$$

Fogyasztói bírálatok során a módszer jól alkalmazható, ugyanis a vizsgálatok során n fogyasztó m tulajdonság alapján értékelt „ p ” terméket. Ezeket az adatokat 3 dimenziós $n \times m \times p$ típusú X adatmátrixba rendezhetjük. A módszer egyike azon dekompozíciós eljárásoknak, amely felbontja az $X = \{\mathbf{x}_{ijk}\}$ adatmátrixot az 3. egyenlet alapján (Harshman, 1970; Harshman és Lundy, 1994; Brereton, 2007):

$$\mathbf{x}_{ijk} = \sum_{r=1}^q \mathbf{a}_{ir} \mathbf{b}_{jr} \mathbf{c}_{kr} + \mathbf{e}_{ijk} \quad 3. \text{ egyenlet},$$


ahol $(i = 1, \dots, n; j = 1, \dots, m; k = 1, \dots, p)$, $X = \{\mathbf{x}_{ijk}\}$ az n fogyasztó által m tulajdonság alapján értékelt „ p ” termékek kedveltségi értékeit tartalmazó $n \times m \times p$ típusú „ X ” adatmátrix. Ahol $\mathbf{a}_{ir}$, $\mathbf{b}_{jr}$ és $\mathbf{c}_{kr}$ az „ A ”, „ B ” és „ C ” komponens (loading) mátrixok elemei, $\mathbf{e}_{ijk}$ a becslés hibái, amelyeket az „ E ” mátrix tartalmaz. Az „ A ” mátrix egy $n \times q$ típusú mátrix, amely a fogyasztók koefficienseit tartalmazza a q komponensekre nézve. A „ B ” egy $m \times q$ típusú mátrix, amely a termékek koefficienseit tartalmazza, a „ C ” mátrix $p \times q$ típusú, amely a vizsgálat tulajdonságok koefficienseit tartalmazza, q pedig a komponensek száma.

Az előnézeti metszetei az „ X ” mátrixnak p db $n \times m$ típusú adatmátrixszal azonosak. A PARAFAC modell mátrixos alakban az előnézeti metszeteket használva a következő (16. ábra, 4. egyenlet):

$$\mathbf{X}_k = \mathbf{A} \mathbf{D}_k \mathbf{B} + \mathbf{E}_k \quad 4. \text{ egyenlet}$$

, ahol $\mathbf{X}_k$ a k -adik előnézeti metszete az „ X ”-nek, „ $\mathbf{D}_k$ ” egy diagonális mátrix, amely a „ C ” mátrix k -adik sorának elemeit tartalmazza a főátlójában, „ $\mathbf{E}_k$ ” pedig a hibatagok $n \times m$ -es mátrixa a k -adik tulajdonságra ($k=1, \dots, p$). Mivel az előnézeti metszeteket bontjuk fel, innen az elnevezés: „szintenkénti faktorelemzés” (PARAFAC). Az előnézeti metszetekben az „ A ” és „ B ” mátrixok

közösek, a felbontásban csak a diagonális mátrixok különböznek. Az előlnézeti metszet a szakirodalomban first mode, azaz első módként szerepel. A fentiekhez hasonló módon létezik a második mód (horizontális metszet), és a harmadik mód (oldaliránti metszet).



16. ábra: A PARAFAC mátrixainak ábrázolása

Mint a hagyományos főkomponens-elemzésben (*principal component analysis*, PCA), itt is az a célunk, hogy megkeressük a legfontosabb információkat az adathalmazból. Ezt úgy érjük el a PARAFAC esetében is, hogy kevesebb számú optimális komponenssel reprezentáljuk mind a fogyasztókat, mind a termékeket, mind a tulajdonságokat. A komponensek olyan értelemben véve nevezhetők optimálisnak, hogy a lehető legnagyobb mennyiséget magyarázzák az adathalmaz varianciájából.

A preferencia-térképek elkészítéséhez ezeket a PARAFAC mátrixokat használjuk fel. A PARAFAC egyik legnagyobb előnye a kialakított komponensek egyedisége. A tradicionálisan alkalmazott PCA során a komponensek forgatása (rotálása) nem változtatja meg a modell illeszkedését, csak a szemléletesebb ábrázolást segíti elő. Ezzel szemben a PARAFAC esetében a modell illesztése jelentősen romlana egy esetleges rotálás után.

4.3. A Tucker-3-modell

A modell nevét Ledyard R. Tucker után kapta, noha már 1927-ben Frank Lauren Hitchcock is foglalkozott a tenzorok (többdimenziós tömbök) felbontásával. A Tucker-3-modell részletesebb tárgyalása előtt a további két kapcsolódó Tucker-modellt (Tucker-1 és Tucker-2) röviden az alábbiak szerint használhatjuk (Kiers, 1991).

A Tucker-1-modell három kibontott mátrixon egyenként végrehajtott főkomponens elemzésből áll, amely így nem veszi figyelembe az adatok háromszempontos jellegét. Az R-project 3.0.2 programcsomag „*ThreeWay*” package segítségével a megadott háromszempontos tömb a T1

paranccsal közvetlenül elemezhető. A tömb egyes mátrixai egymástól függetlenek a Tucker-1 modellben.

A Tucker-2-modell az X tömb egyik módját nem tömöríti. Emiatt a modell csak két komponensmátrixot, ám mégis egy teljes magmátrixot, használ. A Tucker-2 esetében a magmátrixot gyakran kiterjesztett magmátrixnak nevezik. A modell az 5. egyenlettel adható meg:

$$x_{ijk} = \sum_{l=1}^{w_1} \sum_{m=1}^{w_2} a_{il} b_{jm} g_{lmk} \quad 5. \text{ egyenlet}$$

A fenti egyenletben a harmadik módot nem tömörítjük, így csak az „A”, „B” és „G” mátrixok találhatóak benne. A Tucker-2 modell már az adatok háromszempontos felépítését teljesen kihasználja.

A három modell közül a Tucker-3-modell a valódi háromszempontos modell, mivel itt határozottan a három mód faktorai közötti kapcsolatot keressük. Azonban alacsony megfigyelésszám esetében érdemesebb a Tucker-2 modellt használni, mivel ez csak két komponensmátrixot használ. A fogyasztói érzékszervi vizsgálatok esetében azonban a minimum létszám a 60 fő, így a Tucker-3-modell alkalmazása nem ütközik problémába.

A PARAFAC mellett preferencia-térképezésre alkalmazható módszer a PARAFAC általánosításának tekinthető Tucker-3-modell is, amely általában véve jobban illeszkedik az adathalmazra, mint a PARAFAC. A Tucker-3-modell a 6. egyenlettel adható meg (Brereton, 2007):

$$x_{ijk} = \sum_{r=1}^{q_a} \sum_{s=1}^{q_b} \sum_{t=1}^{q_c} a_{ir} b_{js} c_{kt} g_{rst} \quad 6. \text{ egyenlet},$$

ahol ($i = 1, \dots, n$; $j = 1, \dots, m$; $k = 1, \dots, p$), a_{ir} , b_{js} , c_{kt} az ún. „A”, „B” és „C” faktorsúly (loading) mátrixok elemei. A q_a , q_b és q_c a komponensek számai az első, második és harmadik dimenzióban. A g_{rst} egy ún. „G” (mag)mátrix (*core*) elemeit jelöli. A magmátrixon keresztül az összes lehetséges háromtagú interakciót figyelembe vehetjük.

A modell illesztéséhez Harshman egy veszteségfüggvényt definiált, amely az eredeti adatok és a PARAFAC-felbontás közötti eltérést jelenti a következőképpen (7. egyenlet):

$$PRAFAC(A, B, C) = \sum_{k=1}^p (X_k - AD_k B)^2 \quad 7. \text{ egyenlet},$$

amely a hibatagok négyzetösszegét adja. Nincs olyan módszer, amely közvetlenül megadná a legalkalmasabb „A”, „B” és „C” mátrixokat, így a felváltva minimalizáló legkisebb négyzetek módszerét (*alternating least squares*, ALS) használják a veszteségfüggvény minimalizálására, mivel először minimalizálják a veszteséget fix „B” és „C” mátrixokkal, majd fix „A” és „C”, majd fix „A” és „B” mátrixokkal.

A Tucker-3-modell módjainak faktorszámát több módszerrel is megadható, mint például a split-half (Kroonenberg, 2008), keresztellenőrzés (Louwerse *et al.*, 1999), vagy a magyarázott variancia százalékának értékelése (Khayamian *et al.*, 2012).

A Tucker-3- és PARAFAC-modell alapvetően megegyezik a következőkben: mindkettő közvetlenül illeszti a modellt a megfigyelt adatokhoz, nem közvetetten a kovarianciamátrixhoz, illetve a faktorsúlyok mindhárom szempontban hasonlóan értelmezhetők, a faktorok fontosságát fejezik ki az adott szempontban. Emellett a három szempont egyike sem kitüntetett vagy preferált.

A Tucker-3- és PARAFAC-modellek fő különbségei a következők (Kroonenberg, 2008):

- 1 A Tucker-3-modell más „faktor” fogalmán alapul, mint a PARAFAC.
- 2 A Tucker-3-modellben minden faktorkombináció lehetséges.
- 3 A Tucker-3 tartalmaz egy negyedik paramétert is (g_{rst}), ami a faktorok közötti interakciókat tartalmazza. Ezért a Tucker-3 kvadrilineáris és nem trilineáris.
- 4 A Tucker-3-modellben az „A” szempont faktorainak a száma (az A oszlopvektorainak száma) különbözhet a „B” szempont és a „C” szempont faktorainak (komponenseinek, látens változóinak) a számától.
- 5 A Tucker-3 nem rendelkezik a valódi tengely megoldással, de nagyobb a faktorok transzformációjának lehetősége, mint a kétszemponos esetben.

A koncepcionális különbség azt jelenti, hogy a PARAFAC modellben egy faktort a megfigyelt változókon keresztül mérünk, nem az adatok, mérések klasszifikációjának eredménye. A PARAFAC-faktor a három szempont mindegyikére ható látens változó. A Tucker-3-modell faktora viszont az egyes szempontok idealizált eleme, típusa, karaktere. Tucker koncepciójában tulajdonképpen nem a látens faktorok magyarázzák a mérési adatok varianciáját, hanem az egyes szempontok faktorainak interakciói, kölcsönhatásai. Mivel a három szempont szerint a faktorok különbözőek, nem is kell, hogy számuk megegyezzen, szemben a PARAFAC faktoraival, amelyek között az interakciónak nincs értelme, ezért nem is szerepel a modellben a faktorok kapcsolatait kifejező belső struktúramátrix.

A hagyományos kétdimenziós PCA mindig jobban illeszkedik az adathalmazra, mint a PARAFAC és Tucker-3-modellek (3 dimenziós PCA), és a Tucker-3 is jobban illeszkedik, mint a PARAFAC. A PARAFAC egyik legnagyobb előnye, hogy a hiba modellezéséhez sokkal kevesebb szabadságfokot használ fel és ezért az egyik legkorlátozottabb, de egyben legegyszerűbb és legkönnyebben értelmezhető modell is (Bro, 1997). A másik előnye a PARAFAC-modellnek a kialakított komponensek egyedisége. A Tucker-3-modell olyan eredményt adhat, amely esetlegesen

nem elemezhető a PARAFAC-moddal, mivel a Tucker-3 mögöttes feltételezése gyengébb. Azonban néhány esetben a Tucker-3-modell átalakítható a PARAFAC eredményének becslésére (Kroonenberg és Leeuw, 1980). A Tucker-3 hátránya, hogy a modellt nem határozzák meg az adatok. Abban az esetben, ha a Tucker-3 és a PARAFAC hasonló illesztésjóságot ad, a PARAFAC-modell választása a célszerűbb mivel az egyszerűbb és könnyebben értelmezhetőbb eredményt ad.

4.5. Kategória főkomponens-elemzés

A sokváltozós adatelemzés egyik alapvető módszere a főkomponens-analízis, amely a változókat kisebb számú, egymásra merőleges (független), lineáris főkomponensekbe sűríti. Ezek a főkomponensek az adathalmaz információtartalmának minél nagyobb mennyiségét igyekeznek magyarázni. Azonban két fontos hátránya van a PCA-nak. Az első, hogy a változók közti kapcsolatot lineárisnak feltételezi. A második hátrány, hogy eredménye csak akkor értelmezhető helyesen, ha a bemenő változók azonos metrikával mérték (intervallum- vagy arányskála). Sok esetben azonban ezek a feltételek nem teljesülnek, így a PCA alkalmazása nem ad megfelelő eredményt (Linting *et al.*, 2007). A fent említett limitációk kiküszöbölésére egy alternatív, nemlineáris PCA kifejlesztésére volt szükség.

Nominálisnak nevezzük azokat a kategóriaadatokat, amelyek nem rendezett kategóriákból állnak. A nominális kategóriaadatok egyik jó példája a nem, a vallási hovatartozás vagy éppen a nemzetiség. Ilyen esetekben nem használhatóak a megszokott leíró statisztikai mutatószámok, mint például az átlag, összeg, minimum vagy maximum érték. Emiatt a lineáris PCA alkalmazása sem lehetséges, mivel a főkomponensek az eredeti változók súlyozott összegei. A PCA elméleti alapjait az alábbiak alapján fogalmazhatjuk meg. Tegyük fel, hogy $X_1, X_2, \dots, X_p$ jelöli a változókat, az esetek száma pedig 1-től n -ig terjed. Az i -edik változó sajátértékeit az $a_{i1}, a_{i2}, \dots, a_{ip}$ jelölik. A főkomponenseket az alábbi képlet alapján írhatjuk le (8. egyenlet):

$$F_i = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p \quad \text{8. egyenlet,}$$

amely alapján: $a_{i1}^2 + a_{i2}^2 + \dots + a_{ip}^2 = 1$. A korrelálatlan, lineáris főkomponensek (nulla várható értékkel és egy szórással) magyarázott varianciája (σ) a főkomponens sorszámának növekedésével fordítottan csökken ($\sigma(F_1) \geq \sigma(F_2) \geq \dots \geq \sigma(F_p)$).

A rendezett kategóriaadatokról álló változókat hívjuk ordinális változóknak. Sorrendbe rendezhető kategóriák lehetnek egy érzékszervi bírálat során a kedveltség alapján sorba rendezett termékek adatai, vagy akár a Likert-skála értékeit is tekinthetjük ordinális adatnak. Ezeket az adatokat nem minden esetben tekinthetjük folytonosnak, mivel egy 5 pontos skálán (5 – nagyon kedvelem, 4 – kedvelem, 3 – semleges, 2 – nem kedvelem, 1 – nagyon nem kedvelem) az egyes kategóriák közti

távolság nem kvantifikálható. Számszerűen kifejezve, ha két fogyasztó 5-ös és 2-es értéket ad a bírálata során, akkor az nem tekinthető úgy, hogy az egyik bíráló 2,5-szer jobban kedvelte a terméket mint a másik.

A CATPCA eljárás fő célja egy kisebb számú, egymással nem korreláló változókból álló adathalmazt létrehozni, amelyek a lehető legjobban írják le az eredeti adathalmaz variabilitását. Az általánosan alkalmazott PCA lineáris kapcsolatot feltételez a változók között, míg azonban a CATPCA során a változók skálázásával különböző szintek állíthatóak elő bármilyen eloszlást feltételezve (Gifi, 1990). Ezen tulajdonság felhasználásával a CATPCA alkalmassá válik a nemlineáris kapcsolatok többváltozós modellezésére.

A főkomponensek számításakor a lineáris PCA a lehető legnagyobb mennyiségű magyarázott varianciát igyekszik a főkomponensekbe sűríteni. A magyarázott varianciát kifejezhetjük úgy is, hogy a főkomponensek sajátértékeinek összegét elosztjuk a változók számával. A variancia fogalma azonban csak folytonos változók esetében alkalmazható, ezért a lineáris PCA nem futtatható rang vagy kategóriaadatokon. A CATPCA a változók kategóriáit numerikus értékekhez rendeli optimális skálázás során. A kategóriákat numerikusan kódolja minden változó esetében, amely így előteremti a lehetőséget a sztenderd módszerek alkalmazására, mivel ezek az új értékek már rendelkeznek a metrikus változók tulajdonságaival. A skála értékeit iteratív úton határozza meg az algoritmus az alternáló legkisebb négyzet módszer (*alternating least squares*, ALS) alapján (Meulman *et al.*, 2004). Az ilyen értékek tekinthetők a kategóriák számszerűsítésének, egy változó összes értékének számszerűsítése pedig a változó transzformációjának. Az optimális skálázás művelete egy változó kategóriáit oly módon kvantifikálja, hogy a lehető legtöbb magyarázott varianciát megőrizze a változó. A folytonos változókhoz hasonlóan az ilyen átalakított (kvantifikált) változók is hordoznak tradicionális értelemben vett varianciát. A nemlineáris PCA a lineáris PCA-hoz hasonló eredményt ad. Amennyiben a CATPCA folytonos adatokkal fut, úgy az eredmény megegyezik a lineáris PCA megoldásával, mert nincs szükség az optimális skálázásra, így a változókat csak sztenderdizálni kell (Linting *et al.*, 2007).

A lineáris és nemlineáris megközelítés is megadja a sajátértékek, faktorsúlyok (a mérési mutató és a faktor közti korreláció) és szkórok (adott adatpontnak megfelelő transzformált változó érték) értékeit. A magyarázott variancia a nemlineáris esetben is azonos módon számítható, mint a lineáris PCA esetében. Ezek alapján a nemlineáris PCA-val számított főkomponensek is számíthatók, vagyis a főkomponensek tekinthetők az eredeti változók lineáris kombinációinak, a sajátérték pedig azt adja meg, hogy hány változó varianciájának felel meg a komponens által

magyarázott variancia. Az összes előállított főkomponens sajátértékeinek összege megegyezik a változók számával. Amennyiben minden változó minden más változóval erősen korrelál, úgy egy főkomponenst kapunk.

A főkomponensek száma akkor növekszik, ha van legalább két olyan változócsoporthoz, amelyekben belül nagy a korreláció, viszont a két csoport között alacsony. Az egynél több főkomponenst adó megoldásokat többdimenziós megoldásoknak is nevezzük, amikor is a főkomponenseket sajátértékeik alapján rendezzük sorba.

A loadingok számítása során a lineáris PCA esetében a Pearson-féle korreláció számítása a főkomponens és a megfigyelt változó között történik, míg a CATPCA a korrelációt a főkomponens és az optimális skálázás útján kapott kvantifikált változó között végzi. Ha a változó között nemlineáris kapcsolat áll fenn, akkor a nemlineáris PCA magasabb magyarázott varianciaértéket ad. Mindkét módszer esetében az egy komponens változóhoz tartozó loadingok négyzetösszege megegyezik a komponenshez tartozó sajátértékkel. Emellett a nemlineáris PCA eredménye is ortogonálisan rotálható a jobb vizualizáció érdekében.

A két módszer közti legnagyobb különbség az, hogy míg a lineáris PCA közvetlenül a mért változókkal dolgozik, addig a CATPCA egy kvantifikálási lépést is beiktat. A CATPCA számítását SPSS programcsomaggal végeztem. A syntax eredménye azonos a PCA eredményével abból a szempontból, hogy a loadings és a scores plotok is elkészülnek.

4.6. Párkorrelációs módszer

A nemparaméteres párkorrelációs módszert (*pair-correlation method*, PCM) Héberger és Rajkó 2001-ben mutatta be, mint változókiválasztási módszert (Rajkó és Héberger, 2001; Héberger és Rajkó, 2002). Az eredeti PCM-módszer két változó között tett különbséget (Rajkó és Héberger, 2001). Tegyük fel, hogy egy függő változó (Y) tartalmazza egy érzékszervi fogyasztói bírálat során adott kedveltségi értékeket, amelyet további két független változóval (például optimumskálán mért változók, X_1 és X_2) le lehet írni. A PCM a két független változó közül választja ki azt, amelyik a leginkább leírja Y változását.

A PCM-módszert 2002-ben továbbfejlesztette a szerzőpáros, hogy ne csak két változó között tudjon különbséget tenni, hanem több változó esetén is működjön. A módszert általánosított párkorrelációs módszernek (*generalized pair-correlation method*, GPCM) nevezték (Héberger és Rajkó, 2002).


A PCM-módszer nemparaméteres jellege miatt nem igényli a normalitás meglétét. A fenti példát folytatva tegyük fel, hogy az Y függő változóval mindkét független változó (X_1 és X_2 , elemei

i és $j = 1, 2, \dots, N$) pozitívan korrelál. A feladat kiválasztani, hogy a két változó közül melyiknek nagyobb hatása az Y -ra. Vegyük az Y_i vs. X_{1i} és X_{2i} , illetve Y_j vs. X_{1j} és X_{2j} összes elemét (**17. ábra**). Négy alapvető eseményt figyelhetünk meg, amelyeket A , B , C , és D jelölnek. Az A , B , C , és D események (k_A , k_B , k_C és k_D , lásd 5. táblázat) gyakoriságaiból kontingencia táblázat készíthető.

5. táblázat: Az esetek gyakoriságából készített kereszttábla.

	$\Delta X_1 > 0$	$\Delta X_1 < 0$
$\Delta X_2 > 0$	$k_A =$	$k_C =$
$\Delta X_2 < 0$	$k_B =$	$k_D =$

Az A esemény azt jelöli, hogy X_1 és X_2 is erősíti az Y változásait, B esemény azt jelölni, hogy X_1 erősíti, míg X_2 gyengíti az Y változását, C esemény azt jelölni, hogy az X_1 gyengíti, míg az X_2 erősíti az Y -ban a változásokat, végül D esemény azt jelöli, hogy mindkét változó gyengíti az Y változását (**17. ábra**) (Rajkó és Héberger, 2001).



17. ábra: A PCM négy lehetséges kimenetelének grafikus megjelenítése. B és C események gyakoriságát veszi figyelembe a módszer (késsel kiemelve)

A négy lehetséges esemény gyakoriságai egy 2×2 -es kontingencia táblázatba rendezhetők. Ezekből kiszámíthatóak az alábbi különbségek: $\Delta X_1 = X_{1i} - X_{1j}$ és $\Delta X_2 = X_{2i} - X_{2j}$. Ha mindkét különbség (ΔX_1 és ΔX_2) pozitív (vagy mindkettő negatív), akkor X_1 és X_2 között nem lehet különbséget tenni. Ha ΔX_1 értéke (pozitív vagy negatív irányban) szignifikánsan nagyobb, akkor X_1 -et győztesnek nevezzük, ellenkező esetben X_2 -t. Hogy a gyakoriság értéke szignifikánsan nagyobb, azt a megfelelő statisztikai próbával lehet eldönteni. A módszerbe négy tesztet építettek a szerzők: Feltételes F -próba (9. egyenlet), χ^2 -próba (10. és 11. egyenlet), McNemar-próba (12. egyenlet) és Williams-féle t -próba (13. egyenlet) (Conover, 1999). A Williams-féle t -próba paraméteres jellege

miatt került a szoftverbe, főként összehasonlítási célokat szolgál. A fentieket röviden összefoglalva az algoritmus működése a következő egy függő változó (**Y**) és két deskriptor (**X1**, **X2**) esetében:

1. Kiválasztunk egy adatpárt: $y_i > y_j$ $i, j = 1, 2 \dots N$ és $y_i \neq y_j$
2. Kiszámoljuk az alábbi különbségeket: $\Delta X_1 = X_{1i} - X_{1j}$ és $\Delta X_2 = X_{2i} - X_{2j}$. Négyféle eredményt kaphatunk. Ha ΔX_1 és ΔX_2 is pozitív szám, akkor **A**-val, ha ΔX_1 pozitív, ΔX_2 negatív, akkor **B**-vel, ha ΔX_1 negatív és ΔX_2 pozitív, akkor **C**-vel, ha ΔX_1 és ΔX_2 is negatív, akkor **D**-vel jelöljük az adott esetet.
3. A különbségképzést minden adatpárra elvégezzük. Összeszámoljuk az **A**, **B**, **C**, **D** eseteket és kontingenciatáblázatban összegezzük. Az egyes esetek gyakoriságát k_A , k_B , k_C illetve k_D -vel jelöljük (6. táblázat). A kontingenciatáblázatokat statisztikai tesztekkel vizsgáljuk.

A statisztikai tesztek az alábbiak alapján számíthatóak. A jelölések egyértelműsítése érdekében egy példa kontingencia táblázatot mutat be a 6. táblázat.

6. táblázat: Példa 2x2-es kontingencia táblázat.

	X	Y	Sor összegek
Z	$k_A=a$	$k_C=c$	$a+c$
V	$k_B=b$	$k_D=d$	$b+d$
Oszlop összegek	$a+b$	$c+d$	N

Fisher-féle egzakt F-próba:

$$p = \frac{\binom{a+c}{a} \binom{b+d}{b}}{\binom{N}{a+b}} = \frac{(a+c)! (b+d)! (a+b)! (c+d)!}{a! b! c! d! N!} \quad 9. \text{ egyenlet,}$$

ahol a , b , c , d , és n a 6. táblázat alapján számítandó (sz.f. =1, H_0 : a sorok és oszlopok függetlenek).

χ^2 -próba:

$$E = \frac{\text{sorösszeg} \times \text{oszlopösszeg}}{N} \quad 10. \text{ egyenlet,}$$

ahol n a teljes mintaszám, és a számítást a kontingenciatáblázat minden cellájára el kell végezni.

$$\chi^2 = \sum_i \frac{(M_i - E_i)^2}{E_i} \quad 11. \text{ egyenlet,}$$

ahol M a megfigyelt gyakoriság és E az elvárt gyakoriság az i -edik cellára számítva (sz.f. =1, H_0 : a sorok és oszlopok függetlenek).

McNemar-próba:

$$\chi^2 = \frac{(c-b)^2}{c+b} \quad 12. \text{ egyenlet,}$$

ahol b és c a 6. táblázat lapján számítandó (sz.f. =1, H_0 : a sorok és oszlopok függetlenek).

Williams-féle t-próba:

$$t_{N-3} = (r_{12} - r_{13}) \sqrt{\frac{(N-1)(1+r_{23})}{\frac{2(N-1)|R|}{(N-3)} + r^{-2}(1-r_{23})^2}} \quad 13. \text{ egyenlet,}$$

ahol N a megfigyelések száma, r_{12} , r_{13} azon korrelációs koefficiensek, amelyek különbségét teszteljük, r_{23} pedig a két prediktor közti korreláció és $|R|=1-r_{12}^2-r_{13}^2-r_{23}^2+2r_{12}r_{13}r_{23}$ (sz.f. $=N-3$, H_0 : a két populáció korrelációja között nincs különbség).

Általánosított formájában a GPCM minden lehetséges változópárra futtatja a fent leírt algoritmust. Kettőnél több független változó esetén a változókat páronként kell összehasonlítani. Az összevetésnek egy változóra nézve három kimenetele lehet; „győztes”, „vesztes”, illetve „döntetlen”. A győzelmek számát úgy állapítja meg, hogy egyszerűen összeadja az egyes párosítások alkalmával történt győzelmeket, vagyis hányszor volt jobb az egyik változó, mint a többi. Hasonló elven a vereségek száma is kiszámítható az eredményekből. A további értékeléshez három rangsorolási módszer áll rendelkezésre (Héberger és Rajkó, 2002).

Egyszerű rendezésnél (*simple ordering*) a győzelmek száma döntő a rangsorban, különbségrendezésnél (*difference ordering*) a győzelmek számából az algoritmus kivonja a vereségek számát, súlyozásos rendezésnél (*significance ordering*) pedig figyelembe veszi, hogy mekkora mértékű volt a győzelem az egyes összehasonlításokkor, azaz valószínűségekkel súlyozza a győzelmek és vereségek különbségét. A módszer előnye, hogy eloszlásfüggetlen, és akkor is képes különbséget tenni két független változó között, amikor a paraméteres eljárások nem. Hátránya viszont, hogy előrejelzésre nem alkalmazható, és érzékeny a függő változó esetleges kiugró értékeire.

4.6.1. Egyszerű rendezés

A PCM-et le kell futtatni minden lehetséges változópárra. Három kimenet várható (k és l indexek 1, 2, és N értékeket vehetnek fel): (1) az Xl változó jobb, mint az Xk (Xl a győztes), (2) Xk jobb, mint Xl (Xk a győztes, vagy más szavakkal Xl a vesztes). (3) a változók hatásai nem különböznek szignifikánsan, döntetlen.

Egyszerű rangsorolásnál csak a győzelmek számát kell figyelembe venni, vagyis a változók a győzelmeik száma alapján vannak rangsorolva. Azon változók, amelyek egyszer sem nyernek, automatikusan kizárásra kerülnek az elemzésből (Héberger és Rajkó, 2002).

4.6.2. Különbségrendezés

Ennél a GPCM rangsorolási módszernél úgy kell a változókat rendezni, hogy a győzelmek számából ki kell vonni a vereségek számát. Azok a változók, amelyek egyáltalán nem győztek, vagy

a győzelmeik száma alacsonyabb mint a vereségek száma, illetve az egyenlő győzelemmel és vereséggel rendelkezők kizárásra kerülnek.

4.6.3. Súlyozásos rendezés

A PCM-et ebben az esetben is el kell végezni az összes változópárra. A győzelmek és vereségek száma az előzőekhez hasonlóan történik, ám itt a statisztikai módszer által számított konfidencia szinttel ($1-\alpha$) vannak súlyozva. Más szavakkal figyelembe vesszük mekkora mértékű volt a győzelem az egyes összehasonlításokkor, azaz valószínűségekkel súlyozzuk a győzelmek és vereségek különbségét. Így a változók a súlyozott különbségek összege alapján rangsorolhatóak. A kiválasztott változók számát a fentiekkel azonos módon kell számítani. A hibát kivonva a győzelmek és vereségek számából nem lesz egész szám (Héberger és Rajkó, 2002). Ez a rangsorolás a legérzékenyebb a három közül, mivel figyelembe veszi, hogy a győzelmek száma túlsúlyban volt-e. A GPCM ingyenesen hozzáférhető egy Microsoft Excel 2003 VBA makróban és az alábbi linkről letölthető: <http://aki.ttk.mta.hu/gpcm>. A doktori dolgozatomban történő számítások is ezzel a VBA makróval készültek.

4.7. Rangszámkülönbségek összege

A rangszámkülönbségek összege (*sum of rank-differences*, SRD) módszer elvét Héberger (2010), validálását és szoftveres implementálását Héberger és Kollár-Hunek valósította meg (Héberger, 2010; Héberger és Kollár-Hunek, 2011). A módszer nemparaméteres elven működve nem követeli meg a normalitást az adathalmazban. Az SRD-módszer 2013-ig történő alkalmazását Kollár-Hunek (2013) cikkében részletesen bemutatja (Kollár-Hunek és Héberger, 2013).

A Microsoft Excel VBA-n alapuló makró bemeneti formátumként megköveteli az esetek (érzékszervi bírálók, tulajdonságok) sorokba, míg az összehasonlítani kívánt változók (termékek, terméktulajdonságok) oszlopokba történő rendezését. Az összehasonlításhoz négy lehetőség közül lehet választani. Ezeket referenciaértékként kezeli a szoftver, és ezek lehetnek: átlag (Ave), maximum (Max), minimum (Min), vagy beolvasott értékek (Read). A módszer azon alapul, hogy a rangsor minél közelebb van a referencia/sztenderd SRD-értékhez, annál inkább hasonlít a vizsgált változóhoz (modell, bíráló, termék stb.). A következőkben példaként az maximum (Max) referenciaértéket használok fel, mivel az eredmények értékelése során is ezt választottam az optimumváltozók kedveltségére gyakorolt hatásának vizsgálata során. Első lépésben az algoritmus megkeresi esetenként (soronként) a legmagasabb értéket az adattáblában (7. táblázat).

7. táblázat: Maximális érték számítása és a bemenő adattábla.

	OLS	Penalty	bPenalty	GPCM	PLS-dummy	MLR	wPAforJARMean	wPAforGrandMean	Max
Méret+	3,224	3,122	3,122	1,44	3,166	3,243	3,295	3,131	3,295
Méret–	3,23	3,194	3,193	3,162	3,173	3,196	3,257	3,19	3,257
Szín+	3,359	3,296	3,296	3,464	3,178	3,269	3,177	3,151	3,464
Szín–	3,352	3,344	3,343	3,859	3,177	3,329	3,194	3,148	3,859
Íz+	3,427	3,384	3,385	3,008	3,178	3,465	3,232	3,135	3,465
Íz–	3,525	3,303	3,303	3,867	3,188	3,534	3,198	3,121	3,867
Sósíz+	3,2	3,331	3,332	2,45	3,183	3,318	3,318	3,265	3,332
Sósíz–	3,474	3,141	3,14	3,003	3,188	3,359	3,284	2,989	3,474
Vastagság+	3,325	3,278	3,278	3,156	3,175	3,224	3,175	3,154	3,325
Vastagság–	3,337	3,327	3,325	2,836	3,176	3,195	3,202	3,148	3,337
Ragadósság+	3,522	3,323	3,322	3,743	3,192	3,709	3,196	3,125	3,743
Ragadósság–	3,308	3,373	3,373	1,342	3,244	4,36	3,172	3,156	4,36

A következő lépésben a kiszámított maximális értékeket rangsorolja növekvő sorrendben, amely megadja a rang (rnk) értékét. Az rnk alapján sorba rendezi az eseteket a jobb áttekinthetőség érdekében (8. táblázat).

