

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra ekonomiky



**Česká
zemědělská
univerzita
v Praze**

Disertační práce

**Analýza stochastické volatility na trhu zemědělských
komodit**

Autor: Ing. Michal Čermák

Školitel: prof. Ing. Lukáš Čechura, Ph.D.

© 2024 ČZU v Praze

Poděkování

Rád bych poděkoval mému školiteli prof. Ing. Lukáši Čechurovy, Ph.D. za vedení disertační práce, za cenné rady a připomínky. Dále bych chtěl poděkovat konzultantovi doc. Ing. Petru Procházkovi, MSc., Ph.D. za pomoc při zpracovávání práce. V neposlední řadě bych chtěl poděkovat mé rodině a všem členům katedry ekonomiky PEF ČZU.

Abstrakt

Disertační práce se zabývá problematikou efektů přelévání volatility a vzájemné propojenosti mezi kontrakty futures na trhu zemědělských komodit v oblasti komplexní analýzy stochastické volatility. Pro zachycení efektů přelévání volatility mezi zemědělskými komoditními futures je využita metoda Diebold-Yilmaz (2009; 2012). Pro determinace různých režimů volatilit je model rozšířen na bázi markovského řetězového procesu. Vzájemná propojenost a kauzalita jednotlivých trhů je dále zjišťována na základě časově frekvenční analýzy – vlnové analýzy. Mezi zemědělskými komoditami existují empiricky prokázané vazby a režimy přelévání volatilit způsobené na základě spekulativních aktivit investorů, sezónnosti a stochastických šoků.

Klíčová slova: vlnová transformace, vlnová koherence, přelévání volatility, spekulace, zemědělské komodity, DY volatility connectedness model, vlnová analýza, skryté Markovské modely, simulace, lead-lagged vztah

Annotation

The dissertation deals with the issue of volatility spillover effects and interconnectedness between futures contracts in the agricultural commodity market in the field of complex stochastic volatility analysis. The Diebold Yilmaz (2009; 2012) method is used to capture volatility spillover effects among agricultural commodity futures. To determine the different volatility regimes, the model is extended based on a Markov chain process. The interconnectedness and causality of the different markets is further identified based on time-frequency analysis - wavelet analysis. There are empirically established linkages and spillover volatility regimes among agricultural commodities due to investor speculative activities, seasonality, and stochastic shocks.

Keywords: wavelet transform, wavelet coherence, volatility spillovers, speculation, agricultural commodities, DY volatility connectedness model, wavelet analysis, hidden Markov models, simulation, lead-lagged relationship

Obsah

1	Úvod	8
1.1	Motivace	9
2	Cíle práce	12
3	Metodika	14
3.1	Data	14
3.2	Design výzkumu	15
3.3.	Časově frekvenční analýza	18
3.4.	Skryté Markovské modely	24
3.3.	Časově variační přelévání volatilit	28
4	Literární rešerše	32
4.1.	Historický přehled	32
4.2.	Futures trh zemědělských komodit	35
4.3.	Cenová volatilita	36
4.4.	Determinanty cenové volatilit na komoditních trzích	42
4.5.	Řízení rizika: koncept Value at Risk	48
4.6.	Spillover efekt	52
4.7.	Literární přehled empirických studií o analýze stochastické volatilit	58
5	Empirická část	63
5.1.	Analýza dat	63
5.1.1.	Testování jednotkového kořene	68
5.2.	Diskrétní vlnová transformace (DWT)	70
5.3.	Vlnová koherence	77
5.4.	Testování vlnových fázových diferencí a koherencí volatilit	93
5.5.	Částečná vlnová koherence na trhu pšenice a kukuřice	99
5.6.	Determinace a simulace režimů volatilit	104
5.7	Analýza spillover efektů volatilit a vzájemné propojenosti	115
5.7.1.	Analýza úplného vzorku přelévání volatilit	115
5.7.2.	Dynamická a síťová analýza přelévání volatilit	117
6	Politické a investiční implikace	123
7	Závěr	126
8	Seznam zdrojů	129

Seznam obrázků

Obrázek 1: Schéma empirické strategie	17
Obrázek 2: Schéma skrytého Markovského modelu	25
Obrázek 3: Změna ceny pšenice v %	65
Obrázek 4: Změna ceny kukuřice v %	65
Obrázek 5: Změna ceny sójové boby v %	65
Obrázek 6: Změna ceny káva v %	66
Obrázek 7: Změna ceny kakao v %	66
Obrázek 8: Změna ceny cukr v %	66
Obrázek 9: Analýza korelací a pravděpodobnostního rozdělení	68
Obrázek 10: DWT – Pšenice	71
Obrázek 11: DWT – Kukuřice	72
Obrázek 12: DWT – Sójové boby	73
Obrázek 13: DWT – Kakao	73
Obrázek 14: DWT – káva	74
Obrázek 15: DWT – Cukr	75
Obrázek 16: Vlnová koherence – kukuřice a pšenice	78
Obrázek 17: Vlnová koherence – pšenice a sójové boby	79
Obrázek 18: Vlnové koherence – pšenice a cukr	80
Obrázek 19: Vlnová koherence – pšenice a kakao	81
Obrázek 20: Vlnová koherence – pšenice a káva	82
Obrázek 21: Vlnová koherence – pšenice a sójové boby	83
Obrázek 22: Vlnová koherence – kukuřice a kakao	84
Obrázek 23: Vlnové koherence – kukuřice a káva	85
Obrázek 24: Vlnové koherence – kukuřice a cukr	86
Obrázek 25: Vlnové koherence – sójové boby a kakao	87
Obrázek 26: Vlnové koherence – sójové boby a káva	88
Obrázek 27: Vlnová koherence – sójové boby a cukr	89
Obrázek 28: Vlnové koherence – kakao a káva	90
Obrázek 29: Vlnové koherence – kakao a cukr	91
Obrázek 30: Vlnové koherence – káva a cukr	92
Obrázek 31: Vlnové křížové spektra	93
Obrázek 32: Vlnové koherence volatilit	97
Obrázek 33: Částečná vlnová koherence – pšenice a kukuřice	100
Obrázek 34: Skryté Markovské modely, kukuřice	106
Obrázek 35: Skryté Markovské modely, pšenice	107
Obrázek 36: Skryté Markovské modely, sójové boby	108
Obrázek 37: Skryté Markovské modely, káva	110
Obrázek 38: Skryté Markovské modely, kakao	111
Obrázek 39: Skryté Markovské modely, cukr	113
Obrázek 40: Směrová propojenost sítě	118
Obrázek 41: Čistá párová propojenost sítě	119
Obrázek 42: Celkový index přelévání	120
Obrázek 43: Propojení sítě komodit	121

Seznam grafů

Graf 1: Vývoj komoditního indexu.....	34
Graf 2: Ceny zemědělských komodit.....	64

Seznam tabulek

Tabulka 1: Zemědělské komodity a zdroje dat.....	14
Tabulka 2: Sumarizace indexů přelévání volatility dle Diebold, Yilmaz (2009).....	31
Tabulka 3: Přístupy k měření volatility.....	40
Tabulka 4: Determinanty cenové volatility.....	46
Tabulka 5: Přehled studií Diebold a Yilmaz.....	54
Tabulka 6: Popisné statistiky.....	67
Tabulka 7: Testování jednotkového kořene.....	69
Tabulka 8: Úplný vzorek spillover efektů.....	116

Seznam použitých zkratek

CBOE – Chicago Board of Option Exchange

CWT – Continuous Wavelet Transform (Spojitá vlnová transformace)

ČR – Česká republika

DWT – Discrete Wavelet Transform (Diskrétní vlnová transformace)

DY – Diebold Yilmaz

EU – Evropská unie

GMO – geneticky modifikované organismy

HMM – Hidden Markov model (Skryté Markovské modely)

OECD – Organizace pro hospodářskou spolupráci a rozvoj

OTC – Over the Counter

PWC – Partially Wavelet Coherence (Částečná vlnová koherence)

TCI – Index celkové konektivity

USA – Spojené státy americké

USD – Americký dolar

VaR – Hodnota v riziku

VAR – Vektorová autoregrese

VIX – index volatility

Vol – volatilita

WC – Wavelet Coherence (Vlnová koherence)

1 Úvod

Na trhu zemědělských komodit došlo k rozvoji dynamického kolísání a fluktuace cen od dob liberalizace světového trhu, a to zvláště po podepsání Marakéšské dohody v roce 1994. Z důvodu zvýšené cenové variability zemědělských produktů vyvstávají pro tvůrce obchodní politik nové příležitosti.

Výzkum pohybů variability komoditních cen na finančních trzích je potřebný z hlediska obecného charakteru zemědělských produktů – významný vliv přírodních a ekonomických faktorů. V rámci ekonomického charakteru zemědělských komodit je cena v tomto případě významně ovlivněna produkcí a poptávkou. Riziko extrémních cenových výkyvů na trhu základních agrárních produktů, respektive komodit může prohloubit sociálně ekonomické riziko v případě potravinové soběstačnosti, lidského rozvoje či politické stability. Hlavním motivujícím faktorem je celospolečenská poptávka po základních zemědělských plodinách jako kukuřice, rýže, pšenice, káva, cukr, sójové boby, kakao a jejich zásadní význam pro tvorbu obchodních politik mezi státy.

Hlavní přínos této disertační práce tudíž vychází z komplexního propojení vysokofrekvenčních dat zemědělských komodit s empirickou stránkou jejich využití. Používání burzovních dat zemědělských komodit spadá do oblasti denních frekvencí, což je robustní s použitými metodami. Analýza strategické literatury nepřináší v současnosti pohled na vztah mezi burzovními indexy a vývojem zemědělských cen, tudíž není popsána problematika výkonosti hospodářství a cenových změn agrárních komodit. Důležitým přínosem této práce jsou také poznatky, které jsou užitečné pro zkoumání zdrojů rizika na poli mezinárodního agrárního trhu. Na základě politik OECD je výzkum v této oblasti velmi důležitý, neboť veškeré rozhodnutí na straně tvůrců trhu je potřeba realizovat s předstihem. Výstupem této práce jsou simulace koherentních cenových vztahů, determinace režimů a efektů přelévání volatilit s možností následného využití pro investory a tvůrce politik.

Studie chování cenové volatility, a zvláště její přelévání na různé trhy nejvýznamnějších zemědělských komodit jako je pšenice, kukuřice, sója, cukr, kakao a káva má významný vliv na tvorbu cen.

