

DÖMÖTÖR BARBARA–MAROSSY ZITA

A likviditási mutatószámok struktúrája

A likviditás mérésére többféle mutató terjedt el, amelyek a likviditás jelenségét különböző szempontok alapján számszerűsítik. A cikk a szakirodalom által javasolt, különféle likviditási mutatókat elemzi sokdimenziós statisztikai módszerekkel: főkomponens-elemzés segítségével keresünk olyan faktorokat, amelyek legjobban tömörítik a likviditási jellemzőket, majd megnézzük, hogy az egyes mutatók milyen mértékben mozognak együtt a faktorokkal, illetve a korrelációk alapján klaszterezési eljárással keresünk hasonló tulajdonságokkal bíró csoportokat. Arra keressük a választ, hogy a rendelkezésünkre álló minta elemzésével kialakított változócsoportok egybeesnek-e a likviditás egyes aspektusaihoz kapcsolt mutatókkal, valamint meghatározhatók-e olyan összetett likviditási mérőszámok, amelyeknek a segítségével a likviditás jelensége több dimenzióban mérhető.

1. A PIACI LIKVIDITÁS ASPEKTUSAI

A 20. században a pénzügyi elméletek fontos kiindulópontja a korlátlan piaci likviditás feltételezése volt. A portfólióelméletben a portfólió értéke megfelel az alkotóelemek piaci értékkel súlyozott átlagának, ahol a piaci érték az aktuális ár mennyiséggel vett szorzata, tehát az elmélet feltételezi, hogy a piaci áron bármikor korlátlan mennyiségben lehet kereskedni, vagyis a piac likvid. A likviditás a század vége felé jelent meg az elméleti kutatásokban, a válságok kapcsán bekövetkező illikviditás okozta piaci anomáliák hívták fel a figyelmet a jelenség fontosságára.

A likviditás önmagában nem, csak különböző aspektusokban definiált változókkal mérhető. Az egyes dimenziók alapján mért likviditás nem feltétlenül azonos, előfordulhat, hogy a piac egyik szempont szerint likvid, a másik szerint nem. A szakirodalom (von Wyss [2004]) alapvetően 4 dimenzióját különbözteti meg a likviditásnak (1. ábra), amelyek alapján különböző likviditási mérőszámok definiálhatók. Az egyes dimenziók között kapcsolat van, így a mutatók besorolása nem minden esetben egyértelmű.

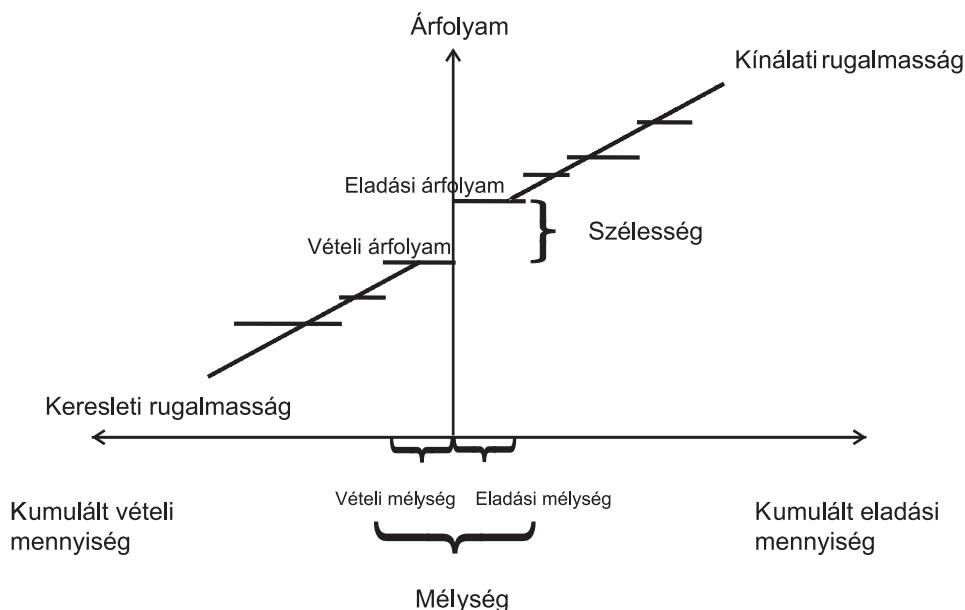
1. *Időhöz kapcsolódó mutatók*: a kereskedés gyorsaságát, azonnalíságát kívánják megragadni a kereskedett mennyiség, illetve a tranzakciókhoz kapcsolódó várakozási idő figyelembe vételével.
2. *Szélesség¹ (tightness)*: az azonnali kereskedés költségét számszerűsító vételi és eladási árfolyam különbségét (spread) mérő mutatók.
3. *Mélység (depth)*: A legjobb vételi és eladási áron kereskedhető mennyiségből kiindulva meghatározott mennyiségi mutatók.
4. *Rugalmasság (resiliency)*: a keresleti és kínálati görbe egészét figyelembe vevő mutatók.

¹ Az angol kifejezések fordítása: I. KUTAS és VÉGH [2005].

A likviditás összetett jelenségének megragadására számos, a fenti dimenziókban meghatározott mutató kombinációjaként definiált, többdimenziós mérőszámot is javasolnak egyes szerzők (Kluger és Stephan [1997]).

1. ábra

**Az ajánlati könyv egy pillanatfelvétele:
a likviditás különböző aspektusai**



Forrás: von Wyss [2004]

Vizsgálatunk arra irányul, hogy a sokféleképpen definiált likviditási mutatószámok koherensek-e, azaz a likviditást egyféle szempontból mérő mutatók valóban együtt mozognak-e, illetve a likviditás más dimenzióit számszerűsítő mutatószámok elkülönülnek-e egymástól. Az elemzés exploratív adatelemzés, nem hipotézisek alátámasztásáról szól, hanem a rendelkezésre álló tőzsdei adatok alapján a likviditási mutatók viselkedését keresztmetszetileg vizsgáljuk. Megnézzük a likviditási mutatók együttmozgását az elemzés mintájául szolgáló vállalatok adatai alapján, arra keressük a választ, hogyan néz ki a likviditási mutatószámok struktúrája.

2. MÓDSZERTAN

A likviditási mutatószámok együttmozgását befolyásoló, fontosabb faktorok meghatározását főkomponens-elemzéssel végezzük el, míg a mutatószámok empirikus adatokon történő csoportosítása k középpontú klaszterezési eljárás segítségével történik. Ebben a fejezetben bemutatjuk az alkalmazott módszereket.

2.1. Az együttmozgás leírása: főkomponens-elemzés

A főkomponens-elemzés² (principal component analysis – PCA) többváltozós adatok esetén a vizsgált változók együttmozgásának szerkezetét segít feltérképezni. Precízebben: a PCA használatával meghatározhatók az egymással lineárisan korreláló változók mögötti, egymással nem korreláló faktorok (főkomponensek). A főkomponensek az eredeti változók lineáris kombinációi, így:

$$y_1 = Xa_1, y_2 = Xa_2, \dots, y_p = Xa_p, \quad (1)$$

ahol p a rendelkezésre álló adataink dimenziója, azaz a változók száma, a_i -k a főkomponenseket definiáló súlyok, míg X a rendelkezésünkre álló adatokat megadó $n \times p$ -s mátrix, n pedig a megfigyelések száma. A főkomponenseket megadó súlyokról feltételezzük, hogy hosszuk egységnyi.