8. táblázat: A rangsor alapján sorbarendeztet esetek.

	Max	rnk	OLS	rnk1	diff1	Penalty	rnk2	diff2
Méret+	3,29	2	3,22442	2	0	3,1223	1	1
Méret–	3,26	1	3,23004	3	2	3,1936	3	2
Szín+	3,46	6	3,35854	8	2	3,2961	5	1
Szín–	3,86	10	3,35158	7	3	3,344	10	0
Íz+	3,46	7	3,42674	9	2	3,3841	12	5
Íz–	3,87	11	3,52465	12	1	3,3029	6	5
Sósíz+	3,33	4	3,20039	1	3	3,3306	9	5
Sósíz–	3,47	8	3,4741	10	2	3,1409	2	6
Vastagság+	3,33	3	3,32504	5	2	3,2777	4	1
Vastagság–	3,34	5	3,3372	6	1	3,3267	8	3
Ragadósság+	3,74	9	3,52156	11	2	3,3227	7	2
Ragadósság–	4,36	12	3,30815	4	8	3,3732	11	1
SRD=					28	SRD= 32		

Az összes változóhoz rangszámot rendel, szintén növekvő sorrend alapján, amelyet rnk_j -vel jelöl (M = változók száma, $j=1,2,\dots,M$, n =esetek száma, $k=1,2,\dots,n$). A transzformált változókból (rnk_j) ezután kivonja az rnk változót (referencia rangsor), amelyet a következőképpen lehet felírni (14. egyenlet):

$$diff_j(k) = abs|rnk(k) - rnk_j(k)| \quad 14. \text{ egyenlet}$$

Az így kapott rangszámkülönbségek ($diff_j(k)$) összegzésével számítható az SRD-értéke változónként, amelyet az alábbi képlet ír le (15. egyenlet):

$$SRD(j) = \sum_{k=1}^n diff_j(k) \quad 15. \text{ egyenlet}$$

A következő lépésben a $SRDmax$ -értékét kell meghatározni az alábbi egyenletek segítségével (16. egyenlet):

$$SRDmax = \begin{cases} 2z^2 & \text{if } n = 2z \\ 2z(z+1) & \text{if } n = 2z+1 \end{cases} \quad 16. \text{ egyenlet}$$


Amennyiben n páros, úgy az első kifejezést használjuk, amennyiben azonban páratlan, úgy a második kifejezést. A z számítása ebből fakadóan páros elemszámnál (17. egyenlet):

$$z = \frac{n}{2} \quad 17. \text{ egyenlet},$$

míg páratlan elemszámnál (18. egyenlet):

$$z = \frac{n-1}{2} \quad 18. \text{ egyenlet}$$

A SRD-módszer validálását 3.000.000 szimulált véletlen számokkal származtatott SRD eloszlással való összehasonlítás (*compare ranks with random numbers*, CRRN), permutációtesztekkel végezték. Kis mintaelemszám esetén az elméleti eloszlás alapján kiszámítottak egy rekurzív algoritmust, amellyel közelíteni lehet az eloszlásfüggvényt. Nagy elemszám esetén ($n > 8$) a normális eloszlás jó közelítésként használható az elméleti (véletlen) SRD eloszlásfüggvényének leírásához. Az SRD-értékek elméleti eloszlásának normál approximációját Héberger és Kollár-Hunek (2011) mutatta be, majd ennek továbbfejlesztését is, amely már az adatokban jelenlévő kötéseket is tudja kezelni (Héberger és Kollár-Hunek, 2011; Kollár-Hunek és Héberger, 2013). Az érzékszervi minősítés során elsősorban a rangsorban levő ismétléseket (kötéseket) is kezelni tudó CRRN alkalmazása a célravezető, mivel az alkalmazott skálák általában szűkek (0-100), illetve sok esetben kategóratermészetűek (5 vagy 7 elemű optimumskálák). Emellett (különösen a fogyasztói tesztek) nagy létszámmal végzik, így a kötések kialakulásának az esélye nagy. Ahogy az n növekszik, a normál eloszlás közelítése annál jobb eredményt ad (**18. ábra**) (Kollár-Hunek és Héberger, 2013).



18. ábra: SRD-eloszlások (kötés nélkül) különböző elemszáma (n), (Forrás: Kollár-Hunek és Héberger, 2013)

Nagy elemszám esetén a közelítés elvégzésekor kiszámítható az SRD_{max} az adott mintaelemszámra. A számítás részleteit Kollár-Hunek és Héberger (2013) munkája alapján mutatom be (Kollár-Hunek és Héberger, 2013). Az ordinátát az alábbi képlet adja meg, amely az SRD-értékek normálását (SRD_{nor}) jelenti (19. és 20. egyenlet):

$$SRD_{nor} = \frac{100 \cdot SRD}{SRD_{max}} \quad 19. \text{ egyenlet}$$

A normáláskor az abszcisszát a


$$dSRD_{nor} = \frac{2}{SRD_{max}} \quad 20. \text{ egyenlet}$$

egyenlet adja meg. A program nagy mennyiségű véletlen SRD-értéket generál egy adott mintaelemszámhoz, és minden egyes SRD-elem a $[0; SRD_{max}]$ intervallumának relatív gyakoriságát értékeli. Ezt követően alakítja ki a közelítő elméleti SRD-eloszlást. A program kiértékeli a relatív gyakoriságok normál becsléseit a Gauss-féle haranggörbe kiinduló paramétereivel (átlag és szórás) és az Excel Solver bővítményével elvégzi a szimulált és a becsült relatív gyakoriságok legkisebb négyzetek szerinti becslését.

Az eredmények ábrázolása előtti utolsó lépésben az $SRD\%$ számítása történik az SRD_{max} és a változók SRD-értéke alapján az alábbi egyenlet alapján (21. egyenlet).

$$SRD\% = \frac{100 \cdot diff1(j)}{SRD_{max}} \quad 21. \text{ egyenlet}$$

Az ezt követő ábrázolás során a normál közelítéshez tartozó értékek a jobb oldali abszcisszán olvashatóak, az $SRD\%$ -értékek a bal oldali abszcisszán és az ordinátán szerepelnek (19. ábra).



19. ábra: Az SRD-módszer eredménye. A sorátlag értékeket alkalmaztuk a referencia oszlopban. A skálázott SRD-értékek láthatóak az x és y tengelyeken, a jobb y tengely a validáció során generált relatív gyakoriságokat mutatja (fekete görbe). Az 5 %-os (XX1), a Median (Med) és a 95 %-os (XX19) valószínűségi értékeket szaggattal jelöltem.

Az SRD-módszert eddig sikerrel alkalmazták módszerek, modellek értékelésére (kromatográfiás oszlopok kiválasztására (Héberger, 2010), érzékszervi panel megbízhatóságának

vizsgálatára (Kollár-Hunek *et al.*, 2008; Sipos *et al.*, 2011), osztályozási algoritmusok összevetésére (Szöllősi *et al.*, 2012), telített észterek gázkromatográfiás retenciós idejének előrejelzésére (D'Archivio *et al.*, 2014). A legfrissebb kutatások során varianciaanalízissel kombinálva alkalmazták genotoxicitás vizsgálatára kagylókban (Héberger *et al.*, 2014), laboratóriumi körvizsgálatok eredményeinek értékelésére (Škrbić *et al.*, 2013), analitikai teljesítményjellemzők vizsgálatára (Carlsen *et al.*, 2015), ligandum alapú mérések kiértékelésére (Moorthy *et al.*, 2015), lipofilicitás vizsgálatára (Andrić és Héberger, 2015) és a szelektivitási és a termodinamikai kötési profilok közti kapcsolat vizsgálatára (Tarcsay és Keserű, 2015). A módszer továbbfejlesztésével kapcsolatosan is jelent meg publikáció (Koziol, 2013), azonban az érzékszervi minősítésben JAR-adatok elemzésére még nem alkalmazták, noha itt is a termékek és módszerek összehasonlítása a cél.

4.8. Túléléselemzés


A módszert olyan vizsgálatokra fejlesztették, amikor egy esemény bekövetkezéséig eltelt idő vizsgálata a cél, amelyet gyakran neveznek túlélési időnek is (Hough *et al.*, 2003). Az élelmiszer-kutatásokban eddig legfőképpen lejárati idő becslésére alkalmazták (Hough és Garitta, 2012). Eredetileg biológiai és orvosi alkalmazásoknál használták, ahonnan a neve is ered. Az orvosi kutatások során a túlélési idő vizsgálata speciális vizsgálati módszereket igényel (pl. két csoport között az idők átlagait nem lehet direkt módon összehasonlítani), illetve a túlélési idő nem normális eloszlású (korlátozó feltétel). A módszer célja a túlélési függvény becslése, illetve az ehhez kapcsolódó szignifikanciavizsgálatok. A túlélési függvény megadja, hogy egy kezdő eseménytől számítva várhatóan hogyan csökken a túlélők aránya az idő függvényében.

Az cenzorálás a hiányzó adatok problémája, amely általánosan előforduló jelenség a túlélés analízisben. Ha csak az ismert, hogy az esemény mi után következett be, akkor jobbra cenzorálás történik. Jobbra cenzorálás fordul elő akkor is, amikor a kezdőpont ismert, de az alany nem fejezi be a vizsgálatot. Ha az esemény hamarabb következik be, mint egy bizonyos időtartam, akkor balra cenzorálás történik (Kleinbaum és Klein, 2005). Túlélési függvényt a leggyakrabban a Kaplan-Meier eljárás (*Kaplan–Meier product–limit estimate*, KM) alapján készítik. A KM-eljárás során a feltételes valószínűségek szorzatát kell számítani a 22. egyenlet alapján:

$$P(T \geq t_i) = P(T \geq t_i | T \geq t_{i-1}) = P(T \geq t_i | T \geq t_{i-1}) \cdot P(T \geq t_{i-1} | T \geq t_{i-2}) \cdot \dots \cdot P(T \geq t_0) = \prod_{j=1}^i \left(1 - \frac{d_j}{n_j}\right) \quad 22. \text{ egyenlet,}$$

ahol T a túlélési idő, $t_1, t_2, \dots, t_i$ adja az időpontokat, ahol a vizsgált esemény bekövetkezését megfigyelik, d_j adja a t_j időpontban bekövetkezett események számát, n_j pedig a t_j időpontban azon egyedek számát adja meg, akiknél az esemény még bekövetkezhet (Balogh *et al.*, 2006). Az így kapott

eredményeket ábrázolva adható meg a túlélési függvény (jellegzetes lépcsős függvény). Az üdítőital-termékek döntési idejére a következő Kaplan-Meier túlélési függvényt határoztam meg **20. ábra**.



20. ábra: A négy üdítőital-termék túlélési függvénye Kaplan-Meier módszerrel ábrázolva (saját elemzés). Az egyes résztvevőket körökkel jelöltem, a döntés meghozatala jelenti a „túlélést”. Cenzorálás nem történt, mert minden résztvevő a teljes vizsgálaton részt vett és jelezte választását.

Az elemzés során azt vizsgáltam, hogy az üdítőital termékek esetében hogyan változott az egyének válaszadási ideje. A görbe a 0. időponttól indul, ez jelzi a megfigyelés kezdetét. Ebben az időpontban természetesen még egyik résztvevő sem döntötte el, hogy melyik terméket választja, így a függvény maximális értékű, azaz 1 (vagy 100%). Az első választás a második másodpercben történik, az utolsó pedig a 23. másodpercben. Valahányszor egy esemény bekövetkezik (egy-egy résztvevő döntést hoz), a függvény értéke csökken, amelyet a „o” jel jelez a grafikonon. A görbén a T jel jelzi, hogy nem következett be a vizsgált esemény (cenzorált). A KM módszer során ezen felül különböző egyváltozós leíró statisztikai információk is megadhatók az adathalmazról (medián, túlélési idő stb.) és a görbék lefutását is össze lehet vetni a termékek közti különbségek meghatározására.

Az így kapott túlélési görbék összehasonlítása az alábbi módszerekkel tehető meg (Machin *et al.*, 2006):

- *Általánosított (generalizált) Wilcoxon-teszt*: a korai események nagyobb súlyt kapnak.
- *Mantel–Cox-teszt*: egy exponenciális szkór- teszt. Lényegében egy log–rank teszt.
- *Breslow-teszt*: a korai megfigyeléseket súlyozza, kevésbé érzékeny a későbbi eseményekre.
- *Tarone–Ware-teszt*: a Breslow- és a Mantel–Cox-teszt között helyezkedik el. Az eseményeket közepesen súlyozza.
- *Peto–Prentice-teszt*: az általánosított Wilcoxon-teszttel analóg.
- *Log-rank-teszt*: a két csoport közötti mortalitási arány egymás konstans-szorosa.

A fenti módszerek közül a leginkább elterjedt módszerek a Cox-regresszióval történő függvény-összehasonlítás, illetve az általánosított Wilcoxon-tesztek (Allison, 1995). A túléléselemzést a Statistica 12.0 programcsomaggal (Statsoft Inc. Tulsa, OH, USA) végeztem.

4.9 A szemkamerás mérés módszertana

4.9.1 Vizuális ingerek

Kilenc eltérő élelmiszertípus vizsgálatát hajtottunk végre. Az egyes élelmiszertípusokon belül négy termékalternatívát mutattunk be a résztvevőknek. Az első terméktípust bemelegítésként alkalmaztuk (sütötök minták), hogy a résztvevők megismerkedhessenek a feladattal és a szemkamerás méréssel. Ez a bemelegítő feladat nem szerepelt a későbbi adatértékelés során, így összesen nyolc terméktípusra rögzítettük az eredményeket. Ezek a terméktípusok az alábbi termékcsoportokból álltak: alma, üveges sör, csokoládé, instant levespor, saláta, virsli és üdítőital (**21. ábra**).



21. ábra: A nyolc vizsgált termékcsoport, termékcsopontonként négy-négy termékkel. A bal felső sarokból indulva: alma, üveges sör, kenyér, csokoládé, instant levespor, saláta, virsli és üdítőital.

Minden termékcsoport esetében a négy terméket úgy rendeztük el, hogy a képernyő közepe szabad maradjon. Erre azért volt szükség, mert az egyes termékcsoportok között egy fekete „+”, ún.

fixációs kereszt jelent meg a képernyő közepén. A fixációs kereszt segítségével sztenderdizáltuk a résztvevők szemmozgásának kezdőpontját, így mindenki ugyanarról a pontról kezdte a termékek vizsgálatát.

Az egyes termékek képeinek kiválasztására 40 főből álló fogyasztói panelt kérdeztünk meg egy előteszt keretében. A 40 fős panel tagjai a főtesszt tagjaihoz hasonló kor és nem eloszlású volt (18 és 28 év közötti hallgatók, azonos nem eloszlásban). Az előteszt során a küllemet, a termék ismeretét és a kedveltséget értékelték a résztvevők. A több lehetőség közül végül azt a négyet választottuk a főtesszthez, amelyet hasonló mértékben ismertek és kedveltek a fogyasztók. Különös hangsúlyt fektettünk a felhasznált képek megfelelő minőségére, a termékek azonos megvilágítására és a képek méretére (felbontására). Az elrendezésből eredő hatások kivédése céljából a termékeket véletlenszerűen helyeztük el az egyes résztvevők között, mivel az irodalmi adatok alapján általában a bal felső terméket vizsgálják meg a résztvevők először (Reutskaja *et al.*, 2011).

4.9.2 Résztvevők

A bécsi BOKU (*University of Natural Resources and Life Sciences Vienna*) 78 hallgatója vett részt a tesztekben (18 és 28 év közötti hallgatók, 39 férfi és 39 nő). A 78 résztvevő közül 19 esetben szembesültünk adatrögzítési problémákkal, így ezeket az eredményeket nem használtuk fel az adatelemzésben. Kilenc résztvevő esetében a szemkamera rögzítési minősége nem volt megfelelő, amelynek oka elsődlegesen az lehetett, hogy a vizsgálat közben a Tobii T60 szemkamera rögzítési tartományán kívülre mozdították fejüket, illetve lehetett szemüveg okozta fényvisszaverődés is. Hat résztvevő sikertelenül jelölte meg a választott terméket, akik közül négyen a döntés meghozása után hosszasan, több terméket is megvizsgáltak illetve két résztvevő a termékek kiválasztása során két termék közé kattintott és nem a kiválasztott termékre. Összesen négy résztvevőnek okozott problémát az instrukciók követése. Végül 59 hallgató (18 és 28 év közötti 29 férfi és 30 nő) adatait fogtuk el az adatelemzéshez.


A kutatás során a BOKU tudományetikai előírásait követtük. A vizsgálatok előtt minden résztvevővel ismertettük a szemkamerás mérési módszer alapjait és felhívtuk figyelmüket, hogy szemmozgás adatik rögzítésre kerülnek. Továbbá biztosítottuk őket, hogy akár indoklás nélküli kérésükre is töröljük az értékeléseiket. Minden résztvevő beleegyezett a kísérletben történő részvételbe.

4.9.3. Szemkamerás mérési módszer

Tobii T60 szemkamerát és Tobii Studio (version 3.0.5, Tobii Technology AB, Sweden) adatfeldolgozó szoftvert alkalmaztunk a kutatás során a 78 résztvevő szemmozgás adatainak

rögzítésére és feldolgozására. A statikus szemkamera kijelzőjén (17 col, 1280 × 1024 képpontos felbontás) jelenítettük meg a vizuális ingereket adó képeket. A kísérlet ellenőrzött körülmények között (világítás, hőmérséklet), csendes környezetben zajlott a BOKU Élelmiszer-tudományi és – technológiai Tanszékének Érzékszervi Minősítő Laboratóriumában (*Sensory Laboratory of the Department of Food Science and Technology at the University of Natural Resources and Life Sciences, Vienna*).

A „több alternatívás kötelező választás” (*Four Alternative Forced Choice, 4-AFC*) eljárást követtünk, amely során nem határoztunk meg időlimitet. A teszt megkezdése előtt a résztvevők helyet foglaltak a szemkamera monitorja előtt, ügyelve arra, hogy szemük nagyjából 70 cm-es távolságban legyen a monitortól. A vizsgálat során nyugalmi állapotban szemlélték a bemutatott képeket, közben domináns kezüket az egéren tartva. Külön felhívtuk figyelmüket, hogy a vizsgálat során ne változtassák testhelyzetüket. A sikeres kalibrációt követően instrukciókat tartalmazó szöveget olvastak a monitoron, amelyben részletesen megismerkedtek a vizsgálat menetével (a részletes folyamatábrát a **22. ábra** mutatja be). A vizsgálat során időkorlát nélkül megvizsgálták a bemutatott termékeket, majd kiválasztották a nekik leginkább tetszőt. A feladatok előtt és között, egy fekete „+” jel volt látható a monitor közepén 3 másodperc hosszan. Ennek segítségével sztenderdizáltuk a figyelem kezdőpontját. Ezt követően az első választási feladat volt látható a képernyőn addig, amíg a résztvevő meg nem hozta döntését. A döntés meghozatalát a bal egérrel történő kattintással jelezte. A kattintás után az eddig nem látható egér megjelent a képernyőn egy szöveggel együtt, amelyben arra kértünk mindenkit, hogy az egérrel klikkeljen az általa leginkább kedvelt termékre. Az adatértékelés során csak az első szakasz szemmozgás adatait dolgoztuk fel, amíg a kurzor nem volt látható. Emellett kiszűrtük azokat a résztvevőket is, akiknek több mint 2 másodpercre volt szüksége kiválasztani a terméket, illetve azokat is, akiknél az egér mozgása arra utalt, hogy más termékeket is megvizsgált és hezitált. Ezzel biztosítottuk, hogy a döntéshozatal (első kattintás) és a döntés kifejezése (második kattintás) között ne változtassa meg a döntését. A folyamatot részletesen bemutattuk a résztvevőknek a vizsgálat előtt. A bemelegítő lépésben szereplő döntési helyzetről kapott eredményeket nem vettük bele a későbbi adatelemzésbe. A feladatok végeztével szocio-demográfiai kérdések következtek (nem, kor stb.).



22. ábra: A vizsgálat folyamatábrája az alma termék példáján szemléltetve. A döntési szakasz szemmozgás adatai kerültek kiértékelésre, időlimit nem volt megszabva.

4.9.4. Statisztikai elemzés

Az adatokat Tobii Studio szoftverrel (version 3.0.5, Tobii Technology AB, Sweden) rögzítettük. Az egyes termékekhez tartozó szemmozgást leíró változókat exportálás után IBM SPSS Statistics 20 (IBM Corporation, Armonk, USA) szoftverrel elemeztük. A választási gyakoriságok (vagyis ahányszor a terméket a fogyasztók kiválasztották) elemzéséhez χ^2 -próbát alkalmaztunk. Az adatokat ismételt mérések varianciaanalízis (*repeated measures analysis of variance*, RMANOVA) segítségével értékeltük. Független változóként az első fixációig eltelt időt (*time to first fixation – TTFF*), első fixáció hosszát (*first fixation duration – FFD*), fixációk hosszát (*fixation duration – FD*), fixációk számát (*fixation count – FC*), látogatások hosszát (*total dwell duration – DD*) és a látogatások számát (*dwell count – DC*) határoztuk meg, míg fix faktorként (*between subjects effect*) a terméket, az ismétlés faktoraként (*within subjects effect*) a választott terméket. Binomiális-próbát alkalmaztunk az utolsó fixáció helye (*last fixation – LF*) és a választott termék összehasonlítására. Lineáris diszkriminanciaelemzés (*linear discriminant analysis*, LDA) segítségével jeleztük előre a választott terméket az alábbi változók adataiból: FC, DD, DC és LF.

5. Eredmények

5.1. Háromszempontos modellek alkalmazása

5.1.1. Belső preferencia-térképek megalkotása PARAFAC- és TUCKER 3-módszerekkel

A külső és belső preferencia-térképek megalkotására általánosan alkalmazott eljárások (PCA, PLS, CVA) olyan esetekben alkalmazhatóak, amikor az adatok mátrixalakba rendezettek. Az érzékszervi minősítés gyakorlatában azonban egyre gyakrabban fordulnak elő olyan kutatások, amelyekben műszeres eredmények is rendelkezésre állnak a humán érzékszervi adatok mellett. Ez különösen a külső preferencia-térképek létrehozásakor jelentett adatfeldolgozási kihívást, ebben az esetben ugyanis a termékeket egy szakértői és egy fogyasztói bírálói panel is vizsgálta, és ezenfelül állnak rendelkezésre a különböző műszeres adatok. Belátható, hogy az összes adattábla PCA vagy éppen PLS elemzése külön-külön nem biztosít lehetőséget arra, hogy a rendelkezésre álló eredmények egymásra irányuló hatását is vizsgálni tudjuk.

A szakértői-, fogyasztói- és műszeres adatok közös elemzése, három-szempontos adatelemzési módszerek alkalmazásával egy újfajta megközelítést jelent. A PARFAC- és Tucker-3-modellek az ilyen jellegű problémák megoldását támogatják, azonban megfelelő alkalmazásukhoz néhány akadály leküzdése szükséges.

Alapvetően a PARFAC- és Tucker-3-modellek a PCA általánosításának tekinthetők, viszont a PCA-val ellentétben háromdimenziós mátrixokon alkalmazható módszerek. A háromszempontos adatelemzés segítséget nyújt a termékek, terméktulajdonságok és bírálók közötti hasonlóságok és különbségek feltárására. Az eredményeket két- vagy háromdimenziós pontdiagramban szemléletesen lehet ábrázolni.

Munkám során a PARAFAC- és Tucker-3-modellek alkalmazhatóságát vizsgáltam csemegekukorica-fajták háromszempontos preferencia-térképeinek létrehozására, amelyben szakértői érzékszervi, fogyasztói érzékszervi, illetve műszeres mérési eredményeket integráltam. A fő hangsúlyt a két vizsgált módszer hasonlóságainak és különbözőségeinek feltárására helyeztem. A kutatás során vizsgált csemegekukorica-termék preferencia-térképe eddig egyedülálló a nemzetközi szakirodalomban.

A két modell validálására a rendelkezésre álló felosztási módszerek közül a Harshman és Lundy által javasolt split-half módszert alkalmaztam (Harshman és Lundy, 1994). A két részre osztást kétféleképpen is elvégeztem, amelyek közül az egyik osztási mód (split-half1) szerint egyszerűen feleztam az adathalmazt az elemszám felénél, a másik osztási mód (split-half2) szerint a páratlan

sorszámú fogyasztókat az első csoportba, míg a páros sorszámú fogyasztókat a második csoportba soroltam. A két modellt az R-project R 3.0.2 verziója alatt futó PTak package segítségével illesztettem. Mindkét modellt a teljes adathalmazra és a két splithalf-módszer szerint felosztott adathalmazokra is illesztettem. A PARAFAC esetében az illesztés eredményét a 9. táblázat tartalmazza.

9. táblázat: A PARAFAC-modell illesztése a két módszerrel szétbontott adathalmazra és a teljes adathalmazra.

	splithalf 1		splithalf 2		Teljes adathalmaz
Korrigált R ² (%)	1. rész 89,86	2. rész 90,89	1. rész 91,71	2. rész 90,22	90,70
Faktor	Magyarázott variancia (%)				
1	89,35	90,42	91,11	88,87	88,84
2	40,31	27,27	54,5	71,41	62,25
3	14,30	23,27	7,74	66,43	24,95
F-statisztika	2837**	3195**	3540**	2952**	6243**

** $p < 0,01$

A 9. táblázat alapján látható, hogy a különböző módon részekre darabolt fogyasztói mintákra illesztett PARAFAC-modell magyarázó ereje stabilnak tekinthető. Az első kialakított faktor magyarázó ereje igen magasnak adódott (90 % körüli értéke alakult), és az első két faktor tekinthető jelentősnek az adathalmaz jellemzésében. A Tucker-3-modell validálása és a magmátrix (*core matrix*) megbízhatóságának vizsgálata a splithalf 1 és 2 szerinti futtatások alapján kapott magmátrixok és a teljes adathalmazra futtatott Tucker-3-modell magmátrixának elemenkénti összevetésével történt. Vizsgáltam továbbá az összesen magyarázott varianciarányadot, amelynek értéke minden futtatás során (splithalf 1 és 2) 92 % körül ingadozott, valamint az összes adatot figyelembe véve az korrigált R² értéke 90,70 %-nak adódott.

A nem megfelelő eredmények elkerülése érdekében konvergenciakritériumot és szigorú előkészítést hajtottam végre. Konvergenciakritériumnak az illesztés relatív csökkenését választottam, amelyet 10⁻⁶ értékűnek adtam meg, míg a maximális iterációszámot 1000-re állítottam. A PARAFAC A, B és C mátrixaiból kialakított minden komponens kombinációjára kiszámítottam a Bro (1997) által javasolt hármaskoszinusz (*triple cosine*, TC) mérőszámot (23. egyenlet) az alábbiak alapján:

$$TC_{ij} = \cos(a_i, a_j) \times \cos(b_i, b_j) \times \cos(c_i, c_j) \quad 23. \text{ egyenlet,}$$

ahol $i, j = 1, 2, 3$ és $i \neq j$, a_i, a_j, b_i, b_j, c_i és c_j az „A”, „B” és „C” komponens (*loading*) mátrixok oszlopai. Az eredmények alapján az azonos módban található faktorsúly (*loading*) vektorok nem

korrelálnak erősen, valamint megfelelő a PARAFAC-megoldás eredménye is ($TC_{12}=-0,117$, $TC_{13}=0,012$, $TC_{23}<0,001$) és Tucker-3 ($TC_{12}=-0,121$, $TC_{13}=-0,004$, $TC_{23}<0,001$).

A *B* és *C* mátrixok elemzése jól magyarázza a későbbiekben bemutatott tri- és biplotok (három és kétdimenziós pontdiagramok) kialakulását. A 9. táblázat és a 10. táblázat az összehasonlítás kedvéért tartalmazzák a kétszemponos PCA eredményeit is, így a módszerek közti hasonlóságok és különbségek jobban kiemelkednek. (A kétszemponos PCA számítása az R 3.0.2. verziójának, stats package prcomp függvényével történt.) A *C* mátrix elemei mindkét háromszemponos módszer esetében azonosnak adódtak, ezért a PARAFAC megoldását a 10. táblázat mutatja be.

10. táblázat: Faktorsúly-mátrix (*B*) és PCA-faktorsúlyok*

	PARAFAC			Tucker-3			Kétszemponos PCA		
	1.faktor	2.faktor	3.faktor	1.faktor	2.faktor	3.faktor	1.faktor	2.faktor	3.faktor
Állomány	0,369	-0,093	0,542	0,400	-0,066	0,639	0,528	-0,203	0,644
Illat	0,166	<u>-0,544</u>	<u>-0,808</u>	0,148	<u>-0,170</u>	<u>-0,732</u>	0,525	0,132	<u>-0,727</u>
Íz	<u>-0,856</u>	0,815	0,036	<u>-0,852</u>	0,803	-0,114	0,494	<u>-0,607</u>	-0,109
Megjelenés	0,321	-0,178	0,229	0,304	<u>-0,567</u>	0,207	0,447	0,757	0,212

*a dőlttel jelzett értékek pozitív, az aláhúzással jelzett értékek negatív hatást jeleznek. A nulla közeli faktorsúlyok halvány szürkével jelöltek.

A PARAFAC-modell alapján az első faktor negatív töltöttségét az íz adja meg, amely egyben a legfontosabb szempontnak adódott a fogyasztók számára (10. táblázat). A faktor pozitív irányát az állomány és megjelenés tulajdonságok határozzák meg. Az első faktor tehát az íz tényezőt különíti el a másik három tényezőtől, de leginkább a megjelenéstől és az állománytól. A másodlagosan diszkrimináló faktor az adott ízt preferálók körében tesz különbséget az illat alapján. A harmadlagosan befolyásoló faktor elsődlegesen az állományt különbözteti meg az illattól. A PCA és a PARAFAC harmadik faktora majdnem azonosnak adódott, míg a PCA második faktora a PARAFAC első faktorával azonos azzal a kivétellel, hogy az ízt főleg az állománytól különíti el. A második PARAFAC-faktor nem feleltethető meg egyetlen PCA faktornak sem. A PCA első két faktora csupán 51,29 % és 20,53 % varianciát magyaráz, az első három pedig összesen 87,48 %-ot. A Tucker-3 és a PARAFAC eredményei nagyon hasonlóak az első és a harmadik faktor tekintetében. A fő különbség a második faktor esetében jelentkezik, ahol is a Tucker-3 megoldása az íz paramétert a megjelenéstől különíti el és nem az illattól, mint a PARAFAC esetében. A különbség oka módszertani okokra vezethető vissza, miszerint a Tucker-3-modell nem állít elő egyedi faktorokat, és a megoldás során az összes lehetséges faktorkombináció szerepel a modellben. Ezzel szemben a PARAFAC egyedi megoldást készít, azaz nincs szükség egy további rotálásra (nem úgy, mint a PCA-alapú modelleknél). A két módszer szerint számított *C* mátrixok elemei azonosak voltak (11. táblázat).

11. táblázat: Faktorsúly-mátrix (C) és PCA-faktorsúlyok*.


	PARAFAC			Kétszemponos PCA		
	1.faktor	2.faktor	3.faktor	1.faktor	2.faktor	3.faktor
Turbo	0,350	<u>-0,455</u>	<u>-0,084</u>	0,471	<u>-0,217</u>	0,018
Legend	0,342	<u>-0,414</u>	0,066	0,395	<u>-0,306</u>	0,094
Madonna	0,210	<u>-0,470</u>	0,195	0,272	<u>-0,593</u>	<u>-0,134</u>
Rebecca	<u>-0,029</u>	0,413	0,184	<u>-0,477</u>	0,006	<u>-0,372</u>
Jumbo	<u>-0,238</u>	0,130	<u>-0,565</u>	0,122	0,471	<u>-0,463</u>
GSS 8529	<u>-0,452</u>	0,240	0,310	<u>-0,346</u>	0,086	0,513
Overland	<u>-0,560</u>	0,309	0,455	<u>-0,431</u>	0,034	0,557
Spirit	0,376	<u>0,246</u>	<u>-0,551</u>	0,007	0,528	<u>-0,213</u>

* Az aláhúzással jelzett értékek negatív hatást jeleznek. A nulla közeli faktorsúlyok halvány szürkével jelöltek.