Obchodování komodit jako předmětu mezinárodního obchodu se stalo významným činitelem na poli burzovních transakcí. Z toho vyplývá, že je komoditní cena determinována mnoha faktory jako např. produkcí, odběrateli, přírodními podmínkami nebo liberalizací světového

obchodu. Zemědělské finanční deriváty se obchodují na nejvýznamnějších komoditních burzách jako například CME (Chicago Mercantile Exchange), CBOT (Chicago Board of Trade) nebo ICE (Intercontinental Exchange). Na OTC trzích jsou obchody realizovány prostřednictvím kontraktů typu forward.

V současném dynamickém prostředí je nutné zachytit všechny efekty mezi kolísáním cen komodit a ekonomickými nebo finančními šok na specifickém trhu zemědělských komodit. Počet studií cenové volatility na finančních trzích za poslední dekádu nebývale vzrostl. Logickým důvodem je rozmach elektronického obchodování a rozvoj ICT obecně. Využití umělé inteligence přineslo množství modelů a nových teoretických přístupů ve studiu cenových závislostí mezi trhy.

Dynamika cenových procesů na finančních trzích přináší potřebu kvantifikace rizika, které postupují účastníci na těchto trzích. Komoditní, a zvláště zemědělský trh je charakteristický zvýšeným tržním rizikem. Nutnost sledování výkonnosti portfolií a taky jejich maximální možnou ztrátou je základním nástrojem finančních manažerů pohybujících se v oblasti investic. V neposlední řadě vstupuje do rozhodovacího procesu při tvorbě investičních portfolií, které jsou složeny z komodit, efekt diverzifikace. V tomto případě je nutnost užití numerické analýzy pro zařazení jednotlivých komodit.

1.1 Motivace

Jako historickým počátkem v problematice extrémního kolísání cen potravin bylo vypracováno několik výzkumů detailněji popsané autorem Abel (1966). Jeho výzkum potvrdil důvody pro extrémní výkyvy cen zemědělských komodit v oblasti politických a ekonomických šoků, například transmise krize zemědělství do prostředí měst. Rozsáhlá analýza krize cen zemědělských komodit byla v 70. letech zaměřena na produkci a obchodování šoků. Problematika volatility zemědělských komodit je značně propojena s konceptem potravinové bezpečnosti. Významné jsou čtyři pilíře v mezích potravinové dostupnosti, ekonomickému a fyzickému přístupu k potravinám, využití potravin a potravinová stabilita (FAO¹, 1996, 2015). Převážně v letech 2007/2008 vstoupil do popředí zájem o spolehlivý a stabilní potravinový systém.

¹ Food and Agriculture Organization

Potravinová politika představuje politicky citlivou věc v rámci narůstajícímu trendu urbanizace celosvětové populace. Na základě výzkumu (Béné et al., 2015) existují doporučení, jak pracovat se zvýšenou volatilitou komoditních cen prostřednictvím specifických cílů potravinové politiky, zvláště pro tvůrce politik. Zvyšování či vysoká fluktuace cen potravin je impulsem pro každou vládu na světě. Jsou známy případy, kdy cenové zvýšení vedlo k celospolečenským protestům ve městech Port au Prince v roce 2008, nebo v Alžíru v roce 2011. Právě zvýšení cen základních potravin vedlo k trvalým protestům proti vládě. V letech 2007/2008 vedlo zvýšení cen potravin taktéž k společenským protestům v Bangladéši. Autor Bellemare (2015) zkoumal v rámci empirického výzkumu kauzální vztah mezi cenami potravin a sociálními negativními efekty jako výsledek zvyšování cen. Mnoho vlád v rozvojových státech jsou zodpovědné za zajištění určitého stupně potravinové bezpečnosti a životních podmínek občanů. Jestliže tyto podmínky zaostávají nebo jsou omezené, statní instituce rychle ztrácejí svou legitimitu. Následně vystupuje problém s již zmíněnými celospolečenskými protesty.

V případě extrémního zvyšování cen potravin nebo k vysokým cenovým fluktuacím, je toto téma otevřeno a diskutováno mezi mezinárodními organizacemi, jako například OECD. Významný podíl těchto reakcí na stoupající ceny potravin měl ale částečný účinek (Martin a Anderson, 2012). Jedním z hlavních důvodů selhání těchto společných akcí je rostoucí integrace místních zemědělských trhů do globálních struktur. Tento fakt nese stav, kdy je tradiční zemědělský trh integrován plně do širokého spektra finančních trhů. Tímto se stává identifikace původců zvýšené volatility obtížná. Tradiční pojetí nabídky a poptávky na trhu zemědělských komodit má menší vysvětlující vlastnost pro cenovou fluktuaci. Důležité faktory na zemědělském trhu jsou ceny energetických komodit, úrokové sazby, měnové politiky centrálních bank, spekulace a investice, obchodní restrikce nebo nedostatek informací.

Studium cenové volatility na trzích komodit, respektive na finančních trzích obecně, je vysoce oceňované v akademickém a investorském prostředí. Současným trendem finančního inženýrství a modelování je právě studium cenové dynamiky a fluktuace cen aktiv. Motivem proč zkoumat právě cenovou volatilitu je úzká relace pro praktické obchodování a spekulativní aktivitu investorů. Právě vzrůstající tendence spekulací na různých trzích jsou faktorem, který ovlivňuje potřebu výzkumu cenových pohybů. Obliba finančních produktů v návaznosti na volatilitu v prostředí tržní nejistoty významně roste. Za poslední více než dvě dekády zajišťování a investování prostřednictvím arbitrážních strategií a strategií zaměřující se na volatilitu proběhlo nespočet výzkumů a simulací zaměřující se na studium cenové fluktuace.

Obliba u institucionálních investorů je také v opčním indexu VIX, který od počátku 90. let sleduje vývoj očekávané volatility na opčním trhu.

Tato disertační práce je založena na metodice mající původ v teorii signálové dekompozice, strojového učení a v poslední řadě vektorové dekompozice více rozpracované prostřednictvím Diebold a Yilmaz (2009; 2012) se specifickým zaměřením na trh zemědělských komodit. Užitím vysokofrekvenčních dat je otevřen výzkum cenové volatility s využitím neparametrických nástrojů časově frekvenční analýzy. Rámec výzkumu výše uvedených autorů bere do úvahy i toky a přesuny efektů přelévání volatility. Výhodou analýzy v rámci režimů můžeme spatřovat v dynamičtějším a lépe identifikovatelném pohledu na různé stavy volatility, neboť přesuny v režimech jsou náhodné a nepredikovatelné.

2 Cíle práce

Hlavním cílem disertační práce je determinovat a simulovat stochastickou volatilitu s efekty přelévání na trhu burzovně obchodovaných zemědělských komodit, jmenovitě pšenice, kukuřice, sójové boby, kakao, káva a cukr za účelem komplexního vyhodnocení a determinace chování cenové volatility a společných pohybů. Dílčí cíle jsou seřazeny v posloupnosti kapitol v empirické části.

Dílčí cíle jsou formulovány následovně:

- 1) Podat přehled o různých metodách měření cenové volatility
- 2) Dekomponovat cenový proces zemědělských komodit do diskrétního zobrazení
- 3) Vyhodnotit společné pohyby a vzorce cenové fluktuace
- 4) Určit a vysvětlit cyklické a anticyklické vztahy mezi komoditami.
- 5) Vyhodnotit koherentní vztahy mezi komoditami
- 6) Determinovat cenově předbíhající a zpožďující se komodity
- 7) Lokalizovat frekvence, na kterých jsou zemědělské komodity ovlivněny mezi sebou navzájem.
- 8) Simulovat skryté režimy volatilit na trhu zemědělských komodit
- 9) Determinovat frekvenci přepínání mezi jednotlivými režimy volatility
- 10) Determinovat příjemce a transmittory volatility mezi komoditami.
- 11) Určit mezi kterými komoditami dochází k transmisi rizika.

Pro splnění cílů jsou formulovány následující výzkumné otázky:

- 1) Ve kterých obchodních periodách dochází k vyšším cenovým variacím u jednotlivých zem. komodit?
- 2) Na jakých frekvencích jsou zemědělské komodity mezi sebou korelované?
- 3) Existuje mezi zemědělskými komoditami globální nebo tranzitní efekt?
- 4) Které zemědělské komodity jsou párově předbíhající a zpožďované?

- 5) S jakou frekvencí se mění posteriorní pravděpodobnosti režimů volatility na komoditních zem. trzích?
- 6) Které zemědělské komodity jsou vysílající a přijímající šoky volatility?

3 Metodika

Disertační práce je zaměřena na analýzu stochastické volatility finančních časových řad cen zemědělských komodit. V rámci sub-kapitoly 3.1 je proveden popis použitých dat. Tato kapitola podává přehled o základní empirické strategii (viz sub-kapitola 3.2) a jednotlivých metodách (sub-kapitoly 3.3. – 3.5.), které jsou použity pro dílčí výzkum ve sledu definovaném designem výzkumu.

3.1 Data

Pro výzkum v oblasti analýzy efektů přelévání volatility mezi trhy a vyšetření vzájemných souvislostí jsou využity denní zavírací ceny futures kontraktů zemědělských komodit. Následující tabulka zobrazuje použité zemědělské komodity a zdroje dat:

Tabulka 1: Zemědělské komodity a zdroje dat

Komodita	Jednotka	Burzovní data	Zdroje dat
Futures pšenice	USD/Bušl	Chicago Board of Trade (CBOT®), Euronext, Minneapolis Grain Exchange (MGEX)	Tradingeconomics.com Finance.yahoo.com
Futures kukuřice	USD/Bušl	Chicago Board of Trade (CBOT®)	Investing.com; Finance.yahoo.com
Futures sójové boby	USD/Bušl	Chicago Board of Trade (CBOT®)	Investing.com; Finance.yahoo.com
Futures cukr	Cent/Lb	Intercontinental Exchange (ICE)	Tradingeconomics.com Finance.yahoo.com
Futures káva	USD/Lbs	Intercontinental Exchange (ICE)	Investing.com Finance.yahoo.com
Futures kakao	USD/Mt	New York Mercantile Exchange (NYMEX), Intercontinental Exchange (ICE)	Investing.com Finance.yahoo.com

Zdroj: Vlastní zpracování

Období sledování je v průběhu období 1/2012 až 12/2020. Pro empirický výzkum je zvolená perioda po skončení dopadů světové finanční krize v roce 2008, aby se šoky vzniklé v rámci krize dostatečně absorbovaly na trhu. Nicméně konec periody zasažen šoky související

s počátkem pandemie Covid-19. V tomto případě se předpokládá opožděný externích šoků související s pandemickou krizí začínající na přelomu let 2019/2020. Data jsou získány na denní bázi pěti obchodních dnů v týdnu.² Vysokofrekvenční data jsou testována na existenci jednotkového kořeny pomocí testů ADF a Phillip-Peron test za účelem zjištění stacionarity komoditních futures cen (Said a Dickey, 1984)

Pro kalkulaci logaritmických výnosů je využit vztah:

$$r_t = \left(\ln \frac{P_t}{P_{t-1}} \right) \quad (1)$$

Kde P_t je závěrací cena komodity a P_{t-1} je závěrací cen v minulém období.³

Pro analýzu přelévání volatilit a vzájemné propojenosti Diebold a Yilmaz (2012) navrhli volatilitu, rozšířenou dle Parkinson (1980), která je založena na $\sigma^2 = 0,361 [\ln(P_t^{High}) - \ln(P_t^{Low})]^2$, kde P_t^{High} a P_t^{Low} představují nejvyšší a nejnižší komoditní denní ceny v čase t .