Célunk, hogy olyan főkomponenseket kapjunk, amelyek az eredeti változók varianciájának minél nagyobb hányadát magyarázzák meg. Megmutatható (Kovács [2009] vagy Baran és munkatársai [2000]), hogy ennek a feltételnek eleget tevő, egymással korrelálatlan főkomponenseket a változók kovariancia mátrixának sajátérték-sajátvektor felbontása segítségével tudjuk meghatározni. A kovarianciamátrix sajátvektorai adják az a_i súlyokat, míg a hozzájuk tartozó λ_i sajátértékek adják meg a sajátvektorok által definiált főkomponensek varianciáját. Az eredeti változóinkról legtöbb információt hordozó főkomponens tehát a legnagyobb sajátértékhez tartozó sajátvektorral állítható elő. Az i . főkomponens által hordozott információ:

$$\frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \quad (2)$$

Az i . főkomponens ekkora hányadát írja le az eredeti változóink varianciájának.

A gyakorlatban sokszor nem a kovarianciamátrix, hanem a korrelációs mátrix sajátérték-sajátvektor felbontása adja a főkomponenseket. A korrelációs mátrix használatával lényegében ugyanazokat az eredményeket kapjuk, mintha az eredeti változóinkat sztenderdizáltuk volna. A korrelációs mátrix használata tehát biztosítja, hogy egyik változó sem dominálja a nagyságrendjéből következően a PCA végeredményét.

A főkomponens-elemzéssel elhelyezhetjük a változóinkat a főkomponensek terében. A sajátérték-sajátvektor felbontással ugyanis megkaptuk a változók korrelációs mátrixának egy ortogonális bázisát, azaz az eredeti változók kifejezhetők ezen egymásra merőleges (egymással nem korreláló) főkomponens terében. Az eredeti változóink megadhatók egy p dimenziós koordinárendszerben, ahol az egyes koordináták az adott főkomponensekhez tartozó együtthatókat jelölik. Belátható, hogy a c_{ij} koordináta (*component loading*) a j . főkomponens és az i . változó közötti korrelációval egyezik meg. A C mátrixba rendezett koordinátákat komponensmátrixnak (*component matrix*) nevezzük.

A főkomponens-elemzést felhasználhatjuk dimenziócsökkentésre is. Levezethető (Baran és munkatársai [2000]), hogy ha p helyett k ($< p$) dimenzióban akarjuk kifejezni

2 A módszer bemutatása Kovács [2009] alapján történik.

az eredeti változóinkat, akkor a legjobb eredményt (a változók varianciáját tekintve, a legkisebb elvesztegetett információt) akkor kapjuk, ha a legnagyobb k darab sajátértékkel megadott főkomponenshez tartozó koordinátát megtartjuk, a többi főkomponenst pedig elhagyjuk. Ezzel a módszerrel egyszerűsíteni tudjuk az eredeti változóink együttmozgásának struktúráját, így könnyebben tudjuk értelmezni a változók közötti kapcsolatot. Gyakran alkalmazott eljárás, hogy a korrelációs mátrix felbontása esetén az egynél kisebb sajátértékhez tartozó főkomponenseket hagyjuk el. Ennek az áll a háttérében, hogy ebben az esetben a sajátértékek összege p ($=$ a sajátértékek száma), így az átlagos sajátérték ($= 1$) alatti sajátértékeket hagyjuk el.

A főkomponensek terében a változókon kívül az n darab megfigyelésünket is el szeretnénk helyezni. Az i . megfigyeléshez ekkor hozzárendeljük az adott j . főkomponensre vett „kitettséget” (score) a következőképpen:

$$y_{ij} = a_j^T x_i \quad (3)$$

Ezek után a főkomponensekkel mint egyszerű változókkal dolgozhatunk tovább. Ha a dimenziók számát csökkentettük, akkor a megfigyeléseinket kevesebb változóval sikerült leírunk.

A kapott főkomponenseket gyakran értelmezni is szeretnénk. Ez akkor lehetséges, ha elkülöníthető, hogy egyes főkomponensek mely változókkal korrelálnak egyértelműen, és melyekkel nem. Ezt akkor érhetjük el, ha a főkomponenseket elforgatjuk úgy, hogy a főkomponensek továbbra is korrelálatlanok maradjanak, míg a főkomponensek és a változók közötti korrelációk közel legyenek nullához vagy abszolút értékben 1-hez. Ezzel a módszerrel könnyebben tudjuk tartalommal feltölteni az egyes főkomponenseket. A cikkben az ún. varimax eljárást használjuk, ahol az elemzésben benne hagyott faktorok által magyarázott teljes variancia nem változik.

A főkomponens-elemzés algoritmus a bármely korrelációs mátrixon lefuttatható, hiszen a módszer a sajátértékek létezésére és pozitivitására (nemnegativitására) épül. Ahhoz azonban, hogy az eredeti változóink dimenzióját csökkenteni tudjuk, arra van szükség, hogy ezek a változók egymással korreláljanak, és legyenek mögöttük közös faktorok. Bár léteznek formális tesztek annak eldöntésére, hogy a rendelkezésre álló minta megfelelő-e a főkomponens-elemzéshez (Kovács [2009]), ezeket a tesztek az adatainkon nem fogjuk lefuttatni. Az elemzésből látni fogjuk, hogy a dimenzió sikeresen csökkenthető.

Az algoritmus alkalmazásának egy alapfeltételét is meg kellett sértenünk az elemzés során. A szakkönyvek azt javasolják, hogy $n \geq 5p$ legyen, azaz a megfigyeléseink legyenek jóval többen, mint a változóink. A feltétel megsértése komoly gondokat okozhat (pl. a korrelációs mátrix együtthatóinak becslése bizonytalan, vagy akár a korrelációs mátrix nem lesz pozitív definit). A mintaelemszámra vonatkozó feltételt a rendelkezésre álló adatok hiánya miatt nem tudtuk biztosítani (az adatokról bővebben l. a 3. fejezetet). Az eredmények értékelésénél ezt a tényt figyelembe kell venni, de úgy gondoltuk, hogy az elemzést ezzel a megkötéssel is érdemes elvégezni.

2.2. Csoportosítás: k középpontú klaszterezés

A k középpontú klaszterezési eljárás (k-means clustering) során a megfigyeléseinket előre megadott k darab csoportba³ szeretnénk sorolni. A célunk, hogy a csoporton belül egymáshoz hasonló megfigyelések legyenek, míg a különböző csoportok egyedei különbözzenek egymástól. A k középpontú klaszterezési eljárás során előre megadjuk, hogy végeredményként k darab csoportot szeretnénk kapni. Az algoritmus működése a következő⁴:

1. Soroljuk be a megfigyeléseket véletlenszerűen a csoportokba.
2. Számítsuk ki a csoportok közepét.
3. Az egyes egyedeket soroljuk át abba a csoportba, amelynek a csoportközéppontjához a legközelebb vannak.
4. Ismételjük a 2-3. pontokat addig, amíg a csoportközepek változnak.

Az adatainkat jellemzően egy X mátrixsal adjuk meg, ahol x_{ij} az i . megfigyelés j . változó szerinti értékét jelöli. Ekkor a 2. lépésben megadott csoportközepeket úgy számolhatjuk, mint a csoportban szereplő megfigyelések átlagát koordinátáinként, míg a 3. lépés megvalósításához szükséges távolságot egyszerű euklidészi távolságként definiálhatjuk.

Az eljárás akkor ad jó eredményeket, ha a mintánkban jól elkülöníthető, különbözőképpen viselkedő egyedek vannak.

Mint említettük, a csoportszámot az algoritmus lefuttatása előtt kell megadnunk. Előfordulhat, hogy egy csoportba túl sok, vagy esetleg túl kevés megfigyelés kerül. A csoportosítás eredményeinek fényében más csoportszámmal újrafuttathatjuk a számításokat egészen addig, amíg számunkra kielégítő eredményeket nem kapunk.