Az első faktor pozitív töltöttségét a Turbo, Legend, Madonna és Spirit termékek adják, a negatív töltöttségét pedig elsősorban a GSS 8529 és az Overland termékek (11. táblázat). Az első faktorról pozitívan korreláló termékeket elsősorban állományuk alapján kedvelik a fogyasztók, a negatívan korrelálókat pedig elsősorban ízük miatt.


A második faktor negatív töltöttségét a Turbo, Legend, Madonna termékek adják, a pozitív töltöttségét pedig a szuperédes Overland, GSS 8529 és Rebecca fajták. A másodlagos tényező az illat (10. táblázat), amely a Turbo és Legend, valamint Madonna fajtákhoz köthető. A modellek A, B és C mátrixai alapján elkészíthetők a termékek belső preferencia-térképei is egy triplotban külön a PARAFAC (23. ábra) és külön a Tucker-3 (24. ábra) modell alapján. A triplotok alapján látható, hogy a fő különbség a fogyasztói paraméterek elhelyezésében jelenik meg, ahol az illat paraméter a Tucker-3-modell alapján kevésbé hangsúlyos.

A 10. táblázat alapján látható, hogy a PCA faktorai a PARAFAC-hoz képest kissé eltérnek. A 10. táblázat és a 11. táblázat bemutatja, hogy a PARAFAC nagyobb mennyiségű varianciát magyaráz, mint a PCA, illetve a faktorok jelentése is némileg eltér. Az összehasonlítás céljából metrikus és nem metrikus többdimenziós skálázást (*multidimensional scaling*, MDS) is alkalmaztam, mivel a PARAFAC-CANDECOMP-modell MDS típusú. Az eredmények erősen függtek az alkalmazott modelltől (metrikus – nem metrikus), az adatelőkészítéstől (-1 és 1 közé történő transzformálás vagy sztenderdizálás 1-es szórásra stb.) és a távolságmértéktől. Metrikus és nem metrikus MDS esetén is a PCA-val azonos megoldást kaptam mindhárom faktorra az Euklideszi távolság és a [-1,1] intervallumba történő skálázással.



23. ábra: A PARAFAC triplotja (belső preferencia-térkép). A triplotban mindhárom mód eredményei láthatóak (fogyasztók, tulajdonságok és fajták).

A Tucker-3 magmátrixának elemzése megmutatja, hogy a módok első faktorai (A , B és C mátrixok, első oszlop) a variancia 97,59 %-át magyarázzák. A második legfontosabb faktorkombináció az utolsó két mód két faktora (B és C mátrixok, második oszlop) és az első mód első faktora (A mátrix, első oszlop). Ez a kombináció 61 %-ot magyaráz. A B és C mátrixok második oszlopa alapján a Turbo, Legend és Madonna fajták a megjelenés alapján köthetőek össze (11. táblázat).




24. ábra: A Tucker-3-modell triplotja (belső preferencia-térkép). A triplotban mindhárom mód eredményei láthatóak (fogyasztók, tulajdonságok és fajták). A PARAFAC-ábrához (23. ábra) képest a megjelenés és illat elhelyezkedésében látható különbség.


5.1.2. Külső preferencia-térképek megalkotása PARAFAC- és Tucker-3-módszerekkel

A PARAFAC és Tucker-3-modellek külső preferencia-térképeit a 25. és 26. ábrák mutatják be. A Tucker-3-modell szerinti külső preferencia-térképen az első dimenzióban az íz különül el elsősorban az állománytól, a második dimenzióban pedig a megjelenéstől illetve illattól. Az illat azonban a fogyasztók szempontjából nem releváns. A szuperédes GSS 8259, Rebecca és Overland fajták elsődlegesen az ízük alapján különültek el a többi fajtától. A Jumbo, Legend és Madonna fajtákat elsősorban az állomány, sós íz és megjelenés alapján különítették el a szakértő bírálók. A

fogyasztókat egyértelműen az íz és az állomány/megjelenés befolyásolja a leginkább, amely a fogyasztói klaszterek elhelyezkedéséből látható.



25. ábra: A PARAFAC modell külső preferencia-térképe az érzékszervi és műszeres adatok integrálásával.



26. ábra: A Tucker-3-modell külső preferencia-térképe az érzékszervi és műszeres adatok integrálásával. A PARAFAC-ábrához (25. ábra) képest a megjelenés és illat elhelyezkedésében látható különbség.

Látható, hogy a PARAFAC és a Tucker-3-modellek alapján készített külső preferencia-térképek némileg különbözöek. Ennek elsődleges oka a két módszer szerint eltérő fogyasztójellemző adatok számításában rejlik. Mindkét módszer elsődleges fogyasztói döntést befolyásoló tényezőként (driverként) azonosítja az ízt mint a többitől eltérő tényezőt. A másodlagos fogyasztói döntést befolyásoló tényező a PARAFAC szerint az illat, Tucker-3 szerint a megjelenés (11. táblázat, második faktor).

A Tucker-3-modell alapján az állomány és az íz a két legfontosabb paraméter, a második helyen a megjelenés található, míg az illat paraméter semleges. A PARAFAC-modell eredményeit részletesebben is elemeztem. A bemutatott ábrákon (25. ábra és 26. ábra) egy k -közép klaszterezés alapján létrehozott négyklasztteres megoldás látható. A klaszterezés eredményeinek validálásához hierarchikus klaszterezést is végrehajtottam Euklideszi távolsággal és Ward-metrikával, illetve a legközelebbi szomszéd módszert is futtattam négyzetes Chord-távolsággal. A fogyasztók mintegy 90 %-a mindhárom klaszterezés alapján azonos csoportba esett. A 12. táblázat mutatja be a létrehozott klaszterek főbb karakterisztikáit.

12. táblázat: A kutatás során létrehozott klaszterek főbb karakterisztikái.

Klaszter	A fogyasztók						
	átlagos kora (év)	neme (%)		saját maguk hozzák döntéseiket (%)	átlagos fogyasztási gyakorisága	nettó jövedelme (%)	
		Férfi	Nő			< 150 eFt	150 eFt<
1	20,7	47,1	52,9	52,9	havonta	35,3	64,7
2	23,9	80	20	33,3	havonta	86,7	13,3
3	23,3	53,8	46,2	38,5	kéthetenként	76,9	23,1
4	21,9	60	40	53,3	kéthetenként	86,7	13,3

1. Az első klaszterbe 17 fogyasztó került (a nemek aránya közel azonos). Ezen klaszter tagjai magasabb nettó jövedelemmel rendelkeznek, mint a többi klaszter tagjai, amelyet a χ^2 -próba is bizonyít ($\chi^2 > 138,66$; sz.f. = 1; $p < 0,001$). Azon fogyasztók aránya, akik saját maguk hozzák meg a vásárlással kapcsolatos döntéseket szintén nagyobb ebben a klaszterben a második és harmadik klaszterhez viszonyítva ($\chi^2 = 17,36$ és $9,36$; sz.f. = 1; $p < 0,001$ és $p = 0,008$). Átlagosan havonta fogyasztanak csemegekukoricát (medián=4 a kilenctagú skálán). A klaszter tagjainak átlagos életkora szignifikánsan alacsonyabb, mint a másik két klaszterben, amelyet Mann–Whitney U-próbával ellenőriztem ($Z = -2,794$ és $-2,085$; $p = 0,005$ és $p = 0,037$).

2. A második klaszterben (15 fogyasztó) a legnagyobb a férfiak aránya, és a legalacsonyabb a saját döntést hozók aránya. A nemek arányának χ^2 -próbája szignifikánsnak adódott ($\chi^2 > 180,66$; sz.f. = 1; $p < 0,001$).
3. A harmadik klaszter tagjai (13 fogyasztó) kéthetente fogyasztanak csemegekukorica terméket. A nemek aránya kiegyenlített, azonban a saját döntést hozók aránya alacsony.
4. A negyedik klaszter tagjai (15 fogyasztó) szintén kéthetente fogyasztanak csemegekukorica-termékeket, és szignifikánsan nagyobb a férfiak aránya ebben a klaszterben mint az egyes és hármas klaszterben ($\chi^2 = 10,64$ és 190 ; sz.f. = 1; $p = 0,007$ és $p < 0,001$). A klaszter tagjai nagyobb arányban hoznak saját maguk döntést, mint a második és harmadik klaszter tagjai ($\chi^2 = 17,61$ és $9,57$; sz.f. = 1; $p < 0,001$ és $p = 0,005$).

A PARAFAC első kvadránsában az elsődleges paraméter az állomány és a megjelenés (Madonna, Legend és Jumbo), míg az íz másodlagos. Az első kvadráns a második fogyasztói klaszterrel állítható összefüggésbe.

A második kvadránsban az íz az elsődleges az állománnyal és megjelenéssel szemben (GSS 8529 és Legend). A második driver az ízzel szemben az illat. A szuperédes fajták között az illatuk alapján volt különbség, mivel a GSS 8529 elkülönült a Rebecca és Overland fajtáktól. A második kvadránsba a negyedik klaszter tagjai esnek.


A Rebecca és Overland fajták a harmadik kvadránsban találhatóak, ahol az elsődleges driver az íz, míg a másodlagos az illat. Ebbe a kvadránsba esnek az első klaszter tagjai. A negyedik kvadránsban található a Spirit és a Turbo, ahol az állomány az elsődleges driver, amely egyértelműen elkülöníti a Turbo fajtát a többitől. A másodlagos driver az illat. Ebbe a kvadránsba a harmadik klaszter tagjai esnek. Általánosságban elmondható, hogy a szuperédes fajtákat kedvelő fogyasztók nagy hangsúlyt fektetnek az ízre, fiatalabbak, magasabb a jövedelmük és ritkábban (havonta) vásárolnak csemegekukorica termékeket. A csemegekukoricát gyakran fogyasztók a Turbo, Spirit, GSS 8529 és Legend fajtákat kedvelik leginkább.

5.2. Preferencia-térképek létrehozása kategóriaadatokból

A kutatás során ízesített kefirtermékek belső preferencia-térképet készítettem el. A kutatás különlegessége, hogy több módszerrel is összehasonlítottam a fogyasztók preferenciáit, a tradicionális MDPREF mellett a rangsor adatokat felhasználó CATPCA módszerét, és a kategóriaadatokon futtatható korrespondencia elemzés módszerét alkalmaztam.

5.2.1. Az általános MDPREF-modell

A fogyasztói kedveltségi adatokból belső preferencia-térképet állítottam elő MDPREF algoritmus alkalmazásával. Az általános kedveltség érzékszervi tulajdonság eredményeiből készített preferencia-térképet mutatom be részletesen, mert ez szolgáltat összehasonlítási alapot a rangsor adatokból készült preferencia-térképhez. Mivel az MDPREF PCA-alapú megközelítés, ezért a futtatás előtt a PCA feltételeit ellenőriztem. Az adatokra futtatott Pearson-féle korrelációs mátrix több változópár esetén is magas és szignifikáns korrelációs koefficienseket tartalmazott. A korrelációs mátrixot ezt követően a Bartlett-féle szfericitás tesztnek is alávettem, amely a korrelációs mátrixot egy korrelálatlan változóknak megfelelő korrelációs mátrixhoz hasonlítja. A teszt eredménye szignifikánsnak adódott ($\alpha = 0,05$), így a PCA azon feltétele, hogy szignifikánsan korreláló változókon futtatható, teljesül. A Kaiser-Meyer-Olkin mutató értéke megfelelően nagynak adódott, 0,6-os eredményt adott (számítása megtalálható az **M11.3 melléklet**ben). A PCA változói így közepesen alkalmasnak tekinthetők. Az első két főkomponens (*principal component*, PC) a teljes variancia 75,35 %-át (PC1 = 45, 54 %, PC2 = 29,81 %) magyarázza. Az eredmények jobb ábrázolhatósága kedvéért Varimax rotációt alkalmaztam, amely a négyzetes faktorsúlyok összegét maximalizálja. Az így kapott összes magyarázott variancia 80,02 %-ra (PC1 = 36,1 %, PC2 = 43,92 %) nőtt. Az ízeket elsősorban a PC1 különítette el, ám a ribizli íz elkülönítéséhez szükség van a PC2-re is. Az elemzéssel nem sikerült elkülöníteni az ízesítési szinteket, minden pár egymáshoz közel, azonos kvadránsban helyezkedik el. Az elemzés során kapott biplotban (**27. ábra**) látható, hogy a fogyasztókat reprezentáló vektorok főleg a ribizli és szőlő ízesítésű termékek felé irányulnak. A szőlő ízesítésű termékek az első, a ribizli a második, míg a zöldalma aromával készült termékek a harmadik kvadránsban találhatóak. Általánosságban elmondható, hogy a fogyasztói kedveltség két irányba mutat, amelyek közül az első a ribizli-szőlő irány, míg a második a ribizli-zöldalma irány. Nem mutatható ki különbség a fogyasztói kedveltségben az ízesítési szintek között a fogyasztói kedveltségek alapján. A belső preferencia-térkép alapján az alacsonyabb aromakonzentrációjú ribizli ízesítésű termék adódott a legkedveltebb a fogyasztók körében.



27. ábra: A termékek és fogyasztói kedveltségek közti kapcsolat (MDPREF, Varimax rotáció). A magasabb aromakonzentrációjú terméket A-val, az alacsonyabbat B-vel jelöltem.

5.2.2. Kategóriaadatokból létrehozott preferencia-térkép

CATPCA-elemzést futtattam a fogyasztói bírálat rangsorolási feladatának eredményein. A feladat során a fogyasztók általános kedveltségük alapján rangsorolták a termékeket. Spearman-féle rangkorrelációs elemzést hajtottam végre a rangsor adatokon, amely eredményét a 13. táblázat mutatja be. A CATPCA a PCA-hoz hasonlóan egymással korreláló változók jelenlétét követeli meg.

13. táblázat: A 60 fogyasztó által értékelt 6 termék közti Spearman-féle rangkorrelációs táblázat

Termék	Szőlő B	Szőlő A	Alma B	Alma A	Ribizli B	Ribizli A
Szőlő B	–	0,478	-0,530	-0,532	-0,159	-0,047
Szőlő A	0,000	–	-0,315	-0,483	-0,398	-0,120
Alma B	< 0,0001	0,014	–	0,304	-0,165	-0,525
Alma A	< 0,0001	< 0,0001	0,018	–	-0,292	-0,261
Ribizli B	0,220	0,002	0,204	0,023	–	0,227
Ribizli A	0,717	0,355	< 0,0001	0,043	0,079	–

A félkövérrel szedett korrelációs koefficiens értékek $\alpha=0,05$ szignifikancia szinten különböznek 0-tól. A jobb felső fél a korrelációs koefficienseket, míg a bal alsó táblázatrész a hozzájuk tartozó p-értékeket mutatja.


Page-próba segítségével egy meglévő rangsort hasonlíthatunk az adatokban fellelhető rangsorhoz. Esetemben a kedveltségi adatokból kapott kedveltségi sorrendet hasonlítottam a rangsor adatokhoz. A módszerrel a kedveltség állandóságát és megbízhatóságát teszteltem. A CATPCA előtt ezért Page-próbát hajtottam végre a rangsoradatokon, majd Cabilio-Peng-féle *post-hoc* tesztet (Cabilio és Peng, 2008). Amennyiben a folytonos skálán mért, egyenként értékelt termékek kedveltsége hasonló tendenciát ad, mint az egymáshoz hasonlított rangsorskálán mért eredmény, úgy

a kedveltség stabilnak tekinthető. A kedveltségadatok alapján felállított terméksorrend a következőnek adódott (csökkenő kedveltség alapján): ribizli B, ribizli A, zöldalma B, zöldalma A, szőlő B és szőlő A. Ezt a rangsort tekintettem *a priori* rangsornak, majd Page-próbával vizsgáltam a nullhipotézis fennállását. A Page-próbát egy 1000-szeres Monte-Carlo-szimulációval futtattam az eredmények megbízhatósága érdekében. A termékek eredményeit ezt követően a Cabilio–Peng-féle többszörös páros összehasonlítás módszerével homogén csoportokban rendeztem. Az eredmény 0,003-as *p*-értéket adott, így a mintákra adott rangsorértékek szignifikánsan különböznek az $\alpha=0,05$ szinten. A minták rangsorában csak a szőlő A és a zöldalma A termékek helye cserélődött fel, a többi eredmény azonos. Az eredmények alapján a rangsoradatok és a folytonos adatok eredményei azonos információt hordoznak, így a CATPCA és az MDPREF eredményei összevethetőek. A 14. táblázat alapján szignifikáns különbség adódott a Ribizli B és Zöldalma A, Zöldalma B, Szőlő A, Szőlő B illetve a Ribizli A és Szőlő A, Szőlő B, Zöldalma A között.

14. táblázat: Cabilio-Peng-féle többszörös páros összehasonlítás eredményei a rangsoradatokra (6 termék, 61 fogyasztó).

Minta	Gyakoriság	Rangszámösszeg	Rangátlag	Csoportok
Ribizli B	61	179,000	29,833	A
Ribizli A	61	191,500	31,917	A B
Alma B	61	222,000	37,000	B
Szőlő A	61	227,000	37,833	C
Szőlő B	61	229,500	38,250	C
Alma A	61	232,000	38,667	C

A rangsoradatok kétdimenziós CATPCA elemzése 73,91 %-os (PC1 = 43,16 %, PC2 = 30,75 %) magyarázott varianciányadot adott. Az MDPREF-hez hasonlítva a magyarázott variancia mennyisége kismértékben csökkent. A CATPCA futtatása előtt a Cronbach-alfa értékét vizsgáltam meg. Az össz Cronbach-alfa értéke 0,921-nek adódott, ami alapján elmondható, hogy az elemek szoros kapcsolatban állnak egymással. A 28. ábra mutatja be a CATPCA eredményeit egy biplotban. Az ábra alapján látható, hogy a fogyasztói kedveltségvektorok főként a ribizli A és ribizli B termékek felé mutatnak. Az MDPREF-hez hasonlóan itt sem sikerült az ízesítési szintek között különbséget tenni. A fogyasztókat preferenciájuk alapján két csoportba lehet osztani, az egyik a ribizli-szőlő (1-es klaszter), a másik a ribizli-alma (2-es klaszter) irány. Az ábrán (28. ábra) látható a CATPCA szkórjainak *k*-közép klaszterezési megoldása is. A megfelelő klaszterezési algoritmus és klaszterszám meghatározásakor az alábbi módszereket vizsgáltam: véletlen klaszterezés, hierarchikus klaszterezés euklideszi távolság és Ward-módszere alapján, illetve a *k*-közép klaszterezés.



28. ábra: A k -közép klaszterezés által azonosított fogyasztói klaszterek és a termékek közti kapcsolat. A zöld pontok (●) az első klaszter ($n=26$), a sárga háromszögek (▲) a második klaszter ($n=9$), míg a piros négyzetek (■) a harmadik klaszter ($n=26$) tagjait jelenítik meg. A megnövelt méretű szimbólumok a klaszterközéppontokat, a sarkára állított négyzetek a termékeket jelölik.

Az alkalmazott indexek alapján (Silhouette-index, Calinski-Harabasz-index és Dunn-index) a k -közép klaszterezés 3 klaszteres megoldása adta a legmagasabb értékeket. Az ábráról továbbá az is látható, hogy a fogyasztók elsősorban a ribizli ízesítésű termékeket kedvelték és a másodlagos kedveltség alapján alakult ki a két eltérő csoport (**28. ábra**). A második klaszter tagjairól elmondható, hogy vagy nem kedvelték a kefir termékeket, vagy nagyon ellentmondásos eredményeket adtak.

A módszer alkalmasnak bizonyult a preferencia-rangsorok feldolgozására, emellett a fogyasztói preferenciaállandóságának mérésére is. Az MDPREF- és CATPCA-eredmények erős hasonlóságot mutattak. A CATPCA előnye, hogy a rangsoradatok gyűjtése egyszerűbb, kisebb a hibalehetőség, a fogyasztókat kevésbé terheli mentálisan, és rövidebb időt vesz igénybe, mint a megszokott termékenkénti értékelés folytonos skálán. Emellett a rangsoradatok a folytonos adatokhoz hasonlóan további statisztikai elemzéseknek is alávetethetők, szemben az optimumskála adataival. A CATPCA további előnye, hogy az MDPREF-nél megszokott maximálisan hat mintánál többet is lehet egyszerre vizsgálni a feladat egyszerűsége miatt. A rangsoradatok hátránya azonban, hogy a termékek közötti távolságok elvesznek, míg a folytonos skálák tartalmazzák ezt az információt.

5.3. Optimumskála-adatok értékelési módszereinek fejlesztése

5.3.1. Általánosított párkorrelációs eljárás

Az optimumskálák adatainak értékelése során arra keressük a választ, hogy melyek azok a terméktulajdonságok, amelyek a legnagyobb hatással vannak a termékek kedveltségére. A skálák nemparaméteres természetéből adódóan azonban az alkalmazható módszerek száma korlátozott. Kutatásomban egy eddig nem alkalmazott megközelítés alapján, a GPCM-módszer segítségével dolgoztam fel a skála adatait. Az eredményeket az ízesített ásványvíztermékek példáján mutatom be.

A három legfontosabb tulajdonságnak a gyümölcsíz-, utóíz+ és keserű íz+ adódtak. Az egyszerű rendezés adta a legtöbb szignifikáns változót, mivel ez tekinthető a legkevésbé szigorú módszernek a három rendezési eljárás közül (csak a győzelmek száma mérvado). A 15. táblázatból látható, hogy a különbségrendezés és a súlyozásos rendezés jóval szigorúbb volt. A rendezési módszerek alapján az egyszerű rangsor adta a 16 érzékszervi tulajdonság közül a legtöbb szignifikáns rangsorút. A 15. táblázatban a nemparaméteres próbák (Fisher-féle egzakt-próba (CondExact), McNemar-próba (McNemars), χ^2 -próba (ChiSquare) és a Williams-féle t-próba (Williams' t)) legalább 10 tulajdonságnál szignifikáns kapcsolatot mutatnak a kedveltséggel. A három legfontosabb tulajdonság rangsorában konszenzus volt a próbák között:

- 1) nem elég erős gyümölcsíz intenzitás,
- 2) túl erős utóíz intenzitás,
- 3) túl erős keserű íz intenzitás.

A tulajdonságok rangsorolása is hasonlóan adódott, csak néhány esetben fedezhető fel eltérés a próbák eredményei között. A 15. táblázat utolsó oszlopában az összehasonítási céllal implementált paraméteres próba eredményei láthatóak. Csak három tulajdonság hatását találta szignifikánsnak, amelyek közül az első kettő azonos volt a nemparaméteres próbák által adott megoldással.

A vereségeket is figyelembe vevő különbségrendezésnél és a súlyozásos rendezésnél nagyon hasonló eredmények láthatóak. Az egyszerű rendezéshez hasonlítva, a legnagyobb különbség a szignifikáns változók számában látható, amelyek az alkalmazott próbától függően 2 és 5 között változnak. A különbségrendezés a második legérzékenyebb módszer, ám az adatok jellege ebben az esetben is befolyásolhatja a szignifikáns különbségek számát (15. táblázat).


15. táblázat: A mangó-passiógyümölcs-termék tulajdonságainak sorrendje a GPCM eredményei alapján.

	Tulajdonságok	Feltételes F-próba	McNemar-próba	χ^2 -próba	Williams-féle t-próba
egyszerű rendezés	gyümölcsíz-	1	1	1	1
	utóíz+	2	2	2	2
	keserű íz+	3	3	3	NS
	édesíz-	4	5	5	3
	savanyú íz+	5	4	4	NS
	szénsavasság+	6	6	6	NS
	illat-	7	7	7	NS
	savanyú íz-	8	8	8	NS
	édes íz+	9	10	10	NS
	szín+	10	9	9	NS
	szénsavasság-	11	NS	11	NS
	illat+	NS	NS	12	NS
különbség rendezés	gyümölcsíz-	1	1	1	1
	utóíz+	2	2	2	2
	keserű íz+	3	3	3	NS
	édesíz-	4	NS	5	NS
	savanyú íz+	5	NS	4	NS
Súlyozásos rendezés	gyümölcsíz-	1	1	1	1
	utóíz+	2	2	2	2
	keserű íz+	3	3	3	NS
	édesíz-	4	4	5	NS
	savanyú íz+	5	NS	4	NS

A félkövérrel szedett tulajdonságok a JAR-skála „túl erős”, a dőlttel szedett tulajdonságok a „túl gyenge” oldalát jelölik, NS: nem szignifikáns.

A súlyozásos rendezés tekinthető a legszigorúbbnak és a legkevésbé érzékeny módszernek a három közül. A sorrend itt a próbák között nem változik, ez alól egyedül a McNemar-próba egy esete a kivétel. Itt ugyanis a túl gyenge édes íz tulajdonság a negyedik helyen szerepel, ám az egyszerű rendezésnél az ötödik helyen áll. (15. táblázat).

Egy új ábrázolási eszköz segítségével a három rendezési mód és a három próba eredményei jól szemléltethetőek (29. ábra).



29. ábra: Vonaldiagram a három rendezési módszer és három értékelési próba eredményeinek megjelenítésére. A keresztező vonalak a módszerek/próbák közti egyet nem értést jelölik. A tulajdonságok sorrendjét a kedveltségre gyakorolt hatás alapján állítja fel a módszer. Első helyre kerül a kedveltséget legnagyobb mértékben befolyásoló tulajdonság. Jelölések: feltételes F-próba (CondExact), χ^2 -próba (ChiSquare) McNemar-próba (McNemars) Williams-féle t-próba (William's t).

Az egyes rangszámot a kedveltséget leginkább befolyásoló tulajdonság kapja (gyümölcsíz-), a másodikat a második (utóíz+) és így tovább. Az ábrán a vízszintes vonalak a konszenzust jelentik, míg az egymást keresztező vonalak alapján arra következtethetünk, hogy a módszerek nem értenek egyet az adott tulajdonság rangszámával. A pontok összekötésének matematikai jelentősége nincs, csupán a vizualizációt könnyítendő szerepük van. A módszerek összehasonlításához célszerű a módszerek alapján csoportosítani az x-tengelyen. Az új ábrázolási technika egy diagramban jeleníti meg a GPCM eredményeit, így a 16. táblázatban bemutatott eredmények értelmezése egyszerűbbé és gyorsabbá válik.

16. táblázat: A Fisher-féle egzakt-próba szerinti rangsorolás a három rendezési módszerrel.

Egyszerű rendezés					Különbségrendezés					Súlyozásos rendezés				
Változó	Győz.	Vereség	Döntetlen	Rang	Változó	Győz.	Vereség	Döntetlen	Rang	Változó	P-győz	P-vereség	Döntetlen	Rang
szín+	4	6	5	10	szín+	4	6	5	10	szín+	3.9951	6	5	10
illat+	3	9	3	12	illat+	3	9	3	12	illat+	2.9986	8.9989	3	12
gyümölcsíz+	3	10	2	13	gyümölcsíz+	3	10	2	13	gyümölcsíz+	2.9813	9.9141	2	13
szénsavasság+	7	4	4	6	szénsavasság+	7	4	4	6	szénsavasság+	6.9815	3.999	4	6
édes íz+	5	7	3	9	édes íz+	5	7	3	9	édes íz+	4.9691	6.9996	3	9
savanyú íz+	8	1	6	5	savanyú íz+	8	1	6	5	savanyú íz+	7.9988	0.9975	6	5
keserű íz+	10	0	5	3	keserű íz+	10	0	5	3	keserű íz+	9.9999	0	5	3
utóíz+	12	1	2	2	utóíz+	12	1	2	2	utóíz+	11.9927	1	2	2
<i>szín-</i>	0	11	4	16	<i>szín-</i>	0	11	4	16	<i>szín-</i>	0	10.9965	4	16
<i>illat-</i>	6	5	4	7	<i>illat-</i>	6	5	4	7	<i>illat-</i>	5.9576	4.9533	4	7
<i>gyümölcsíz-</i>	12	0	3	1	<i>gyümölcsíz-</i>	12	0	3	1	<i>gyümölcsíz-</i>	11.9999	0	3	1
<i>szénsavasság-</i>	4	7	4	11	<i>szénsavasság-</i>	4	7	4	11	<i>szénsavasság-</i>	3.9567	6.9575	4	11
<i>édes íz-</i>	9	2	4	4	<i>édes íz-</i>	9	2	4	4	<i>édes íz-</i>	8.9717	1.9952	4	4
<i>savanyú íz-</i>	5	6	4	8	<i>savanyú íz-</i>	5	6	4	8	<i>savanyú íz-</i>	4.9904	5.9924	4	8
<i>keserű íz-</i>	1	12	2	15	<i>keserű íz-</i>	1	12	2	15	<i>keserű íz-</i>	1	11.9813	2	15
<i>utóíz-</i>	2	10	3	14	<i>utóíz-</i>	2	10	3	14	<i>utóíz-</i>	1.9925	9.9999	3	14
<i>p</i> (megadott)	0.05	Krit.	86.45-88.00		<i>p</i> (megadott)	0.05	Krit.	48.45-50.00		<i>p</i> (megadott)	0.05	Krit.	48.45-50.00	
<i>p</i> (számított)	0.0329	szum			<i>p</i> (számított)	0.0196	szum			<i>p</i> (számított)	0.0196	szum		

A sötétszürke kiemelés a szignifikáns ($p = 0,05$) rangszámokat, a szürke jelölés a diszkrét pontok közé eső értékeket jelölik, amelyekről nem állapítható meg, hogy szignifikánsak-e. Rövidítések: P-győz, súlyozott győzelem különbségek, P-vereség: súlyozott vereség különbségek, Rang: a változó fontosságának rangszáma. A félkövérrel szedett tulajdonságok a JAR-skála „túl erős”, a dőlttel szedett tulajdonságok a „túl gyenge” oldalát jelölik.

A GPCM a független változókat a függő változóra (fogyasztói kedveltség) gyakorolt hatásuk alapján hasonlítja össze. A következő példában a szín+ és az illat- összehasonlítását mutatom be a feltételes F-próba alapján (17. táblázat). Az eredmények a GPCM Excel makró által lementett adatfájlból kimásolhatóak és ellenőrizhetőek.

17. táblázat: A szín+ és illat+ összehasonlítása Fisher-féle egzakt-próbával.

	D(szín+)>0	D(szín+)<0
D(illat+)<0	$k_D = 54$	$k_B = 32$
D(illat+)>0	$k_C = 27$	$k_A = 99$

Mivel az egyenlő Y értékek nem hordoznak érdemi információt, ezeket kizárjuk. Kritikus érték=23, hibahatár $\alpha(\text{user}) = 0,05$, elméleti határ $\alpha = 0,5401$. Egyik tulajdonság sem nyert, mivel $27 > 23$.

Az 17. táblázat alapján látható, hogy a p -érték nagyobb, mint a kritikus érték (0,05), így nem lehet megállapítani a példában szereplő két tulajdonság közül, hogy melyik a győztes. A következő példában egy egyértelmű esetet szemléltetünk, amelyben a szín+ és szénsavasság+ tulajdonságok összehasonlítása során a szénsavasság+ egyértelműen győztes (18. táblázat). A táblázat átlójában lévő elemek alapján dönthető el a győzelem. Az alkalmazott statisztikai próba (ebben az esetben a feltételes F-próba) mutatja meg, hogy mely tulajdonságok között van szignifikáns különbség. A makró automatikusan számítja a kritikus összeg és elméleti határértékeket, amelyek alapján a B és C cellák még éppen szignifikánsnak nevezhetőek. Minden változópárra elkészül a számítás.


18. táblázat: A szín+ és szénsavasság+ összehasonlítása Fisher-féle egzakt-próbával.

	D(szín+)>0	D(szín+)<0
D(szénsavasság+)<0	$k_D = 58$	$k_B = 9$
D(szénsavasság+)>0	$k_C = 64$	$k_A = 89$

Mivel az egyenlő Y értékek nem hordoznak érdemi információt, ezeket kizárjuk. Kritikus érték=30, hiba határ $\alpha(\text{user}) = 0,05$, elméleti határ $\alpha = 0,0000$. szénsavasság+ nyer, mivel $9 < 30$.

Egy szintén új, a penalty analysis mean drop ábrájához hasonló vizualizációs eszközzel a fogyasztók százalékosan kifejezett száma ábrázolható a GPCM által adott rangszámértékekkel szemben egy buborék ábrában (30. ábra). Az ábrát a feltüntetett két vonal négy térrészre osztja fel. A vízszintes vonal a fogyasztók azon 20 %-át jelöli, akik úgy vélték, hogy a termékre igaz egy tulajdonság valamely végpontja. A függőleges vonal a szignifikáns tulajdonságok határát jelöli. A buborékok mérete a kedveltségre gyakorolt hatás erősödése alapján növekszik. A bal felső térrészben a szignifikáns és fontos – a fogyasztók több, mint 20 %-a vélekedik így – tulajdonságok találhatók. A termékfejlesztés során ezeket a tulajdonságokat kell elsősorban vizsgálni és fejleszteni. A bal alsó térrészben a szignifikáns, ám kevésbé fontos – a fogyasztók kevesebb, mint 20 %-a vélekedik így – tulajdonságok találhatók. Ezek a tulajdonságok csak a fogyasztók kis aránya számára vannak hatással

kedveltségre, a többség számára nem fontosak. A jobb felső kvadránsban a nem szignifikáns, de fontos tulajdonságok találhatóak. Ezen tulajdonságok ugyan nem befolyásolják szignifikánsan a kedveltséget, ám a fogyasztók több mint 20 % szerint igazak a termékekre. A jobb alsó térrészben található tulajdonságok nem szignifikánsak és nem is fontosak a fogyasztók megítélése alapján. Minél nagyobb a tulajdonságokat jelző buborék mérete, annál nagyobb annak hatása a fogyasztói kedveltségre.