3.2 Design výzkumu

Analýza cenové volatility je mezi odbornou veřejností zabývající se finančním modelování jedním z důležitým problémům. Jedná se o velmi široký pojem zahrnující základní nepodmíněné model až po analýzu transmise skoků a šoků mezi různými trhy. Obecně analýza ohroženosti ekonomik, institucí na finančním trhu nebo investičním portfoliem nabývá významu ve formě, jak jsou tyto objekty ovlivněné šoky, stavem ekonomiky nebo finančního trhu jako celku. V disertační práci jsou využity alternativní metody výzkumu cenové volatility, které jsou založeny na systémovém přístupu využití vysokofrekvenčních dat.

Pro analýzu společných pohybů a vzájemných souvislostí mezi různými trhy zemědělských komodit obchodovaných na burze je využita časově frekvenční metoda, respektive vlnová koherence. Motivací pro využití této metody je schopnost zachytit simultánní vztahy sledovaných komodit v rámci času a frekvenčního prostoru. Teorie signálů je robustním

² Odpovídající 252 dnů v roce

³ Studie Udeaja (2019)

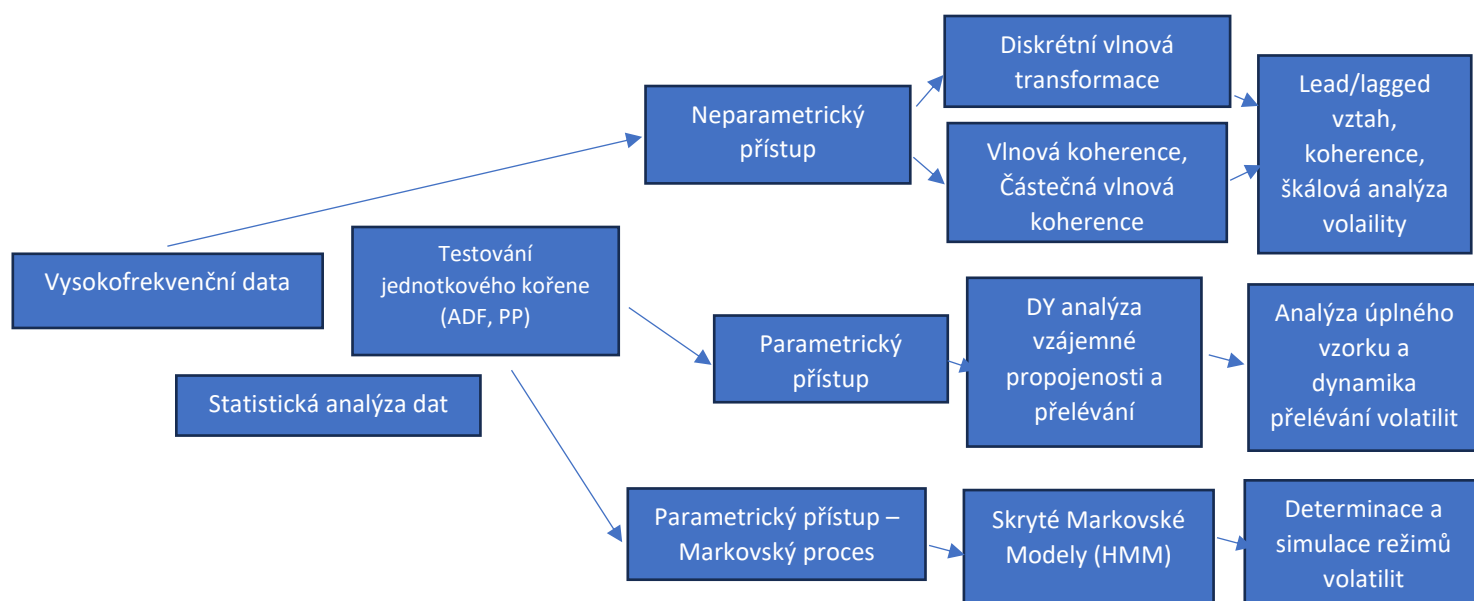
základem pro vysvětlení finančních a ekonomických vztahů (Gallegati et al., 2014; Baruník et al., 2016). Široká oblast zpracování signálů je založena dekompozici komplexní exponenciály signálů prostřednictvím Fourierovy transformace.

Determinace a simulace režimů volatility komoditních futures cen je vyhodnocena pomocí metod učení bez učitele – skrytých Markovských modelů. Tato metoda vychází z málo prozkoumané aplikační oblasti finančních dat na poli strojového učení. Hlavním principem je zjištění pravděpodobnosti režimů, které jsou generovány vnitřním skrytým procesem. Tento princip představuje hlavní motiv využití této málo aplikované metody strojového učení.

Pro ekonomickou analýzu a interpretaci přelévání volatility je jednoduchým a nejpoužívanějším modelem multivariační VAR, jak uvádějí Diebold a Yilmaz (2009, 2012). Modely VAR jsou využívány, a zvláště jejich redukovaná forma jako dominantní strategie v empirické makroekonomii od doby výzkumu autora Sims (1980).

Pro zjištění konečných výsledků v rámci analýzy efektů a šoků přelévání volatility je konstruována funkce Forecast Error Variance Decomposition (FEVD), viz Lütkepohl (2005) nebo Pesaran, Shin (1998). Velikost efektů a šoků závisí v tomto případě na velikosti a distribuci režimů. V souvislosti s analýzou indexů volatility, prezentované ve výzkumu Diebold, Yilmaz (2009, 2012, 2014), jsou šoky poté časově variační. Jinými slovy velikostně větší šoky mají potencionálně různé efekty než šoky malé. Empirická strategie je poté zobrazena na obr. č. 1.

Obrázek 1: Schéma empirické strategie



Zdroj: Vlastní zpracování

V rámci empirické strategie pro naplnění cílů této práce jsou využity neparametrické, parametrické a Markovské přístupy. Cíle disertační práce odpovídají navrženým analýzám. Využití vysokofrekvenčních komoditních futures cen je vhodné pro jak parametrické, tak neparametrické přístupy v empirické strategii. V rámci cílů je sestavena komplexní empirická strategie postupu analýz a simulací. Metodika je založena na třech přístupech: (1) Diebold Yilmaz (2009; 2012) analýza propojenosti a přelévání volatilit vyžadující stacionární proces. (2) Vlnová transformace sestávající se z koherentní a fázové analýzy, diskrétní vlnové transformace zachycující strukturální a sezónní vzorce cenových procesů. (3) Skryté Markovské modely založené na Markovském procesu determinující nepozorovatelné stavy a transmise. Empirický výzkum je podmíněn následující posloupností řešení: (a) Statistická analýza dat (b) Dekompozice signálů na časově frekvenční komponenty využitím nestacionárních dat (c) Vlnová transformace prostřednictvím CWT a párová koherence nestacionárních dat (d) Analýza fázových diferencí s robustním testováním koherentních vztahů vzešlé z předchozího bodu pomocí metody PWC (e) Testování jednotkového kořene (f) Determinace a simulace režimů volatilit pomocí Skrytých Markovských modelů využívající logaritmické výnosy (g) Analýza přelévání volatilit pomocí metody Diebold-Yilmaz (2009;

2012). Pro zobrazení grafů je využit software MATLAB a R-Studio, pro odhady a zobrazení Diskrétní vlnové transformace a vlnové koherence je využit software MATLAB, pro odhad částečné vlnové koherence, skrytých Markovských modelů a DY přelévání volatilita je využit software R-Studio. Pro zobrazení výnosů je využit software Gretl.

3.3. Časově frekvenční analýza

Pro frekvenční a časovou analýzu je využita metoda vlnové koherence (wavelet coherence), která se stala populární v oblasti financí a ekonomiky. Analýza zachycuje interakce mezi různými časovými řadami a jejich vývoj v čase a frekvenčním prostoru. Vlnová koherence je účinná v identifikaci oblastí s vyššími společnými pohyby v časově frekvenčním prostoru, viz například Křišťoufek et al. (2016). Další výhodou využití této metody je v oblasti zachycení vedoucích zpoždění v nelineárním vztahu mezi časovými řadami. Dle autora Cohen (2019) je použití vlnové analýzy nejrozšířenější metodou ke zpracování nestacionárních časových řad, což je případ pro finanční časové řady komoditních cen. Vlnová transformace je filtrována do různých segmentů v časové oblasti (Zhao et al., 2004). Koncept vlnové transformace vychází z Fourierovy transformace, která ovšem převádí signál jen do čisté frekvenční oblasti.

Vlnová analýza byla v posledních letech intenzivně využívána mnoha výzkumníky, viz (Kassouri et al., 2022; Kuskaya, Bilgili, 2020; Magazzuno et al., 2022; Mutascu et al., 2022; Rubbaniy et al., 2022; Omane-Adjepong, 2019; Shehzad, et al., 2021). Všechny existující výzkumy byly zaměřeny na užití statistických technik pro zachycení vztahu mezi dvěma proměnnými, které jsou reprezentovány časovou řadou.⁴ Pro porovnání s tradičními metodami frekvenční analýzy, např. ve studii Maghyereh (2021) využívající křížovou spektrální koherenci tyto metody však selhávají v zachycení simultánního vztahu mezi časovou a frekvenční proměnnou.