2.3. Csoportosítás a főkomponensek terében

Az általunk alkalmazott megközelítés lényege a következő:

1. Adott N vállalat esetén P darab likviditási mutatószám. Főkomponens-elemzéssel megkeressük a mutatószámok mögötti közös faktorokat (főkomponenseket⁵), majd elhelyezzük a mutatószámokat a faktorok terében. Ezek a főkomponensek adják meg az alapvető likviditási aspektusokat, amelyeket az egyes mutatószámok mérnek. A változók és a főkomponensek együttmozgásából tartalmat keresünk az egyes faktoroknak.
2. Arra keressük a választ, hogy vannak-e hasonlóan viselkedő likviditási mutatószámok. Ha a főkomponensek írják le a likviditási aspektusokat, akkor az egymáshoz hasonlóan viselkedő mutatók közel vannak egymáshoz a faktorok terében. A csoportok megtalálásához k középpontú klaszterezést hajtunk végre a faktorok terében a mutatószámokra.⁶ Jelentést adunk az egyes csoportoknak is.

3 A k csoportszámot ne tévesszük össze a PCA csökkentett dimenziójával, amit szintén k -val jelöltünk a 2.1. fejezetben! Mindkét helyen a hivatkozott szakirodalmak megszokott jelöléseit követtük, ezért jelent meg kétszer ugyanaz a szimbólum.

4 A módszer bemutatása Kovács [2009] alapján történik.

5 A „faktor” és „főkomponens” elnevezéseket szinonimaként használjuk a 2.1. alfejezetben bemutatott értelemben.

6 Vegyük észre, hogy itt az eredeti „változóink” a „megfigyelések” szerepét töltik be, míg itt a „változók” a faktorok.

A módszerrel szemben két ellenvetés tehető. Az egyik az, hogy mivel a hasonló tulajdonságokkal rendelkező, vagyis egymáshoz közeli csoportok kialakítása egy redukált térben történik, így előfordulhat, hogy olyan elemek is azonos csoportba kerülnek, amelyek a figyelemben nem vett dimenziókban egymástól távol esnek. Ezzel a problémával nem foglalkozunk, hiszen a PCA során a dimenziócsökkentés úgy történt, hogy azokat a dimenziókat hagytuk el, amelyek nem lényegesek a mutatószámok közötti különbségekben. Így az a dimenzió, amelyet nem veszünk figyelembe a klaszterezésnél, a PCA szerint nem is lényeges.

A másik lehetséges ellenvetés az lehet, hogy az alkalmazott két módszer egymással ellentétes feltételezésekre épül: a PCA esetén azt szeretnénk, hogy a változóink korreláljanak, a klaszterezésnél az a jó, ha a likviditási mutatószámok a csoportok között különböznek. Tekintsünk egy kicsit előre, és az eredmények fényében értékeljük ezeket a követelményeket! Látni fogjuk, hogy ezt az ellentmondást részben a PCA kárára lehet majd feloldani. Találni fogunk néhány független faktort, és a vizsgált változóink vagy az egyik, vagy a másik faktorhoz közel fognak elhelyezkedni, így a sok, egymással páronként korreláló változó feltétele sérül. Másrészt vannak olyan mutatószámok is, amelyek több faktorra is együtt mozognak. Ezeket a különbözőképpen mozgó tipikus csoportokat a PCA és a klaszterezés segítségével sikeresen el tudjuk különíteni.

A PCA-t és a klaszterezést SPSS programcsomaggal végezzük el.

3. AZ ADATOK BEMUTATÁSA

A piaci likviditási mutatók forrása általában valamilyen ajánlati könyv, ahol a kereskedési adatok hozzáférhetőek. A legtöbb empirikus vizsgálat a tárgyban a tőzsdei részvénykereskedelemhez kapcsolódik, de fontos új kutatási irány a kötvénypiaci likviditás is.

A jelen vizsgálatban mintaelemként a Svájci Értéktőzsde 18 vállalati részvénye szerepel (1. táblázat), amelyekre vonatkozóan 31 likviditási mutató mint változó (2. táblázat) vizsgálatát végezzük el. A likviditási mutatószámok az ajánlati könyvön, valamint a beérkezett kötésenkénti ajánlatok dinamikáján alapulnak. A likviditási adatok forrása Rico von Wyss disszertációja (von Wyss [2004]), amelyben a szerző a 2002. május 2. és július 31. közötti 65 kereskedési nap 5 perces adatai alapján minden időpontra kiszámolja a 31 likviditási mutató értékét, és ezek átlaga, illetve mediánja szerepel az elemzésünkben minden vállalatra vonatkozóan.

1. táblázat

Vizsgált részvények

Adecco	Holcim	Surveillance
Baer	Kudelski	Sulzer
Richemont	Lonza	Syngenta
Ciba	SwissRe	SwatchBearer
Clariant	Swisscom	SwatchRegist
Givaudan	Serono	Unaxis

Forrás: von Wyss [2004]

3.1. Az elemzésbe bevont likviditási mutatószámok

A 31 mutató vizsgálatunkban redundáns rendszert alkot, mivel több olyan mutatócsoport is van, amelyeknek az eredménye teljesen azonos a vizsgált időszakban (a relatív különbség 3 mérőszáma, valamint a relatív effektív különbség 2 mérőszáma). Ezen mutatók különböző piaci turbulenciák esetén mutatkozik meg, amikor előfordulnak ugrásszerű árfolyamváltozások. Az adatok egyezése azt mutatja, hogy a fenti időszak nyugodtnak mondható.

A redundancia következménye, hogy a változók közötti korrelációs mátrix nem lesz pozitív definit. A nulla megjelenik, mint a korrelációs mátrix többszörös sajátértéke. A korrelációs mátrix nullán kívüli sajátértékei mind pozitívak, így a korrelációs mátrix pozitív szemidefinit. A PCA így (SPSS figyelmeztetés mellett) lefuttatható, és az eredmények értelmezhetők.

A likviditási mutatók egy része a likviditás jelenségét azonos irányban méri, vagyis a nagyobb mutatószám likvidebb piacot jelez (pl. volumen, mennyiség jellegű mutatók), másik része pedig éppen ellentétesen (pl. vételi-eladási árfolyamok különbsége, áreltérítő hatás mérése), tehát a jobb likviditást kis értékek jelentik.

Célunk a mögöttes rendszer megértése, ezért az összes likviditási mutatót felhasználjuk az elemzés során. Az eredményeink mind a redundáns mutatószámokat, mind a különböző mérési irányokat figyelembe veszik és leírják.

Az elemzésünk előtt az eredeti adatainkat módosítanunk kellett. A likviditási ráta (LR1) tartalmát megváltoztattuk, mivel az eredeti adatbázis nullának vette az értékét, ha a nevezőben nulla szerepelt (*Melléklet I.*), ami ellentmond annak, hogy ebben az esetben rendkívül nagyoknak kellene lennie a mutatónak. Ilyen esetekben átállítottuk a mutató értékét – a mutatószám mintabeli maximumát figyelembe véve – 300 millióra. A mutatók számításánál bizonytalansági tényező, hogy amennyiben az ajánlati könyv nem tartalmazott elegendő mennyiséget, akkor a market impact mutatónál úgy veszi a forrásadatbázis, mintha a legkedvezőtlenebb (vételi esetében legmagasabb, eladási esetében legalacsonyabb) áron korlátlan mennyiségben lehetne kereskedni.