30. ábra: Buborék ábra az egyszerű rendezés, Fisher-féle egzakt-próba eredményeinek ábrázolására. A függőleges vonal a szignifikáns tulajdonságok határát jelzi. A vízszintes vonal a 20%-os fogyasztói értéket jelöli, hasonlóan, mint az általánosan alkalmazott penalty analízis esetében. A buborékok mérete a kedveltségre gyakorolt hatás alapján növekszik.

A tulajdonságok rangsora a fogyasztói kedveltség alapján került meghatározásra (x koordináta és a buborékok mérete), míg az y koordináta a fogyasztói létszámot adja meg százalékban kifejezve. A szín esetében például a fogyasztók 30 %-a vélte úgy, hogy nem elég intenzív (szín-), ám ennek nincs szignifikáns hatása a kedveltségre (rangszáma 16). Ezzel ellentétben a fogyasztók 5 %-a vélte úgy, hogy a szín túl intenzív (szín+), ám ezen fogyasztók számára ez szignifikáns hatással volt a kedveltségre.

A GPCM nem követeli meg, hogy a változók között erős korreláció álljon fenn. A JAR-változók nemparametrikus jellegéből adódóan a kedveltséggel való kapcsolatuk szorosságát Spearman-féle rangkorrelációs együtthatóval számítottam, ahol a tulajdonságukat korrelációjuk erőssége alapján rendeztem (19. táblázat).

19. táblázat: Spearman-féle rangkorrelációs mátrix.

Változó	Kedveltség
gyümölcsíz-	0,477
utóíz+	-0,342
édes íz-	0,315
keserű íz+	-0,305
illat-	0,227
savanyú íz-	0,224
szénsavasság+	-0,213
savanyú íz+	-0,188
szénsavasság-	0,155
édes íz+	-0,155
gyümölcsíz+	-0,082
utóíz-	0,074
illat+	0,07
szín+	0,065
keserű íz-	-0,012
szín-	0,001

A félkövérrel szedett értékek szignifikánsan ($\alpha=0,05$) különböznek 0-tól (XL-Stat). A félkövérrel szedett tulajdonságok a JAR-skála „túl erős”, a dőlttel szedett tulajdonságok a „túl gyenge” oldalát jelölik.

A többváltozós lineáris regresszió esetében a 16 változóból 7 esetében figyelhető meg valamilyen (pozitív vagy negatív) hatás a kedveltségre: gyümölcsíz- (pozitív), utóíz+ (negatív), szénsavasság+ (negatív), gyümölcsíz+ (negatív), utóíz- (pozitív), szénsavasság- (pozitív), savanyú íz+ (negatív). Így ezeket a tulajdonságokat kell részletesebben megvizsgálni. A hatás iránya (pozitív vagy negatív) adja meg, hogy milyen irányba kell az adott érzékszervi tulajdonságot megváltoztatni a termékben. Amennyiben az előjel pozitív, úgy növelni kell az erősséget (egy bizonyos pontig). Hasonlóan, negatív előjel esetén az intenzitás csökkentése a cél. A gyümölcsíz+ és utóíz+ adódtak a legfontosabb tulajdonságoknak a t -értékek alapján. A 20. táblázatban láthatóak a többváltozós lineáris regresszió eredményei, amelyben a változókat a t -értékük alapján rendeztem növekvő sorrendbe.

20. táblázat: A többváltozós lineáris regresszió szignifikáns paraméterei (változószelekció után). Csak a szignifikánsnak adódott változók szerepelnek a táblázatban. A változók a hozzájuk tartozó t -értékek alapján csökkenő sorrendben szerepelnek.

Forrás	átlag	szórás	t -érték	$\text{Pr} > t $
Tengelymetszet	7,837	0,236	33,201	< 0,0001
gyümölcsíz-	1,554	0,228	6,823	< 0,0001
utóíz+	-1,041	0,237	-4,393	< 0,0001
szénsavasság+	-0,751	0,274	-2,738	0,007
gyümölcsíz+	-0,926	0,347	-2,67	0,009
utóíz-	0,614	0,253	2,426	0,017
szénsavasság-	0,571	0,263	2,174	0,032
savanyú íz+	-0,885	0,436	-2,029	0,045

RMSE: 1,360, szabadsági fokok száma: 109, $R^2 = 0,508$, $F(7;109) = 16,073$, $p < 0,0001$

Az MLR után PLS-R módszert alkalmaztam az adatsorra a kedveltségre szignifikánsan ható változók azonosítására. A PLS-R modell kissé gyengébben teljesített, mint az MLR ($R^2=0,480$ illetve 0,508, RMSE=1,347 illetve 1,360). A PLS-R modell metszéspontja (7,673) alacsonyabban van mint az MLR esetében (7,837), amit úgy lehet értelmezni, mint az átlagos becsült kedveltségi értéke, ha minden tulajdonság pont jó értékkel rendelkezik.


A PLS-R során a redundanciákból számítható a változók fontossági értéke (*variable importance for the projection*, VIP), amely megadja a magyarázó változók fontosságát a t -komponensek felépítése során. A 21. táblázatban mutatom be a modell változóinak VIP-értékeit. Ez alapján gyorsan és pontosan azonosíthatóak a modellben legnagyobb szerepet játszó komponensek. A PLS-R VIP-értékeinek eredményei alapján a gyümölcsíz- (pozitív), utóíz+ (negatív), édes íz- (pozitív), illat- (pozitív), keserű íz+ (negatív), savanyú íz- (pozitív), szénsavasság+ (negatív), szénsavasság- (pozitív) változók hatnak szignifikánsan a kedveltségre.

21. táblázat: A PLS-R eredménye. A változók fontossági értékeik (VIP) alapján vannak sorba rendezve. A felső vastag vonal a $VIP = 1$ értéket jelöli, az alsó a $VIP = 0,8$ értéket

változó	VIP	szórás	sztdenderizált koefficiensek (kedveltség változóra):
gyümölcsíz-	2,133	0,251	0,280
utóíz+	1,616	0,274	-0,212
édes íz-	1,359	0,191	0,178
illat-	1,249	0,491	0,164
keserű íz+	1,143	0,260	-0,150
savanyú íz-	0,974	0,407	0,128
szénsavasság+	0,952	0,264	-0,125
szénsavasság-	0,848	0,273	0,111
savanyú íz+	0,769	0,393	-0,101
édes íz+	0,682	0,480	-0,089
utóíz-	0,454	0,510	0,060
gyümölcsíz+	0,390	0,589	-0,051
szín+	0,282	0,262	0,037
illat+	0,187	0,474	0,025
keserű íz-	0,127	0,270	-0,150
szín-	0,076	0,395	0,010

RMSE = 1,347 115 szabadsági fokkal, $R^2 = 0,482$, $R_{val} = \sqrt{Q^2} = 0,610$, tengelymetszet = 7,673, megfigyelt átlag = 5,812, becsült átlag = 5,812.

A VIP-ábrán a 0,8-as határértéket jelző vonalat tüntettem fel (31. ábra). A 0,8-as határértéket Wold alapján választottam (Wold, 1995). A $0,8 < VIP < 1$ VIP értékek részben, míg a $VIP > 1$ értékek erősen befolyásolják a modellt.



31. ábra: A változók fontossági értékei (variable importance) alapján felállított sorrend. A két szaggatott vonal a 0,8 és 1 értékeket jelölik


A penalty analízisben az általánosan alkalmazott egymintás t -próba segítségével állapítható meg, hogy az adott végpont szignifikáns-e. A próba megköveteli a változók normális eloszlását, azonban a Shapiro-Wilk normalitásvizsgálat eredménye alapján látható, hogy nem minden változó követ normál eloszlást (22. táblázat). A táblázatban félkövérrel emeltem ki azokat az eseteket, amikor a normalitás **nem** sérül.

22. táblázat: A penalty analízis eredménye. A táblázat két utolsó oszlopa a normalitásvizsgálat eredményét tartalmazza.

Változó	Szint	%	átlag (kedveltség)	mean drop	t-próba p-érték	Shapiro- Wilk's W	Shapiro- Wilk's p-érték
szín	Túl gyenge	30,77 %	5,806	-0,032	0,933	0,96092	0,00295
	JAR	64,10 %	5,773			0,95053	0,00533
	Túl erős	5,13 %	6,333	-0,56		0,92664	0,55438
illat	Túl gyenge	32,48 %	5,263	0,787	0,033	0,96446	0,26424
	JAR	51,28 %	6,05			0,9459	0,01004
	Túl erős	16,24 %	6,158	-0,108		0,95886	0,55008
gyümölcsíz	Túl gyenge	51,28 %	5,033	2,146	< 0,0001	0,96766	0,11198
	JAR	33,33 %	7,179			0,91346	0,00549
	Túl erős	15,38 %	5,444	1,735		0,91132	0,09078
szénsavasság	Túl gyenge	21,37 %	5,24	1,039	0,025	0,94495	0,1925
	JAR	58,12 %	6,279			0,95743	0,00094
	Túl erős	20,51 %	5,083	1,196	0,006	0,95789	0,00175
édes íz	Túl gyenge	31,62 %	4,973	1,657	< 0,0001	0,9474	0,07956
	JAR	46,15 %	6,63			0,91244	0,00078
	Túl erős	22,22 %	5,308	1,322	0,001	0,94394	0,16676
savanyú íz	Túl gyenge	39,32 %	5,261	1,18	0,001	0,9498	0,04608
	JAR	50,43 %	6,441			0,9366	0,0042
	Túl erős	10,26 %	4,833	1,607		0,83658	0,02516
keserű íz	Túl gyenge	24,79 %	5,655	0,58	0,127	0,89523	0,00755
	JAR	58,12 %	6,235			0,93174	0,00109
	Túl erős	17,09 %	4,6	1,635		0,92624	0,1307
utóíz	Túl gyenge	25,64 %	5,6	0,977	0,009	0,96637	0,44519
	JAR	44,44 %	6,577			0,93477	0,0069
	Túl erős	29,91 %	4,857	1,72	< 0,0001	0,90538	0,00553

A félkövérrel szedett értékek $\alpha = 0,05$ szignifikancia szinten különböznek 0-tól (XL-Stat).

A penalty analysis során az alábbi változókat azonosítottam szignifikánsként: illat-, gyümölcsíz-, szénsavasság-, szénsavasság+, édes íz-, édes íz+, savanyú íz-, utóíz+ és utóíz-. A *mean drop* értékek alapján történő sorbarendezés után adódott sorrend: gyümölcsíz-, utóíz+ és az édes íz-. A *mean drop* ábra alapján csak a gyümölcsíz- tulajdonság adódott fontosnak, vagyis a módszer csak ezt javasolja mint továbbfejlesztendő tulajdonságot. Az utóíz+ és édes íz- fontossága nem tűnik ki (32. ábra). A *mean drop* ábra egyik hátránya, hogy csak a gyümölcsíz- emelkedik ki, mint módosítandó tulajdonság (szignifikáns és fontos). Emellett nehéz megállapítani a második, illetve harmadik legfontosabb tulajdonságot.



32. ábra: A penalty analízis *mean drop* ábrája. A *mean drop* értékeket a fogyasztói létszám százalékos értékeivel szemben ábrázoljuk. A függőleges vonal a fogyasztók 20 %-át jelöli.

A 23. táblázat alapján látható, hogy az első két legfontosabb változó sorrendje azonos az összes módszer esetében. Az ezt követő sorrend erősen függ az alkalmazott módszertől és kritériumoktól. A legtöbb szignifikáns tulajdonságot a GPCM egyszerű rendezés feltételes F-próba (CondExact) adta, míg a legszigorúbb a GPCM különbségrendezés és súlyozásos rendezés voltak.

23. táblázat: A módszerek összevetése.

	PCM (egyszerű rendezés, CondExact)	PCM (súlyozásos rendezés, CondExact)	PCM (különbség rendezés, CondExact)	Többszörös lineáris regresszió	PLS- regresszió	penalty analysis
1	gyümölcsíz-	gyümölcsíz-	gyümölcsíz-	gyümölcsíz-	gyümölcsíz-	gyümölcsíz-
2	utóíz+	utóíz+	utóíz+	utóíz+	utóíz+	utóíz+
3	késérű íz+	késérű íz+	késérű íz+	szénsavasság-	édes íz-	édes íz-
4	édes íz-	édes íz-	édes íz-	savanyú íz+	illat-	édes íz+
5	savanyú íz+	savanyú íz+	savanyú íz+	gyümölcsíz+	késérű íz+	szénsavasság+
6	szénsavasság+	-	-	szénsavasság+	savanyú íz-	savanyú íz-
7	illat-	-	-	utóíz-	szénsavasság+	szénsavasság-
8	savanyú íz-	-	-	-	szénsavasság-	utóíz-
9	édes íz+	-	-	-	-	-
10	szín+	-	-	-	-	-
11	szénsavasság-	-	-	-	-	-

5.3.2. A rangszámkülönbségek összegén alapuló módszer alkalmazása a JAR-változók azonosítására

Számos adatelemzési módszer áll rendelkezésre mind a nemzetközi szakirodalomban, mind az élelmiszeriparban az optimumadatok (*just-about right*, JAR) elemzésére. Ezen módszerek közül munkámban azokra a módszerekre fókuszáltam, amelyek a JAR-skálákat két részre bontják, és a fogyasztói kedveltségi adatokat is figyelembe veszik. A módszerek számítási módjaikból adódóan – bizonyos esetekben – eltérő, esetleg ellentmondó eredményeket szolgáltathatnak. Munkám során eddig nem sikerült olyan adatelemzési módszert és/vagy munkafolyamatot találni, amely több eltérő módszer eredményét is figyelembe véve adja meg, hogy mely érzékszervi tulajdonságokat célszerű módosítani egy terméken ahhoz, hogy a fogyasztók jobban kedveljék azt. Több szempont alapján történő optimalizálási kérdéseket más tudományterületen már megoldottak. A rangszámkülönbségek összegén alapuló módszert már sikeresen alkalmazták a kemometriában. A különböző adattáblák és eltérő skálákon mért változók miatt a módszer azonban csak normalizált adatokon futtatható. A szenzometriában eddig csak néhány publikáció jelent meg az SRD alkalmazásáról, amelyek leginkább a képzett érzékszervi panel teljesítményjellemezésére alkalmazták a módszert.

Az SRD bemenő adatmátrixába a maximumértékek kerültek a referenciaoszlopba (Max), mivel az egyes változók fontossága a kedveltségre történő hatásuk mértéke alapján került meghatározásra. A számításba bevont módszerek a következők voltak, ahol zárójelben a továbbiakban alkalmazott rövidítések, illetve a módszer alkalmazott paramétere: legkisebb négyzetek elvén alapuló regresszió (OLS, *t*-értékek), penalty analysis (penalty, *mean drop* értékek), bootstrappelt penalty analysis (bPenalty, *mean drop* értékek), általánosított párkorrelációs módszer (GPCM, győztesek százalékos értékei), részleges legkisebb négyzetek elvén alapuló regresszió álváltozókkal (PLS-dummy, *t*-értékek), többszörös lineáris regresszió (MLR, *t*-értékek), JAR-átlaghoz igazított penalty analysis (wPAforJARMean, *mean drop* értékek), nagyátlaghoz viszonyított súlyozott penalty analysis (wPAforGrandMean, *mean drop* értékek). A kutatás során az Amerikai Anyagtudományi és Ellenőrzési Társaság (*American Society for Testing and Materials*, ASTM) által kiadott optimumskálákkal foglalkozó szabványban felhasznált adatokon alkalmaztam módszereket (ASTM MNL-63, 2009).

Mivel a sorok száma 14-nél kevesebb volt ($n=8$), egy szimulált SRD-eloszlást használtam a módszer alapján. Az SRD-számítások részletes eredményeit az 24. táblázat tartalmazza, illetve a 33. ábra jeleníti meg.


24. táblázat: A JAR-tulajdonságok rangsora és a véletlen rangsorolás valószínűségei.

Rangsor eredmények		<i>p</i> %		<i>SRD</i> _{max} =32
Név	SRD	<i>x</i> < SRD > = <i>x</i>		<i>normSRD</i>
íz–	4	0,02025	0,10007	12,5
ragadósság+	6	0,10329	0,38221	18,75
szín–	10	1,20908	3,07284	31,25
XX1	12	3,12	6,83	
szín+	12	3,11759	6,83328	37,5
íz+	12	3,11759	6,83328	37,5
ragadósság–	14	6,91171	13,1449	43,75
méret–	18	22,448	34,3173	56,25
sós íz–	18	22,448	34,3173	56,25
vastagság+	18	22,448	34,3173	56,25
X1	18	22,45	34,32	
vastagság–	20	34,49	48,47	62,5
méret+	22	48,65	63,10	68,75
MED	22	48,65	63,10	
sós íz+	24	63,25	76,64	75
Q3	24	63,25	76,64	
XX19	30	94,21	98,57	

A félkövérrel és dőlttel szedett tulajdonságok szignifikánsak $p = 0,05$ szinten. A szürkével szedett sorok az 5 % (XX1), 25 % (Q1), 50 % (Med), 75 % (Q3) és 95 % (XX19) percentilisek.

A 24. táblázat 2. oszlopa tartalmazza az egyes tulajdonságok rangszámkülönbségek összegeit (SRD-értékeit). A p % oszlopban két valószínűségi érték látható az eloszlás diszkrét jellegéből adódóan. Ezek a tulajdonságok véletlen értékelésének valószínűségi sávját adják meg. Az *SRD*_{max} számítása során az $SRD_{max}=2z^2=32$ egyenletet alkalmaztam, mivel $n=8$, $k=n/2=4$. A 24. táblázat utolsó oszlopa tartalmazza a 0 és 100 közé skálázott SRD-értékeket (*normSRD*). A táblázat további sorai az 5 %-os (XX1), 25 %-os (Q1), 50 %-os (Med), 75 %-os (Q3) és 95 %-os (XX19) percentiliseket jelzik. Ha egy változó *normSRD*-értéke kisebb, mint az XX1 (5 %-os percentilis) által határolt érték, akkor az adott JAR-változó szignifikánsnak tekinthető a $p = 0,05$ szinten. Az eredmények alapján az íz–, a ragadósság+ és a szín– tulajdonságokat azonosítottam szignifikánsként.

Az összehasonlításokat a *normSRD*-értékek alapján tettem meg, ami nulla érték esetén azt jelenti, hogy nincs különbség a referenciaoszlop és az adott tulajdonság között. Minél nagyobb a *normSRD*-értéke, annál nagyobb a különbség a referencia oszlop és az adott tulajdonság között. Amennyiben a *normSRD*-értéke metszi a Gauss-görbét például $p = 0,10$ értéknél, úgy a módszer a változót 10 %-os valószínűséggel rangsorolja véletlenszerűen (33. ábra).




33. ábra: A JAR-tulajdonságok skálázott SRD-értékei. A sorátlag értékeket alkalmaztuk a referencia oszlopban. A skálázott SRD-értékek láthatóak az x és y tengelyeken, a jobb y tengely a validáció során generált relatív gyakoriságokat mutatja (fekete görbe). Az 5 %-os (XX1), a Median (Med) és a 95 %-os (XX19) valószínűségi értékeket szaggatottal jelöltem

Továbbá az SRD-értékek alapján történő rangsor nem csak a referencia oszloptól való távolságot adja meg a tulajdonságokra, hanem ezzel egy időben a szignifikáns változókat is rangsorolja. A legalacsonyabb *normSRD*-értékkel rendelkező változónak van a legnagyobb hatása a kedveltségre a JAR-változók közül, így azt érdemes elsősorban megváltoztatni. A **33. ábra** alapján az alábbi sorrendet határoztam meg: íz-, ragadósság+ és szín-. A többi változó esetében az XX1-nél magasabb *normSRD*-értékeket figyeltem meg, így ezen változók rangsora nem különböztethető meg a véletlen rangsortól 95 %-os szignifikancia szinten. Ettől függetlenül ez nem jelenti azt, hogy a közöttük felállított rangsor nem hordoz információt, csupán a kedveltségre nem hatnak szignifikánsan. A magas *normSRD*-értékek akkor keletkeznek, ha az adott tulajdonságot a módszerek eltérően rangsorolták (a módszerek közt nincs összhang, egyetértés). Az SRD-módszer egyik fő előnye ezáltal az, hogy több JAR-adatértékelő módszer eredményei alapján mutatja be a legfontosabb terméktulajdonságokat.

Három, véletlentől eltérően rangsorolt tulajdonságot (íz-, ragadósság+ és szín-) azonosítottam, amelyek nem fednek át a véletlen számokból előállított eloszlással (fekete Gauss-görbe, **33. ábra**). A szín- véletlen értékelésének valószínűsége 1,21 % és 3,07 % közti (*normSRD* = 37,5), azaz jóval az előre megadott hibahatáron (5 %) belül van. A íz- tulajdonság helyezkedett el a legközelebb a maximum értékekhez, azaz ennek a tulajdonságnak volt a legnagyobb hatása a kedveltségre a módszerek értékelése alapján.

Az SRD-ábrája tovább fejleszthető, így még inkább alkalmazhatóvá válik a módszer a termékfejlesztésben és a JAR-adatelemezésben. Amennyiben a fogyasztók százalékban kifejezett gyakoriságértékeit az y-tengelyen vesszük fel, úgy a szignifikáns és (a fogyasztók számára) fontos terméktulajdonságok még könnyebben azonosíthatóak. Az így készült új ábra segítségével a fogyasztói igényeket még pontosabban értékelhetjük (34. ábra).



34. ábra: Az SRD és a fogyasztói gyakoriság eredmények egyesítése útján létrejött módosított SRD-ábra. A vastag fekete vonal jelzi a 20 %-os küszöbértéket, amelyet a penalty analysis-ben is általánosan alkalmaznak.

A 34. ábra két részre osztható az ábrán látható vastag fekete vonal alapján, amely a 20 %-os fogyasztói határértéket jelöli. Azon tulajdonságok, amelyeket a fogyasztók termékre jellemzőnek éreztek, a vonal felett helyezkednek el. Ezen tulajdonságok megváltoztatása a fogyasztók nagy arányánál jelentős kedveltségi pontszám növekedést vált ki. Az ábra értelmezése nagyon hasonló az SRD-ábrához, mivel amelyik tulajdonság SRD%-értéke alacsonyabb, mint az XX1 értéke, az a tulajdonság $\alpha = 0,05$ szinten szignifikánsnak tekinthető. Az SRD randomizációs tesztje alapján az XX1-től jobbra elhelyezkedő tulajdonságok nem tekinthetők szignifikánsnak. Az SRD-ábra nemcsak a fontosság alapján felállított sorrendet adja meg, hanem a véletlenszámokkal történő összevetés lehetőségét is. Ezek alapján az új ábrázolási mód megadja azokat a tulajdonságokat, amelyeket az érzékszervi vizsgálat során a fogyasztói bírálók fontosnak tartottak és azokat is, amelyeket az SRD-módszer szignifikánsként azonosított. Az eredmények alapján a íz- tekinthető a legfontosabb terméktulajdonságnak, így az ízintenzitás növelésével magasabb fogyasztói kedveltség érhető el. A ragadósság+ és a szín- tulajdonságokat csak egy kisebb számú fogyasztói csoport azonosította fontosságnak. Ezen fogyasztók elutasították a terméket, mivel túl ragadósak és gyenge

színintenzitásúnak találták. A fogyasztói értékelések nem voltak egybehangzóak a méret és sótartalom szempontjából, ezért az SRD-adatelemzés nem találta ezeket a tulajdonságokat szignifikánsnak. Ezek a tulajdonságok, noha a fogyasztók számára fontosak voltak, nem hatottak a kedveltségre szignifikánsan.

Az SRD-módszerrel kutatásomban sikeresen rangsoroltam a JAR-változókat egy referenciaoszlophoz viszonyítva (a módszerek maximumértékei), és azonosítottam a szignifikáns terméktulajdonságokat. Ezek alapján a terméktulajdonságok közötti rangsort is sikerrel állítottam fel. Az SRD-módszer segítségével megadható, hogy mely tulajdonságokat módosítsuk nagyobb fogyasztói kedveltség eléréséhez. A módszer további előnye, hogy a figyelembe vett JAR-adatelemzési módszerek könnyedén módosíthatóak, az eredmények értelmezése nem igényel komoly előképzettséget, illetve ingyenesen rendelkezésre áll felhasználóbarát felülettel.

Amennyiben a fogyasztói gyakoriságok adataival kibővítjük az eredeti SRD-ábrát, úgy a szignifikáns és a (fogyasztók számára) fontos terméktulajdonságok azonosíthatóak. Általánosságban elmondható, hogy a kidolgozott módszer gyakorlati előnye az, hogy több módszer eredményének figyelembevételével sokkal komplexebb kép kapható a terméktulajdonságokról, továbbá segítségével könnyedén lehet fókuszálni a legfontosabb tulajdonságokra a termékfejlesztés során.

5.3.3. Rangszámkülönbségek összege módszer JAR-adatelemző módszerek összehasonlítására

Az SRD-módszer jellegéből adódóan nemcsak a szignifikáns terméktulajdonságok vizsgálatára alkalmas, hanem a JAR-adatértékelő módszerek összhangjának megadására is. Kutatási kérdésem arra irányult, hogy a JAR-adatértékelő módszerek mennyire vannak összhangban, van-e eredményeikben különbség. Az SRD módszerével összehasonlítottam a JAR-módszereket, rangsort állítottam fel, hogy mely módszer tudja leginkább helyettesíteni a többit. A számításba bevont módszerek a következők voltak, ahol zárójelben a továbbiakban alkalmazott rövidítések, illetve a módszer alkalmazott paramétere: legkisebb négyzetek elvén alapuló regresszió (OLS, *t*-értékek), penalty analysis (Penalty, *mean drop* értékek), bootstrappelt penalty analysis (bPenalty, *mean drop* értékek), általánosított párkorrelációs módszer (GPCM, győztesek százalékos értékei), részleges legkisebb négyzetek elvén alapuló regresszió álváltozókkal (PLS-dummy, *t*-értékek), többszörös lineáris regresszió (MLR, *t*-értékek), JAR-átlaghoz igazított penalty analysis (wPAforJARMean, *mean drop* értékek), nagyjátlaghoz viszonyított súlyozott penalty analysis (wPAforGrandMean, *mean drop* értékek). Az SRD-számítás részletes eredményeit a 25. táblázatban látható és grafikus megjelenítését a 35. ábra mutatja be. Feltételeztem, hogy minden módszer értékeli a JAR-eredményeket, de csak bizonyos hibával terhelt. Jó megoldás az átlagok használata, mivel a

rendszeres és véletlen hibák, legalábbis részlegesen kiegyenlítik egymást. Az SRD-rangsor azt adja meg, hogy az egyes módszerek értékelése mennyiben tér el a vizsgálatba vont egyéb módszerek átlagos értékelésétől. A zérus pont reprezentálja a módszerek átlageredményét, mivel a referenciaoszlopba a sorok átlaga került. A módszerek konszenzusa alapján a zérus ponthoz legközelebbinek (legjobbnek) sorrendben a GPCM adódott (25. táblázat). A GPCM mellett az egyváltozós lineáris regresszió (*ordinary least squares regression*, OLS) eredménye is szignifikánsan eltér a véletlen értékeléstől. A többi módszer (ami az XX1-en túl van) különböző mértékben, de a véletlenszerű értékeléssel összemérhetően értékelte a tulajdonságokat.

25. táblázat: A JAR-módszerek rangsora és a véletlen rangsorolás valószínűsége.


Rangsor eredmények		p%		SRDmax=72
Név	SRD	x <SRD> =x		normSRD
GPCM	12	5,01E-03	7,68E-03	16,67
OLS	22	0,22	0,31	30,56
XX1	32	4,52	5,61	
MLR	38	12,10	14,34	52,778
PLS-dummy	40	16,83	19,60	55,556
Q1	42	22,61	25,88	
Penalty	44	29,38	33,07	61,11
bPenalty	44	29,38	33,07	61,11
Med	48	49,22	53,39	
Q3	55	72,84	76,19	
wPAforGrandMean	58	82,17	84,76	80,556
wPAforJARMean	60	87,09	89,17	83,33
XX19	64	93,93	95,09	

A félkövérral szedett módszerek szignifikánsak $p = 0,05$ szinten. A szürkével szedett sorok az 5 % (XX1), 25 % (Q1), 50 % (Med), 75 % (Q3) és 95 % (XX19) percentilisek.

A 25. táblázat SRD-oszlópa tartalmazza az egyes tulajdonságokra vonatkozó összegzett tulajdonságonkénti abszolút ragszámkülönbségeket (SRD-értékeket). A táblázat soraiban szereplő XX1 az 5 %-os, a Q1 az 25 %-os, a Med az 50 %-os, a Q3 a 75 %-os, míg az XX19 a 95 %-os percentilist jelöli. Amennyiben az adott JAR-módszerhez tartozó számított *normSRD*-érték kisebb, mint a véletlen értékelés eloszlásához tartozó 5 %-os percentiliséhez (XX1) tartozó elméleti valószínűségi sáv, akkor szignifikánsnak tekintjük a módszert az 5 %-os szignifikancia szinten. (A $p\%$ oszlop két valószínűségi értéket tartalmaz, az eloszlás diszkrét jellege miatt, az egyik biztosan az 5 %-os érték alatt a másik biztosan felette van.)

A 35. ábra alapján jellegzetes csoportosulásokat azonosítottam. Az MLR és PLS-dummy egymáshoz közel helyezkednek el, mert az átlagtól hasonlóan térnek el, ami annak tudatáig, hogy


mindkettő regressziós úton közelíti meg a problémát. Hasonló eset figyelhető meg a wPAfor-GrandMean és wPAfor-JARMean párnál. Míg a Penalty és bPenalty rangsorolása teljesen egyformának adódott.



35. ábra: A JAR-tulajdonságok skálázott SRD-értékei. A sorátlag értékeket alkalmaztuk a referencia oszlopban. A skálázott SRD-értékek láthatóak az x és y tengelyeken, a jobb y tengely a validáció során generált relatív gyakoriságokat mutatja (fekete görbe). Az 5 %-os (XX1), a Median (Med) és a 95 %-os (XX19) valószínűségi értékeket szürkével jelöltük.

A csoportosulások jól látszanak az ábrán (**35. ábra**). Az SRD-adatok hierarchikus klaszterelemzése során Euklideszi távolságot és Ward módszerét alkalmaztam. Az optimális klaszterszám meghatározásához a Silhouette- (Rousseeuw, 1987) és Dunn-indexet (Halkidi *et al.*, 2001) alkalmaztam. Az indexek eredményei alapján a háromklaszteres megoldás adódott a legcélravezetőbb klaszterezési számnak. Eredményeim alapján három egymástól elkülönülő csoportot határoztam meg: az első klaszter tagjai a GPCM és OLS, a második klaszterbe az MLR, PLS-dummy, a Penalty és bPenalty tartozik, míg a negyedik klasztert a wPAfor-GrandMean és wPAfor-JARMean alkotja.

Amennyiben az SRD-értékek bizonytalanságát is meghatározzuk, azaz egy többemű kihagyásos keresztellenőrzést végzünk, és a bizonytalanságokat doboz-bajusz-ábrán ábrázoljuk, úgy a mediánok és szórások átfedése alapján vizsgálhatjuk az egyes csoportokat (**36. ábra**).



36. ábra: A validáció után futtatott SRD-elemzés hierarchikus klaszterelemzése euklideszi távolság és Ward-módszer alapján. A szaggatott vörös vonal pontos pozíciója nem ismert (~40 és ~120 között), az optimális klaszterszám meghatározására szolgál, amelyet Silhouette- és Dunn-indexek alapján számítottam.


Egy csoportba azok kerültek, ahol a mediánok és a szórások is átfedtek. Az eredmények számszerű értékeléséhez az ismeretlen rangsor páronkénti szignifikáns differenciáinak összevetését előjel-próbával határoztam meg (26. táblázat). Így a klaszterelemzést megalapozó, de annál érzékenyebb, statisztikailag igazolható eredményt kaptam.

26. táblázat: Az ismeretlen rangsor páronkénti szignifikáns differenciáinak összevetése előjel-próbával az SRD-LOO-értékek alapján (p-értékek és Z-értékek).