Hlavní motivační silou pro využití vlnové analýzy jsou pak následující důvody. Pomocí této metody lze zachytit časově variační trend v procesu vývoje cen komodit, interakce mezi jednotlivými úrovněmi zpoždění a možného zachycení vzorů chování vývoje časových řad.⁵

⁴ Některé studie využívaly principu tzv. bivariačního křížového kvantilogramu pro zachycení vztahu mezi dvěma časovými řadami (Corbet et al., 2020)

⁵ Viz Sherif (2020)

Dále, pro využití metody vlnové koherence má pozitivní roli nestacionární chování signálů, které je rozšířené právě v případě komodit, respektive zemědělských komodit (Demir et al., 2021). Pro využití metody vlnové koherence je také důvodem i lepší zachycení strukturálních změn v časové řadě. Naopak metody, které jsou založené na autoregresní struktuře, jako například Grangerova nebo dynamická kauzalita, v tomto případě nejsou schopné vysvětlit simultánní vztah mezi časem a frekvencí ve strukturálních zlomech (Křišťoufek et al., 2016).

Vlnová funkce $W_{(s,n)}t$ je pak definovaná jako: (Matalgah et al., 1997)

$$W_{(s,n)}t = \frac{1}{\sqrt{n}} \int_{-\infty}^{\infty} x(t)b^* \left(\frac{t-s}{n} \right) dt, \quad (2)$$

kde je n škálovací parametr a s je proměnlivý parametr, proměnná x_t je tzv. analyzovaná vlna. V rovnici (2) je výraz $\frac{1}{\sqrt{n}}$ pro zajištění síly energetického působení frekvenční analýzy. Parametr b^* je poté komplexní časový prvek samotné vlnové funkce b . Tento parametr je efektivní v zajištění stability obou časových dimenzí. Nejznámějším typem vlnové analýzy je Morletovská vlnová transformace.⁶

Křížová vlnová transformace (CWT)⁷ dvou časových řad x_t a y_t definovaná autory Torrence a Compo (1998) s vlnovými transformátory $W_n^x(u, s)$ a $W_n^y(u, s)$ specifikovanými v rovnici (3):⁸

$$W_{x,y}(u, s) = W_x(u, s)W_y^*(u, s) \quad (3)$$

⁶ Více viz Torrence et al. (1998)

⁷ Cross-wavelet transform

⁸ Dle Firouzi a Wang (2019) je funkce CWT využitelná pro detekci informace mezi dvěma nestacionárními časovými řadami a pro určení fázových rozdílů v časově frekvenční oblasti.

Kde $W_x(u, s)$ a $W_y^*(u, s)$ jsou spojité vlnové transformace obou časových řady x_t a y_t ; u je poté poziční index s je poté škálovací parametr a symbol $*$ zobrazuje komplexní časovač. Vlnová transformace předpokládá lokální kovarianci mezi oběma proměnnými.

Síla křížového vlnové vztahu určuje oblasti, kde dochází k významné korelaci mezi proměnnými X_t a Y_t (Grinsted et al., 2004). Metoda vlnové koherence má předpoklady zůstat robustní k měření křížového vlnového vztahu se zobrazením významných kovariancí na každé škále časové řady (Torrence a Compo, 2004). Rozšířením práce autory Torrence a Webster (1999) je poté definovaná rovnice zahrnutím čtverců koeficientů vlnové koherence:

$$R^2(u, s) = \frac{|S(s^{-1}W_{x,y}(u, s))|^2}{S(s^{-1}|W_x(u, s)|^2) S(s^{-1}|W_y(u, s)|^2)}, \quad (4)$$

kde parametr s je operátor času a prostoru, a vlnový koeficient čtverců poté nabývá hodnot $0 \leq R^2(u, s) \leq 1$, viz Rua a Nunes (2009). Jedná se o klasický korelační koeficient bez vyhlazovací koherence. Vyhlazovací operátor s v rámci času a frekvenční dimenze je poté:

$$S(W) = S_{scale} \left(S_t(w_n(s)) \right), \quad (5)$$

kde je S_{scale} vyhlazení vlnové škály a S_t je vyhlazení skrze čas. Pro detekci vyššího společného pohybu mezi dvěma časovými řadami je poté hodnota vlnové koherence čtverců $R^2(u, s)$ také vyšší a naopak.

Problémem koeficientu vlnové koherence čtverců je nabývání hodnot v pozitivním smyslu v intervalu (0–1). Tento problém způsobí, že je nemožné pozorovat rozdíly mezi pozitivními a negativními společnými pohyby časové řady. Kvůli překonání tohoto problému, Grinsted et al., (2004) a Torrence, Compo (1998) navrhli užití fázových diferencí. Tímto je rozdíl mezi pozitivními a negativními pohyby již zachycen. Pro účely fázové difference vztahu obou časových řad je definována poté rovnice: (autory viz výše)

$$\beta^{x,y} = \arctan \left[\frac{Im(W^{x,y}(s, n))}{Re(W^{x,y}(s, n))} \right], \quad (6)$$

kde $Im(W^{x,y})$ a $Re(W^{x,y})$ jsou imaginární a reálné komponenty vyhlazené křížové vlnové transformace.⁹ Fázová proměnná $\beta^{x,y} \in \left(0; \frac{\pi}{2}\right)$ determinuje, že druhá proměnná y je zpožděná vůči první proměnné (x). Naopak, vztah $\beta^{x,y} \in \left(0; -\frac{\pi}{2}\right)$ determinuje, že první proměnná (x) je zpožděná, kdežto druhá proměnná se pohybuje ve fázi.

Pro empirickou analýzu vzájemných souvislostí časových řad jsou výsledky zobrazené ve formě mapy s několika ukazateli nebo oblastmi zkoumání: závorky s osmi možnými směry vyjádřeným následujícími šipkami ($\leftarrow, \rightarrow, \uparrow, \downarrow, \nearrow, \searrow, \swarrow, \nwarrow$), černé vrstevnice, dvě osy na mapě, teplé a chladné barvy¹⁰. Symboly \rightarrow (\leftarrow) zobrazují fázový (mimo fázový) vztah nebo pozitivní (negativní) korelaci. V případě symbolů \uparrow (\downarrow) je zobrazen vedoucí efekt jedné či druhé časové řady. Symbol „ \searrow “ ve vlnové analýze ukazuje fázový vztah a pozitivní společné pohyby obou časových řad. V tomto případě první proměnná je zpožděná o $\frac{\pi}{2}$. Naopak symbol „ \swarrow “ potvrzuje mimo fázový vztah a negativní pohyb obou časových řad. Zde v tomto případě je druhá časová řada zpožděná o $\frac{\pi}{2}$.

V mapě je zobrazena černá křivka, která detekuje oblasti koherence s 5% významností. Dalším objektem studia je bílá zvoncovitá křivka, která v rámci vlnové koherence detekuje kuželovitou oblast zájmu.

Černé ohraničení nacházející se v grafu je zobrazením oblastí s 5% v rámci kónické influence. Všechny hodnoty v rozmezí této významnosti jsou vypočítané na základě Monte Carlo

⁹ Použití funkce \tan^{-1} v rovnici (5) je bráno na rozšíření obecného komponentu funkce \tan v intervalu $180 \left(\frac{\pi}{2}\right)$ až

$$-180 \left(-\frac{\pi}{2}\right), \text{ viz Torrence, Compo (1998): } \tan^{-1}\left(\frac{m}{n}\right) \begin{cases} \tan^{-1}\left(\frac{m}{n}\right) & n > 0, \\ \tan^{-1}\left(\frac{m}{n}\right) + \pi & n < 0, \quad m \geq 0, \\ \tan^{-1}\left(\frac{m}{n}\right) - \pi & n < 0, \quad m < 0, \\ \frac{\pi}{2} & n = 0, \quad m \geq 0, \\ -\frac{\pi}{2} & n = 0, \quad m < 0 \end{cases}$$

¹⁰ Teplé barvy v základní podobě: červená, žlutá, oranžová, a jejich odstíny
Chladné barvy v základní podobě: modrá, zelená, černá, hnědá, a jejich odstíny

metody.¹¹ V oblasti kónické influence dochází ke zkreslení interpretace vlivem konečné časové řady pozorování.

V rámci interpretace zobrazuje graf vlnové koherence na horizontální ose čas a na ose vertikální frekvenci, přičemž platí, že s nižší frekvencí roste hodnota na škále. Pro oblasti s teplejšími barvami (červené) je charakteristická vysoká a významná vzájemná závislost. Naopak oblasti s chladnějšími barvami (modré) představují nízkou nebo žádnou vzájemnou závislost mezi sledovanými časovými řadami.

Pro detekci fázových diferencí jsou významné šipky, jejichž směr detekuje cyklickou či anticyklickou vzájemnost. Obě časové řady jsou ve společném směru pohybu, když je detekováno chování „ve fázi“. Na druhé straně chování časových řad „proti fázi“ determinuje anticyklické či protichůdné chování.

Z hlediska interpretace grafu vlnové koherence v oblasti rozdílných frekvencí se rozlišuje nízká a vysoká frekvence. Krátkodobé vlnové působení je založeno na společných pohybech časových řad. Tyto časové řady jsou silnější na vyšších frekvencích v krátkém období. Naopak velké vlnové vlivy mají za následek společné pohyby na nižších frekvencích.

Pro analýzu informačního působení v rámci časově frekvenční oblasti je nutno zdůraznit, že nízké frekvence způsobují efekty světových informačních toků v rámci dynamiky časové řady. Na druhé straně jsou vysoké frekvence odpovědné za informační působení v rámci přechodných informačních toků v časové řadě.

Diskrétní vlnová transformace je silný nástroj pro identifikaci škál, sezónnosti, posunů a časové variantnosti ve vysokofrekvenčních časových řadách (Akansu, A. N.; Medley, 1999). Tato metoda je vhodná pro dekompozici signálu do větších detailů a odstranění nevýznamného šumu v cenových procesech (Daubechies, 1988; Mallat, 1989, a,b,c). Pro zachycení síly informace v cenovém vývoji jsou využity závírací ceny komoditních futures, naproti tomu např. autoři Yang et al. (2016) využívají k DWT analýze cenové výnosy. Zkoumané spektrální transformace jsou založeny na vlnové analýze dle Daubechies, více viz dekompoziční techniky vlnové

¹¹ Pro účely empirického výzkumu je využito 1000 simulací Monte Carlo metody. Statistická významnost je kalkulována na bázi červeného šumu.

analýzy¹². Vlnový rozklad je tudíž vyjádřen dekompozicí třetí úrovně: $s = a_3 + d_3 + d_2 + d_1$, kde s reprezentuje časovou řadu, a_3 aproximaci daného signálu, a d_3, d_2, d_1 jsou poté jednotlivé komponenty (koeficienty) časové škály.