2. táblázat

Az elemzésbe bevont likviditási mutatók⁷

Rövidítés	Magyarázat	Mérés iránya
Q	Időegység alatt kereskedett mennyiség	+
V	Időegység alatt kereskedett forgalom	+
D	Legjobb vételi és eladási mennyiség összege	+
Dlog	Mélység logaritmus	+
D\$	Mélység dollárban	+
N	Időegység alatti tranzakciók száma	+

⁷ A mutatók számítási módját a *Melléklet* tartalmazza.

Rövidítés	Magyarázat	Mérés iránya
NO	Időegység alatti megbízások száma	+
Sabs	Abszolút különbség: legjobb vételi és eladási árfolyam különbsége	–
LogSabs	Abszolút különbség logaritmusa	–
SrelM	Relatív különbség: az abszolút különbség, osztva a közép-árfolyammal	–
Srelp	Relatív különbség: az abszolút különbség, osztva az utolsó kötés árfolyamával	–
Srellog	Log relatív különbség: legjobb eladási és vételi árfolyam hányadosának logaritmusa	–
Logsrellog	Log relatív különbség logaritmusa	–
Seff	Effektív különbség: a legutóbbi kötés árfolyamának és a középárfolyam különbségének abszolút értéke	–
Seffrelp	Relatív effektív különbség: effektív különbség és az utolsó kötés árfolyamának hányadosa	–
SeffrelM	Relatív effektív különbség: effektív különbség és a közép-árfolyam hányadosa	–
QS	Jegyzési meredekség: abszolút különbség és a mélység logaritmusának hányadosa	–
LogQS	Log jegyzési meredekség: log relatív különbség és a mélység logaritmusának hányadosa	–
LogQSadj	Módosított log jegyzési meredekség: vételi/eladási oldal különbségével korrigált mutató	–
CL	Composite liquidity: a relatív különbség és a dollárban kifejezett mélység hányadosa	–
LR1	Likviditási ráta 1: Forgalom és az időegység alatti hozam abszolút értékének hányadosa	+
LR3	Likviditási ráta 3: a hozam abszolút értékének és a kereskedett mennyiségnek a hányadosa	–
FR	Flow ráta: a forgalom és a várakozási idő hányadosa	+
OR1	Order ráta: a legjobb vételi és eladási mennyiség különbségének abszolút értéke, osztva a forgalommal	–

Rövidítés	Magyarázat	Mérés iránya
MIV	Meghatározott mennyiséghez kötött legjobb eladási és vételi árfolyam különbsége	–
MAIV	Meghatározott mennyiséghez kötött legjobb eladási árfolyam és a középárfolyam különbsége	–
MIBV	Középárfolyam és meghatározott mennyiséghez kötött legjobb vételi árfolyam különbsége	–
DIAk	Vételi árfolyam meghatározott változásához szükséges mennyiség	+
DIBk	Eladási árfolyam meghatározott változásához szükséges mennyiség	+
PIAq	Meghatározott mennyiség megvételéhez szükséges összegnek és a középárfolyamon kalkulált összeg hányadosának a logaritmusa	–
PIBq	Meghatározott mennyiség eladásával realizált összegnek és a középárfolyamon kalkulált összeg hányadosának a logaritmusa	–

Forrás: von Wyss [2004])

4. ELEMZÉS

4.1. Első eredmények és a módszertan újragondolása

A főkomponens-elemzés segítségével öt olyan főkomponens azonosítható, amelynek 1-nél nagyobb a sajátértéke. A mutatók által hordozott információ jól sűríthető, mivel ez az öt főkomponens a teljes variancia több mint 94%-át magyarázza, az első három főkomponens magyarázó ereje pedig 81% feletti (3. táblázat).

3. táblázat

Az első 5 főkomponens által magyarázott variancia

Főkomponens	Kezdeti sajátérték			Rotált megoldás		
	Teljes	Variancia %-ában	Kumulált variancia	Teljes	Variancia %-ában	Kumulált variancia
1	15,393	49,655	49,655	9,290	29,969	29,969
2	6,080	19,613	69,268	9,221	29,745	59,714
3	3,704	11,947	81,215	6,373	20,557	80,271
4	2,846	9,180	90,395	3,095	9,983	90,253
5	1,228	3,961	94,356	1,272	4,103	94,356

A likviditási mutatók és a főkomponensek közötti korrelációt tartalmazó komponensmátrix (*Melléklet II.*) alapján látható, hogy a likviditási mutatóknak mintegy a fele (az alacsony, 0,3 alatti korrelációkat elhanyagolva) egyértelműen egy (az 1.) főkomponenshez kapcsolódik, a mutatók másik felére azonban nem kapunk tiszta struktúrát, mert azok több komponenssel is korrelálnak. Ez a jelenség megfelel annak az elképzelésünknek, hogy a likviditás egyes aspektusai nem függetlenek egymástól, és bizonyos mutatók több dimenzióhoz is kapcsolódnak.

A hasonlóan viselkedő mutatószámok megkeresése előtt felmerült a kérdés, hogy a negatív korrelációkat hogyan kezeljük. Nyilvánvaló ugyanis, hogy ha egy faktor és egy változó között nagy abszolút értékű negatív korrelációs együttható van, akkor ez ellentétes irányú, de erős kapcsolatot jelez, vagyis célszerű azokat a mutatókat együtt kezelni, amelyek akármelyik irányban, de erőteljesen kapcsolódnak az egyes főkomponensekhez. A hasonló mutatószámok megkeresését célzó klaszterezést ezért elvégeztük az eredeti és az abszolút értékeket tartalmazó korrelációk (komponensmátrix) alapján is, hogy megnézhessük, mely likviditási mutatószámok változtatnak a jellegükön az abszolút érték hatására. Egyetlen változó került másik csoportba az abszolút korrelációk alapján, a log depth (mélység, vagyis a legjobb vételi és eladási árfolyamokon ajánlott mennyiség összegének a logaritmus). Bár a komponensmátrix abszolút értékén alapuló csoportosítás segít azonosítani az ellenkező irányban együtt mozgó változókat, a különböző típusú likviditási mutatószámok együttmozgásának megértéséhez nem az abszolút értékkel, hanem az eredeti komponensmátrixszal célszerű dolgozni. Az erős negatív korrelációk hatását az elemzésünkben ezért úgy kezeltük, hogy az egyetlen „problémás” változó ellentettjét ($-\log \text{depth}$) kiszámoltuk, majd az eredeti változót ezzel helyettesítve, újraszámoltuk a főkomponenseket, és az új eredmények felhasználásával végezzük el a csoportosítást a főkomponensek terében. Ez a módosítás nem változtat a 3. táblázat eredményein.

4.2. A likviditási mutatószámok csoportjai

A klaszterezés során a 2.2. alfejezetben említett eljárással négy csoportot alakítottunk ki. A 4. táblázat mutatja be, hogy az egyes csoportokba mely mutatószámok kerültek. A mutatók tartalma alapján a csoportok megfeleltethetők a likviditás egyes dimenzióinak. Az első csoportba a vételi és eladási árfolyam különbözetét (spreadet) relatív módon mérő mutatók tartoznak, ezek a piaci szélesség mérőszámai. A második csoport az idő, illetve mennyiség alapú likviditási mutatókat tartalmazza, míg a harmadikban jelennek meg a mélység, a legjobb árhoz tartozó mennyiség mérőszámai. A negyedik csoportba kerültek az abszolút spreadet, valamint adott mennyiséghez tartozó spreadet (market impact) mérő mutatók, amelyek a piaci szélességet és rugalmasságot jellemzik.

Az első és a negyedik csoport a feszességet, tehát a piac azon tulajdonságát jellemzi, hogy milyen költséggel lehet tranzakciót végrehajtani. A második és harmadik csoportba a mennyiség alapú mérőszámok tartoznak, amelyek a likviditást a kereskedhető mennyiségekben keresztül próbálják megragadni.