	OLS	Penalty	bPenalty	GPCM	PLS-dummy	MLR	wPAforJARMean	wPAforGrandMean
OLS	-	3,328201	3,328201	3,328201	3,328201	3,328201	3,328201	3,328201
Penalty	0,000874	-	0	3,328201	2,020726	2,84605	3,328201	3,328201
bPenalty	0,000874	1	-	3,328201	2,020726	2,84605	3,328201	3,328201
GPCM	0,000874	0,000874	0,000874	-	3,328201	3,328201	3,328201	3,328201
PLS-dummy	0,000874	0,043308	0,043308	0,000874	-	1,581139	3,328201	3,328201
MLR	0,000874	0,004427	0,004427	0,000874	0,113846	-	3,328201	3,328201
wPAforJARMean	0,000874	0,000874	0,00874	0,000874	0,000874	0,000874	-	0,353553
wPAforGrandMean	0,000874	0,000874	0,00874	0,000874	0,000874	0,000874	0,723	-

A táblázatban félkövérrel jelöltem a szignifikáns különbségeket ($p < 0,05$).

Öt egymástól elkülönülő csoportot határoztam meg sorrendben a legkisebb SRD értékűtől kezdve a GPCM szignifikánsan különbözik, jobb az OLS-nél, ami jobb, mint az MLR és PLS-dummy csoportja (amelyek nem különböznek szignifikánsan egymástól), ezektől is szignifikánsan különbözik a Penalty és bPenalty csoportja, míg az ötödik a wPAfor-GrandMean és wPAfor-JARMean csoportja lett, amit a **37. ábra** is szemléltet.



37. ábra: Az LOO-validáció után futtatott SRD-elemzés doboz-bajusz-ábrája.

Az SRD-módszer gyorsan, hatékonyan állít fel sorrendet a módszerek között. A vizuálisan is megjelenített eredmények azt mutatták, hogy a módszerek konszenzusa alapján a GPCM-et vagy az OLS-t válasszuk a vizsgált módszerek közül. Ez a két módszer került szignifikánsan közel a módszerek konszenzusát jelentő, átlageredményét reprezentáló zérus ponthoz ($normSRD=0$). A többi módszer nem adódott szignifikánsnak – bár sorrendjük hordoz információt – nem különböztethető meg a JAR-tulajdonságok véletlen értékelésétől.

A $normSRD$ -értékei távolságokként történő értelmezésével a klaszteranalízis dendrogramban történő vizualizációja is hasonló eredményt adott. A JAR-módszerek nem skálázott SRD-eredményeinek doboz-bajusz-ábrában történő grafikus ábrázolásával azonosítottam a módszerek csoportok közötti és csoporton belüli viszonyait is. Az előjel-próba páronkénti szignifikáns differenciái megerősítették ezeket a grafikus eredményeket.

A módszerek azonos csoportokba kerültek, az SRD doboz-bajusz-ábrája és a klaszterelemzés alapján is. Amennyiben nem a klaszterezési indexek alapján, hanem empirikus úton vágjuk a dendrogramot, úgy az előjel-próba eredménye is ugyanazt adja, mint az 5 klaszteres megoldás (amennyiben a 20-as kötési távolságnál (*linkage distance*) vágjuk a dendrogramot, úgy az előjel-próba eredményeihez jutunk). Ez azonban csak a csoportosulást tekintve helytálló. Hogy melyik modell a legjobb, melyik tudja helyettesíteni az összes többi, az a klaszteranalízis segítségével nem megállapítható. Ezt az SRD-érték nagysága határozza meg.

A JAR-adatokat értékelő többi módszerrel kapcsolatban megállapítható, hogy a bPenalty és a Penalty szignifikánsan nem különbözik az normSRD alapján, így a bootstrap előnyeit itt nem lehetett érvényesíteni. A két módszer közötti különbség csak a 4. tizedestől fejeződik ki. A wPAfor-GrandMean és wPAfor-JARMean az normSRD-értékek alapján gyengébben teljesített, mint az eredeti penalty analysis. Eredményeim felhívják a figyelmet arra, hogy JAR-változók kiválasztásához vagy több módszert alkalmazzunk együttesen (kihasználva a módszerek közötti konszenzus lehetőségét az SRD-módszerrel), vagy pedig a GPCM használata (esetleg OLS) ajánlható.

5.4. A szemkamerás mérések eredményei

5.4.1. Túléléselemzés alkalmazása a döntési idő vizsgálatára

A döntési idő vizsgálata során első lépésben egyszempontú varianciaanalízist (*one-way analysis of variance*, ANOVA) alkalmaztam, amely alapján a döntésig eltelt idő hossza szignifikánsan különbözött a nyolc termék kategória között (27. táblázat). Az ANOVA futtatása előtt ellenőriztem az adatok normál eloszlását és a varianciák homogenitását. Az üdítőitalok esetében figyeltem meg a legrövidebb döntési időt 4,7 másodperces átlaggal, míg az instant levesek esetében a 6,7 másodperces átlagérték adódott a leghosszabbnak.


27. táblázat: A döntési idők ismételt mérés ANOVA eredményei és átlagértékei az egyes termék csoportokra lebontva ($F(1;58)=274,36$; $p < 0,001$), páronkénti összehasonlítás Tukey-HSD alapján.

Minta	Átlag	Szórás	Szignifikáns különbségek
Üdítőital	4,677	0,455	A
Saláta	5,554	0,354	B
Virslí	5,577	0,450	B
Alma	5,764	0,494	B
Csokoládé	5,834	0,426	B
Kenyér	5,901	0,440	B
Sör	6,308	0,483	B C
Instant levespor	6,668	0,516	C

A varianciaanalízis során az egyéneket az átlagtól való eltérés alapján tudjuk jellemezni. Ezzel szemben a túléléselemzés során a kezdőpillanattól a döntésig eltelt idő alapján tudjuk ábrázolni, elemezni és összehasonlítani mind a résztvevőket, mind pedig a termékeket. A modell felállítása során az első egérkattintástól (első találkozás a termékekkel) a döntés meghozatalát jelző második kattintásig eltelt időket vizsgáltam. Cenzorálásra nem volt szükség, mert minden résztvevő hozott döntést a vizsgált időintervallum végéig. A logisztikus eloszlás paraméterei alapján illesztettem az

adatokat Kaplan-Meier-módszerrel, ahol a kattintásig eltelt idő és a döntésüket meghozók arányát számítottam.

A **38. ábra** alapján láthatóak a termékekre készített túlélési görbék, amelyek közül az üdítőitalok görbéje a legmeredekebb. Ez azt jelenti, hogy itt volt szükség a legrövidebb időre a döntést meghozni. A görbék mediánjainak összevetésével a görbék első felét lehet jellemezni. Az elemzés során az üdítőitaloknál figyeltem meg a legalacsonyabb medián értéket (3,70 s). 5 másodpercnél alacsonyabb medián értékeket találtam a csokoládé (4,66 s), a virsli (4,79 s) és a saláta (4,84 s) termékek esetében. Hosszabb időre volt szükség az almák (5,13 s) és a sörök (5,16 s) vizsgálatakor a döntés meghozatalára. A legmagasabb medián értékeket azonban a kenyerek (5,42 s) és az instant levesek (5,89 s) vizsgálatakor találtam. Az eredmények alapján látható, hogy a résztvevőknek nagyjából másfélszer több időre volt szüksége a kenyerek és instant levesek kiválasztására, mint az üdítőitalok esetében.



38. ábra: A résztvevők adataiból elkészített túlélési függvények (n=59). Az illesztés Kaplan-Meier-módszerrel történt a kattintásig eltelt idő és a döntésüket meghozók arányát alapján.

A különbségek statisztikai elemzését a Gehan-féle általánosított Wilcoxon-próbával végeztem el (28. táblázat). A táblázat alapján szignifikáns különbséget találtam az üdítőitalok és majdnem az összes többi termék között. További eredmény, hogy a virslitermékek döntési ideje szignifikánsan alacsonyabb volt, mint az instant levesek esetében megfigyelt értékek. Az eredmények alapján

megállapítható, hogy a résztvevőknek szignifikánsan rövidebb időre volt szüksége az üdítőitalok kiválasztására, mint a többi terméknél.

28. táblázat: A túlélési függvények szignifikáns különbségei az alkalmazott Gehan-féle általánosított Wilcoxon-próba alapján.

	Alma	Sör	Kenyér	Üdítő	Csokoládé	Saláta	Levespor	Virslis
Alma	-	1,1249	-0,3363	2,3897	-0,3660	-0,2556	-1,7088	0,4024
Sör	0,2606	-	0,5813	3,4366	0,8288	1,0011	-0,5920	1,4363
Kenyér	0,7365	0,5610	-	2,7585	0,7535	0,1803	-1,3805	0,7781
Üdítő	0,0168	0,0005	0,0058	-	-2,6346	-2,7046	-4,1524	-1,8869
Csokoládé	0,7143	0,4071	0,9399	0,0084	-	0,1830	-1,3724	0,6145
Saláta	0,7982	0,3167	0,8569	0,0068	0,8548	-	-1,6012	0,5126
Levespor	0,0874	0,5538	0,1674	0,0001	0,1699	0,1093	-	1,9656
Virslis	0,6873	0,1509	0,4364	0,0591	0,5388	0,6081	0,0493	-

A félkövérrel szedett értékek $\alpha=0,05$ szinten különböznek nullától. A táblázat felső háromszögében a Gehan-féle próbastatisztika eredményei, míg az alsó felében a p-értékek láthatóak.

Az eredmények további értelmezése során túléléselemzéssel összehasonlítottam az üdítő-termékcsoport négy termékét is (29. táblázat). Az eredmények alapján az első üdítőtermék kiválasztása adta a legalacsonyabb mediánt, azonban a Gehan-féle általánosított Wilcoxon-próba ezt a különbséget nem tudta szignifikánsan igazolni.


29. táblázat: A négy üdítőital-termék döntési idejének leíró statisztikái.

Termék	Medián	Átlag	Szórás.	Total N
Üdítő 3	3,91	4,81133	2,60626	15
Üdítő 4	3,7	4,57539	3,59394	13
Üdítő 2	3,62	4,06545	1,46551	11
Üdítő 1	3,26	4,89524	4,65103	20
Total	3,695	4,65283	3,46825	59

A túléléselemzés alapján vizsgált döntési idők eredménye az ANOVA-hoz hasonlóan kiemelte, hogy a résztvevők gyorsabban választottak az üdítők közül, mint a többi termék közül. Az ANOVA eredménye ezen felül még két csoportot különített el, a többi terméktől szignifikánsan hosszabb döntési időt társított az instant levespor terméknek. Ezeket az eredményeket nem támasztotta alá sem a túléléselemzés, sem a kapott diagramok vizuális elemzése. Az adatok összesítő statisztikájának elemzésekor megfigyelhető, hogy minden termék esetében a résztvevők 88,1 – 93,2 %-a 10 másodperc alatt tudott döntést hozni. Amennyiben az adatok közt van olyan résztvevő, akinek a többiekhez képes sokkal hosszabb időre van szüksége (a leggyakoribb 10 másodpercnél rövidebb idő helyett 20-25 másodperc), úgy az átlag alkalmazása torzíthatja a minták közti különbségeket. Ennek kivédésére a nemparaméteres megközelítés és a túléléselemzés alkalmazása javasolt.

5.4.2. A szemmozgás és a döntés közti kapcsolatok

Az étel-miszer-választással kapcsolatos szemkamerás vizsgálatok egyik alapvető kérdése, hogy a szemkamera segítségével mérhető, szemmozgást leíró változók közül melyik milyen kapcsolatban áll a döntéssel, vagyis a választott étel-miszerrel. Bécsi kutatásaim második lépésében a szemkamera változói és a választás közti kapcsolatok feltárására fókuszáltunk. A vizsgált termékek közül legalább négy alkalommal minden terméket megjelöltek a résztvevők, és emellett statisztikailag szignifikáns különbségeket találtunk a nyolc termékcsoporthoz öt esetben a választási gyakoriságok között (39. ábra). A sörök és a saláták esetében ezek a különbségek kiemelkedőek voltak, ugyanis volt olyan termék a négy között, amelyet a résztvevők kevesebb mint 10 %-a választott.



39. ábra: A választások gyakorisága a nyolc döntési szituációban. Minden esetben négy termék közül kellett a leginkább kedveltet kiválasztani. A szignifikáns különbségeket * jelzi: * $p < 0,05$ ** $p < 0,01$ és *** $p < 0,001$.

Az ismételt mérés varianciaanalízis (*repeated measures analysis of variance*, RMANOVA) eredményei alapján (30. táblázat) a termék szignifikáns hatással volt a szemmozgásra a csokoládé ($p < 0,001$), a saláta ($p = 0,001$), az üdítőital ($p < 0,001$) és a leves ($p < 0,001$) esetében. Erős szignifikáns interakciót figyeltünk meg a termék és a választás között mind a nyolc termék kategóriában. Az RMANOVA futtatása előtt ellenőriztem az adatok normál eloszlását, a kiugró adatok szűrését, a függő változók korrelációját, a multikollinearitást és a varianciák homogenitását.

30. táblázat: *RMANOVA* eredményei, ahol függő változóként az első fixációig eltelt időt (*time to first fixation* - *TTFF*), első fixáció hosszát (*first fixation duration* - *FFD*), fixációk hosszát (*fixation duration* - *FD*), fixációk számát (*fixation count* - *FC*), látogatások hosszát (*total dwell duration* - *DD*) és a látogatások számát (*dwell count* - *DC*) határoztuk meg, míg csoportokon belüli faktorként a terméket, csoportok közötti faktorként a választást.

		Alma	Sör	Kenyér	Csokoládé	Instant levespor	Saláta	Virslis	Üdítőital
Faktor	Sz.f.	F-érték	F-érték	F-érték	F-érték	F-érték	F-érték	F-érték	F-érték
Termék	(18,38)	0,989	1,511	0,565	4,561***	2,655**	3,18**	1,356	2,128***
Választás	(18,156)	0,983	1,232	0,835	0,937	0,764	1,117	0,919	1,069
Termék*Választás	(54,120)	3,423***	2,452***	4,345***	2,781***	1,803***	2,333***	2,210***	2,703***

A szignifikáns különbségeket * jelzi: * $p < 0,05$, ** $p < 0,01$ és *** $p < 0,001$.

Az eredmények részletes elemzése során az egyváltozós próbák eredményei (31. táblázat) alapján a termék szignifikáns hatással volt a TTFF-re ($p = 0,007$) a sör esetében és az FD-re ($p = 0,03$) a csokoládé esetében. További szignifikáns termékhatást figyeltünk meg az FC-n és DC-n a saláta ($p = 0,006$; $p = 0,003$) és a virslis ($p = 0,034$; $p = 0,035$) esetében is (31. táblázat). A hatásokat tovább elemezve megállapítottuk, hogy a legtöbb esetben a *post-hoc* tesztek (Tukey HSD és Sheffé-próbák) nem mutattak ki határozott szignifikáns különbségeket.

Több szemkamerás paraméter esetében is szignifikáns interakciót figyeltünk meg a termék és a választás között, például: TTFF, FD, FC, DD és DC (31. táblázat). Az utóbbi három paraméter erős szignifikáns hatást mutatott mind a nyolc termékcsoporthoz esetében ($p < 0,001$ minden esetben, kivéve az üdítőitalokat, ahol $p = 0,003$ az FC-nél, $p = 0,002$ a DD-nél és $p < 0,001$ a DC-nél). Az eredmények alapján a választott és a nem választott termékekre fordított vizuális figyelem közötti különbségek jól elkülöníthetők. Összefoglalóan tehát a választott termék (szignifikánsan) nagyobb vizuális figyelmet kapott.

31. táblázat: RMANOVA változónkénti (UNIANOVA) eredményei, ahol függő változóként az első fixációig eltelt időt (time to first fixation - TTFF), első fixáció hosszát (first fixation duration - FFD), fixációk hosszát (fixation duration - FD), fixációk számát (fixation count - FC), látogatások hosszát (total dwell duration - DD) és a látogatások számát (dwell count - DC) határoztuk meg, míg csoportokon belüli faktorként a terméket, csoportok közötti faktorként a választást.

Hatás	Szemkamera paraméter	Sz.f.	Alma	Sör	Kenyér	Csokoládé	Instant levespor	Saláta	Virslis	Üdítőital
			F-érték	F-érték	F-érték	F-érték	F-érték	F-érték	F-érték	F-érték
Termék	TTFF	(3,165)	2,395	4,162**	0,063	1,065	1,266	0,806	0,246	0,367
	FFD	(3,165)	0,413	0,813	0,155	0,925	1,059	2,296	0,186	1,321
	FD	(3,165)	0,326	1,279	,079	3,043*	0,605	0,223	0,895	0,964
	FC	(3,165)	0,338	0,208	1,800	1,820	4,393**	4,353**	2,959*	1,145
	DD	(3,165)	0,280	0,621	1,032	1,332	4,182**	2,870*	1,958	0,526
	DC	(3,165)	2,167	0,071	0,800	0,101	5,721**	4,733**	2,928*	1,914
Termék* Választás	TTFF	(9,165)	0,862	2,722***	0,588	0,622	1,145	0,497	0,68	0,419
	FFD	(9,165)	1,189	1,490	0,964	1,669	0,468	1,303	1,645	0,636
	FD	(9,165)	2,872**	0,454	4,625***	1,78	0,594	0,662	1,067	2,596**
	FC	(9,165)	9,364***	6,261***	1,304***	5,891***	6,236***	4,041***	5,157***	2,901**
	DD	(9,165)	13,695***	8,185***	14,85***	6,289***	8,063***	3,803***	5,64***	3,098**
	DC	(9,165)	9,866***	6,001***	11,95***	6,169***	6,572***	4,007***	5,305***	5,113***

A választás faktor eredményei nem szerepelnek a táblázatban, mivel az RMANOVA nem mutatott szignifikáns különbségeket. A szignifikáns különbségeket * jelzi: * $p < ,05$, ** $p < ,01$ és *** $p < ,001$.

A nyolc termékre kapott fixációk számának vizsgálata során 32 esetből 31 esetben a választott termékre több fixációt rögzítettünk, mint a nem választott termékre. A részletes eredményeket a 32. táblázatban tüntettük fel. 17 esetben a csoportokon belüli kontraszt megadta, hogy a választott termékre szignifikánsan több fixáció érkezett, mint a másik három termékre. Összefoglalóan megállapítható, hogy a választott termék nagyobb vizuális figyelmet kapott a fixációk számát tekintve.


A látogatások hosszának elemzése hasonló eredményeket adott, mint a fixációk számának vizsgálata. 32 esetből 31-ben hosszabb ideig szemlélték a választott terméket, mint a többi terméket. 24 esetben volt szignifikáns ez a különbség. Összefoglalóan megállapítható, hogy a fixációk számához hasonlóan, a választott termék nagyobb vizuális figyelmet kapott a látogatások hosszát tekintve: 32 esetből 31-ben több alkalommal fixálták a választott terméket, mint a több terméket. 20 esetben a választott terméket szignifikánsan többször látogatták meg, mint a másik három terméket. Kijelenthetjük, hogy a választott termék nagyobb vizuális figyelmet kapott a látogatások számát tekintve.

32. táblázat: A szemmozgás és a választás összefüggései. A szürke cellák jelölik az adott szemkamera-paraméter legmagasabb értékét. A csoportok közti különbségeket kontrasztok számításával igazoltuk. A szignifikáns különbségeket * jelzi: * $p < ,05$, ** $p < ,01$ és *** $p < ,001$.

		Szemkamera paraméterek															
		Látogatások hossza [s]				Fixációk száma [n]				Látogatások száma [n]							
		Termék 1	Termék 2	Termék 3	Termék 4	Termék 1	Termék 2	Termék 3	Termék 4	Termék 1	Termék 2	Termék 3	Termék 4				
		Termék 1	Termék 2	Termék 3	Termék 4	Termék 1	Termék 2	Termék 3	Termék 4	Termék 1	Termék 2	Termék 3	Termék 4				
Választás	Alma	Termék 1	2,37**	1,21	0,97	0,86	6,70*	3,90	3,40	3,30	3,10*	2,40	1,90	2,00			
		Termék 2	0,81	1,52*	1,04	0,95	3,20	5,10*	3,40	3,50	2,00	3,00*	1,60	2,00			
		Termék 3	0,68	0,75	1,92**	0,75	2,36	2,64	5,00*	2,91	1,73	1,82	2,82*	1,64			
		Termék 4	0,89	0,85	0,69	1,88***	3,32	2,96	2,46	5,29***	2,07	2,04	1,64	2,71***			
	Sör	Termék 1	1,74*	0,89	1,18	0,97	5,85	3,40	5,05	3,75	2,70	1,50	2,30	1,75			
		Termék 2	1,38	2,22*	1,19	1,25	5,40	6,80	4,80	4,80	2,60	3,40	2,40	2,40			
		Termék 3	0,85	1,01	1,58*	0,85	3,18	3,59	5,00*	3,59	1,86	2,00	2,32	1,86			
		Termék 4	0,93	1,49	1,07	2,25**	4,08	5,17	4,67	7,50**	2,17	2,17	2,17	3,08**			
	Kenyér	Termék 1	2,28***	0,84	1,08	1,20	5,96**	3,00	3,69	3,89	2,89***	1,65	1,77	1,85			
		Termék 2	0,57	2,86*	0,80	1,13	2,38	9,25*	3,50	3,88	1,25	3,00*	1,63	1,88			
		Termék 3	0,67	0,82	1,78***	0,54	2,56	2,81	5,25***	1,94	1,56	1,56	2,56***	1,38			
		Termék 4	0,80	0,75	0,69	2,00***	2,89	3,11	2,44	6,44***	1,56	1,89	1,44	2,44			
	Csokoládé	Termék 1	1,54*	0,95	1,02	0,89	6,467*	4,47	4,13	4,53	2,73**	2,13	1,93	1,67			
		Termék 2	1,08	1,20	0,83	0,75	4,27	5,07	3,60	3,53	1,80	2,27	1,80	1,67			
		Termék 3	0,98	0,65	1,93**	1,09	4,05	2,96	6,32*	4,32	1,50	1,36	2,27**	1,55			
		Termék 4	1,72	1,60	1,05	2,77*	5,14	6,29	4,71	11,43*	2,29	2,29	2,29	3,29			
	Instant levespor	Termék 1	1,71	1,46	1,08	1,10	6,48	5,89	5,04	4,48	2,48**	1,81	1,56	1,48			
		Termék 2	0,83	2,33*	0,95	1,16	3,56	8,67	5,00	5,00	1,78	2,44*	1,89	2,00			
		Termék 3	0,90	1,41	2,03*	1,35	3,82	5,46	7,64	5,73	1,73	1,82	2,72**	1,91			
		Termék 4	1,15	1,32	1,41	2,45**	4,33	5,58	4,92	9,50*	1,83	1,67	1,58	2,17			
	Saláta	Termék 1	1,40*	0,65	0,99	0,75	4,83*	2,67	3,33	2,22	2,61*	2,11	2,11	1,67			
		Termék 2	1,04	1,49*	0,97	0,86	3,69	4,76*	3,48	2,93	2,21	2,93**	2,14	1,66			
		Termék 3	1,39	0,75	1,64	0,72	5,38	2,88	5,50	2,63	3,25	2,00	3,25	1,75			
		Termék 4	0,95	0,88	1,67	1,37	3,00	3,50	5,25	4,25	1,75	1,75	2,00	2,00			
	Virslis	Termék 1	1,15*	0,84	0,63	0,76	3,87	3,67	2,73	2,93	2,40*	2,07	1,67	1,60			
		Termék 2	1,23	2,16**	1,20	1,13	4,60	7,95**	4,80	4,30	2,75	3,55***	2,30	2,35			
		Termék 3	0,81	1,10	1,73*	0,78	3,29	4,41	6,29	3,00	2,06	2,12	2,71	1,88			
		Termék 4	0,61	0,60	0,65	0,88	2,57	2,57	2,29	3,86	1,71	1,57	1,43	2,00			
	Üdítőital	Termék 1	1,40	0,48	1,07	0,59	4,15	2,35	3,60	2,60	2,50*	1,50	1,95	1,70			
		Termék 2	0,73	1,25*	0,52	0,57	3,18	4,27	2,27	2,27	1,82	2,27*	1,46	1,27			
		Termék 3	0,95	0,64	1,04	0,72	3,33	2,53	3,87	2,27	1,80	1,40	2,27*	1,33			
		Termék 4	0,66	0,86	0,64	1,17	3,15	3,15	2,62	4,08	1,92	1,77	1,77	2,54			

A Binomiális-próba eredménye nem adódott szignifikánsnak, vagyis a négy vizsgált termékcsoport esetében nem lehetett bizonyítani ($p > 0,05$), hogy az először fixált terméket nagyobb valószínűséggel választották, mint a többi (40a. ábra). Az eredmények alapján tehát nem igazolható, hogy az először fixált termékre nagyobb valószínűséggel esik a választás, mint a többi termékre

Az utoljára fixált termék és a választott termék 69 % (saláta) és 88 % (kenyér) közötti értékeket mutatott (40b. ábra). A Binomiális-próba ebben az esetben szignifikánsnak adódott ($p < 0,001$) a nyolc termékcsoportra. Összefoglalóan tehát az utoljára fixált termékre nagyobb valószínűséggel esik a választás, mint a többi termékre.



40. ábra: a.) Az először fixált termék és a választott termékek százalékos összevetése a termékcsoportok között.
b.) az utoljára fixált termék és a választott termékek százalékos összevetése a termékcsoportok között.

Az RMANOVA eredményei alapján (lásd. 30. táblázat és 31. táblázat, illetve 39. ábra) a szemmozgás és a választás közti kapcsolat szoros volt a nyolc vizsgált termékcsoport esetében. Ennek ellenére kisebb eltérések figyelhetők meg a salátatermékeknél, különösen akkor, amikor a 4. saláta terméket választották a megkérdezettek (32. táblázat). Összefoglalóan tehát a szemmozgás és a választás közti kapcsolat független a termékcsoportoktól.

Lineáris diszkriminanciaelemzéssel (*linear discriminant analysis*, LDA) predikciós modellt hoztam létre, amellyel a választott terméket jeleztem előre a szemmozgás adatok felhasználásával. Az LDA futtatása előtt ellenőriztem a változók normál eloszlását, a változók közti korrelációt, teszteltem a szóráshomogenitást, illetve a maradékok normál eloszlását. Annak érdekében, hogy növeljem az utoljára fixált termékből történő előrejelzés pontosságát, további változókat vontam be a modellbe: fixációk száma, látogatások száma és látogatások hossza. A változókat előrelépéses kiválasztáson alapuló változószelekció segítségével választottam ki. A bevont változók mind a nyolc

termékkategória esetében szignifikánsnak adódtak (33. táblázat). Az általánosítás megőrzése miatt minden termékcsoportban ugyanezeket a változókat alkalmaztam. Az eredmények alapján az LDA-val készített modell nagyobb találati arányt ért el, mint az utoljára fixált termékből történő előrejelzés (33. táblázat). A legnagyobb különbséget a saláta esetében találtam, ahol mindössze 69,4 % pontossággal jelezte előre a választást az utoljára fixált termék, noha az LDA 88,1 % pontossággal tette ugyanezt. A legkisebb különbséget az üdítőital esetében találtam, ahol az LDA mindössze 1,8 %-kal mutatott jobb teljesítményt (81,4 %). Az eredmények alapján az utoljára fixált termék alapján végzett előrejelzés találati aránya javítható több szemmozgás-változó bevonásával és lineáris diszkriminanciaelemzés alkalmazásával.

33. táblázat: Az utolsó fixációból előrejelzett választás és a lineáris diszkriminanciaelemzés (LDA) által előrejelzett eredmények összehasonlítása. Az LDA-modell az FC, DD, DC és LF változókat használta a választás előrejelzésére.

Termékcsoport	Utolsó fixáció helye	LDA
Alma	84,7 %	89,8 %
Sör	74,5 %	84,7 %
Kenyer	88,1 %	98,3 %
Csokoládé	78,0 %	83,1 %
Instant levespor	76,2 %	79,7 %
Saláta	69,4 %	88,1 %
Virsli	74,5 %	81,4 %
Üdítőital	79,6 %	81,4 %

Az eredményeink alapján megállapítottam, hogy erős kapcsolat áll fenn a szemmozgás és a választás között. A választott termék nagyobb vizuális figyelmet kap, amely a fixációk számában, a látogatások számában és a látogatások hosszában is megjelenik. Az eredmények (33. táblázat) alátámasztják és igazolják mind a három vizsgált paramétert. Ezek az eredmények összhangban vannak az Orquin és Mueller Loose (2013) által összegzett kutatások eredményeivel, illetve a Jantathai, Danner, Joechl, és Dürschmidt (2013) által publikált eredményekkel is. A három vizsgált paraméter közül (fixációk száma, látogatások hossza és látogatások száma), a látogatások hossza adta a leghatározottabb eredményt, miszerint a választott termékre nagyobb vizuális figyelem irányul.

Nem tudtuk bizonyítani, hogy az első alkalommal fixált terméket nagyobb valószínűséggel választják ki a résztvevők, mint a többi terméket. Az eredmények ellentétben állnak Schotter, Berry, McKenzie, és Rayner (2010), illetve Glaholt és Reingold (2012) eredményeivel, akik úgy találták, hogy az első alkalommal fixált terméket nagyobb valószínűséggel választják a résztvevők. Ezzel szemben Laura N. van der Laan, Hooge, de Ridder, Viergever, és Smeets (2015) eredményei összhangban vannak a kutatásunk eredményeivel.

Az utolsó fixáció és a választott termék egyezőségéről kapott megfigyelt gyakoriságok **(40b. ábra)** 88 %-os értéket adtak a kenyér és 69 %-os értéket a saláta termékcsoporthoz. A többi termék az előbbi két érték közti értékeket mutatott. Az eredmények a véletlen megegyezéshez viszonyítva (25 %) jelentősen magasabbak lettek. Ezek alapján Orquin és Mueller Loose (2013) eredményeit is alátámasztja kutatásunk.

Az utoljára fixált termékre nagyobb valószínűséggel esik a választás, mint a többi termékre. A saláta termékek esetében figyeltünk meg eltéréseket, különösen akkor, amikor a válaszadók a negyedik terméket választották mint legkedveltebb termékalternatívát. Ezt a fogyasztói csoportot részletesebben elemezve kiderült, hogy a fogyasztók kevesebb mint 10 %-a választotta a negyedik terméket. Ilyen kis elemszámnál azonban nem lehet egyértelműen megállapítani, hogy vajon ezeket az eltéréseket a termékek külleme okozta vagy pedig más egyéb jellemző.

A lineáris diszkriminanciaelemzés eredményei alapján egyértelműen látszik, hogy a módszer alkalmas a fogyasztói választás előrejelzésére. Az eredmények jobb predikációs képességet mutatnak, mint az utolsó fixáció helyéből történő előrejelzés. Az LDA-modell a választást 79,7 % - 98,3 % közötti pontossággal jelezte előre a nyolc vizsgált termékcsoporthoz, így az eredmények általánosan helytállóak.

Kutatásunkban a vizuális ingert ismert és hasonló kedveltségű termékek szolgáltatták. Jövőbeni kutatásokat célszerű úgy végezni, hogy a fent említett tényezőket ellenőrzött körülmények között különböző változatokban prezentáljuk a résztvevőknek. További kutatási kérdés, hogy az egyetemistákhoz képest milyen eltérések figyelhetők meg az idősebbek, a gyerekek és az étkezési problémákkal küzdők csoportjai között. A lineáris diszkriminanciaelemzésen kívül további modellek tesztelése (döntési fák, neurális hálók stb.) szükséges annak megállapítására, hogy melyik modellt célszerű szemkamera adatokon alkalmazni.

A multialternatív döntési szituációk során vizsgált szemmozgásadatok elemzése során erős korrelációt mutattunk ki a választás és a szemkamerával rögzített szemmozgásadatok között, amelyek a több fixáció, a hosszabb látogatási idő és több látogatás formájában nyilvánultak meg. Nem találtunk szignifikáns összefüggést az első fixáció helye, az első fixációig eltelt idő és az első fixáció hossza és a választás között. Eredményeink a nyolc termék kategóriában minden termékcsoporthoz azonosnak adódtak.

5.4.3. A választást előrejelző modellek összehasonlítása

A szemkamera által mért változók döntésre gyakorolt hatásának vizsgálata során további kutatási kérdésként merült fel, hogy amennyiben sikeresen előre lehet jelezni a változókból az élelmiszerválasztást, akkor azt milyen módszerrel lehet a legpontosabban megtenni. A módszerek alkalmasságának elemzésekor még szélesebb kép kapható a választás és a változók közti összefüggésekről.