Diskrétní vlnová analýza (DWT) je zaměřena jeden z nejznámějších z typů vlnové transformace, a to Daubechies vlnová transformace. Tyto vlnky jsou vhodné pro analýzu lokální funkce signálu. Tento typ diskrétní vlnové transformace je vhodný pro analýzu nestacionárních časových řad.

Nechť diskrétní vlnová funkce je definována vztahem (Akansu et al.; 1992):

$$\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k), \quad (7)$$

$$j, k \in \mathbb{Z}; z = \{0, 1, 2, \dots\}^1, \quad (8)$$

kde ψ je reálná funkce, a $\int_{-\infty}^{\infty} \psi(t) dt = 0$

Vlnová transformace je odhadnuta dilatačními rovnicemi:

$$\phi(t) = \sqrt{2} \sum_k l_k \phi(2t - k), \quad (9)$$

$$\phi(t) = \sqrt{2} \sum_k h_k \phi(2t - k),$$

Morletovské vlny jsou definované posledními dvěma rovnicemi $\phi(2t - k)$.

¹² Akansu, A., N.; Haddad, Richard, A, 1992, Poznámka: V rámci DWT analýzy je využit typ Fourierovy transformace pomocí Db1 (Daubechies), některé studie využívají typ Haar vlnové analýzy, jenž je ovšem jejím speciálním případem (Chui, Charles, K., 1992), studie ve finančních aplikacích Ardila (2016)

3.4. Skryté Markovské modely

Skryté Markovovy modely (HMM) se staly významným nástrojem v oblasti financí, zejména pro pochopení a předpovídání režimů volatility cen zemědělských komodit (Li, 2016), pro detekci tržních režimů více viz Guidici, P.; Hashish, A., I. (2020); Kritzman et al. (2012); De Angelis, Paas, J., L. (2013). Zemědělské komodity, které jsou ovlivňovány množstvím faktorů, jako jsou povětrnostní podmínky, dynamika nabídky a poptávky a geopolitické události, vykazují složitý cenový proces obsahující různé cenové režimy nebo stavy. HMM nabízí robustní rámec pro zachycení těchto měnících se režimů volatility, který pomáhá při hodnocení rizik, obchodních strategiích a rozhodování investorů, výrobců i tvůrců politik na vládní i lokální úrovni.

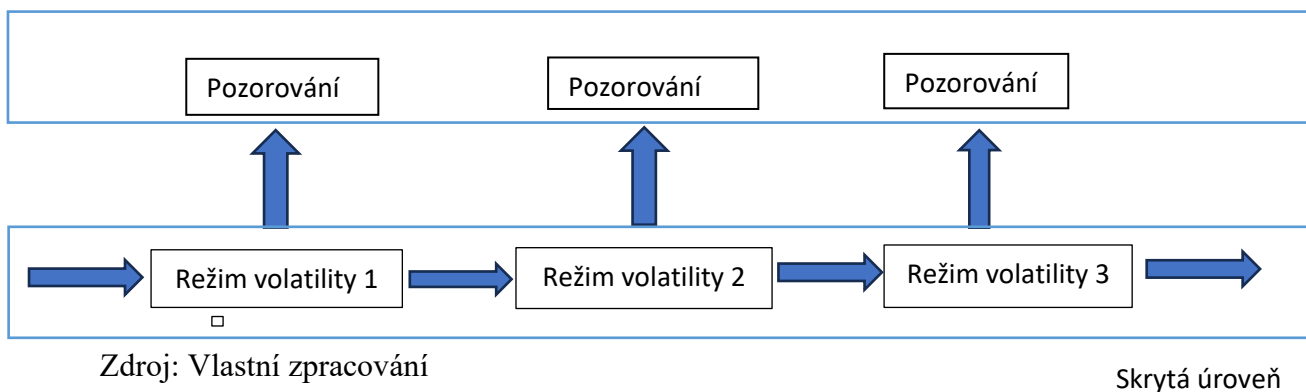
Pozorovanou posloupnost symbolů lze označit jako $x = x_1x_2 \dots x_L$ a posloupnost základního stavu jako $y = y_1y_2 \dots y_L$, kde y_n je základní stav n -tého pozorování x_n .

$$P\{y_{n+1} = j | y_n = i, y_{n-1} = i_{n-1}, \dots, y_1 = i_1\} = P\{y_{n+1} = j | y_n = i\} = t_{(i,j)}, \quad (10)$$

kde je pro všechny stavy $i, j \in S$ a pro všechna $n \geq 1$. Pevně daná pravděpodobnost přechodu ze stavu i do stavu j se nazývá pravděpodobnost přechodu a označujeme ji $t_{(i,j)}$. Pro počáteční stav y_1 označujeme pravděpodobnost počátečního stavu jako $\pi(i) = P\{y_1 = i\}$ pro všechna $i \in S$.

Parametry Skrytého Markovského modelu jsou pozorovatelné, nicméně nepozorované zůstávají latentní (vnitřní) vztahy, které tento proces generují. Tyto stavy představují jednotlivé režimy použité pro empirickou analýzu (Bulla, 2006). Schématické zobrazení je na obr. č. 2:

Obrázek 2: Schéma skrytého Markovského modelu



Nechť je posloupnost symbolů $x = x_1 x_2 \dots x_L$. Pro kalibraci modelu HMM je výše uvedený postup numericky náročný. Vycházíme z potřeby vypočítat pravděpodobnost pozorování $P\{x | \theta\}$. Výpočet pravděpodobnosti $P\{x | \theta\}$ je přirozeným způsobem "bodování" nové posloupnosti pozorování x na základě daného modelu.

Neexistuje pro dané x přímo pozorovatelná stavová posloupnost a dále může existovat mnoho stavových posloupností, které formují x . Proto je jedním ze způsobů výpočtu pravděpodobnosti pozorování všech možných stavových posloupností y pro dané x . Tyto pravděpodobnosti lze sečíst takto:

$$P\{x | \theta\} = \sum_y P\{x, y | \theta\}. \quad (11)$$

Numericky je tento vztah však velmi náročný, protože existuje M^L možných posloupností stavů. Z tohoto důvodu je nutné použít efektivnější metody pro výpočet $P\{x | \theta\}$. Pro kalibraci modelu HMM je využita metody dynamické optimalizace Viterbiho algoritmus (Viterbi, A., J.; 1976), který může identifikovat optimální cestu y^* :

$$\gamma(n, i) = \max_{y_1, \dots, y_{n-1}} P\{x_1 \dots x_n, y_1 \dots y_{n-1} y_n = i | \theta\}, \quad (12)$$

Lze využít log formu rovnice (Cappe et al., 2005):

$$\begin{aligned}
 & \log \phi_{0:k+1|k+1}(x_0, \dots, x_{k+1}) \\
 &= (\mathcal{L}_k - \mathcal{L}_{k-1}) + \log \phi_{0:k|k}(x_0, \dots, x_k) \\
 &+ \log q_{x_k x_{k+1}}(x_0, \dots, x_k) + \log g_{k+1}(x_{k+1}),
 \end{aligned} \tag{13}$$

kde $\phi_{0:k|k}$ představuje společnou pravděpodobnost stavu $x_{0:k}$ daného pozorováním $Y_{0:k}$ a funkce logaritmické věrohodnosti je pak dána jako \mathcal{L}_k za účelem převodu Viterbiho algoritmu do rekurzivní formy:

$$m_{k+1}(j) = \max_{i \in \{1, \dots, r\}} [m_k(i) + \log q_{ij}] + \log g_{k+1}(j) \tag{14}$$

Vzorec lze přepsat:

$$m_0(i) = \log (v_i(i)g_0(i)) \tag{15}$$

Lze poté zapsat \hat{x}_n jako stav, který akceluruje maximální hodnotu $m_n(j)$. Následně pro $k=n-1, n-2, \dots, 0$ proměnná \hat{x}_n je vyjádření stavu, který kalkuluje s maximalizací funkce (j je nahrazeno \hat{x}_n):

$$m_{k+1}(\hat{x}_n) = \max_{i \in \{1, \dots, r\}} [m_k(i) + \log q_{i\hat{x}_n}] + \log g_{k+1}(\hat{x}_n) \tag{16}$$

Algoritmus je založen na kalkulaci pravděpodobnosti optimální cesty v rámci času k . Pokud je nalezena cesta vedoucí ke stavu s nejvyšší pravděpodobností, tak pak algoritmus na následující krok (Persson, 2021) Optimální cesty jsou důležité pro determinaci pravděpodobnosti dosažení jednotlivých stavů (Cappe, et al. 2005).

Režim 1 představuje úroveň nízké cenové volatility a je charakteristický stabilním prostředním. Investoři vytvářejí obchodní strategie s menším rizikem. Struktura trhu je ovlivněna ekonomickou stabilitou a také tržním sentimentem s býčím¹³ trendem. V rámci tohoto období jsou vhodnými nástroji strategie zaměřené na buy and hold¹⁴ koncept nebo profitující z menších cenových změn.

V rámci *Režimu 2* jsou finanční trhy charakteristické zvýšenou cenovou volatilitou s krátkodobými fluktuacemi. Hlavními faktory v tomto období jsou šoky, nejistota, politické vlivy nebo nové zprávy, které ovlivňují tržní sentiment. Vhodné strategie jsou „volatility trading“, kde investoři a tradeři profitují ze zvýšené volatility na trhu. Oblíbenou obchodní strategií je scalping, který staví na zvýšené volatilitě při rychlém uzavření obchodu. Hlavním cílem obchodování v tomto období je rychlá reakce na rychlé změny cen.

Dalším typem režimu je v rámci 3režimového modelu HMM „střední“ neboli „neutrální“ režim, kdy cenové pohyby oscilují kolem střední hodnoty. Vedle řízení rizika je zde v tomto režimu možné i profitovat z mírné hladiny volatility.