A csoportba sorolás a legtöbb mutatóra megfelel előzetes várakozásainknak, két esetet érdemes kiemelni: a likviditási ráta kétféle mérőszáma külön csoportba került, ami – elte-

kintve attól, hogy kicsit másként mérik a mennyiséget és a hozamot – abból adódik, hogy ezek egymás reciprokai. A másik érdekesség, hogy a negatív mélység logaritmusa ($-\log$ depth), amely egy mennyiség típusú változó, a vételi és eladási különbséget abszolút módon mérő mutatók csoportjához tartozik.

4. táblázat

Klaszterelemzéssel előállított mutatócsoportok

1 Relatív spread	2 Idő/volumen	3 Mélység	4 Abszolút spread
SrelM	Q	OR1	–Dlog
Srelp	V	D	PIAq
Srellog	N	D\$	PIBq
LogSrellog	NO		MIV
Seffrelp	LR1		MIAV
SeffrelM	FR		MIBV
LogQS	DIAk		QS
LogQSadj	DIBk		Seff
CL			Sabs
LR3			LogSabs

4.3. A faktorok értelmezése

A főkomponensek értelmezéséhez megnéztük, hogy a csoportközépek, amelyek a csoport tipikus viselkedését leírják, hogyan helyezkednek el a faktortérben. A csoportközépek faktorokra vetített koordinátái (5. táblázat) alapján összekapcsolhatók a főkomponensek és a csoportok. Az egyes csoportba tartozó mutatók változását elsősorban az a faktor határozza meg, amelyre a faktorkoordináta értéke magas. Ezeket a magas értékeket az 5. táblázatban kiemeléssel jelezzük. A relatív spread mutatók egyértelműen az első faktorhoz kapcsolódnak, ezért az első faktor azonosítható úgy, mint az a likviditási mérték, amely a piac relatív szélességét határozza meg. Ez a változó magyarázza a likviditási mérőszámok szóródásának legnagyobb hányadát (mintegy 30%-ot); minél alacsonyabb az értéke, annál likvidebb a piac. A második faktorhoz kapcsolódnak az abszolút spread típusú mutatók, és kisebb mértékben a mennyiségi mutatók. Ez a faktor az abszolút (mértől függő) szélességet tartalmazó változó, a teljes variancia újabb közel 30%-át magyarázza, kis értékkel jelezve a nagyobb likviditást. A harmadik faktor a második csoporttal mozog együtt, volumenváltozóként azonosítható, a teljes variancia 20%-át magyarázza. A negyedik faktor értelmezése szintén egyszerű, mivel mozgása egyértelműen megfeleltethető a harmadik csoportbeli mutatóknak, vagyis ez a faktor azonosítható a mélységgel. Az ötödik faktor nem mutat szignifikáns kapcsolatot egyik csoporttal sem, és magyarázó ereje alapján sem olyan jelentős, ezért ezt nem értelmezzük.

5. táblázat

A csoportközépek koordinátái a faktortérben

	Csoport 1	Csoport 2	Csoport 3	Csoport 4
Faktor 1	0,8787 (0,0309)	-0,1581 (0,0618)	0,0000 (0,0000)	0,2012 (0,0677)
Faktor 2	0,1105 (0,00737)	-0,1948 (0,0956)	-0,0916 (0,0916)	0,8627 (0,0282)
Faktor 3	-0,0284 (0,0284)	0,8281 (0,0335)	0,0894 (0,0894)	-0,0288 (0,0288)
Faktor 4	0,0322 (0,0322)	0,0336 (0,0336)	0,9108 (0,0182)	-0,0402 (0,0402)
Faktor 5	-0,0817 (0,0548)	-0,0157 (0,0941)	0,0000 (0,0000)	0,0042 (0,0475)

Megjegyzés: zárójelben tüntetjük fel a csoporton belüli szórást

Ahogy a likviditás dimenziói is összefüggnek, az egyes mutatócsoportok sem tekinthetők függetlennek. A faktortérben ábrázolva a csoportközépeket mint vektorokat, a csoportok közötti korreláció (6. táblázat) megkapható a vektorok által bezárt szög cosinusaként. Látható, hogy a relatív és az abszolút spread mutatói korrelálnak leginkább, illetve a spread és a mennyiség típusú változók közötti korreláció negatív.

6. táblázat

A csoportok korrelációja a faktortérben

Csoport	1	2	3	4
1	1	-0,235	0,020	0,343
2	-0,235	1	0,154	-0,293
3	0,020	0,154	1	-0,145
4	0,343	-0,293	-0,145	1

4.4. Az elemzés kiterjesztése a mediánadatokra

A vizsgált időszak 6500 adatának nemcsak az átlaga, hanem a mediánja is rendelkezésre áll. Az eddig bemutatott eredményeket a 6500 adat átlaga alapján elvégzett számítással kaptuk. A bemutatott elemzéseket elvégeztük a mediánadatokra is, és megnéztük, hogy ezekre is ugyanazt a struktúrát kapjuk-e vissza. A mediánadatoknál is a mélység logaritmusának ellentettjével számoltunk. Az első főkomponensek magyarázó ereje kicsit kisebb lett – az első három főkomponens a teljes variancia 75%-át, az első öt pedig 93%-át magyarázza.

A mutatók klaszterezésével ugyanazt a négy csoportot kaptuk (7. táblázat), mint az átlagadatok esetén, csak a csoportok számozása tér el a két adatbázisra.⁸ A főkomponensek ér-

⁸ A 7. táblázatban a mediánadatokra adódó csoportok és faktorok esetén feltüntettük azok megfelelőit az átlag elvégzett elemzés esetére. Látható, hogy az 1-es és 2-es faktor sorrendje megcserélődik. Mivel a csoportok számozása a klaszterezés esetén tetszőleges, ezért a kétféle számítás esetén a csoportszámok esetlegesen változnak. A mediánadatokra végzett elemzés esetén kapott 2-es csoport például a 4-es csoportnak felel meg az átlaggal végzett elemzés esetén.

telmezése is megegyezik, de az első két főkomponens sorrendje megváltozik: a legnagyobb magyarázó erővel (31%) bíró főkomponens az abszolút szélesség, a második főkomponens, amely a teljes variancia 25,5%-át magyarázza, a relatív szélesség változójának értelmezhető. Ez az eredmény feltehetően abból adódik, hogy a mediánadatok robosztusabbak, kevésbé érzékenyek a kiugró értékekre, mint az átlag, így a méretfüggő mutatók jelentősége relatíve megnőtt. A harmadik és negyedik főkomponens, ugyanúgy, mint az átlagadatoknál, a volumen és a mélység változójaként azonosítható.

Az átlag és a medián alapján számolt likviditási mutatók elhelyezkedése az első három főkomponens terében nagyon hasonló (*Melléklet III.*).

7. táblázat

Mediánadatokra a csoportközepek koordinátái a faktortérben

	Csoport 1	Csoport 2	Csoport 3	Csoport 4	Átlag faktor
Faktor 1	0,1096 (0,0730)	0,8971 (0,0198)	- 0,1792 (0,0891)	0,0000 (0,0000)	2
Faktor 2	0,8137 (0,0658)	0,1604 (0,0539)	- 0,0393 (0,0393)	0,0000 (0,0000)	1
Faktor 3	- 0,0353 (0,0353)	- 0,0310 (0,0310)	0,7858 (0,0594)	0,0000 (0,0000)	3
Faktor 4	- 0,0297 (0,0555)	- 0,0406 (0,0406)	0,0380 (0,0380)	0,9484 (0,0191)	4
Faktor 5	- 0,1265 (0,0922)	0,0501 (0,0334)	0,1214 (0,1036)	0,0000 (0,0000)	5
Átlag csoport	1	4	2	3	

Megjegyzés: Zárójelben tüntetjük fel a csoporton belüli szórást.