Az adatelemzés első lépésében Fisher-féle és Relief-F változószelekciós eljárásokat (eljárás, amely megadja, hogy mely változókat tartsuk meg egy predikciós modell felállításához) alkalmaztam az adatelemzés megkezdése előtt, hogy kiválasszam azt a redukált változóhalmazt, amelyek a legjobban leírják a függő változó (fogyasztói döntés) és a független változók (szemkameraadatok) közötti kapcsolatot. A változók kiválasztása során azokat a közös változókat hagytam az adatelemzésben, amelyek mindkét változókiválasztási módszer szerint a legfontosabbak között voltak.

A második lépésben tizenhárom predikciós modell (k -legközelebbi szomszédok elvén alapuló klasszifikáció (KNN), iteratív elkülönítés 3 algoritmus (ID3), célfüggvényes döntési fák algoritmus (CSMC4), Quinlan-féle C4.5-ös döntési fák algoritmus (C4.5), célfüggvényes osztályozási fa (CSCTR), random döntési fa (RND), részleges legkisebb négyzetek elvén alapuló diszkriminanciaelemzés (PLS-DA), lineáris diszkriminanciaelemzés (LDA), többrétegű perceptron neurális hálózat (MLP), naive Bayes féle becslés folytonos változóra (NBC), radiális alapfüggvényekből álló neurális hálózat (RBF), prototype legközelebbi szomszéd elvén alapuló neurális háló (PNN) és multinomiális logisztikus regresszió (MLoR)) tréningelése és tesztelése történt, amelyekkel egytől egyig a fogyasztói választást jeleztem előre a Relief-F és a Fisher-féle változószelekciós eljárás során meghatározott változókkal (34. táblázat). A fenti tizenhárom modell kiválasztása során az alábbi szempontokat vettem figyelembe:

- 1) kezelje a kategóriaskálán mért függő változót,
- 2) legyen általánosan elérhető és
- 3) ugyanazon teljesítményjellemzők számíthatóak legyenek minden esetben.


34. táblázat: Az alkalmazott modellek általános jellemzői

	Számítási időigény	Bemenő adatok	Főbb előnyök	Főbb hátrányok	Átlános pontosság	Magyarázó képesség, az osztályozás átláthatósága	Típus
KNN	nagyon nagy	folytonos	egyszerű, könnyű kivitelezhetőség	érzékeny a zajos, sokdimenziós adatokra	magas	jó	példa alapú tanulás
ID3	közepes	folytonos/diszkrét	rekurzív algoritmus	nem kezeli a hiányzó adatokat	közepes	kiváló	logika alapú tanulás
CSMC4	közepes	folytonos/diszkrét	ferde eloszlású adatokat is kezel	könnyen félreosztályoz	közepes	kiváló	logika alapú tanulás
C4.5	nagyon nagy	folytonos/diszkrét	magas dimenziószámot, hiányzó és a zajos adatokat is jól kezel	összetett, nagy fa	közepes	kiváló	logika alapú tanulás
CSCRT	közepes	folytonos/diszkrét	ferde eloszlású adatokat is kezel	könnyen félreosztályoz	alacsony	kiváló	logika alapú tanulás
RND	közepes	folytonos/diszkrét	alacsony hibával dolgozik	gyakran bonyolult szabályrendszer	magas	kiváló	logika alapú tanulás
PLS-DA	alacsony	folytonos/bináris	robustus a hiányzó adatokra, multikollinearitást kezel	egy adott megfigyelés több osztályba is sorolható	magas	jó	statisztika alapú tanulás
LDA	alacsony	folytonos	maximális elkülönítést biztosít	Gauss-eloszlást feltételez, túlillesztés lehetősége	magas	jó	statisztika alapú tanulás
MLP	nagy	folytonos	kis hiba	nehéz értelmezés	magas	átlagos	perceptron-alapú
NBC	közepes	folytonos/diszkrét	nagy mennyiségű és zajos adatokat is jól kezel	nem ad minimum hibázási arányt	közepes	kiváló	statisztika alapú tanulás
RBF	nagy	folytonos	járulékos tanulási folyamatot biztosít	a megfelelő számú függvény kiválasztása nehézkes	alacsony	átlagos	perceptron-alapú
PNN	nagyon nagy	folytonos	könnyű kivitelezhetőség	hosszú időt igényel a megfelelő megoldás megtalálása	közepes	jó	példa alapú tanulás
MLoR	közepes	folytonos	valószínűségi kimenet, interakciók tesztelése	érzékeny a multikollinearitásra	magas	jó	statisztika alapú tanulás

Rövidítések: *k*-legközelebbi szomszédok elvén alapuló klasszifikáció (KNN), iteratív elkülönítés 3 algoritmus (ID3), célfüggvényes döntési fák algoritmus (CSMC4), Quinlan-féle C4.5-ös döntési fák algoritmus (C4.5), célfüggvényes osztályozási fa (CSCRT), random döntési fa (RND), részleges legkisebb négyzetek elvén alapuló diszkriminanciaelemzés (PLS-DA), lineáris diszkriminanciaelemzés (LDA), többretegű perceptron neurális hálózat (MLP), naive Bayes féle becslés folytonos változóra (NBC), radiális alapfüggvényekből álló neurális hálózat (RBF), prototype legközelebbi szomszéd elvén alapuló neurális háló (PNN) és multinomiális logisztikus regresszió (MLoR).

A kiegyenlítettség elérése miatt 1000-szeres bootstrappinget alkalmaztam a termékcsoportokon belül minden termékalternatívára. Erre azért volt szükség, mert a termékalternatívák választási gyakorisága eltérő volt (**39. ábra**). A választott modellek fontosabb jellemzőit a 34. táblázat tartalmazza, részletes leírásuk megtalálható Bhavsar és Ganatra (2012), S. B. Kotsiantis, Zaharakis és Pintelas (2006) illetve S. B. Kotsiantis (2007) publikációiban.

A modellek összehasonlítására és a legjobb teljesítményű modell kiválasztására az alábbi mérőszámokat alkalmaztam: hibaarány, keresztellenőrzés eredményei (minimum, maximum és átlag), előrejelzés pontossága a négy termékalternatívára lebontva, bootstrappelt hibázási arány és *leave-one-out* keresztellenőrzés. A futtatások során minden modell esetében a megadott változóhalmazból a lehető legpontosabb előrejelzést kerestem a termékcsoportokra. A modellek számításait Tanagra (version 1.4.50) szoftverrel végeztem (Rakotomalala, 2005). A kutatás menetét a **41. ábra** szemlélteti.



41. ábra: Az adatelemzés folyamatábrája. Az adatrögzítés, adatelemzés és értékelés fázisait színes keretek különítik el.

A Relief F- és Fisher-változószelekció után a következő változókat választottam ki az egyes termékcsoportok esetében: alma (látogatások hossza, fixációk száma és fixációk hossza), saláta (látogatások száma és fixációk hossza), instant levespor (látogatások hossza és látogatások száma), virsli (első fixáció hossza és látogatások száma), üdítőitalok (látogatások száma és látogatások hossza) és sör (első fixáció hossza és látogatások hossza). A fenti változók mutatták a legjobb összefüggést a választással a változószelekciós eljárás alapján.

Krajbich, Lu, Camerer és Rangel megállapították, hogy az utoljára fixált termék és a választás között erős korreláció áll fenn (Krajbich *et al.*, 2012). Kiszámítottam a modellek pontosságát és összehasonlításképpen a 35. táblázatban mutatom be, hogy milyen arányban egyezett meg az utoljára fixált termék a választott termékkel. A kapott értékek 69,4 % (saláta) és 84,7 % (kenyér) között mozogtak. Az eredmények alapján az alkalmazott statisztikai modellek pontosabb becslést adtak, mint az utolsó fixáció önmaga. A modellek független változói között nem szerepelt az utoljára fixált termék változója, csak a fixációk/látogatások hossza és száma.


35. táblázat: Az alkalmazott modellek predikciós pontossága százalékosan kifejezve és az utoljára fixált termékből származtatott értékekkel összevetve

	Alma	Sör	Üdítőital	Saláta	Instant levespor	Virsli	Összes termék egyben
<i>Utolsó fixáció helye</i>	84,70	74,50	79,60	69,40	76,20	74,50	76,50
KNN	99,75	99,75	99,50	98,25	99,75	99,75	99,75
ID3	97,25	97,00	98,75	97,25	97,00	97,50	99,63
CSMC4	95,00	96,50	91,00	78,50	91,25	93,50	84,58
C4.5	99,75	99,75	99,50	98,50	99,75	99,75	99,75
CSCRT	98,75	96,00	95,75	96,00	87,50	96,50	79,67
RND	99,75	99,75	98,00	95,25	99,75	99,75	99,58
PLS-DA	61,25	65,25	50,25	60,50	56,25	59,00	51,25
LDA	60,75	62,50	50,75	58,50	55,75	58,75	52,42
MLP	64,00	76,00	62,50	65,25	66,25	73,25	55,46
NBC	58,75	69,25	51,25	60,75	56,75	66,50	50,79
RBF	63,75	70,75	51,50	58,50	56,00	67,50	50,83
PNN	61,00	61,25	51,50	57,25	56,50	57,00	50,96
MLoR	62,50	65,50	50,50	60,25	56,00	60,00	52,04

Rövidítések: *k*-legközelebbi szomszédok elvén alapuló klasszifikáció (KNN), iteratív elkülönítés 3 algoritmus (ID3), célfüggvényes döntési fák algoritmus (CSMC4), Quinlan-féle C4.5-ös döntési fák algoritmus (C4.5), célfüggvényes osztályozási fa (CSCRT), random döntési fa (RND), részleges legkisebb négyzetek elvén alapuló diszkriminanciaelemzés (PLS-DA), lineáris diszkriminanciaelemzés (LDA), többrétegű perceptron neurális hálózat (MLP), naive Bayes féle becslés folytonos változóra (NBC), radiális alapfüggvényekből álló neurális hálózat (RBF), prototype legközelebbi szomszéd elvén alapuló neurális háló (PNN) és multinomiális logisztikus regresszió (MLoR).

A KNN, ID3, CSMC4, C4.5, CSCRT és RND nagy pontossággal dolgoztak, miközben egészen hasonló teljesítményt mutattak. Előrejelzési pontosságuk 50 % és 76 % között mozgott a modell-termék kombinációtól függően. Ezek alapján azonban nem lehet pontosan megadni, hogy melyik modell teljesített a legjobban, ezért a korábban felsorolt teljesítményjellemzők bevonásával a rangszámkülönbségek módszerét kell alkalmazni a kérdés megválaszolásához.

A **42. ábra** jellemző csoportosulásokat mutat. Az SRD-elemzés segítségével jóval részletesebb eredmények kaphatóak a modellek teljesítményéről, a fent említett hat, hasonlóan jó teljesítményt mutató modell is jól elválik egymástól.



42. ábra: A modellek skálázott SRD-értékeit teljesítményjellemzőik alapján a rangszámkülönbségek összege módszerrel állapítottuk meg. Az elméleti legjobb értékeket (Read) adtuk meg referenciaként. Az x-tengelyen a skálázott SRD-értékek, míg az y-tengelyen a validáció során generált relatív gyakoriságot (fekete görbe) ábrázoltuk. Az 5 %-os (XX1), 50 %-os (Med) és 95 %-os (XX19) valószínűségi értékeket szürke függőleges vonalak jelzik. Amennyiben egy modell a Gauss-görbét például $p = 0,10$ -nél metszi, úgy az értékelése 10 %-os valószínűséggel véletlenszerűnek tekinthető. a) – alma, b) – saláta, c) – instant levespor, d) – virsli, e) – üdítőital, f) – sör, g) – összes termék

Az alma és az instant levesek SRD-elemzése alapján a C4.5 döntési fa volt a legközelebb a zérusponthoz ($SRD = 0$), vagyis ez a modell állt a legközelebb az elméleti legjobb modellhez (36. táblázat). Az összes többi modell esetében magasabb SRD-értékek láthatóak, így ezek teljesítménye gyengébbnek bizonyult. Hasonlóan jó eredményeket láthatunk az ID3-modell esetében a virslik és üdítőitalok közelebbi elemzése során. A salátatermékek eredményei pedig a KNN modelljét adták meg legjobbként. A modellek a legjobb teljesítményt a sörök elemzése során mutatták, itt a KNN-, ID3-, CSCRT- és RND-modellek egyformán alacsony SRD-értéket értek el, vagyis nem lehet köztük különbséget tenni. A 36. táblázat további elemzése megadta, hogy a C4.5- ID3- és KNN-modellek általában alacsony rangszámot értek el, azonban ezekből az eredményekből továbbra sem állapítható meg a legjobb modell. Továbbá az RND-, CSCRT- és CSMC4-modellek mind a hat termékcsoporthoz szignifikánsnak adódtak. Az alma- és sör-termékcsoporthoz az összes modell szignifikánsnak adódott, mivel értékeik az 5 %-os szignifikanciaszinten belül helyezkedtek el (XX1-gyel jelölve az ábrán). A legnagyobb számú nem szignifikáns modell a virsli és üdítőital termékek esetében figyelhető meg, ami azt is magában foglalja, hogy a modellek teljesítménye ezeknél a termékeknél nem volt egységes.

36. táblázat: A rangszámkülönbségek összege-módszer eredményei. A vizsgált modelleket teljesítményjellemzőik alapján rangsoroltuk a vizsgált hat termékcsoporthoz.

Rangszám	Alma	Saláta	Instant levespor	Virsli	Üdítő	Sör	Összes termék
1	C4.5	KNN	C4.5	ID3	ID3	KNN	ID3
2	ID3	ID3	CSMC4	CSCRT	CSMC4	ID3	CSMC4
3	CSCRT	RND	RND	C4.5	C4.5	CSCRT	C4.5
4	RND	C4.5	ID3	CSMC4	KNN	RND	RND
5	KNN	CSCRT	KNN	RND	CSCRT	CSMC4	KNN
6	CSMC4	MLP	LDA	KNN	RND	C4.5	CSCRT
7	LDA	CSMC4	MLP	PLS-DA	RBF	PLS-DA	RBF
8	PLS-DA	PLS-DA	PLS-DA	LDA	MLP	MLP	MLP
9	MLoR	PNN	MLoR	RBF	MLoR	PNN	PNN
10	NBC	LDA	PNN	PNN	NBC	MLoR	PLS-DA
11	RBF	RBF	CSCRT	MLoR	PLS-DA	LDA	NBC
12	MLP	MLoR	NBC	NBC	LDA	NBC	MLoR
13	PNN	NBC	RBF	MLP	PNN	RBF	LDA

A C4.5-, ID3- és KNN-modelleket félkövér aláhúzott betűtípus jelöli. A szürke színezés a nem szignifikáns modelleket jelöli (amelyek az XX1 után helyezkednek el ($\alpha = 0,05$)), keretezett módszerek azonos SRD-értékeket mutattak.

A kutatás következő lépésében az eltérő stimulusokat kizártam, és az összes terméket egy adatmátrixba rendezve elemeztem. A 35. táblázat utolsó oszlopa tartalmazza az összesített adattáblán futtatott modellek eredményeit. Az utolsó fixáció helye alapján történő előrejelzés pontossága 76,5 %-nak adódott, amit a KNN, ID3, CSMC4, C4.5, CSCRT és RND túlteljesített, azonban a többi

modell nem eredményezett ilyen magas értékeket. Az egyesített adathalmazban a modellek két csoportja jól elválik egymástól már a pontosságuk alapján is.

A Relief F- és a Fisher-változószelekció után az egyesített adathalmaz értékelésekor a modellek a látogatások hossza, fixációk száma és a fixációk hossza változókat használták fel a döntés előrejelzéséhez. A kiválasztott változók minden modellben szignifikánsnak adódtak. A teljesítményjellemzők SRD-elemzése megadta, hogy a legalacsonyabb SRD-értékek az ID3-modell esetében keletkeztek. Ez azt jelenti, hogy az ID3-modell rendelkezik a legalacsonyabb hibával, keresztellenőrzésének maximális, minimális és átlagos hibája alacsony, emellett szintén alacsony a bootstrappelt hibája és az egyszeres kihagyásos validációból eredő hibája is. Továbbá predikciós pontossága a négy termékalternatívára nézve a legmagasabb a vizsgált modellek között. A második helyen három modell található: CSMC4, C4.5 és RND. A harmadik helyre az utolsó szignifikáns modell került az SRD-elemzés alapján, amely a KNN volt. Az összes többi modell az XX1 (az 5 %-os valószínűségi határ) után található, ami azt jelenti, hogy az értékelésük véletlenszerű volt.

Kutatásomban szoros kapcsolatot állapítottam meg a szemmozgás és a fogyasztói választás között, mely eredmények alátámasztják Orquin és Mueller Loose megállapításait (Orquin és Mueller Loose, 2013). A Relief F és a Fisher-féle szűrési eljárást alkalmazva meghatároztam azokat a szemkamera paramétereket, amelyek a legjobb előrejelzést adják az egyes termékcsoportokban. A kiválasztott változók mindegyike szignifikánsnak adódott a modellekben is. Eredményeim alátámasztják, hogy a pontosságon kívül további teljesítményjellemzőket is szükséges figyelembe venni a modellek teljesítményének komplex értékeléséhez. Az alkalmazott 10 teljesítményjellemző alapján a 13 modell összehasonlítása egyszerűen megadható az SRD módszerével. A C4.5-, ID3-, KNN-, CSCRT- és RND-modellek a termékfüggetlen elemzés során minden esetben a legjobb öt modell között szerepeltek. Az adathalmazok összesítése után a következő sorrend adódott: ID3, majd holtversenyben CSMC4, C4.5 és RND a második helyen és harmadikként a KNN. Eredményeim alátámasztják az irodalmi adatokat, amelyek alapján a választással kapcsolatos szemmozgásmintázat különböző stimulusok és feladatok esetén is hasonló (Chandon *et al.*, 2009; Atalay *et al.*, 2012; van der Laan *et al.*, 2015). A döntési fa alapú algoritmusok jobb teljesítményt mutattak, ami a logika alapú rendszerüknek köszönhető. A prediktor változók ezek alapján inkább logikai, semmint nemlineáris, lineáris vagy példa alapú kapcsolatban állnak a választott termékkel.

A nem szignifikáns modelleket (amelyek alkalmazása nem ajánlott az ilyen jellegű problémák megoldására), is sikerrel azonosítottam (LDA, MLoR és NBC). A kutatásom során összeállított munkafolyamat jól alkalmazható hasonló gyakorlati szemkamerás vizsgálatokban.

6. Új tudományos eredmények

1. Munkámban bizonyítottam, hogy a párhuzamos faktorelemzés (*parallel factor analysis*, PARAFAC) és a Tucker-3-módszerek hatékonyan alkalmazhatók az érzékszervi és műszeres eredmények együttes preferencia-térképezésében. A létrehozott külső preferencia-térkép triplotjában szemléletesen, egy térképen ábrázolhatóak a bírálók, a tulajdonságok és a vizsgált termékek. A főkomponens-elemzés, Tucker-3- és PARAFAC-modellek összehasonlítását megtettem.

Publikáció: **A. Gere**, V. Losó, A. Györey, S. Kovács, L. Huzsvai, A. Nábrádi, Z. Kókai, L. Sipos (2014): *Applying parallel factor analysis and Tucker-3 methods on sensory and instrumental data to establish preference maps. Case study on sweet corn varieties. Journal of the Science of Food and Agriculture*, 94(15) pp 3213-3225 DOI: 10.1002/jsfa.6673.

2. Ízesített kefirtermékek érzékszervi adatainak elemzésével bizonyítottam, hogy a kategóriaadatok nemlineáris főkomponens-elemzésével lehetőség nyílik belső preferencia-térképek elkészítésére rangsoradatokról is. Az általánosan alkalmazott főkomponens-elemzésen alapuló modellek erre alkalmatlanok az adatok nemlineáris jellege miatt.

Publikáció: **A. Gere**, S. Kovács, K. Pásztor-Huszár, Z. Kókai, L. Sipos (2014): *Comparison of preference mapping methods: a case study on flavored kefir. Journal of Chemometrics*, Vol. 28, Issue 4, pp 293–300. DOI: 10.1002/cem.2594.

3. Számításaimmal igazoltam, hogy az általánosított párkorrelációs módszer az eddig alkalmazott módszereknél hatékonyabb az optimumskálák adatainak kiértékelésére. Az általánosított párkorrelációs módszer eredményeinek szemléltetésére új „buborékábrát” és „keresztvonalábrát” fejlesztettem. A létrehozott ábrák új értékelő és döntéstámogató eszközként alkalmazhatóak.

Publikáció: **A. Gere**, L. Sipos, K. Héberger (2015): *Pair-wise correlation and method comparison: impact assessment for JAR attributes on overall liking. Food Quality and Preference*. Vol. 43, pp: 88-96. DOI:10.1016/J.FOODQUAL.2015.02.017.

4. Eredményeimmel bizonyítottam, hogy a rangszámkülönbségek összegének (*sum of rank-difference*, SRD) módszer az optimumskálákra mért adatok elemzésére alkalmazott módszerek szignifikáns rangsorba állíthatóak. Igazoltam továbbá, hogy az általam alkalmazott általánosított párkorrelációs módszer adja a legpontosabb eredményeket optimum-változók kedveltségére gyakorolt hatásának meghatározására. A módszer javasolható az ASTM MNL63-szabványban javasoltak helyett.

Manuscript submitted to Journal of Sensory Studies: **A. Gere**, Héberger, K., S. Kovács, Z. Kókai, L. Sipos: *Which JAR feature should be changed if evaluations deviate?*

5. Eredményeimmel bizonyítottam, hogy egy transzponált mátrixon futtatott rangszámkülönbségek összege módszerével az optimumskála változóinak kedveltségére gyakorolt hatása több JAR-adatelemző módszer eredményének együttes alkalmazásával pontosabban meghatározható. Ennek alapján a termékfejlesztési irányok több módszer eredményeinek együttes

figyelembevételével adhatóak meg, ami megbízhatóbbá teszi az eredményeket, különösen akkor, ha az ASTM MNL63-szabványban javasolt módszerek ellentmondásos eredményt adnak.

Manuscript submitted to Journal of Sensory Studies: A. Gere, Héberger, K., S. Kovács, Z. Kókai, L. Sipos: Which JAR feature should be changed if evaluations deviate?

6. Számításaimmal bizonyítottam, hogy a szemkamerás mérések során a fogyasztói választás több élelmiszer-termékcsoportha kiterjedően predikációs modellekkel előre jelezhető, a modellek teljesítményjellemzői alapján képzett szignifikáns rangsort felhasználva az optimális statisztikai modell kiválasztható. Ennek alapján általánosan alkalmazható fogyasztói választást előrejelző modelleket határoztam meg.

First Revision submitted to Food Quality and Preference: A. Gere, L. Danner, N. Antoni, S. Kovács, K. Dürschmid, L. Sipos: Gazing behavior and food choice prediction: an alternative approach to choose the best models.

7. Bizonyítottam, hogy a szemkamerás mérések gyakorlatában bevált utolsó fixáció értékkel való fogyasztói választás előrejelzése helyett többváltozós statisztikai modellekkel pontosabb előrejelzés tehető a szemmozgás-adatok alapján a vizsgált élelmiszer-termékcsoportha esetében.

Manuscript submitted to Journal of Food Science: L. Danner, N. Antoni, A. Gere, L. Sipos, S. Kovács, K. Dürschmid: Make a choice! Visual attention and choice behavior in multialternative choice situations investigation different food product groups.

8. Bizonyítottam, hogy szemmozgásadatok alapján a fogyasztói választás gyorsasága túléléselemzés segítségével hatékonyan vizsgálható. Alátámasztottam, hogy bizonyos termékcsoportha esetében szignifikánsan gyorsabban hoznak döntést a fogyasztók.

9. Bizonyítottam, hogy szemmozgásadatok alapján a fogyasztói választás gyorsasága túléléselemzés segítségével hatékonyan elemezhető. Alátámasztottam, hogy bizonyos termékcsoportha esetében szignifikánsan gyorsabban hoznak döntést a fogyasztók.

Publikáció: A. Gere, L. Danner, N. De Antoni, S. Kovács, K. Dürschmid, L. Sipos (2015): Comparison of decision times during and eye-tracking experiment. Conferentia Chemometrica 2015, 13-16 September, Budapest, Hungary. P18.

7. Következtetések és javaslatok

Doktori dolgozatomban az érzékszervi minősítés és a szenzometria területén eddig feltáratlan kérdések megválaszolására törekedtem, azonban ezek az eredmények újabb tudományos és gyakorlati kérdéseket indukáltak.

A bemutatott módszerek egyszerűbb és könnyen hozzáférhető futtatásához elengedhetetlen a megfelelő szoftveres háttér, amely biztosítja, hogy a teljes érzékszervi folyamat automatizáltan, számítógépeken valósuljon meg. A szoftveres támogatásnak biztosítania kell a kísérlettervezés, bírálati terv/lap elkészítés, adatrögzítés, adatfeldolgozás, statisztikai értékelés, grafikai megjelenítés feltételeit. A teljes informatikai támogatásnak köszönhetően a korrekt bírálati tervek automatizáltakká válnak, a kísérleti tervek időszükséglete lerövidül, a számítási hibák lecsökkennek, a korábban lapokról átkonvertált adatbevitelből származott hibák minimálisra csökkennek.

Jelenleg érzékszervi vizsgálatokat támogató szoftverek hozzáférhetők (Compusense five, Fizz, RedJade, EyeQuestion, stb.), azonban ezek drága, zárt forráskódú szoftverek, így az új módszerek implementálása nehezen vagy nem oldható meg. Ezzel szemben a statisztikai értékeléseket támogató nemzetközi, ingyenesen hozzáférhető, szabadon felhasználható R-project rendszere kizárólag az adatalemzésre fókuszál. Az előnyök (célszoftverek és adatalemző szoftver) integrálásával az érzékszervi vizsgálatokat és értékeléseket támogató hatékony, nyílt forráskódú rendszerek építhetők. Véleményem szerint az ilyen célszoftver programnyelve web alapú platformfüggetlen legyen (Windows, Android, IOS, Linux), hogy mindösszesen egy böngésző (Google Chrome, Mozilla FireFox, Opera stb.) segítségével a kívánt eszközön (tablet, okostelefon, számítógép) futtatható legyen a teljes érzékszervi folyamat támogatása mellett. Ezzel a megoldással a saját fejlesztésű, adott ipari/kereskedelmi/kutatási igényekre optimalizált módszerek integrálhatóak.

Az élelmiszerek érzékelésével kapcsolatban számos műszeres és érzékszervi kutatást folytatnak. A nemzetközi szakirodalomban egyre inkább az a tendencia, hogy az élelmiszerek emberi érzékelését humán bírálói csoportok és érzékszervi műszerek együttes alkalmazásával elemzik, a legújabb kutatásokban pedig integrált humán és műszeres érzékszervi rendszereket hoznak létre. Az általam alkalmazott szemmozgási paramétereket rögzítő szemkamerás rendszerek mellett az arc-mimikát, pupillatágulást, bőrellenállást, pulzust és agyhullámokat monitorozó szenzorokat tartalmazó műszereket integrálhatunk az élelmiszerek érzékelésének alaposabb feltérképezésére. A szenzorokat tartalmazó műszerek eredményei és a vizsgált élelmiszerre adott válaszreakció (kedveltség) közötti összefüggések modellezhetők.

Az optimumskálák alkalmazásának egyik legnagyobb hátránya, hogy az elemzés végén nem adja meg, milyen mértékben kell mennyiségileg megváltoztatni az adott terméktulajdonságot. A módszer jelenleg csak azt adja meg, hogy a tulajdonságot milyen irányban kell megváltoztatni a magasabb kedveltség eléréséhez, azonban nem ad pontos iránymutatást, hogy milyen mértékben kell a változtatást megtenni. Ennek megválaszolása újabb kutatásokat igényel.

Tanulságos, hogy a nemzetközi publikációk között nem található olyan optimum skálákon alapuló tudományos kísérlet, amely a fogyasztói preferenciáknak megfelelően többszörösen visszacsatolt termékfejlesztéserket mutat be. Ennélfogva nem ismeretes, mely termékcsoporthoz hány termékfejlesztési ciklus optimális az adott fogyasztói szegmensre vonatkozóan. A ciklusok számának optimalizálásához meg kell határozni, hogy hol van a kedveltség és a ráfordított erőforrások egyensúlya. Egy idő után ugyanis már nem éri meg a fejlesztés, az újonnan meglépett kedveltségi szint javulása egyre kisebb lesz, a ráfordított költségek viszont növekednek. Ha kizárólag a termékek kedveltségének maximalizálására törekszünk, abban az esetben feltehetőleg az első néhány fejlesztési ciklus magas, de a lépések számával csökkenő kedveltségnövekedést ér el. A ciklusokat ebből a szempontból addig célszerű ismételni, ameddig az preferencianövekedést okoz. A kérdések fókuszja a fejlesztés során az, hogy miként változik a „pont jó” megítélésű fogyasztók aránya.

A közösségi médián keresztül egyre nagyobb hozzáférhető adatmennyiség keletkezik, amelynek elemzése szövegbányászati és hálózatelemzési módszerekkel kombinálva választ adhat különböző élelmiszerekkel kapcsolatos preferenciákra, különleges értrendű fogyasztók igényeire, asszociációs kapcsolatokra élelmiszerek/marketing eszközök és megítélésük között. Emellett az így gyűjtött adatok előnye, hogy a fogyasztó saját közegében fogyasztja a terméket, nem érzékszervi laboratóriumi körülmények között. A hálózatelemzéssel továbbá azonosíthatók a véleményvezérek (médiaszemélyiség, dietetikusok, sportolók, orvosok), akik a fogyasztók szokásaira nagy hatással vannak.

8. Összefoglaló

Az érzékszervi minősítés és a szenzometria napjainkban is dinamikusan fejlődő tudományterületek, számtalan új kihívással és megválaszolandó kérdéssel. A nemzetközi publikációkban és konferenciák témáiban elmélyülve egy olyan kirakós képe rajzolódik ki a kezdő kutatók szeme előtt, amelyből helyenként hiányoznak elemek. PhD dolgozatom célkitűzései ezek alapján olyan új módszertanok fejlesztése az élelmiszertermékek preferencia-térképezésének gyakorlatában, amelyekkel egyrészt részletesebb, másrészt a gyakorlatban is jól alkalmazható módszerkiválasztásra vonatkozó, harmadrészt pedig szemkamerát integráló komplex eredmények kaphatóak.

Munkám első elemében, a **részletesebb preferencia-térképek** megalkotása során bizonyítottam, hogy a párhuzamos faktorelemzés, illetve a Tucker-3-módszerek hatékonyan alkalmazhatók a szakértői-, fogyasztói érzékszervi és több, eltérő műszeres mérési eredmény együttes, háromszempontos preferencia-térképeinek megalkotására, triplotjában egy térképen ábrázolhatóak a bírálók, a tulajdonságok és a vizsgált termékek. A fogyasztói preferenciák állandóságának vizsgálatára a könnyen és gyorsan végrehajtható rangsorolás eredményeinek értékelésével bizonyítottam, hogy a kategóriaadatok nemlineáris főkomponens-elemzésével lehetőség nyílik belső preferencia-térképek elkészítésére.

A **gyakorlatban alkalmazható** statisztikai módszerek kiválasztása során számításaimmal igazoltam, hogy az általánosított párkorrelációs módszer jól alkalmazható az optimumskálák értékeléséhez, az eddig alkalmazott módszereknél pontosabb eredményt ad. További adatelemzési módszerként bemutattam a rangszámkülönbségek összegén alapuló módszert, amely szignifikáns rangsorba állítja az optimumskála változóit azok kedveltségre gyakorolt hatása alapján. A megközelítés továbbfejlesztésével megadtam, hogy az optimumskálák elemzéséhez használt szabványos módszereket szignifikánsan felülmúlja az általam alkalmazott általánosított párkorrelációs módszer.

A **szemkamera integrálásával** kapcsolatos munkám során számításaimmal bizonyítottam, hogy a szemkamerás mérések során a fogyasztói választás predikciós modellekkel jól előrejelezhető, továbbá igazoltam, hogy a szemkamerás mérések gyakorlatában bevált utolsó fixáció helyéből történő választás alkalmazása helyett pontosabb előrejelzés tehető meg a szemmozgásadatok alapján. Túléléselemzést alkalmaztam a fogyasztói választás gyorsaságának vizsgálatára, ami alátámasztotta, hogy bizonyos élelmiszer-termékcsoportok esetében szignifikánsan gyorsabban hoznak döntést a fogyasztók.

Doktori munkám során a kirakós hiányzó darabjainak pontos helyére illesztésével a kutatásokban és az ipari gyakorlatokban is jól alkalmazható eljárásokat dolgoztam ki, validáltam és valódi mérési adatsorokon mutattam be gyakorlati alkalmazhatóságukat élelmiszeripari termékek elemzésén és fejlesztésén keresztül.

9. Summary

Sensory analysis and sensometrics are dynamically improving fields, facing numerous new challenges and problems. Reviewing the international literature and the recent topics of sensory conferences and symposiums, one finds a puzzle not having all its pieces in the perfect place. The aims of my PhD work were therefore to complete three main parts of the global puzzle by fulfilling three main goals. I aimed to create new, improved methodologies for the food industry by getting more detailed preference maps, giving practical solutions for method comparison and selection and integrating eye-tracking technologies.