¹³ Býčí sentiment: investoři předpokládají růst trhu

¹⁴ Buy and hold: nákup aktiv a jejich následná držba s cílem profitovat na růst ceny

3.3. Časově variační přelévání volatility

Diebold a Yilmaz (2009) vytvořili koncept přelévání založené na rozklad rozptylu chyb prognózy z modelu VAR v časově variačním procesu TVP-VAR. Tento rozklad zobrazuje vztah mezi proměnnou i prostřednictvím h -steap-ahead rozkladu rozptylu chyb a jinou proměnnou j , respektive jakou intenzitou působí tyto dvě proměnné navzájem. Jinými slovy tento vztah determinuje, jak intenzivně předpověď dekompozice rozptylu každé proměnné může být vysvětlena exogenními šoky k ostatním proměnným. Výzkum autorů Pesarana a Shina (1998), Diebold a Yilmaz (2012) rozšířil metriku přelévání, zajišťující invariantnost v řádech, za pomoci obecné impulse – response funkce, která nevyžaduje ortogonalizaci Choleského dekompozice a konstrukce směrových indexů efektů přelévání. Tento navržený rámec zprostředkovává velké množství informací skrze jediného měření efektu přelévání.¹⁵ Účelem tohoto rámce zachycení vzájemných propojeností od více agregovaných proměnných až po ty dis agregované (mikroekonomické proměnné). Uvažujeme model časově variačních vzájemných souvislostí:

$$\begin{aligned} z_t &= b_t z_{t-1} + u_t, u_t \sim N(0, \Sigma_t) \\ \text{vec}(B_t) &= \text{vec}(B_{t-1}) + v_t, v_t \sim N(0, R_t), \end{aligned} \quad (17)$$

kde je z_t $k \times I$ dimenzovaný vektor v čase t a u_t pak náhodná složka. Dimenzované matice o velikosti $k \times k$ reflektující časově variační kovariance a časově variační VAR koeficient jsou poté Σ_t a B_t (Antonakakis, 2020).

Formálně, uvažujeme kovariantně-stacionární model v rámci vektorového klouzavého průměru (VMA), (Koop et al., 1996):

$$y_t | s_t = \omega_k + \sum_{j=0}^{\infty} A_{k,j} u_{s_t, t-j} \quad (18)$$

¹⁵ Connectedness table – plný soubor dekompozice rozptylu, vztah mezi různými vzájemnými souvislostmi mezi proměnnými

kde $A_{k,j}$ jsou $(n \times n)$ matice, které jsou vymezeny následujícím výrazem:

$$A_{k,j} = \sum_{i=1}^p \Phi_{k,j} A_{k,j-i} \omega \quad (19)$$

s počáteční hodnotou jako identitní matice $A_{k,j} = I_n$ a $A_{k,j} = \mathbf{0}$ pro $j < 0$. Vektor ω_k je získán aplikací inverzním autoregresním zpožděným operátorem vůči v_k , např., $\omega_k = (I_n - \sum_{i=1}^p \Phi_{k,i})^{-1} v_k$, nenarušující aplikaci dekompozice rozptylu (Diebold, Yilmaz; 2009).

Obecný h -step-ahead forecast error variance decomposition, který má režim k je definován poté:

$$\theta_{k,ij}^g(h) = \frac{\sigma_{k,jj}^{-1} \sum_{l=0}^{h-1} (e_i' A_{k,l} \sum_k e_j)^2}{\sum_{l=0}^{h-1} e_i' A_{k,l} \sum_k A_{k,l}' e_j} \quad (20)$$

kde je $\sigma_{k,j}$ standardní odchylka náhodné složky pro j -té rovnici a e_i je výběrový vektor s i -tým prvkem rovnající se 1 a 0 případně. Jestliže je rozklad rozptylu založen na zobecněné Impulse-response funkci, pak součet každé řady v rámci rozkladu rozptylu je $\sum_{j=1}^n \theta_{k,ij}^g(h) \neq 1$. Tudíž jsou normalizovány podíly rozptylu pro zajištění každé řady a jejich součtu:

$$\tilde{\theta}_{k,ij}^g(h) = \frac{\theta_{k,ij}^g(h)}{\sum_{j=1}^n \theta_{k,ij}^g(h)} \quad (21)$$

Lze definovat celkový index přelévání v režimu k k měření šoků přelévání volatility mezi proměnnými vůči celkové chybě předpovědi rozptylu v rovnici (22):

$$S_k^g(h) = \frac{1}{n} \sum_{\substack{i,j=1 \\ i \neq j}}^n \tilde{\theta}_{k,ij}^g(h) \quad (22)$$

Alternativně lze získat směrové efekty přelévání volatility za účelem zjištění, jak jednotlivé trhy generují efekty přelévání volatility mezi jednotlivými trhy z hlediska směrů. Rozlišuje se také mezi efekty přelévání původem z trhu i od ostatních trhů, viz rovnice (6) a efekty z transmise z trhu i do vše ostatních trhů, viz rovnice (7).

$$S_{all \rightarrow i}^g(h) = \frac{1}{n} \sum_{\substack{j=1 \\ i \neq j}}^n \tilde{\theta}_{k,ij}^g(h) \quad (23)$$

$$S_{i \rightarrow all}^g(h) = \frac{1}{n} \sum_{\substack{j=1 \\ i \neq j}}^n \tilde{\theta}_{k,ij}^g(h) \quad (24)$$

Generující efekt přelévání z ostatních trhů v rámci rovnice (23) je součet řad stojící mimo hlavní diagonálu normalizovaných zobecněných částí rozkladu rozptylu z rovnice (21), a nikdy nedosáhne hodnoty 100 % kvůli tomu, že součet řad je roven 1. Na stejném základě, přínosy efektu přelévání do ostatních trhů v rámci rovnice (24) jsou součty sloupců stojící mimo diagonálu zobecněného rozkladu rozptylu z rovnice (21). Hodnota efektu přelévání dosáhne 100 % v případě, když trh má významný vliv na transmisi šoků do ostatních trhů.

Následně lze definovat čisté efekty přelévání volatility z trhu i do všech ostatních trhů, viz rovnice (25). Tato rovnice je založena na rozdílu mezi hrubou hodnotou volatility šoků v rámci transmise z trhu i na ostatní trhy a hrubé hodnoty volatility šoků z ostatních trhů do trhu i .

$$S_{i,j}^g(h) = S_{i \rightarrow all}^g(h) - S_{all \rightarrow i}^g(h) \quad (25)$$

Finálně, je potřeba definovat index čistých vzájemných směrových propojeností, kde dochází ke vztahu ovlivnění proměnné i a j mezi sebou.

$$NPDC_{k,i}^g(h) = [\tilde{\varphi}_{jit}(h) - \tilde{\varphi}_{ijt}(h)], \quad (26)$$

kde v rámci pozitivní (negativní) NPDC hodnoty proměnná i dominuje (je dominovaná) proměnné j .

Pro determinaci zpoždění jsou využity metody AIC a BIC s hodnotou $p = 2$

Analýza úplného vzorku přelévání šoků volatilita je zobrazena v rámci přehledu o jednotlivých indexech vysvětlených výše na tab. č. 2.

Tabulka 2: Sumarizace indexů přelévání volatilita dle Diebold, Yilmaz (2009)

Index	Popis	Kalkulace
Celkové přelévání	Přelévání volatilita mezi všemi trhy	$S_k^g(h) = \frac{1}{n} \sum_{\substack{i,j=1 \\ i \neq j}}^n \tilde{\theta}_{k,ij}^g(h)$
Směrové přelévání	Přelévání volatilita přijaté trhem i od všech ostatních trhů	$S_{all \rightarrow i}^g(h) = \frac{1}{n} \sum_{\substack{j=1 \\ i \neq j}}^n \tilde{\theta}_{k,ij}^g(h)$
Směrové přelévání	Přelévání volatilita vyslané trhem i do všech ostatních trhů	$S_{i \rightarrow all}^g(h) = \frac{1}{n} \sum_{\substack{j=1 \\ i \neq j}}^n \tilde{\theta}_{k,ij}^g(h)$
Směrové přelévání	Čisté přelévání volatilita z trhů i do ostatních trhů	$S_{k,i}^g(h) = S_{i \rightarrow all}^g(h) - S_{all \rightarrow i}^g(h)$
Čisté vzájemné přelévání	Čisté přelévání volatilita z trhu i do trhu j	$NPDC_{i,j}^g(h) = [\tilde{\varphi}_{jit}(h) - \tilde{\varphi}_{ijt}(h)]$

Zdroj: Vlastní zpracování

4 Literární rešerše

V úvodní části literární rešerše je pojednáno o historickém přehledu vývoje komoditních cen a o burzách se zemědělskými komoditami. Dále, je rozebrána problematika volatility jako pojmu a míry měřící fluktuaci cen. Další sub-kapitola se věnuje problematice přelévání volatility a vlivu na různé trhy. V poslední řadě je proveden teoretický přehled využití volatility v případě analýzy rizika pomocí hodnoty v riziku jako příkladu klasické metody hodnocení cenové volatility.

4.1. Historický přehled

Rozhodujícími světovými vývozci zemědělsko-potravinářských produktů jsou sice stále USA s podílem 13,5 % na globálním agrárním vývozu, Francie (6,5 %), Nizozemí (6 %), Německo (5 %), Kanada a Velká Británie, ale rychle rostoucí zemědělský vývoz Austrálie, Brazílie, Argentiny a některých dalších zemí nepochybně brzy změní uvedené postavení. Teritoriální skladba globálního agrárního vývozu a dovozu se zejména v posledních deseti letech výrazně změnila. Od r. 1989 do r. 1999 se např. dovoz pšenice do zemí střední a východní Evropy téměř ztrojnásobil, dvojnásobku dosáhl tento dovoz v uvedeném období (ze třetích zemí) také do EU.

Na trzích vyspělých států se projevuje vzrůstající vliv zdravotnické osvěty, tendence k racionalizaci výživy, důraz je kladen na nutriční nezávadnost, růst poptávky po biopotravínách, požadavek spotřebitelů po dokonalé znalosti původu potravin, technologii zpracování, informacích o surovinách a cestách ke konečnému spotřebiteli. Významným tržním trendem na vyspělých trzích je růst poptávky po čerstvých potravinách a odklon od spotřeby tradičně konzervovaných pokrmů. V Evropě se zvyšuje tlak na značení původu zejména živočišných produktů, podporovaný rostoucí fobií ze zvířecích chorob přenosných na člověka. Tyto tendence logicky vedou k růstu nákladů na agrární produkci, jsou využívány stále častěji jako netarifní překážky zahraničního obchodu a nezřídka jako záminka k omezení dovozu, a tedy k ochraně vlastního zemědělství. V některých evropských státech je na těchto principech u spotřebitelů systematicky vyvoláván jakýsi druh konzumního vlastnictví a obav z dovážených, zejména živočišných produktů. Významným faktorem, který v posledních letech ovlivňuje objem nabídky a ceny agrárních produktů na mezinárodním trhu jsou geneticky modifikované odrůdy mnoha obchodovaných rostlinných komodit (GMO). Existence GMO pěstovaných nejen v USA, ale zejména v některých důležitých exportních zemích

jíhoamerických a asijských, evidentně zlepšuje ekonomiku produkce a podněcuje tak pěstitele k rozšiřování ploch. Největší roli hrají GMO dosud zřejmě u sójových bobů, kukuřice, řepky a bavlníku.