Elmondhatjuk, hogy vannak kisebb különbségek a mutatószámok idősorának átlagát, illetve mediánját véve, ugyanakkor a végeredmény közel azonos; tehát, bár az egyes mutatók átlaga és a mediánja eltér egymástól, de a mutatók együttmozgása keresztmetszeti (vállalatok közötti) értelemben stabil.

5. ALAPVETŐ ÉS ÖSSZETETT LIKVIDITÁSI MUTATÓK

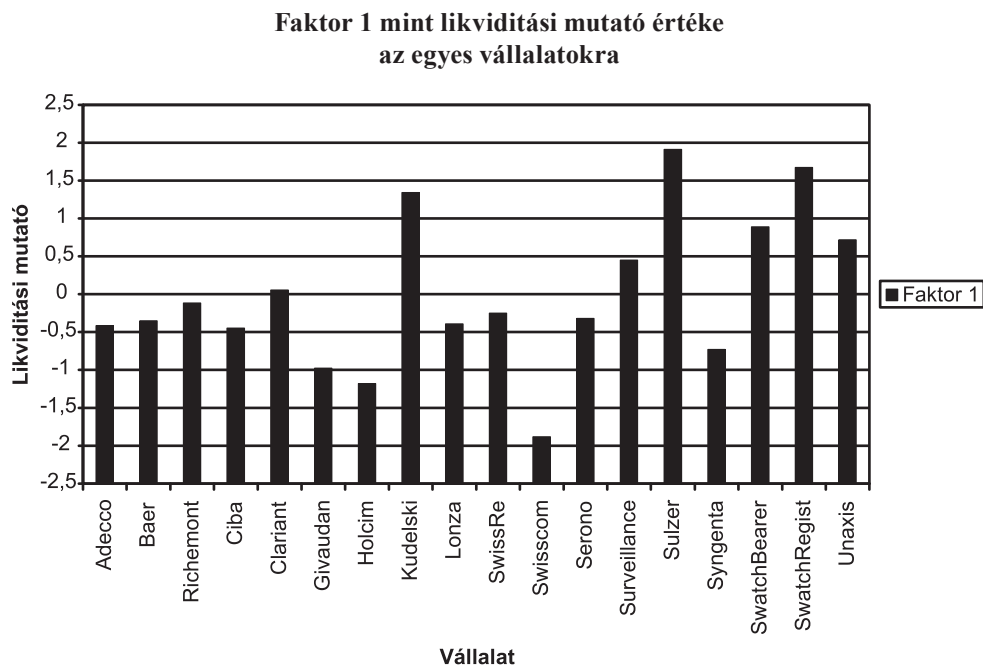
A 4. fejezetben láthattuk, hogy a főkomponensek terében a likviditási mutatók leírhatók egy 5 dimenziós koordináta-rendszerben, ahol a koordináták az egyes likviditási aspektusok szerinti kitettséget jelentik. Megfordítva is igaz: a főkomponensek terében bármely pont értelmezhető likviditási mutatószámként. Speciálisan, ha az egyes tengelyeket megadó, egységnyi hosszúságú vektorokat tekintjük, akkor a meghatározott likviditási aspektust, és csakis azt mérő likviditási mutatószámot kapunk, amely az adott szempont szerinti alapvető likviditási mértékként értelmezhető. A főkomponensek terében kiválaszthatjuk az egyes likviditási mutatócsoportok csoportközepeit is. Ebben az esetben az adott csoport jellemző tulajdonságainak megfelelő komplex (összetett) likviditási mutatószámot kapunk.

A következő alfejezetekben ezekre az alapvető és összetett mutatószámokra hozunk példát, és bemutatjuk az így kapott likviditási mutatószámok használatát.

5.1. Az 1. főkomponens mint likviditási mutató

Amennyiben a főkomponensek terében az $[1; 0; 0; 0; 0]$ pontot választjuk ki, akkor az 1. főkomponensnek megfelelő, alapvető likviditási mutatószámot kapjuk meg, azaz a likviditást kizárólag a relatív szélesség dimenzióban mérjük. Ennek úgy tudunk tartalmat adni, hogy megnézzük a vállalatok elhelyezkedését a faktortérben. Minden vizsgált vállalat megadható szintén 5 koordinátával a főkomponensek terében, a 2.1. alfejezet (3)-ban bemutatott kitétség (*score*) segítségével. Ha azonban csak az első faktor szerinti értékre vagyunk kíváncsiak, akkor csak az első koordináta értékét kell figyelembe vennünk, és megkapjuk a vállalatok likviditási mutatóját abban az esetben, ha a likviditási mérték az 1. főkomponens által megadott alapvető likviditási mutató. A 2. ábra mutatja a vizsgált 18 vállalat esetén a likviditási értéket. Látható, hogy ha a likviditást kizárólag a relatív szélesség szempontból értékeljük, akkor a legkevésbé likvid vállalat a Sulzer, a leglikvidebb a Swisscom (a faktor alacsony értékei mérik a magas likviditást).

2. ábra




5.2. Az 1. csoport mint likviditási mutató

Ha az 1. csoport középpontját tekintjük likviditási mutatószámnak, akkor a vállalatok kitétségeit a csoportközéppel súlyozva kapjuk meg a likviditási mutató értékét. Ebben az esetben a 3. ábrán láthatók a vállalatok likviditási mutatói. A 3. ábra eredményei nagyon hasonlítanak az első főkomponens által megadott likviditási mutatókhoz a 2. ábrán. Ez nem meglepő, hiszen az első csoport leginkább az első faktorról korrelál. A különbség (például a Baer és a Richemont sorrendjének felcserélődése) annak tulajdonítható, hogy az első csoport kis mértékben ugyan, de más likviditási aspektusokat is figyelembe vesz a relatív szélességen kívül.

3. ábra

**Az első csoport középpontjának
mint likviditási mutatónak az értéke az egyes vállalatokra**



5.3. Kevert likviditási mutató

Az előző két példa (a főkomponensek és a csoportközepek használata) természetesen adódik az elemzésből. Ezek mellett tetszőlegesen megadhatók összetett mutatószámok, bármilyen súlyozás használatával. Példaként vehetjük a főkomponensek teréből a $[0,5;0,5;0;0;0]$ pontot, azaz az első két faktor egyenlően súlyozott átlagát. Ez a relatív és abszolút szélességet egyforma súllyal veszi figyelembe. Bár ez a likviditási mutató a kereskedési adatokból közvetlenül nem számolható ki, de megkapható a vállalat score értékeinek és a $[0,5;0,5;0;0;0]$ vektornak a skaláris szorzataként. A 8. táblázatban láthatjuk a likviditási mutatók érté-

keit az első két főkomponens alapján, illetve az itt megadott, összetett likviditási mutató szerint. A vállalatokat sorba rendeztük a likviditási mutatók nagysága alapján. Láthatjuk, hogy az összetett mutató mindkét (relatív spread, abszolút spread) szempontot figyelembe veszi a likviditás megállapításánál. Mivel mindkét faktor alacsony értékkel jelzi a magas likviditást, ezért az összetett mutatószám esetén is az alacsony mutató jelenti a likvidebb részvényt.