I created more detailed preference maps by applying parallel factor analysis and Tucker-3 methods. These methods are suitable to create three-way preference maps using the data of a trained and a consumer sensory panel as well as the data sets of several instrumental measurements. The gained triplots can visualize the relationships between the assessors, attributes and the products. Evaluating the results of ranking, an easy and rapid sensory technique, the application of nonlinear principal component analysis proved to be a successful tool to analyze the stability of the preferences and to create internal preference maps, too.

In order to give practical solutions for method comparison and selection, I proved that generalized pair-correlation method is suitable to evaluate just-about-right scales and it gives more detailed results than other methods. A further approach (sum of ranking differences) was also introduced, which gives the significant rank of the JAR variables based on their effect on consumer liking. An improvement of the approach gave a tool that creates the ranks of the methods based on their performance. This resulted in that the generalized pair-correlation method outperformed the generally recognized standard approaches significantly.

By analysing the results of eye-tracking measurements, I proved that the variables produced by the eye-tracker (as predictors) are suitable to predict consumer choice. Furthermore, I proved that the generally applied choice prediction approach based on the last fixation can be outperformed by the use of other gazing behavior data and prediction models. I firstly applied survival analysis to evaluate the speed of the choosing mechanisms of consumers during eye-tracking measurements which proved that this speed is product-dependent.

My results were tested on practical problems and case studies coming from the development and evaluation of different food products which proves the validity of the new approaches. The newly introduced methodology is expected to be successfully applied in the development of research facilities and by food companies.

10. Irodalomjegyzék

- Allgeyer, L. C., Miller, M. J., és Lee, S. Y. (2010). Drivers of liking for yogurt drinks with prebiotics and probiotics. *Journal of Food Science*, 75(4). <http://doi.org/10.1111/j.1750-3841.2010.01579.x>
- Allison, P. D. (1995). *Survival Analysis Using SAS: A Practical Guide* (első kiad.). Cary, NC USA: SAS Institute Inc.
- Andrić, F., és Héberger, K. (2015). Chromatographic and computational assessment of lipophilicity using sum of ranking differences and generalized pair-correlation. *Journal of Chromatography A*, 1380, 130–138. <http://doi.org/10.1016/j.chroma.2014.12.073>
- Arditti, S. (1997). Preference mapping: a case study. *Food Quality and Preference*, 8(5), 323–327.
- Ares, G., Antúnez, L., Giménez, A., Roigard, C. M., Pineau, B., Hunter, D. C., és Jaeger, S. R. (2014). Further investigations into the reproducibility of check-all-that-apply (CATA) questions for sensory product characterization elicited by consumers. *Food Quality and Preference*, 36, 111–121. <http://doi.org/10.1016/j.foodqual.2014.03.010>
- Ares, G., Barreiro, C., Deliza, R., Giménez, A., és Gámbaro, A. (2010). Application of a check-all-that-apply question to the development of chocolate milk desserts. *Journal of Sensory Studies*, 25(SUPPL. 1), 67–86. <http://doi.org/10.1111/j.1745-459X.2010.00290.x>
- Ares, G., Giménez, A., Barreiro, C., és Gámbaro, A. (2010). Use of an open-ended question to identify drivers of liking of milk desserts. Comparison with preference mapping techniques. *Food Quality and Preference*, 21(3), 286–294. <http://doi.org/10.1016/j.foodqual.2009.05.006>
- Ares, G., Giménez, A., Bruzzone, F., Vidal, L., Antúnez, L., és Maiche, A. (2013). Consumer visual processing of food labels: Results from an eye-tracking study. *Journal of Sensory Studies*, 28(2), 138–153. <http://doi.org/10.1111/joss.12031>
- Ares, G., Giménez, A., és Gámbaro, A. (2006). Preference mapping of texture of dulce de leche. *Journal of Sensory Studies*, 21(6), 553–571. <http://doi.org/10.1111/j.1745-459X.2006.00082.x>
- Ares, G., és Jaeger, S. R. (2015). Examination of sensory product characterization bias when check-all-that-apply (CATA) questions are used concurrently with hedonic assessments. *Food Quality and Preference*, 40, 199–208. <http://doi.org/10.1016/j.foodqual.2014.10.004>
- Ares, G., Mawad, F., Giménez, A., és Maiche, A. (2014). Influence of rational and intuitive thinking styles on food choice: Preliminary evidence from an eye-tracking study with yogurt labels. *Food Quality and Preference*, 31, 28–37. <http://doi.org/10.1016/j.foodqual.2013.07.005>
- ASTM E1697. (2012). Standard Test Method for Unipolar Magnitude Estimation of Sensory Attributes. West Conshohocken, PA: ASTM International. <http://doi.org/10.1520/E1697-15>
- ASTM E253-15. (2015). ASTM E253. Terminology relating to sensory evaluation of materials and products. West Conshohocken, PA: ASTM International. <http://doi.org/10.1520/E0253-15>
- ASTM E456. (2013). ASTM E456, Standard Terminology Relating to Quality and Statistics. West Conshohocken, PA: ASTM International. <http://doi.org/10.1520/E0456>
- ASTM MNL-63. (2009). ASTM MNL-63 Just-About-Right (JAR) Scales: Design, Usage, Benefits, and Risks. <http://doi.org/10.1520/MNL63-EB>
- Atalay, A. S., Bodur, H. O., és Rasolofoarison, D. (2012). Shining in the Center: Central Gaze Cascade Effect on Product Choice. *Journal of Consumer Research*, 39(4), 848–866. <http://doi.org/10.1086/665984>
- Balogh, P., Ertsey, I., és Kovács, S. (2006). A kocasejtezés kockázatának vizsgálata egy nagyüzemi sertéstelepen. *Acta Agraria Kaposváriensis*, 10(3), 263–268.
- Best, D. J., Rayner, J. C. W., és Allingham, D. (2014). A note on formulae for CMH statistics for JAR data. *Food Quality and Preference*, 31(0), 19–21. <http://dx.doi.org/10.1016/j.foodqual.2013.07.006>
- Bialkova, S., és van Trijp, H. C. M. (2011). An efficient methodology for assessing attention to and effect of nutrition information displayed front-of-pack. *Food Quality and Preference*, 22(6), 592–601. <http://doi.org/10.1016/j.foodqual.2011.03.010>
- Biasoto, A. C. T., Netto, F. M., Marques, E. J. N., és da Silva, M. A. A. P. (2014). Acceptability and preference drivers of red wines produced from Vitis labrusca and hybrid grapes. *Food Research International*, 62, 456–466.

<http://doi.org/10.1016/j.foodres.2014.03.052>

Bojko, A. (2013). *Eye tracking the user experience*. Brooklyn, New York: Rosenfeld Media.

Bonany, J., Brugger, C., Buehler, a., Carbó, J., Codarin, S., Donati, F., ... Schoorl, F. (2014). Preference mapping of apple varieties in Europe. *Food Quality and Preference*, 32(PC), 317–329. <http://doi.org/10.1016/j.foodqual.2013.09.010>

Brereton, R. G. (2007). *Applied Chemometrics for Scientist*. Chichester, West Sussex, United Kingdom: John Wiley és Sons, Ltd.

Bro, R. (1997). PARAFAC. Tutorial and applications. *Chemometrics and Intelligent Laboratory Systems*, 38(2), 149–171. [http://doi.org/10.1016/S0169-7439\(97\)00032-4](http://doi.org/10.1016/S0169-7439(97)00032-4)

Burger, K. S., Cornier, M. a, Ingebrigtsen, J., és Johnson, S. L. (2011). Assessing food appeal and desire to eat: the effects of portion size & energy density. *International Journal of Behavioral Nutrition and Physical Activity*, 8(1), 101. <http://doi.org/10.1186/1479-5868-8-101>

Cabilio, P., és Peng, J. (2008). Multiple rank-based testing for ordered alternatives with incomplete data. *Statistics and Probability Letters*, 78(16), 2609–2613. <http://doi.org/10.1016/j.spl.2008.08.001>

Cadena, R. S., és Bolini, H. M. A. (2012). Ideal and relative sweetness of high intensity sweeteners in mango nectar. *International Journal of Food Science and Technology*, 47(5), 991–996. <http://doi.org/10.1111/j.1365-2621.2011.02932.x>

Cadena, R. S., Cruz, a G., Faria, J. a F., és Bolini, H. M. a. (2012). Reduced fat and sugar vanilla ice creams: sensory profiling and external preference mapping. *Journal of dairy science*, 95(9), 4842–50. <http://doi.org/10.3168/jds.2012-5526>

Cadena, R. S., Cruz, A. G., Netto, R. R., Castro, W. F., Faria, J. D. A. F., és Bolini, H. M. A. (2013). Sensory profile and physicochemical characteristics of mango nectar sweetened with high intensity sweeteners throughout storage time. *Food Research International*, 54(2), 1670–1679. <http://doi.org/10.1016/j.foodres.2013.10.012>

Cannata, S., Ratti, S., Météau, K., Mourot, J., Baldini, P., és Corino, C. (2010). Evaluation of different types of dry-cured ham by Italian and French consumers. *Meat Science*, 84(4), 601–606. <http://doi.org/10.1016/j.meatsci.2009.10.018>

Carbonell, L., Izquierdo, L., Carbonell, I., és Costell, E. (2008). Segmentation of food consumers according to their correlations with sensory attributes projected on preference spaces. *Food Quality and Preference*, 19(1), 71–78. <http://doi.org/10.1016/j.foodqual.2007.06.006>

Cardello, A. V., és Schutz, H. G. (1996). Food appropriateness measures as an adjunct to consumer preference/acceptability evaluation. *Food Quality and Preference*, 7(3-4), 239–249. [http://doi.org/10.1016/S0950-3293\(96\)00012-2](http://doi.org/10.1016/S0950-3293(96)00012-2)

Carlsen, L., Bruggemann, R., Kenessova, O., és Erzhigitov, E. (2015). Evaluation of analytical performance based on partial order methodology. *Talanta*, 132, 285–293. <http://doi.org/10.1016/j.talanta.2014.09.009>

Carroll, J. . (1972). *Individual differences and multidimensional scaling*. New York, NY: Seminar Press.

Causse, M., Friguet, C., Coiret, C., LéPicier, M., Navez, B., Lee, M., ... Grandillo, S. (2010). Consumer Preferences for Fresh Tomato at the European Scale: A Common Segmentation on Taste and Firmness. *Journal of Food Science*, 75(9). <http://doi.org/10.1111/j.1750-3841.2010.01841.x>

Chan, S. H., Moss, B. W., Farmer, L. J., Gordon, A., és Cuskelly, G. J. (2013). Comparison of consumer perception and acceptability for steaks cooked to different endpoints: Validation of photographic approach. *Food Chemistry*, 136(3-4), 1597–1602. <http://doi.org/10.1016/j.foodchem.2012.04.069>

Chandon, P., Hutchinson, J. W., Bradlow, E. T., és Young, S. H. (2009). Does In-Store Marketing Work? Effects of the Number and Position of Shelf Facings on Brand Attention and Evaluation at the Point of Purchase. *Journal of Marketing*, 73(6), 1–17. <http://doi.org/10.1509/jmkg.73.6.1>

Chen, A. W., Resurreccion, A. V. A., és Paguio, L. P. (1996). Age appropriate hedonic scales to measure food preferences of young children. *Journal of Sensory Studies*, 11(2), 141–163.

Conover, W. (1999). *Practical Nonparametric Statistics* (3rd kiad.). Oxford: Wiley-Blackwell.

Cordonnier, S. M., és Delwiche, J. F. (2008). An alternative method for assessing liking: Positional relative rating versus the 9-point hedonic scale. *Journal of Sensory Studies*, 23(2), 284–292. <http://doi.org/10.1111/j.1745-459X.2008.00155.x>

Costell, E., Carbonell, I., Tárrega, A., és Bayarri, S. (2010). *Sensory analysis for food and beverage Quality Control*. (D. Kilcast, Szerk.). Woodhead Publishing.

- CPVO. (2010). Protocol for distinctness, uniformity and stability tests, *Zea mays* L., Maize. CPVO-TP/002/3. Elérés forrás http://www.cpvo.europa.eu/documents/TP/agricoles/TP_002-3_ZEA_MAYS.pdf
- D'Archivio, A. A., Maggi, M. A., és Ruggieri, F. (2014). Cross-column prediction of gas-chromatographic retention indices of saturated esters. *Journal of chromatography. A*, 1355, 269–77. <http://doi.org/10.1016/j.chroma.2014.06.002>
- Delgado, C., Gómez-Rico, A., és Guinard, J. X. (2013). Evaluating bottles and labels versus tasting the oils blind: Effects of packaging and labeling on consumer preferences, purchase intentions and expectations for extra virgin olive oil. *Food Research International*, 54(2), 2112–2121. <http://doi.org/10.1016/j.foodres.2013.10.021>
- Deng, X., és Srinivasan, R. (2013). Increase (or Decrease) Food Consumption ? *Journal of Marketing*, 77(5), 104–117.
- Dinnella, C., Recchia, A., Tuorila, H., és Monteleone, E. (2011). Individual astringency responsiveness affects the acceptance of phenol-rich foods. *Appetite*, 56(3), 633–642. <http://doi.org/10.1016/j.appet.2011.02.017>
- Dooley, L., Lee, Y. S., és Meullenet, J. F. (2010). The application of check-all-that-apply (CATA) consumer profiling to preference mapping of vanilla ice cream and its comparison to classical external preference mapping. *Food Quality and Preference*, 21(4), 394–401. <http://doi.org/10.1016/j.foodqual.2009.10.002>
- Earthy, P. J., MacFie, H. J. H., és Hedderley, D. (1997). Effect of question order on sensory perception and preference in central location trials. *Journal of Sensory Studies*, 12(3), 215–237. <http://doi.org/10.1111/j.1745-459X.1997.tb00064.x>
- Epler, S., Chambers, E., és Kemp, K. E. (1998). Hedonic scales are a better predictor than just-about-right scales of optimal sweetness in lemonade. *Journal of Sensory Studies*, 13(2), 191–197. <http://doi.org/10.1111/j.1745-459X.1998.tb00082.x>
- Esmerino, E. A., Cruz, A. G., Pereira, E. P. R., Rodrigues, J. B., Faria, J. A. F., és Bolini, H. M. A. (2013). The influence of sweeteners in probiotic Petit Suisse cheese in concentrations equivalent to that of sucrose. *Journal of Dairy Science*, 96(9), 5512–5521. <http://doi.org/10.3168/jds.2013-6616>
- Felberg, I., Deliza, R., Farah, A., Calado, E., és Donangelo, C. M. (2010). Formulation of a soy-coffee beverage by response surface methodology and internal preference mapping. *Journal of Sensory Studies*, 25(SUPPL. 1), 226–242. <http://doi.org/10.1111/j.1745-459X.2010.00278.x>
- Freitas, D. D. C., és Mattietto, R. D. (2013). Ideal sweetness of mixed juices from Amazon fruits. *Food Science and Technology*, 33, 148–154.
- Gacula, M., Rutenbeck, S., Pollack, L., Resurreccion, A. V. A., és Moskowitz, H. R. (2007). The Just-About-Right intensity scale: Functional analyses and relation to hedonics. *Journal of Sensory Studies*, 22(2), 194–211. <http://doi.org/10.1111/j.1745-459X.2007.00102.x>
- Gallina Toschi, T., Bendini, A., Barbieri, S., Valli, E., Cezanne, M. L., Buchecker, K., és Canavari, M. (2012). Organic and conventional nonflavored yogurts from the Italian market: Study on sensory profiles and consumer acceptability. *Journal of the Science of Food and Agriculture*, 92(14), 2788–2795. <http://doi.org/10.1002/jsfa.5666>
- Ganong, W. F. (1990). *Az orvosi élettan alapjai*. Budapest: Medicina Kiadó.
- Gatti, E., Di Virgilio, N., Magli, M., és Predieri, S. (2011). Integrating sensory analysis and hedonic evaluation for apple quality assessment. *Journal of Food Quality*, 34(2), 126–132. <http://doi.org/10.1111/j.1745-4557.2011.00373.x>
- Gay, C., és Mead, R. (1992). A statistical appraisal of the problem of sensory measurement. *Journal of Sensory Studies*, 7(3), 205–228. <http://doi.org/10.1111/j.1745-459X.1992.tb00533.x>
- Geel, L., Kinnear, M., és Kock, H. L. De. (2005). Relating consumer preferences to sensory attributes of instant coffee. *Food Quality and Preference*, 16, 237–244. <http://doi.org/10.1016/j.foodqual.2004.04.014>
- Gere, A., Kovács, S., Pásztor-Huszár, K., Kókai, Z., és Sipos, L. (2014). Comparison of preference mapping methods: a case study on flavored kefirs. *Journal of Chemometrics*, 28(4), 293–300. <http://doi.org/10.1002/cem.2594>
- Gere, A., Losó, V., Györey, A., Kovács, S., Huzsvai, L., Nábrádi, A., ... Sipos, L. (2014). Applying parallel factor analysis and Tucker-3 methods on sensory and instrumental data to establish preference maps: case study on sweet corn varieties. *Journal of the Science of Food and Agriculture*, 94(15), 3213–3225. <http://doi.org/10.1002/jsfa.6673>
- Gere, A., Sipos, L., és Héberger, K. (2015). Generalized Pairwise Correlation and method comparison: Impact assessment for JAR attributes on overall liking. *Food Quality and Preference*, 43, 88–96. <http://doi.org/10.1016/j.foodqual.2015.02.017>
- Gifi, A. (1990). *Nonlinear multivariate analysis*. Chichester, West Sussex, United Kingdom: John Wiley és Sons, Ltd.

- Glanz, K., Basil, M., Maibach, E., Goldberg, J., és Snyder, D. (1998). Why Americans eat what they do: Taste, nutrition, cost, convenience, and weight control concerns as influences on food consumption. *Journal of the American Dietetic Association*. [http://doi.org/10.1016/S0002-8223\(98\)00260-0](http://doi.org/10.1016/S0002-8223(98)00260-0)
- Goerlitz, C. D., és Delwiche, J. F. (2004). Impact of label information on consumer assessment of soy-enhanced tomato juice. *Journal of Food Science*, 69(9), S376–S379. Elérés forrás WOS:000225959800041
- Gofman, A., Moskowitz, H. R., Fyrbjork, J., Moskowitz, D., és Mets, T. (2009). Extending rule developing experimentation to perception of food packages with eye tracking. *The Open Food Science Journal*, 3, 66–78.
- Graham, D. J., Orquin, J. L., és Visschers, V. H. M. (2012). Eye tracking and nutrition label use: A review of the literature and recommendations for label enhancement. *Food Policy*, 37(4), 378–382. <http://doi.org/10.1016/j.foodpol.2012.03.004>
- Green, B. G., Shaffer, G. S., és Gilmore, M. M. (1993). Derivation and evaluation of a semantic scale of oral sensation magnitude with apparent ratio properties. *Chemical Senses*, 18 (6), 683–702. <http://doi.org/10.1093/chemse/18.6.683>
- Guéguen, N. (2003). Current psychology letters. *Current Psychology Letters*, 2(11), 2–5.
- Guest, S., Essick, G., Patel, A., Prajapati, R., és McGlone, F. (2007). Labeled magnitude scales for oral sensations of wetness, dryness, pleasantness and unpleasantness. *Food Quality and Preference*, 18(2), 342–352. <http://doi.org/10.1016/j.foodqual.2006.03.012>
- Guestrin, E. D., és Eizenman, M. (2006). General theory of remote gaze estimation using the pupil center and corneal reflections. *IEEE Transactions on Biomedical Engineering*, 53(6), 1124–1133. <http://doi.org/10.1109/TBME.2005.863952>
- Guinard, J. X., Uotani, B., és Schlich, P. (2001). Internal and external mapping of preferences for commercial lager beers: Comparison of hedonic ratings by consumers blind versus with knowledge of brand and price. *Food Quality and Preference*, 12(4), 243–255. [http://doi.org/10.1016/S0950-3293\(01\)00011-8](http://doi.org/10.1016/S0950-3293(01)00011-8)
- Halkidi, M., Batistakis, Y., és Vazirgiannis, M. (2001). On clustering validation techniques. *Journal of Intelligent Information Systems*, 17(2-3), 107–145. <http://doi.org/10.1023/A:1012801612483>
- Harshman, R. A. (1970). *Foundations of the parafac procedure: model and conditions for an 'explanatory' multi-mode factor analysis*. (No. 16).
- Harshman, R. a., és Lundy, M. E. (1994). PARAFAC: Parallel factor analysis. *Computational Statistics & Data Analysis*, 18(1), 39–72. [http://doi.org/10.1016/0167-9473\(94\)90132-5](http://doi.org/10.1016/0167-9473(94)90132-5)
- Hassine, K. Ben, Taamalli, A., Slama, M. Ben, Khouloud, T., Kiristakis, A., Benincasa, C., ... Grati-Kammoun, N. (2015). Characterization and preference mapping of autochthonous and introduced olive oil cultivars in Tunisia. *European Journal of Lipid Science and Technology*, 117(1), 112–121. <http://doi.org/10.1002/ejlt.201400049>
- Héberger, K. (2010). Sum of ranking differences compares methods or models fairly. *TrAC Trends in Analytical Chemistry*, 29(1), 101–109. <http://doi.org/10.1016/j.trac.2009.09.009>
- Héberger, K., Kolarević, S., Kračun-Kolarević, M., Sunjog, K., Gačić, Z., Kljajić, Z., Vuković-Gačić, B. (2014). Evaluation of single-cell gel electrophoresis data: combination of variance analysis with sum of ranking differences. *Mutation research. Genetic toxicology and environmental mutagenesis*, 771, 15–22. <http://doi.org/10.1016/j.mrgentox.2014.04.028>
- Héberger, K., és Kollár-Hunek, K. (2011). Sum of ranking differences for method discrimination and its validation: comparison of ranks with random numbers. *Journal of Chemometrics*, 25(4), 151–158. <http://doi.org/10.1002/cem.1320>
- Heberger, K., és Rajko, R. (2002). Generalization of pair correlation method (PCM) for nonparametric variable selection. *Journal of Chemometrics*, 16(8-10), 436–443. <http://doi.org/10.1002/cem.748>
- Hein, K. A., Jaeger, S. R., Carr, B. T., és Delahunty, C. M. (2008). Comparison of five common acceptance and preference methods q. *Food Quality and Preference*, 19, 651–661. <http://doi.org/10.1016/j.foodqual.2008.06.001>
- Hein, K., Ebeler, S. E., és Heymann, H. (2009). Perception of fruity and vegetative aromas in red wine. *Journal of Sensory Studies*, 24(3), 441–455. <http://doi.org/10.1111/j.1745-459X.2009.00220.x>
- Hong, J. H., Yoon, E. K., Chung, S. J., Chung, L., Cha, S. M., O'Mahony, M., ... Kim, K. O. (2011). Sensory Characteristics and Cross-Cultural Consumer Acceptability of Bulgogi (Korean Traditional Barbecued Beef). *Journal of Food Science*, 76(5), S306–S313. <http://doi.org/10.1111/j.1750-3841.2011.02173.x>

- Hough, G., és Garitta, L. (2012). Methodology for sensory shelf-life estimation: A review. *Journal of Sensory Studies*, 27(3), 137–147. <http://doi.org/10.1111/j.1745-459X.2012.00383.x>
- Hough, G., Langohr, K., Gómez, G., és Curia, A. (2003). Survival Analysis Applied to Sensory Shelf Life of Foods. *Journal of f*, 68(1), 359–362. <http://doi.org/10.1111/j.1365-2621.2003.tb14165.x>
- Hurling, R., és Shepherd, R. (2003). Eating with your eyes: Effect of appearance on expectations of liking. *Appetite*, 41(2), 167–174. [http://doi.org/10.1016/S0195-6663\(03\)00058-8](http://doi.org/10.1016/S0195-6663(03)00058-8)
- Imram, N. (1999). The role of visual cues in consumer perception and acceptance of a food product. *Nutrition & Food Science*, 99(5), 224–230. <http://doi.org/10.1108/00346659910277650>
- ISO 11035:1994. (1994). ISO 11035:1994, Sensory analysis -- Identification and selection of descriptors for establishing a sensory profile by a multidimensional approach. ISO.
- ISO 11056:1999. (1999). Sensory analysis -- Methodology -- Magnitude estimation method. ISO.
- ISO 11132:2012. (2012). ISO 11132:2012, Sensory analysis -- Methodology -- Guidelines for monitoring the performance of a quantitative sensory panel. ISO.
- ISO 3972:2011. (2011). ISO 3972:2011, Sensory analysis -- Methodology -- Method of investigating sensitivity of taste. ISO.
- ISO 4121:2003. (2003). ISO 4121:2003, Sensory analysis -- Guidelines for the use of quantitative response scales. ISO.
- ISO 5496:2006. (2006). ISO 5496:2006, Sensory analysis -- Methodology -- Initiation and training of assessors in the detection and recognition of odours. ISO.
- ISO 6658:2005. (2005). ISO 6658:2005, Sensory analysis -- Methodology -- General guidance. ISO.
- ISO 8586:2012. (2012). ISO 8586:2012, Sensory analysis -- General guidelines for the selection, training and monitoring of selected assessors and expert sensory assessors. ISO.
- ISO 8587:2006. (2006). ISO 8587:2006, Sensory analysis -- Methodology -- Ranking. ISO.
- ISO 8589:2007. (2007). ISO 8589:2007, Sensory analysis -- General guidance for the design of test rooms. ISO.
- Jaeger, S. R., és Ares, G. (2014). Lack of evidence that concurrent sensory product characterisation using CATA questions bias hedonic scores. *Food Quality and Preference*, 35, 1–5. <http://doi.org/10.1016/j.foodqual.2014.01.001>
- Jantathai, S., Danner, L., Joechl, M., és Dürschmid, K. (2013). Gazing behavior, choice and color of food: Does gazing behavior predict choice? *Food Research International*, 54(2), 1621–1626. <http://doi.org/http://dx.doi.org/10.1016/j.foodres.2013.09.050>
- Janzantti, N. S., Machado, T. V., és Monteiro, M. (2011). Sensory Acceptance Of Juice From Fcoj Processing Steps. *Journal of Sensory Studies*, 26(5), 322–330. <http://doi.org/10.1111/j.1745-459X.2011.00347.x>
- Jaros, D., Rohm, H., és Strobl, M. (2000). Appearance properties - A significant contribution to sensory food quality? *LWT-Food Science and Technology*, 33(4), 320–326.
- Jorge, É. D. C., Mendes, A. C. G., Auriema, B. E., Cazedey, H. P., Fontes, P. R., Ramos, A. D. L. S., és Ramos, E. M. (2015). Application of a check-all-that-apply question for evaluating and characterizing meat products. *Meat Science*, 100, 124–133. <http://doi.org/10.1016/j.meatsci.2014.10.002>
- Kato, T., Shimoda, M., Suzuki, J., Kawaraya, A., Igura, N., és Hayakawa, I. (2003). Changes in the odors of squeezed apple juice during thermal processing. *Food Research International*, 36, 777–785. [http://doi.org/10.1016/S0963-9969\(03\)00072-3](http://doi.org/10.1016/S0963-9969(03)00072-3)
- Kemp, S. E., Hollowood, T., és Hort, J. (2009). *Sensory Evaluation - A Pratical Handbook* (1st editio). Chichester, West Sussex, United Kingdom: Wiley-Blackwell.
- Khayamian, T., Sajjadi, S. M., Mirmahdieh, S., Mardihallaj, A., és Hashemian, Z. (2012). Simultaneous analysis of bifenthrin and tetramethrin using corona discharge ion mobility spectrometry and Tucker 3 model. *Chemometrics and Intelligent Laboratory Systems*, 118, 88–96. <http://doi.org/10.1016/j.chemolab.2012.08.005>
- Kiers, H. a L. (1991). Hierarchical relations among three-way methods. *Psychometrika*, 56(3), 449–470. <http://doi.org/10.1007/BF02294485>

- Kilcast, D. (2010). Sensory quality control for taint prevention. In D. Kilcast (Szerk.), *Sensory analysis for food and beverage quality control* (o. 156–184). Cambridge: Woodhead Publishing.
- Kleinbaum, D. G., és Klein, M. (2005). *Survival Analysis - A self-learning text. Public Health* (2nd kiad.). New York, NY: Springer. Elérés forrás <http://www.cs.put.poznan.pl/kkrawiec/wiki/uploads/ADHD/Lazar.pdf>
- Kollár-Hunek, K., és Héberger, K. (2013). Method and model comparison by sum of ranking differences in cases of repeated observations (ties). *Chemometrics and Intelligent Laboratory Systems*, 127, 139–146. <http://doi.org/10.1016/j.chemolab.2013.06.007>
- Kollár-Hunek, K., Heszberger, J., Kókai, Z., Láng-Lázi, M., és Papp, E. (2008). Testing panel consistency with GCAP method in food profile analysis. *Journal of Chemometrics*, 22(3-4), 218–226. <http://doi.org/10.1002/cem.1135>
- Koziol, J. A. (2013). Sums of ranking differences and inversion numbers for method discrimination. *Journal of Chemometrics*, 27(6), 165–169. <http://doi.org/10.1002/cem.2504>
- Köster, E. P. (2009). Diversity in the determinants of food choice: A psychological perspective. *Food Quality and Preference*, 20(2), 70–82. <http://doi.org/10.1016/j.foodqual.2007.11.002>
- Krajbich, I., Lu, D., Camerer, C., és Rangel, A. (2012). The attentional drift-diffusion model extends to simple purchasing decisions. *Frontiers in psychology*, 3, 193. <http://doi.org/10.3389/fpsyg.2012.00193>
- Krajbich, I., és Rangel, A. (2011). Multialternative drift-diffusion model predicts the relationship between visual fixations and choice in value-based decisions. *Proceedings of the National Academy of Sciences of the United States of America*, 108(33), 13852–7. <http://doi.org/10.1073/pnas.1101328108>
- Krider, R. E., Raghubir, P., és Krishna, A. (2001). Pizzas: ? or Square? Psychophysical Biases in Area Comparisons. *Marketing Science*, 20(4), 405–425. <http://doi.org/10.1287/mksc.20.4.405.9756>
- Kroonenberg, P. M. (2008). *Applied Multiway Data Analysis. Book*. Chichester, West Sussex, United Kingdom: John Wiley & Sons, Ltd. <http://doi.org/10.1111/j.1751-5823.2008.000626.x>
- Kroonenberg, P. M., Harshman, R. a., és Murakami, T. (2009). Analysing Three-way Profile Data Using the Parafac and Tucker3 Models Illustrated with Views on Parenting. *Applied Multivariate Research*, 13(1), 5–41.
- Kroonenberg, P. M., és Leeuw, D. J. (1980). Principal Component Analysis of 3-Mode Data by Means of Alternating Least-Squares Algorithms. *Psychometrika*, 45(1), 69–97. Elérés forrás //a1980jm94400004
- Kühn, B. F., és Thybo, A. K. (2001). The influence of sensory and physiochemical quality on Danish children's preferences for apples. *Food Quality and Preference*, 12(8), 543–550. [http://doi.org/10.1016/S0950-3293\(01\)00050-7](http://doi.org/10.1016/S0950-3293(01)00050-7)
- Lawless, H. T., és Heimann, H. (2010). *Sensory Evaluation of Food 2nd Ed.* (2nd editio). New York, NY: Springer Verlag. <http://doi.org/10.1007/978-1-4419-6488-5>
- Lawless, H. T., Popper, R., és Kroll, B. J. (2010). A comparison of the labeled magnitude (LAM) scale, an 11-point category scale and the traditional 9-point hedonic scale. *Food Quality and Preference*, 21(1), 4–12. <http://doi.org/10.1016/j.foodqual.2009.06.009>
- Lawless, L. J. R., Threlfall, R. T., Meullenet, J. F., és Howard, L. R. (2013). Applying a Mixture Design for Consumer Optimization of Black Cherry, Concord Grape and Pomegranate Juice Blends. *Journal of Sensory Studies*, 28(2), 102–112. <http://doi.org/10.1111/joss.12026>
- Lee, S. M., Kitsawad, K., Sigal, A., Flynn, D., és Guinard, J. X. (2012). Sensory Properties and Consumer Acceptance of Imported and Domestic Sliced Black Ripe Olives. *Journal of Food Science*, 77(12). <http://doi.org/10.1111/j.1750-3841.2012.03001.x>
- Levitsky, D. a., Iyer, S., és Pacanowski, C. R. (2012). Number of foods available at a meal determines the amount consumed. *Eating Behaviors*, 13(3), 183–187. <http://doi.org/10.1016/j.eatbeh.2012.01.006>
- Lim, J. (2011). Hedonic scaling: A review of methods and theory. *Food Quality and Preference*, 22(8), 733–747. <http://doi.org/10.1016/j.foodqual.2011.05.008>
- Linting, M., Meulman, J. J., Groenen, P. J. F., és van der Kooij, A. J. (2007). Nonlinear principal components analysis: introduction and application. *Psychological Methods*, 12(3), 336–358. <http://doi.org/10.1037/1082-989X.12.3.336>
- Lori, R. (Ben-G. U., és Oded, M. (Tel-A. U. (2008). *Data mining with decision trees*. Singapore: World Scientific

Publishing Co. Pte. Ltd.