Některé tendence, které jsou nepochybně dílčími projevy globalizace, umocňují problém nevyrovnanosti poptávky a nabídky v agrární výseči mezinárodního trhu. Země s nejlepšími přírodními podmínkami a levnou pracovní silou za podpory největších mezinárodních obchodních společností dynamicky rozšiřují vlastní zemědělskou produkci, jejíž nákladové parametry jsou pro Evropu zdrcující. Tak například Brazílie vykazuje náklady na produkci cukru od 4,5 do 5,5 US centů/lb (99,23 až 121,3 USD/t, resp. 3,96 až 4,85 Kč/kg), zhruba 9 US centu/lb činí náklady na produkci cukru v Thajsku a Austrálii, zatímco evropští producenti usilují o dosažení “rovnovážných cen” na úrovni 14 až 17 US centů/lb, tzn. 308,7 až 374,9 USD/t, resp. 12,34 až 15,0 Kč/kg. Ani tyto ceny by však nepokryly náklady výroby v mnoha producentních zemích, včetně ČR. Podle jiných zdrojů činí např. produkční náklady na 1 t sójových bobů v Argentině kolem 70 až 75 USD/t.¹⁶ Je evidentní, že konkurenceschopnost jíhoamerických zemí je z tohoto zorného úhlu velmi vysoká.

Málokdy zmiňovaným faktorem, který poměrně významně ovlivňuje poměry na mezinárodním agrárním trhu, je úsilí mnohých zemí po zajištění vlastní potravinové bezpečnosti, kterou ovšem tyto země chápou jako racionální míru soběstačnosti v hlavních potravinách a zemědělských surovinách. Mnohé země (včetně členských zemí EU) princip soběstačnosti respektují a dohodnutou míru soběstačnosti sledují a udržují. Zvyšující se frekvence meteorologických anomálií v globálním měřítku a již prokazatelné důsledky živelních pohrom pro mezinárodní trh jednotlivých komodit nicméně plně ospravedlňují tuto politiku, která se může perspektivně ukázat jako velmi prozíravá a národohospodářsky efektivní. A naopak, absolutní odmítání strategické míry soběstačnosti v základních potravinách může přinést do národních ekonomik v důsledku možných zhroucení komoditních trhů inflační faktory a sociální problémy


V posledních letech, a zvláště v letech 2006-2011 byly ceny zemědělských komodit, respektive komodit obecně velmi volatilní. Historická zkušenost ale ukázala, že toto období bylo však

¹⁶ Prováděcí nařízení Komise (EU) 2017/1578 ze dne 18. září 2017, kterým se mění prováděcí nařízení (EU) č. 1194/2013 o uložení konečného antidumpingového cla a o konečném výběru prozatímního cla uloženého na dovoz bionafty pocházející z Argentiny a Indonésie

relativně krátké a přerušeno s delším obdobím klidu na trzích. Z tohoto je tudíž velmi obtížně tvrdit, že lze současné vysoké úrovně volatilit transformovat do budoucnosti a konstruovat z toho předpověď.

Dle zjištění autora Gilberta (2006) byla volatilita na trhu zemědělských komodit nejnižší v 60. letech, v 70. letech a první polovině 80. let byla naopak nejvyšší. Koncem milénia a to v 90. letech se hladina cenové volatility vrátila nad úroveň 60. let. Od roku 2002 trh komodit vstoupil do silného a vytrvalého rostoucího trendu. Během druhé poloviny roku 2008, na trhu zemědělských komodit byla patrná korekce trendu s eskalací světové finanční krize. V letech 2008 až 2009 ceny komodit spadly tak překotně, že odepsaly většinu výnosů z minulých let.

Graf 1: Vývoj komoditního indexu



Zdroj: FAO, 2022

Poznámka: Na vertikální ose jsou hodnoty v USD

Graf č. 1 zobrazuje pro názornost vývoj komoditního indexu v posledních dvou dekadách. Index je vyjádřen v amerických dolarech a zvláštních právech čerpání Mezinárodního měnového fondu. Od roku 2000 lze pozorovat rostoucí trend s cyklickým kolísáním. V roce 2008 komoditní index vystoupal k lokálnímu maximu. Empirické výzkumy ukazují možnost výskytu spekulativních bublin (Gutierrez, 2013), navzdory přístupům proti důležitosti spekulativních aktivit cenového vrcholu v letech 2007 až 2008 (Irwin, Sanders, 2011). Výzkum autorů Gheit (2008) a Frenk (2010) ukazuje, že od vzniku rámce standardizovaných komoditních futures jsou ve zvýšené míře transformovány spekulativní investice do trhu komoditních derivátů, což

má za následek rostoucí trend vývoje komodit obecně. Tyto rostoucí cenové hladiny se vymykají stabilním fundamentálním faktorům, viz Gilbert (2010) a Henderson et al. (2012).

Propad komoditních cen v roce 2008 a 2009 vrátil cenovou hladinu komoditního indexu k reálným hodnotám. Po odeznění dopadů finanční krize po roce 2010 následovaly korekce ve vývoji indexu, avšak s výraznějšími cenovými skoky. Reálná úroveň indexu je menší než vyjádření v dolarech. Koncem minulé dekády, a zvláště po roce 2020 následoval výrazný růst komoditních cen zastoupených v indexu tažený fundamentálními faktory. V porovnáním se sledovaným obdobím v práci je zřetelný klesající trend s nestálou volatilitou.

4.2. Futures trh zemědělských komodit

Mezi nejvýznamnějšími komoditami obchodovaných na světových trzích se řadí pšenice, kukuřice a sójové boby (Čermák, et al., 2017). Hlavním fundamentálním důvodem pro vysoký podíl obchodů na mezinárodních trzích je aspekt výživy a zajištění mezi zemědělskými producenty.

Komodita pšenice se obchoduje jako standardizovaná v rámci futures kontraktů. Pšenice se řadí mezi nejlikvidnější futures kontrakty na světě v hodnotě více než 15 milionů tun každý den. Futures pšenice jsou obchodované na Chicago Board of Trade (CBOT), NYSE Euronext, Kansas city Board of Trade (KCBT) a Minneapolisské plodinové burze (MGEX). Jako referenční tržní ceny jsou odvozeny od hodnot na burzách CBOT a KCBT. Největšími producenty pšenice jsou Čína, Indie, Spojené státy, Francie, Rusko, Austrálie a Kanada. Mezi největšími exportéry se zařazuje Rusko. Před rokem 2020 pokrývaly Rusko a Ukrajina téměř 30 % celosvětových exportů.

Komoditní futures na podklad kukuřice se také přiřazují k významným instrumentům obchodovaným na světových komoditních burzách. Samotné institucionální obchodování kukuřice začalo na Chicagské burze v 19. století. Kontrakty futures kukuřice jsou standardizované nebo ETF obchodované na Chicago Board of Trade, NYSE Euronext a na Tokijské obilné burze (TGE). Hlavními exportéry jsou Spojené státy, Argentina, Brazílie a Francie.

Sójové boby v rámci futures kontraktu lze řadit k nejvýznamnějším komoditám zajišťujícím světovou výživu. Mezi hlavní producenty sójových bobů se řadí Spojené státy, Brazílie,

Argentina a Paraguay. Naopak Čína a Mexiko představují importéry. Obchodování na komoditních burzách začalo v případě sójových bobů v roce 1940. Hlavními místy obchodu jsou burzy CME Group, Chicago Board of Trade, Brazílská obchodní a Futures burza (BM&F), Kansai Commodities Exchange (KANEX).

Kávu lze také řadit k významným komoditám, avšak nedosahuje takových objemů jako u základních zemědělských komodit. Káva Arabica je světová referenční komodita pro odvození cen kávy na trzích. Hlavní burza je Inter Continental Exchange (ICE). Káva Arabica je pěstována v Brazílii a v Kolumbii z přibližně 40 % světové produkce. Naopak Robusta pokrývá přibližně 25 % a je pěstována ve Vietnamu a Indonésii.

Komoditní futures kakao se řadí k méně významným artiklům obchodovaných na trzích. Mezi hlavní trhy se řadí New York Mercantile Exchange (NYMEX) a burza Intercontinental Exchange (ICE). Cenové reference pro burzu NYMEX jsou založeny na Jihoasijském trhu, a naopak ceny pro burzu ICE jsou odvozeny od cen kakaa z Afriky. Největším producentem je Pobřeží slonoviny a Ghana. Tyto státy představují více než 60 % světové produkce.

Komoditní futures cukr je méně obchodovatelný produkt na burze. Jako referenční cena lze zařadit kontrakt č. 11, který je k dispozici na burze ICE. Brazílie se řadí k největším světovým producentům a i exportérům.

4.3.Cenová volatilita

Cenová fluktuace neboli volatilita zachycuje změny kolem dlouhodobého trendu komodity či aktiva (Hull, 2009). Jedná se o relativně široký pojem, který zahrnuje kolísání či změnu během obvyklé cenové hladiny v daném čase. Naopak pokud se mluví o krátkodobém trendu výkyvů ceny, pak se uvažuje využití denních, týdenních či měsíčních horizontech. Koncept cenové volatility se rozděluje na dvě perspektivy: volatilita na základě historických dat (ex-post volatilita) a volatilita s výhledem do budoucnosti (ex-ante volatilita). Ex-post volatilita se využívá pro měření realizovaný rozptyl náhodné složky s využitím zpožděných hodnot ceny nebo zpožděných rozptylů (v rámci nepodmíněných volatilit). Realizovaná volatilita je pak počítána v delším časovém horizontu několika cenových pozorování. Pokud se diskutuje o dynamickém modelu volatility, pak je třeba zjistit informace v čase t , za účelem konstrukce předpovědi v čase $t + 1$. Tyto modely jsou vhodné pro předpověď do budoucnosti. Stochastická volatilita jako taková zahrnuje proces variance, který je náhodně distribuován.

Extrémní události, které mají vliv na cenu komodit, jsou „neobvyklé“ jevy nevyskytující se frekventovaně. Pro tyto jevy musí platit, že se vyskytují pouze zřídka (v minulosti též). V rámci normálního rozdělení náhodné veličiny extrémní události jsou velmi těžce předvídatelné a nákladné (Sarris, 2012).