8. táblázat

**Az első és második főkomponens és azok átlaga,
mint likviditási mutató**

Faktor 1		Faktor 2		Átlag	
Swisscom	-1,881	Serono	2,514	Swisscom	-0,893
Holcim	-1,180	Sulzer	1,481	Syngenta	-0,671
Givaudan	-0,975	Surveillance	1,306	Richemont	-0,580
Syngenta	-0,728	Baer	0,626	Ciba	-0,575
Ciba	-0,446	Givaudan	0,546	Holcim	-0,557
Adecco	-0,415	Unaxis	0,480	Lonza	-0,535
Lonza	-0,389	Swisscom	0,094	Clariant	-0,479
Baer	-0,349	Holcim	0,066	Adecco	-0,469
Serono	-0,316	SwissRe	-0,195	SwissRe	-0,222
SwissRe	-0,249	SwatchBearer	-0,403	Givaudan	-0,215
Richemont	-0,115	Adecco	-0,524	Baer	0,139
Clariant	0,055	Syngenta	-0,615	SwatchBearer	0,243
Surveillance	0,452	Lonza	-0,680	Kudelski	0,269
Unaxis	0,719	Ciba	-0,705	SwatchRegist	0,272
SwatchBearer	0,889	Kudelski	-0,803	Unaxis	0,599
Kudelski	1,341	Clariant	-1,013	Surveillance	0,879
SwatchRegist	1,673	Richemont	-1,045	Serono	1,099
Sulzer	1,913	SwatchRegist	-1,129	Sulzer	1,697

Az összetett likviditási mutatószámok definiálásánál szem előtt kell tartanunk, hogy milyen célból vizsgáljuk a likviditást, és annak megfelelően választhatunk mutatót a főkomponensek teréből. Figyelnünk kell továbbá arra is, hogy az egyes főkomponensek magas vagy alacsony értékei jelzik-e a magas likviditást.

6. ÖSSZEGZÉS

Jelen cikkben a likviditási mutatók struktúrájának megértése céljából a likviditás különböző aspektusait számszerűsítő mutatókat elemeztük a Svájci Értéktőzsde részvényeiből álló adatbázis alapján. Főkomponens-elemzéssel sikerült olyan alapvető faktorokat azonosítanunk, amelyek a likviditás jelenségét leírják. Ezek a faktorok a következők: relatív piaci szélesség, abszolút piaci szélesség, piaci volumen és a mélység. A likviditási mutatószámok fontosabb csoportjai egyértelműen azonosíthatók ezen faktorok mentén. Adatelemzésünk eredményei megnyugtató információkat adnak a likviditási mutatószámok működéséről. Egyrészt ezek az eredmények összhangban vannak a likviditási mutatószámokról alkotott, korábbi elképzelésekkel, azaz a faktorok és csoportok a szakirodalom terminológiája és az intuíciók alapján jól értelmezhetők. Másrészt: a faktorok és csoportok viselkedése keresztmetszetileg stabilnak mutatkozott, mivel az átlag és a mediánadatok is ugyanarra az eredményre vezettek.

Az itt bemutatott elemzés lehetőséget ad arra, hogy az eddigi mutatószámok alapján, a főkomponensek segítségével a különböző likviditási mutatókat tetszőleges súlyban tartalmazó likviditási mutatókat definiáljunk.

Vizsgálatunk korlátja, hogy az elemzés csak a likviditási mutatók közötti lineáris kapcsolatokra irányult, illetve az elemzés jellegéből adódóan, az eredmények csak a rendelkezésre álló adatbázisra és meghatározott időszakokra érvényesek. A likviditási struktúra más adatokon történő tesztelése, valamint időbeli stabilitásának vizsgálata további kutatás témája lehet.

IRODALOMJEGYZÉK

- BARAN SÁNDOR–FAZEKAS ISTVÁN–GLEVITZKY BÉLA–IGLÓI ENDRE–ISPÁNY MÁRTON–KALMÁR ISTVÁN–NAGY MÁRTA–TAR LÁSZLÓ–VERDES EMESE [2000]: Bevezetés a matematikai statisztikába. Kossuth Egyetemi Kiadó, Debrecen
- KOVÁCS ERZSÉBET [2009]: Pénzügyi adatok statisztikai elemzése, Tanszék Kft., Budapest
- KLUGER, B. D.–STEPHAN, J. [1997]: Alternative Liquidity Measures and Stock Returns. *Review of Quantitative Finance and Accounting*, Vol. 8., január, 19–36. o.
- KUTAS GÁBOR–VÉGH RICHÁRD [2005]: A Budapest Likviditási Mérték bevezetéséről – A magyar részvények likviditásának összehasonlító elemzése a budapesti, a varsói és a londoni értéktőzsdéken. *Közgazdasági Szemle* LII., július–augusztus, 686–711. o.
- PASCUAL, R.–ESCRIBANO, A.–TAPIA, M. [2004]: On the Bi-Dimensionality of Liquidity. *The European Journal of Finance*, Vol. 10. No. 6., 542–566. o.
- WYSS, v. R. [2004]: Measuring and Predicting Liquidity in the Stock Market, Dissertation, Universität St. Gallen

MELLÉKLET

I. Likviditási mutatók számítása⁹

- Kereskedési volumen (*trading volume*) $Q_t = \sum_{i=1}^{N_t} q_i$
 N_t : ügyletek száma $t-1$ és t közötti időszakban
 q_i : i . tranzakcióban a részvények darabszáma
- Forgalom (*turnover*) $V_t = \sum_{i=1}^{N_t} p_i q_i$
 N_t : ügyletek száma $t-1$ és t közötti időszakban
 q_i : i . tranzakcióban a részvények darabszáma
 p_i : i . tranzakció árfolyama
- Mélység (*depth*) $D_t = q_t^A + q_t^B$
 q_t^A : t időpontban érvényes legjobb eladási árhoz tartozó mennyiség
 q_t^B : t időpontban érvényes legjobb vételi árhoz tartozó mennyiség
- Mélység logaritmusa (*log depth*) $Dlog_t = \ln(q_t^A) + \ln(q_t^B)$
 q_t^A : t időpontban érvényes legjobb eladási árhoz tartozó mennyiség
 q_t^B : t időpontban érvényes legjobb vételi árhoz tartozó mennyiség
- Mélység dollárban (*dollar depth*) $D\$_t = \frac{q_t^A \cdot p_t^A + q_t^B \cdot p_t^B}{2}$
 q_t^A : t időpontban érvényes legjobb eladási árhoz tartozó mennyiség
 p_t^A : t időpontban érvényes legjobb eladási árfolyam
 q_t^B : t időpontban érvényes legjobb vételi árhoz tartozó mennyiség
 p_t^B : t időpontban érvényes legjobb vételi árfolyam
- Tranzakció szám (*number of transaction*)
 N_t : ügyletek száma $t-1$ és t közötti időszakban
- Megbízások száma (*number of orders*)
 NO_t : megbízások száma $t-1$ és t közötti időszakban
- Abszolút spread (*absolute spread*) $Sabs_t = p_t^A - p_t^B$
 p_t^A : t időpontban érvényes legalacsonyabb eladási árfolyam
 p_t^B : t időpontban érvényes legmagasabb vételi árfolyam
- Abszolút spread logaritmusa (*Log absolute spread*)
 $LogSabs_t = \ln(Sabs_t) = \ln(p_t^A - p_t^B)$
 p_t^A : t időpontban érvényes legalacsonyabb eladási árfolyam
 p_t^B : t időpontban érvényes legmagasabb vételi árfolyam