Louwerse, D. J., Smilde, a K., és Kiers, H. a L. (1999). Cross-validation of multiway component models. *Journal of Chemometrics*, 13(5), 491–510. [http://doi.org/10.1002/\(SICI\)1099-128X\(199909/10\)13:5<491::AID-CEM537>3.0.CO;2-2](http://doi.org/10.1002/(SICI)1099-128X(199909/10)13:5<491::AID-CEM537>3.0.CO;2-2)

Machin, D., Cheung, Y. B., és Parmar, M. (2006). *Survival Analysis: A Practical Approach* (2nd kiad.). Chichester, West Sussex, United Kingdom: John Wiley & Sons, Ltd. Elérés forrás http://www.google.pt/books?hl=en&lr=&id=z6_Hr9NGjr0C&pgis=1

Madzharov, A. V., és Block, L. G. (2010). Effects of product unit image on consumption of snack foods. *Journal of Consumer Psychology*, 20(4), 398–409. <http://doi.org/10.1016/j.jcps.2010.06.007>

Måge, I., Menichelli, E., és Næs, T. (2012). Preference mapping by PO-PLS: Separating common and unique information in several data blocks. *Food Quality and Preference*, 24(1), 8–16. <http://doi.org/10.1016/j.foodqual.2011.08.003>

Malherbe, S., Menichelli, E., du Toit, M., Tredoux, A., Muller, N., Næs, T., és Nieuwoudt, H. (2013). The relationships between consumer liking, sensory and chemical attributes of Vitis vinifera L. cv. Pinotage wines elaborated with different Oenococcus oeni starter cultures. *Journal of the Science of Food and Agriculture*, 93(11), 2829–2840. <http://doi.org/10.1002/jsfa.6115>

Marcelino, A. S., Adam, A. S., Couronne, T., Köster, E. P., és Sieffermann, J. M. (2001). Internal and external determinants of eating initiation in humans. *Appetite*, 36(1), 9–14. <http://doi.org/10.1006/appe.2000.0375>

Meiselman, H. L., és Schutz, H. G. (2003). History of food acceptance research in the US Army. *Appetite*, 40(3), 199–216. [http://doi.org/10.1016/S0195-6663\(03\)00007-2](http://doi.org/10.1016/S0195-6663(03)00007-2)

Mela, D. J. (1999). Food choice and intake: the human factor. *The Proceedings of the Nutrition Society*, 58(3), 513–521. <http://doi.org/10.1017/S0029665199000683>

Meullenet, J. F., Xiong, R., és Findlay, C. (2007). *Multivariate and Probabilistic Analyses of Sensory Science Problems* (1st kiad.). Ames, Iowa: Wiley-Blackwell.

Meullenet, J., Xiong, R., Hankins, J. A., Dias, P., Zivanovic, S., Monsoor, M. A., ... Fromm, H. (2003). Modeling preference of commercial toasted white corn tortilla chips using proportional odds models. *Food Quality and Preference*, 14, 603–614. [http://doi.org/10.1016/S0950-3293\(02\)00154-4](http://doi.org/10.1016/S0950-3293(02)00154-4)

Meulman, J., Heiser, W. J., és Carroll, J. . (1986). PREFMAP-3 user's guide. Elérés forrás <http://www.netlib.org/mds/>

Meulman, J. J., van der Kooij, A. J., és Heiser, W. J. (2004). Principal components analysis with nonlinear optimal scaling transformations for ordinal and nominal data. In D. Kaplan (Szerk.), *The Sage handbook of quantitative methodology for the social sciences* (o. 49–70). London: Sage.

Michon, C., O'Sullivan, M. G., Sheehan, E., Delahunty, C. M., és Kerry, J. P. (2010). Investigation of the influence of age, gender and consumption habits on the liking of jam-filled cakes. *Food Quality and Preference*, 21(5), 553–561. <http://doi.org/10.1016/j.foodqual.2010.03.001>

Mitterer-Daltoé, M. L., Queiroz, M. I., Fiszman, S., és Varela, P. (2014). Are fish products healthy? Eye tracking as a new food technology tool for a better understanding of consumer perception. *LWT - Food Science and Technology*, 55(2), 459–465. <http://doi.org/10.1016/j.lwt.2013.10.013>

Moorthy, N. S. H. N., Cerqueira, N. M. F. S. a., Ramos, M. J., és Fernandes, P. a. (2015). Ligand based analysis on HMG-CoA reductase inhibitors. *Chemometrics and Intelligent Laboratory Systems*, 140, 102–116. <http://doi.org/10.1016/j.chemolab.2014.11.009>

Murray, J. M., és Delahunty, C. M. (2000). Mapping consumer preference for the sensory and packaging attributes of Cheddar cheese. *Food Quality and Preference*, 11.

Næs, T., Brockhoff, P. B., és Tomic, O. (2010). *Statistics for Sensory and Consumer Science. Statistics for Sensory and Consumer Science*. <http://doi.org/10.1002/9780470669181>

Neely, E. a., Lee, Y., és Lee, S. Y. (2010a). Cross-cultural comparison of acceptance of soy-based extruded snack foods by U.S. and Indian consumers. *Journal of Sensory Studies*, 25(SUPPL. 1), 87–108. <http://doi.org/10.1111/j.1745-459X.2010.00276.x>

Neely, E. a., Lee, Y., és Lee, S. Y. (2010b). Drivers of liking for soy-based Indian-style extruded snack foods determined by U.S. and Indian consumers. *Journal of Food Science*, 75(6), 292–299. <http://doi.org/10.1111/j.1750->

3841.2010.01672.x

Nestrud, M. A., és Lawless, H. T. (2008). Perceptual mapping of citrus juices using projective mapping and profiling data from culinary professionals and consumers, *19*, 431–438. <http://doi.org/10.1016/j.foodqual.2008.01.001>

Nunes, C. a., Bastos, S. C., Pinheiro, A. C. M., Pimenta, C. J., és Pimenta, M. E. S. G. (2012). Relating consumer acceptance to descriptive attributes by three-way external preference mapping obtained by parallel factor analysis (PARAFAC). *Journal of Sensory Studies*, *27*(4), 209–216. <http://doi.org/10.1111/j.1745-459X.2012.00387.x>

Nunes, C. a., Pinheiro, a. C. M., és Bastos, S. C. (2011). Evaluating Consumer Acceptance Tests By Three-Way Internal Preference Mapping Obtained By Parallel Factor Analysis (PARAFAC). *Journal of Sensory Studies*, *26*(2), 167–174. <http://doi.org/10.1111/j.1745-459X.2011.00333.x>

O'Mahony, M., Park, H., Park, J. Y., és Kim, K. O. K. (2004). Comparison of the statistical analysis of hedonic data using analysis of variance and multiple comparisons versus an R-index analysis of the ranked data. *Journal of Sensory Studies*, *19*(6), 519–529. <http://doi.org/10.1111/j.1745-459X.2004.060904.x>

Orquin, J. L., és Mueller Loose, S. (2013). Attention and choice: A review on eye movements in decision making. *Acta Psychologica*, *144*(1), 190–206. <http://doi.org/http://dx.doi.org/10.1016/j.actpsy.2013.06.003>

Pages, J., Berthelo, S., Brossier, M., és Gourret, D. (2014). Statistical penalty analysis. *Food Quality and Preference*, *32*, 16–23. <http://doi.org/10.1016/j.foodqual.2013.07.008>

Parente, M. E., Manzoni, A. V., és Ares, G. (2011). External Preference Mapping Of Commercial Antiaging Creams Based On Consumers' Responses To A Check-All-That-Apply Question. *Journal of Sensory Studies*, *26*(2), 158–166. <http://doi.org/10.1111/j.1745-459X.2011.00332.x>

Park, J.-Y., Jeon, S.-Y., O'Mahony, M., és Kim, K.-O. (2004). Induction of scaling errors. *Journal of Sensory Studies*, *19*(4), 261–271. <http://doi.org/10.1111/j.1745-459X.2004.tb00147.x>

Piqueras-Fiszman, B., Alcaide, J., Roura, E., és Spence, C. (2012). Is it the plate or is it the food? Assessing the influence of the color (black or white) and shape of the plate on the perception of the food placed on it. *Food Quality and Preference*, *24*(1), 205–208. <http://doi.org/10.1016/j.foodqual.2011.08.011>

Piqueras-Fiszman, B., Ares, G., Alcaide-Marzal, J., és Diego-Más, J. a. (2011). Comparing older and younger users' perceptions of mobile phones and watches using cata questions and preference mapping on the design characteristics. *Journal of Sensory Studies*, *26*(1), 1–12. <http://doi.org/10.1111/j.1745-459X.2010.00315.x>

Plaehn, D. (2013). What's the real penalty in penalty analysis? *Food Quality and Preference*, *28*(2), 456–469. <http://doi.org/10.1016/j.foodqual.2012.11.009>

Plaehn, D., és Horne, J. (2008). A regression-based approach for testing significance of “just-about-right” variable penalties. *Food Quality and Preference*, *19*(1), 21–32. <http://doi.org/http://dx.doi.org/10.1016/j.foodqual.2007.06.003>

Plaehn, D., és Horne, J. (2011). *A Regression-Based Approach for Testing Significance of JAR Variable Penalties*. (L. Rothman és M. J. Parker, Szerk.) *Just-About-Right*. Elérés forrás://WOS:000294328700016

Popper, R., és Gibes, K. (2004). Workshop summary: Data analysis workshop: getting the most out of just-about-right data - Abstracts. *Food Quality and Preference*, *15*(7-8), 891–899. <http://doi.org/10.1016/j.foodqual.2004.04.015>

Popper, R., Rosenstock, W., Schraidt, M., és Kroll, B. J. (2004). The effect of attribute questions on overall liking ratings. *Food Quality and Preference*, *15*(7-8 SPEC.ISS.), 853–858. <http://doi.org/10.1016/j.foodqual.2003.12.004>

Rababah, T. M., Al-u'datt, M., Almajwal, A., Brewer, S., Feng, H., Al-Mahasneh, M., Yang, W. D. (2012). Evaluation of the Nutraceutical, Physiochemical and Sensory Properties of Raisin Jam. *Journal of Food Science*, *77*(6), C609–C613. <http://doi.org/10.1111/j.1750-3841.2012.02708.x>

Raghubir, P., és Krishna, A. (1999). Vital Dimensions in Volume Perception: Can the Eye Fool the Stomach? *Journal of Marketing Research*, *36*(3), 313–326. <http://doi.org/10.2307/3152079>

Rajko, R., és Heberger, K. (2001). Conditional Fisher's exact test as a selection criterion for pair-correlation method. Type I and Type II errors. *Chemometrics and Intelligent Laboratory Systems*, *57*(1), 1–14. [http://doi.org/10.1016/s0169-7439\(01\)00101-0](http://doi.org/10.1016/s0169-7439(01)00101-0)

Rakotomalala, R. (2005). TANAGRA : un logiciel gratuit pour l ' enseignement et la recherche. *Proceedings of*

- EGC'2005, 2, 697–702. Elérés forrás http://eric.univ-lyon2.fr/~ricco/tanagra/fichiers/le_logiciel_tanagra_egc_2005.pdf
- Rebollar, R., Lidón, I., Martín, J., és Puebla, M. (2015). The identification of viewing patterns of chocolate snack packages using eye-tracking techniques. *Food Quality and Preference*, 39(0), 251–258. <http://doi.org/http://dx.doi.org/10.1016/j.foodqual.2014.08.002>
- Réthelyi, M., és Szentágothai, J. (2013). *Funkcionális anatómia* (9th kiad.). Budapest: Medicina Kiadó.
- Reutskaja, E., Nagel, R., Camerer, C., és Rangel, A. (2011). Search dynamics in consumer choice under time pressure: An eye-tracking study. *American Economic Review*, 101(April), 900–926.
- Rocha, M. C., Deliza, R., Ares, G., Freitas, D. D. G., Silva, A. L., Carmo, M. G., és Abboud, A. C. (2013). Identifying promising accessions of cherry tomato: A sensory strategy using consumers and chefs. *Journal of the Science of Food and Agriculture*. <http://doi.org/10.1002/jsfa.5988>
- Rocha, M. D. C., Deliza, R., Corrêa, F. M., Carmo, M. G. F. Do, és Abboud, A. C. S. (2013). A study to guide breeding of new cultivars of organic cherry tomato following a consumer-driven approach. *Food Research International*, 51(1), 265–273. <http://doi.org/10.1016/j.foodres.2012.12.019>
- Rødbotten, M., Martinsen, B. K., Borge, G. I., Mortvedt, H. S., Knutsen, S. H., Lea, P., és Tormod, N. (2009). A cross-cultural study of preference for apple juice with different sugar and acid contents. *Food Quality and Preference*, 20, 277–284. <http://doi.org/10.1016/j.foodqual.2008.11.002>
- Rolls, B. J., Roe, L. S., és Meengs, J. S. (2007). The effect of large portion sizes on energy intake is sustained for 11 days. *Obesity*, 15(6), 1535–1543. <http://doi.org/10.1038/oby.2007.182>
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53–65. [http://doi.org/10.1016/0377-0427\(87\)90125-7](http://doi.org/10.1016/0377-0427(87)90125-7)
- Sajtos, L., és Mitev, A. (2007). *SPSS kutatási és adatelemzési kézikönyv* (első kiad.). Budapest: Alinea Kiadó.
- Schifferstein, H. N. J. (2012). Labeled Magnitude Scales: A critical review. *Food Quality and Preference*, 26(2), 151–158. <http://doi.org/10.1016/j.foodqual.2012.04.016>
- Schutz, H. G. (1964). A Food Action Rating Scale for Measuring Food Acceptance. *Journal of Food Science*, 365–374. <http://doi.org/10.1111/j.1365-2621.1965.tb00316.x>
- Schutz, H. G. (1995). *Appropriateness as a measure of the cognitive-contextual aspects of food acceptance*. (D. M. H. Thomson és H. MacFie, Szerk.). Chapman and Hall.
- Schutz, H. G., és Cardello, A. V. (2001). a Labeled Affective Magnitude (Lam) Scale for Assessing Food Liking / Disliking. *Journal of Sensory Studies*, 16(June 1997), 117–159. <http://doi.org/10.1111/j.1745-459X.2001.tb00293.x>
- Sinesio, F., Cammareri, M., Moneta, E., Navez, B., Peparaio, M., Causse, M., és Grandillo, S. (2010). Sensory quality of fresh French and Dutch market tomatoes: A preference mapping study with Italian consumers. *Journal of Food Science*, 75(1). <http://doi.org/10.1111/j.1750-3841.2009.01424.x>
- Sipos, L., Kovacs, Z., Sagi-Kiss, V., Csiki, T., Kokai, Z., Fekete, A., és Heberger, K. (2012). Discrimination of mineral waters by electronic tongue, sensory evaluation and chemical analysis. *Food Chemistry*, 135(4), 2947–2953. <http://doi.org/10.1016/j.foodchem.2012.06.021>
- Sipos, L., Kovács, Z., Szöllösi, D., Kókai, Z., Dalmadi, I., és Fekete, A. (2011). Comparison of novel sensory panel performance evaluation techniques with e-nose analysis integration. *Journal of Chemometrics*, 25(5), 275–286. <http://doi.org/10.1002/cem.1391>
- Škrbić, B., Héberger, K., és Durišić-Mladenović, N. (2013). Comparison of multianalyte proficiency test results by sum of ranking differences, principal component analysis, and hierarchical cluster analysis. *Analytical and bioanalytical chemistry*, 405(25), 8363–75. <http://doi.org/10.1007/s00216-013-7206-5>
- Stone, H., és Sidel, J. L. (2004). *Sensory Evaluation Practices* (második kiad.). London: Elsevier. <http://doi.org/10.1016/B978-0-12-374181-3.00017-X>
- Sveinsdóttir, K., Martinsdóttir, E., Green-Petersen, D., Hyldig, G., Schelvis, R., és Delahunty, C. (2009). Sensory characteristics of different cod products related to consumer preferences and attitudes. *Food Quality and Preference*, 20(2), 120–132. <http://doi.org/10.1016/j.foodqual.2008.09.002>
- Szőke, A., Losó, V., Sipos, L., Geösel, A., Gere, A., és Kókai, Z. (2012). The effect of brand/type/variety knowledge on

the sensory perception. *Acta Alimentaria*, 41(0), 197–204. <http://doi.org/10.1556/AAlim.41.2012.Suppl.19>

Szöllősi, D., Dénes, D. L., Firtha, F., Kovács, Z., és Fekete, A. (2012). Comparison of six multiclass classifiers by the use of different classification performance indicators. *Journal of Chemometrics*, 26(3-4), 76–84. <http://doi.org/10.1002/cem.2432>

Tang, C., Heymann, H., és Hsieh, F. (2000). Alternatives to data averaging of consumer preference data. *Food Quality and Preference*, 11(1-2), 99–104. [http://doi.org/10.1016/S0950-3293\(99\)00019-1](http://doi.org/10.1016/S0950-3293(99)00019-1)

Tarcsay, Á., és Keserű, G. M. (2015). Is there a link between selectivity and binding thermodynamics profiles? *Drug Discovery Today*, 20(1), 86–94. <http://doi.org/10.1016/j.drudis.2014.09.014>

Teillet, E., Urbano, C., Cordelle, S., és Schlich, P. (2010). Consumer perception and preference of bottled and tap water. *Journal of Sensory Studies*, 25(3), 463–480. <http://doi.org/10.1111/j.1745-459X.2010.00280.x>

Tenenhaus, M., Pagès, J., Ambroisine, L., és Guinot, C. (2005). PLS methodology to study relationships between hedonic judgements and product characteristics. *Food Quality and Preference*, 16(4), 315–325. <http://doi.org/10.1016/j.foodqual.2004.05.013>

Torri, L., Noble, A. C., és Heymann, H. (2013). Exploring American and Italian consumer preferences for Californian and Italian red wines. *Journal of the Science of Food and Agriculture*, 93(8), 1852–1857. <http://doi.org/10.1002/jsfa.5979>

Towal, R. B., Mormann, M., és Koch, C. (2013). Simultaneous modeling of visual saliency and value computation improves predictions of economic choice. *Proceedings of the National Academy of Sciences of the United States of America*, 110(40), E3858–67. <http://doi.org/10.1073/pnas.1304429110>

Valera, P., és Ares, G. (2014). *Novel Techniques in Sensory Characterization and Consumer Profiling*. (V. Paula és A. Gastón, Szerk.) (1st kiad.). CRC Press.

Valli, E., Bendini, A., Popp, M., és Bongartz, A. (2014). Sensory analysis and consumer acceptance of 140 high-quality extra virgin olive oils. *Journal of the Science of Food and Agriculture*, 94(10), 2124–2132. <http://doi.org/10.1002/jsfa.6535>

van der Laan, L. N., de Ridder, D. T. D., Viergever, M. a, és Smeets, P. a M. (2011). The first taste is always with the eyes: a meta-analysis on the neural correlates of processing visual food cues. *NeuroImage*, 55(1), 296–303. <http://doi.org/10.1016/j.neuroimage.2010.11.055>

van der Laan, L. N., Hooge, I. T. C., de Ridder, D. T. D., Viergever, M. a., és Smeets, P. a M. (2015). Do you like what you see? The role of first fixation and total fixation duration in consumer choice. *Food Quality and Preference*, 39, 46–55. <http://doi.org/10.1016/j.foodqual.2014.06.015>

van Kleef, E., van Trijp, H. C. M., és Luning, P. (2006). Internal versus external preference analysis: An exploratory study on end-user evaluation. *Food Quality and Preference*, 17(5), 387–399. <http://doi.org/10.1016/j.foodqual.2005.05.001>

van Trijp, H. C. M., Punter, P. H., Mickartz, F., és Kruithof, L. (2007). The quest for the ideal product: Comparing different methods and approaches. *Food Quality and Preference*, 18(5), 729–740. <http://doi.org/10.1016/j.foodqual.2007.01.005>

Varela, P., Beltrán, J., és Fiszman, S. (2014). An alternative way to uncover drivers of coffee liking: Preference mapping based on consumers' preference ranking and open comments. *Food Quality and Preference*, 32, 152–159. <http://doi.org/10.1016/j.foodqual.2013.03.004>

Vidal, L., Tárrega, A., Antúnez, L., Ares, G., és Jaeger, S. R. (2015). Comparison of Correspondence Analysis based on Hellinger and chi-square distances to obtain sensory spaces from check-all-that-apply (CATA) questions. *Food Quality and Preference*, 43, 106–112. <http://doi.org/10.1016/j.foodqual.2015.03.003>

Villamor, R. R., Daniels, C. H., Moore, P. P., és Ross, C. F. (2013). Preference Mapping of Frozen and Fresh Raspberries. *Journal of Food Science*, 78(6), 911–919. <http://doi.org/10.1111/1750-3841.12125>

Wada, Y., Tsuzuki, D., Kobayashi, N., Hayakawa, F., és Kohyama, K. (2007). Visual illusion in mass estimation of cut food. *Appetite*, 49(1), 183–190. <http://doi.org/10.1016/j.appet.2007.01.009>

Wadhera, D., és Capaldi-Phillips, E. D. (2014). A review of visual cues associated with food on food acceptance and consumption. *Eating behaviors* (Köt. 15). Elsevier B.V. <http://doi.org/10.1016/j.eatbeh.2013.11.003>

Winakor, G., Kim, C. J., és Wolins, L. (1980). Fabric Hand: Tactile Sensory Assessment. *Textile Research Journal*, 50 (10), 601–610. <http://doi.org/10.1177/004051758005001005>

- Wold, S. (1995). PLS for multivariate linear modelling. In H. van de Waterbeemd (Szerk.), *QSAR: Chemometric Methods in Molecular Design* (2. kiad., o. 195–218). Weinheim, Germany: VCH Verlagsgesellschaft mbH.
- Worch, T. (2013). PrefMFA, a solution taking the best of both internal and external preference mapping techniques. *Food Quality and Preference*, 30(2), 180–191. <http://doi.org/10.1016/j.foodqual.2013.05.009>
- Worch, T., Lê, S., Punter, P., és Pagès, J. (2012). Construction of an Ideal Map (IdMap) based on the ideal profiles obtained directly from consumers. *Food Quality and Preference*, 26(1), 93–104. <http://doi.org/10.1016/j.foodqual.2012.04.003>
- Xiong, R., és Meullenet, J. F. (2006). A PLS dummy variable approach to assess the impact of jar attributes on liking. *Food Quality and Preference*, 17(3-4), 188–198. <http://doi.org/10.1016/j.foodqual.2005.03.006>
- Yenket, R., Chambers Iv, E., és Adhikari, K. (2011). A Comparison Of Seven Preference Mapping Techniques Using Four Software Programs. *Journal of Sensory Studies*, 26(2), 135–150. <http://doi.org/10.1111/j.1745-459X.2011.00330.x>
- Yenket, R., Chambers IV, E., és Adhikari, K. (2011). A comparison of seven preference mapping techniques using four software programs. *Journal of Sensory Studies*, 26(2), 135–150. <http://doi.org/10.1111/j.1745-459X.2011.00330.x>

11. Mellékletek

11.1. Nagyságrendi becslő skálák kérdésfeltevése

A nagyságrendi becslő skálák alkalmazását azonban megnehezíti a megfelelő képzés biztosítása a fogyasztói vizsgálatokban. Képzett panel esetén a skálával kapcsolatos ismeretek a képzés szerves részét képezhetik, azonban a fogyasztói bírálatok során ez nem minden esetben megoldható. Éppen ezért a kérdésfeltevés hosszas és nehézkes lehet. Lawless és Heymann bemutatnak egy mintakérdést (Lawless és Heimann, 2010):

„Kérem, kóstolja meg az első mintát, és jegyezze fel édes ízének intenzitását. A soron következő minták édes ízét értékelje oly módon, hogy az első mintához képest mennyire érzi azokat édesnek. Például, ha a következő minta kétszer édesebb, akkor az első mintára adott érték kétszeresét adja. Amennyiben fele olyan édes, az első minta értékének felét adja.”

A fenti kérdésből is látható, hogy a módszer megfelelő instrukciók nélkül nem hajtható végre. Emellett szintén fontos, hogy a tulajdonság egyértelmű legyen, esetlegesen az egyes kategóriáknál szövegesen is jelölni kell a kezdő/végpontok jelentését. A nagyságrendi becslő skálák alkalmazásának két módja ismeretes a nemzetközi szakirodalomban, amelyek a következők:

(1) Létezik referenciatermék/tulajdonság

Ebben az esetben a bírálat kezdetekor a bírálók kapnak egy referenciaterméket/tulajdonságot, amelynek értéke adott. Például ízesített kefir termékeknél az első bírált mintánál megadják a bírálónak, hogy a minta gyümölcsös ízének intenzitása 10-es értékű lesz a bírálat során. Ezt követően minden további terméket ehhez az értékhez viszonyít a bíráló a bírálat során. A módszer előnye, hogy az eredmények könnyebben interpretálhatóak, ugyanis mindenki azonos kezdőpontról indult (10-es intenzitású gyümölcsös íz), azonban a bírálók szempontjából kötöttebb, mivel egy előre meghatározott értékből kell kiindulniuk.

Instrukciók:

„Kérem, kóstolja meg az első mintát és memorizálja édes ízének intenzitását. Ezt az intenzitás értéket a bírálati lapon 10-zel jelöltük. Kérem, a soron következő mintákat ehhez a referenciamintához képest arányosítva értékelje. Például, ha a következő minta kétszer olyan édes, akkor 20-as értéket jegyezzen fel. Amennyiben 3,5-szer édesebb, úgy a 35-ös értéket jegyezze fel. Más szavakkal, az értékelés során adott számértékek a referenciamintához arányosan fejezzék ki a minta édes ízének intenzitását. Bármilyen pozitív szám megadható, akár tört, akár tizedesek formájában.”

(2) Nincs referenciatermék/tulajdonság

Ebben az esetben a fentiekhez képest annyi a módosítás, hogy a kezdő termékhez/tulajdonsághoz nem rendelnek intenzitásértéket. Itt a bírálót arra kéri, hogy maga állapítsa meg a termék intenzitásértékét, azonban a továbbiakban is csak ez alapján bíráljon. Ez a bírálóknak több szabadságot ad, mivel a saját maguk által felállított referencia alapján megadott kezdeti értékhez viszonyítva folytathatják le bírálatukat. Ezzel szemben az adatfeldolgozás során éppen ez a bírálói szabadság adja a legnagyobb nehézséget is, mivel minden bíráló más kezdőpontról bírál (egymáshoz képest eltolódott skálák). Az első módszert inkább a fogyasztói bírálatoknál, míg a másodikat a képzett bírálókkal javasolt használni.

Instrukciók:

„Kérem, kóstolja meg az első mintát, és jegyezze fel édes ízének intenzitását. Kérem, a soron következő mintákat ehhez a referenciamintához képest arányosítva értékelje. Például, ha a következő minta kétszer olyan édes, akkor kétszer akkora értéket jegyezzen fel. Amennyiben 3,5-ször édesebb, úgy egy 3,5-ször nagyobb értéket jegyezzen fel. Más szavakkal, az értékelés során adott számértékek az első mintához arányosan fejezzék ki a minta édes ízének intenzitását. Bármilyen pozitív szám megadható, akár tört, akár tizedesek formájában.”

A nagyságrendi becslőskálákkal részletesen foglalkozik az amerikai ASTM E1697 és az ISO 11056:1999 szabvány is (ISO 11056:1999; ASTM E1697, 2012). Nagyságrendi becslő skálák alkalmazása során jellemzően csak egy tulajdonságot értékelnek a bírálók egy alkalommal. A leíró vizsgálatokban azonban több példát is találni, amikor több tulajdonságot is értékelnek a képzett bírálók. A profilanalízisben nem terjedt el az alkalmazása, noha jellegéből adódóan alkalmas lenne a feladatra. Ennek egyik oka a skála összetettségében keresendő, mivel a kapott értékek mindig arányskálán mért értékek lesznek, így a statisztikai értékelésük is eltér a vonal- vagy kategóriaskálák értékelésétől, illetve a kapott eredmények értelmezése és közlése során is figyelembe kell venni a skála jellemzőit.

11.2. Szemkamera típusok



M11.1.1 ábra: Statikus szemkamera, Tobii T60

(Forrás: https://www.pstnet.com/images/hw_parent/parent_tobii.png)



M11.1.2 ábra: Dinamikus szemkamera, Tobii Glasses 2.

(Forrás: <http://www.forbes.com/sites/jenniferhicks/2014/05/26/eye-tracking-wearables-for-market-research-tobii-glasses-2/>)



M11.1.3 ábra: Szemkamera-elrendezések. A bal felső elrendezéstől kezdve: 1) beépített kivetítőt alkalmazó vizsgáltok; 2) számítógéphez kötött monitoron történő alkalmazás; 3) laptopon történő vizsgálat; 4) televízióhoz/projektorhoz kötött szemkamera.

(Forrás: <http://www.consortworld.com/et-products.html>)



M11.1.4 ábra: Tabletek, okostelefonok felhasználása során egy speciális rögzítő biztosítja a szemkamera alkalmazását.

(Forrás: <http://www.tobii.com/en/eye-tracking-research/global/products/hardware-accessories/mobile-device-stand-X2/>)

11.3. A Kaiser-Meyer-Olkin mutató meghatározása

A Kaiser-Meyer-Olkin mutató az alábbi képlet alapján határozható meg:

$$KMO = \frac{\sum_{i=1}^p \sum_{j=1}^p r_{ij}^2}{\sum_{i=1}^p \sum_{j=1}^p \rho_{ij}^2 + \sum_{i=1}^p \sum_{j=1}^p r_{ij}^2}$$

Ahol:

r_{ij} - az i-edik és a j-edik változók korrelációs együtthatója,

$\rho_{ij} = \frac{R_{ij}}{\sqrt{R_{ii} \cdot R_{jj}}}$ - az i-edik és a j-edik változó parciális korreláció együtthatója.

- ha a KMO értéke $\geq 0,5$ abban az esetben az adatok alkalmasak a főkomponens-analízisre,
- ha a KMO értéke $< 0,5$ abban az esetben az adatok nem alkalmasak a főkomponens-analízisre.

12. Köszönetnyilvánítás

Köszönettel tartozom témavezetőmnek, Dr. Sipos Lászlónak szakmai és emberi támogatásáért. A megannyi kávé melletti megbeszélés, ötletelés minduntalan újabb és újabb kutatási kérdéseket vetett fel, amelyek megválaszolása nélkül ez a dolgozat nem születhetett volna meg.

Külön köszönöm tanszékvezetőmnek Dr. Kókai Zoltánnak, hogy ideális feltételeket teremtett kutatásaimhoz és mindvégig támogatást biztosított. Pozitív gondolataira és örök jókedvére ugyanúgy mindig számíthattam, mint értékes szakmai tanácsaira.

Szakértői munkáját köszönöm Dr. Héberger Károlynak, a Magyar Tudományos Akadémia kemométerének az alapos, mindenre kiterjedő kendőzetlen kritikai észrevételeit, amelyek mind hozzájárultak a tudományos eredmények közléséhez. Továbbá köszönöm Kollárné Dr. Hunek Klárának, a BME matematikusának, Dr. Ladányi Mártának, a BCE Biometria és Agrárinformatika Tanszék vezetőjének, Dr. Kovács Sándornak a Debreceni Egyetem matematikusának, Pásztorné Huszár Klárának, a BCE Hűtő- és Állatiternék Technológiai Tanszék kutatójának, Lukas Dannernek és Klaus Dürschmidtnek, a bécsi BOKU kutatóinak, Lori Rothmannek és Merry Jo Parkernek, az amerikai szabványügyi testület szerkesztőinek, Kurucz Csillának a Magyar Szabványügyi Testület műszaki bizottsági titkárának, Dr. Losó Viktornak a Mirelite Mirsa Zrt. igazgatójának, hogy szakmai tudásukkal, véleményükkel, kritikai észrevételeikkel, tanácsaikkal hozzájárultak munkám eredményességéhez.

Külön köszönettel tartozom szüleimnek, akik biztatása, munkája és áldozatai nélkül nem lennék az aki most vagyok és nem születhetett volna meg doktori disszertációm.

Köszönet illeti feleségemet, Dalmát, aki mindvégig önzetlenül mellettem állt akár éjszakákon át is az írás/szerkesztés/javítás során, türeleme, szakmai és emberi tanácsai, kifogyhatatlan jókedve és bátorítása nélkül ez a munka sem készült volna el, ahogy oly sok más sem.