- Relatív spread középárfolyammal
(*relative spread calculated with mid price*)

$$SrelM_t = \frac{p_t^A - p_t^B}{p_t^M}$$

p_t^A : t időpontban érvényes legalacsonyabb eladási árfolyam

p_t^B : t időpontban érvényes legmagasabb vételi árfolyam

p_t^M : t időpontban érvényes középárfolyam

- Relatív spread utolsó kötési árfolyammal
(*relative spread calculated with last trade*) $Srelp_t = \frac{p_t^A - p_t^B}{p_t}$

p_t^A : t időpontban érvényes legalacsonyabb eladási árfolyam

p_t^B : t időpontban érvényes legmagasabb vételi árfolyam

p_t : t időpont előtti utolsó tranzakció árfolyama

- Relatív spread logárfolyamok alapján (*relative spread of log prices*)

$$Srellog_t = \ln(p_t^A) - \ln(p_t^B)$$

p_t^A : t időpontban érvényes legalacsonyabb eladási árfolyam

p_t^B : t időpontban érvényes legmagasabb vételi árfolyam

- Relatív spread logárfolyamok alapján logaritmusa
(*log relative spread of log prices*) $LogSrellog_t = \ln(Srellog_t)$

- Effektív spread (*effective spread*) $Seff_t = |p_t - p_t^M|$

p_t : t időpont előtti utolsó tranzakció árfolyama

p_t^M : t időpontban érvényes középárfolyam

- Relatív effektív spread középárfolyammal
(*relative effective spread calculated with mid price*)

$$SeffrelM_t = \frac{|p_t - p_t^M|}{p_t^M}$$

p_t : t időpont előtti utolsó tranzakció árfolyama

p_t^M : t időpontban érvényes középárfolyam

- Relatív effektív spread utolsó árfolyammal
(*relative effective spread calculated with last trade*)

$$Seffrelp_t = \frac{|p_t - p_t^M|}{p_t}$$

p_t : t időpont előtti utolsó tranzakció árfolyama

p_t^M : t időpontban érvényes középárfolyam

- Jegyzési meredekség (*quote slope*)

$$QS_t = \frac{Sabs_t}{D \log_t} = \frac{(p_t^A - p_t^B)}{\ln(q_t^A) + \ln(q_t^B)}$$

p_t^A : t időpontban a legjobb eladási árfolyam

p_t^B : t időpontban a legjobb vételi árfolyam

q_t^A : t időpontban érvényes legjobb eladási árhoz tartozó mennyiség

q_t^B : t időpontban érvényes legjobb vételi árhoz tartozó mennyiség

- Log jegyzési meredekség (*log quote slope*)

$$LogQS_t = \frac{Srel \log_t}{D \log_t} = \frac{\ln(p_t^A / p_t^B)}{\ln(q_t^A \cdot q_t^B)}$$

- Módosított log jegyzési meredekség (*adjusted log quote slope*)

$$LogQS_{adj_t} = LogQS_t \cdot (1 + |\ln(qB / q / A)|)$$

- Összetett likviditási mutató (*composite liquidity*) $CL_t = \frac{SrelM_t}{D\$_t}$

- Likviditási ráta 1 (*liquidity ratio 1*)

$$LR1_t = \frac{V_t}{|r_t|} = \frac{\sum_{i=1}^N p_i q_i}{|r_t|}$$

N_t : ügyletek száma $t-1$ és t közötti időszakban

q_i : i . tranzakcióban a részvények darabszáma

p_i : i . tranzakció árfolyama

r_t : $t-1$ és t közötti időszak hozama

- Likviditási ráta 3 (*liquidity ratio 3*) $LR3_t = \frac{\sum_{i=1}^N |r_i|}{N_t}$

N_t : ügyletek száma $t-1$ és t közötti időszakban

r_t : $t-1$ és t közötti időszak hozama

- Flow ráta (*flow ratio*) $FR_t = N_t \cdot V_t$

N_t : ügyletek száma $t-1$ és t közötti időszakban

V_t : forgalom

- Megbízási ráta (*order ratio*) $OR_t = \frac{|q_t^B - q_t^A|}{V_t}$

q_t^A : t időpontban érvényes legjobb eladási árhoz tartozó mennyiség

q_t^B : t időpontban érvényes legjobb vételi árhoz tartozó mennyiség

V_t : $t-1$ és t időpont közötti időszak forgalma

- Piaci befolyás (*market impact*) $MI_t^{V*} = p_t^{A,V*} - p_t^{B,V*}$

$p_t^{A,V*}$: meghatározott kereskedési mennyiséghez (V^*) tartozó eladási árfolyam

$p_t^{B,V*}$: meghatározott kereskedési mennyiséghez (V^*) tartozó vételi árfolyam

V^* : az adatok számításához használt volumen: 500 000 CHF

- Eladási oldali piaci befolyás (*market impact for the ask-side*)

$$MI_t^{A,V^*} = p_t^{A,V^*} - p^M$$

p_t^{A,V^*} : meghatározott kereskedési mennyiséghez (V^*) tartozó eladási árfolyam

p^M : középárfolyam

- Vételi oldali piaci befolyás (*market impact for the bid-side*)

$$MI_t^{B,V^*} = p^M - p_t^{B,V^*}$$

p^M : középárfolyam

p_t^{B,V^*} : meghatározott kereskedési mennyiséghez (V^*) tartozó vételi árfolyam

- Piaci befolyás mélysége eladási oldalon (*depth for price impact ask side*)

$$DI_t^A(k) = Q_k^A$$

Q_k^A : az eladási árfolyam k nagyságú elmozdulásához szükséges mennyiség

k : az adatok számításához használt elmozdulás 2%

- Piaci befolyás mélysége vételi oldalon (*depth for price impact bid side*)

$$DI_t^B(k) = Q_k^B$$

Q_k^B : a vételi árfolyam k nagyságú elmozdulásához szükséges mennyiség

k : az adatok számításához használt elmozdulás 2%

- Árfolyamhatás eladási oldalon (*price impact for the ask-side*)

$$PI^A(q) = \ln \left(\frac{\sum_{k=1}^K p_k \cdot q_k}{q \cdot p^M} \right); \quad q = \sum_{k=1}^K q_k$$

q : 10 000 db részvény vétele k különböző árfolyam mellett teljesíthető adott időpontban

q_k : k -dik mennyiség

p_k : k -dik árfolyam

p^M : középárfolyam

- Árfolyamhatás vételi oldalon (*price impact for the bid-side*)

$$PI^B(q) = -\ln \left(\frac{\sum_{k=1}^K p_k \cdot q_k}{q \cdot p^M} \right); \quad q = \sum_{k=1}^K q_k$$

q : 10 000 db részvény eladása k különböző árfolyam mellett teljesíthető adott időpontban

q_k : k -dik mennyiség

p_k : k -dik árfolyam


p^M : középárfolyam

II. Komponensmátrix 0,3 abszolút érték alatti korrelációk kihagyásával

Elforgatott komponensmátrix					
	Főkomponens				
	1	2	3	4	5
Q		-,461	,815		
V	-,316		,912		
D				,887	
Dlog		-,794		,402	
D\$,947	
N			,878		-,334
NO			,795		-,429
Sabs		,958			
LogSabs		,916			
SrelM	,951				
Srelp	,951				
Srellog	,951				
Logsrellog	,906				
Seff		,960			
Seffrelp	,956				
SeffrelM	,956				
QS		,936			
LogQS	,760	,560			
LogQSadj	,698	,545		,322	
CL	,775				-,452
LR1	-,410		,886		
LR3	,883				-,365
FR			,942		
OR1				,899	
MIV	,401	,851			
MIAV	,388	,874			
MIBV	,385	,780			
DIAk		-,544	,665		,321
DIBk		-,554	,733		,316
PIAq	,476	,683			,339
PIBq	,361	,875			

III. Mutatók az első három főkomponens terében

Átlagadatok



Mediánadatok