Modelování volatility je předmětem výzkumu mnoha finančních analytiků a odborníků, zejména (Reider, 2009), (Zhang, 2015). V počátku zkoumání se Markowitz (1952) zaměřoval na koncept nejistoty ceny aktiv. Problém modelování cenové variability je primárně způsoben obtížemi s výsketem vysokofrekvenčních dat a analýzou modelů pro vhodné užití na časovou řadu, viz Zhang et al. (2015). Struktura cenové trajektorie se během poslední dekády změnila právě kvůli výskytu vysokofrekvenčních dat (Maneesoonthorn, 2015). Cenové pohyby jsou často vyvolávány zpravodajskými oznámeními nebo obchodními aktivitami institucí, např. centrálních bank či finančních institucí. Díky této cenové variabilitě a potažmo pak volatilitě je zřejmý vliv na návratnost a efektivnost komoditního trhu. Schopnost přesně a jednoznačně předpovídat volatilitu na jakémkoli trhu má mnoho aplikací a užití. Existují i jiná využití, avšak nejvýznamnější užitek měření volatility u obchodníků s komoditami a akciemi je patrný v oblasti správy portfolia, které se skládá z aktiv a derivátů (Hull, 1987).

Volatilita je mírou nejistoty ohledně budoucích změn cen nebo výnosů aktiv. Pokud jde o faktory, které volatilitu řídí, existují dva argumenty. Někteří vědci tvrdí, že je to exogenně řízeno nepozorovatelným faktorem, který koreluje s výnosy aktiv. Jiní však dospěli k závěru, že volatilita akciového trhu má velmi silný vzorec hospodářského cyklu. Podle Jonese bude volatilita vyšší během recese než během expanze (Jones, 2002). Ekonomická integrace mezinárodních akciových trhů se stala zvláště důležitou v posledních dvou letech dekády. Podstatný rozvoj technologií a zvýšený tok kapitálu mezi zeměmi jsou hlavními faktory tohoto procesu globalizace. Pochopení vazeb mezi různými finančními trhy je tedy pro portfolio manažery a finanční instituce velmi důležité. Volatilita, měřená směrodatnou odchylkou nebo rozptylem výnosů, se často používá jako hrubé měřítko celkového rizika finančních aktiv (Brooks et al., 2002). V případě důrazu na integraci mezinárodních akciových trhů, existují snahy mnoha studií popsat kauzální vazby výnosů, ale také měření účinků přelévání volatility. Ekonomové a tvůrci politik se domnívají, že finanční globalizace má primární dopad na snižování domácích překážek bránících přeshraničním finančním tokům. Tento posun směrem k volnému a rychlému toku kapitálu má za následek, že všechny země v rámci globálního trhu jsou úzce propojeny a vzájemně na sobě závislé, takže se finanční krize v jedné zemi může

rychle rozšířit do dalších zemí (Dymski, 2005). Existuje mnoho empirických studií, které ukazují existenci společných pohybů a vzájemné závislosti mezi kapitálovými trhy na globálním trhu. Takový společný pohyb může vytvořit interakci mezi volatilitou různých finančních trhů, kterou můžeme nazvat přelévání volatilitu. Přelévání volatilitu může existovat mezi trhy různých geografických lokalit a také mezi různými typy finančních trhů, například mezi akciovými trhy, devizovými trhy a trhy dluhopisů.

Obecně se dělí přístupy cenové volatilitu do dvou základních skupin: 1) volatilitu ex-post, která předpokládá nepodmíněný vztah s konstantním rozptylem generujícího procesu, a 2) dynamickou ex-ante nepodmíněnou volatilitu, která je založena na predikci rozptylu se zaměřením na minulé změny ceny a rozptylu. Nejpoužívanějším modelem stochastické podmíněné volatilitu je model GARCH, konstruující předpověď rozptylu do budoucna (Hull, 2009). Tyto modely ze skupiny podmíněných volatilitu využívají minulé šoky a variance. Model GARCH¹⁷ (p,q) zahrnuje p-řád GARCH proměnné a q-řád proměnné ARCH (Bollerslev, 1986). Rapsomanikis a Mugeru (2011) uvádějí, že multivariační modely GARCH se dají využít na analýzu efektů přelévání volatilitu mezi finančními a komoditními trhy.

Empirickým pozorováním bylo zjištěno, že modely ARCH a GARCH zachycují shlukování volatilitu, kdy tendence ve větší změně ceny jsou následovány významnějšími cenovými změnami, a naopak v případě menších cenových výkyvů (Mandelbrot, 1963).¹⁸ Výskyt jevu shlukování volatilitu jde proti modelu náhodné procházky, a tudíž jsou tyto modely využívány ve větší míře ve finančním modelování a oceňování finančních instrumentů.

Naproti modelům ARCH a GARCH se využívá pro analýzu implikované volatilitu model Black-Scholes, původně Black a Scholes (1973). Merton (1973) rozšířil model pro oceňování opčních teoretických cen. Call a put opce dávají právo držiteli na nákup či prodej podkladového aktiva (hojně na komoditních futures) za předem stanovenou cenu. V případě vysoké implikované volatilitu (na základě tržního vnímání) se stávají opce dražší. Vysvětlením pak můžeme nalézt, že držitel opce má právo nikoliv povinnost nakoupit či prodat podkladové aktivum. Model Black-Scholes je však předmětem kritiky z důvodu nezohlednění reality a neplatností ve všech empirických pozorování. Největším problémem modelu je předpoklad konstantní volatilitu, která je však v reálném světě variabilní. Model BS předpokládá

¹⁷ GARCH a modifikace (EGARCH, IGARCH, NGARCH, GARCH-M, GJR-GARCH), viz Glosten, Jagannathan, Runkle (1993), Bera, Higgins (1992)

¹⁸ Více viz Ding a Granger (1993) a (1996)

stacionární proces časových řad, kterým lze perfektně teoreticky zajistit opční strategie prostřednictvím delta zajištění (Black, Scholes, 1973).

V tabulce č. 3 jsou také zobrazeny dále neparametrické modely volatility, které jsou mnohem flexibilní než modely GARCH, jež jsou ryze parametrické. Tyto modely nepředpokládají specifické funkční formy a jsou využívány v závislosti na použití finančních časových řad, např. Martins-Filho et al. (2018).

Výběr správného modelu volatility záleží na kontextu, datech a jejich dostupnosti a výzkumných otázkách. Modely volatility, které jsou založeny na predikci volatility ex-post, jsou využity na finanční časové řady s menší frekvencí. Lze tyto modely dále využít v těch případech, kdy pozorování chybí (nejčastější případy jsou data z rozvíjejících se zemí). Nepodmíněné modely jsou využitelné také ke studiu vlivu minulých šoků na cenovou dynamiku. Obecně, nepodmíněné modely volatility předpokládají konstantní rozptyl. Tudíž ke studiu časově-variantní volatility nejsou využívány. Na druhé straně modely podmíněné volatility jsou založeny na větším množství datového souboru časových řad, které jsou schopny zachytit dynamiku cenové fluktuace.

Tabulka 3: Přístupy k měření volatility

Nepodmíněná volatilita (ex-post) /realizovaná variabilita		Volatilita ex-ante (podmíněná/dynamická volatilita)			
<i>Standardní odchylka logaritmických výnosů¹⁹</i>	<i>Koeficient variance (střední hodnota/trend)</i>	<i>Podmíněná volatilita (GARCH)</i>	<i>Implikovaná volatilita</i>	<i>Neparametrická volatilita/kvantilové modely</i>	<i>Stochastická volatilita (CEV model)</i>
$V = SD[r_t]$	$V = \frac{[p_t - \bar{p}_t]}{\bar{p}_t}$	σ^2 $= \alpha V_L + \sum_{i=1}^q \alpha_i \varepsilon_{n-i}^2$ $+ \sum_{i=1}^p \beta_i \sigma_{n-i}^2$	$C = f(\sigma^2, \cdot)$	$r_t = m(X_t) + \sigma^2(X_t)\varepsilon_t$ $r > q(\alpha X_t)$	$dS_t = \mu S_t dt + \sigma S_t^\gamma + dW_t^{20}$
Konstantní trend	Využití netrendových cen \bar{p}_t kvůli eliminace dlouhodobých trendů	Volatilita σ^2 je podmíněna na minulých variancích a dlouhodobé volatilitě V_L	Tržní vnímání o budoucí volatilitě	Neparametrický odhad volatilitě $\sigma^2(X_t)$	Zachycení vztahu mezi volatilitou a cenou ²¹
Gilbert, Morgan (2010)	Huchet-Bourdon (2011)	Bollerslev (1986)	Gatheral (2004)	Martins-Filho et al. (2015)	Black,Cox (1975), Yu (2005)

¹⁹ Poznámka: $r = \log(p_t/p_{t-1})$

Uvažujeme model GARCH a modely implikované volatilitě jako součást stochastické volatilitě

²⁰ Wienerův proces

²¹ Leverage effect

V návaznosti na měření cenové volatility z širšího pojetí je potřeba uvést, že existují dva typy volatility:

- Historická volatilita
- Implikovaná volatilita

Historickou volatilitu chápeme jako pásmo ceny aktiva za danou periodu a frekvenci v minulém čase. Tato volatilita je jednoduchá na výpočet, neboť jsou předem známy veškeré parametry. Cenová volatilita je zde vyjádřena jako roční standardní odchylka procentní změny ceny. Pro účely tradingu jsou využity parametry otevíracích, maximálních, minimálních a zavíracích cen v návaznosti zachycení intra denních cenových volatility (Alquist, et al., 2013). Běžnou míru volatility představuje standardní odchylka cenových změn za danou periodu s určitou frekvencí.²²

Jedním z neznámějších modelů stochastické volatility je dle schématu měření volatility (Tabulka – Měření volatility) pro implikovanou volatilitu Black-Scholes model (Black-Scholes, 1973), který je akceptován širokou odbornou veřejností pro svoje analytické řešení. Nicméně v reálných aplikacích, a zvláště v empirických pozorováních prostřednictvím volatility smile²³ selhává skrze funkci konstantní volatility. Podkladové aktivum následuje geometrický Brownův pohyb (GBM). Nicméně navzdory omezení v podobě neměnné volatility je velmi oblíben mezi finančními praktiky (Heston, 1993). Pro zachycení pákového efektu (leverage effect) a vztahu volatility smile empiricky pozorovatelným se využívá alternativní model CEV (constant elasticity variance) navrženým autorem Cox (1975). Elastický parametr zde zachycuje vztah mezi volatilitou a spotovou cenou. Dalším modelem zachycující stochastickou volatilitu je skokově-difuzní model (jump-diffusion) vytvořený autorem Merton (1973).²⁴

Heston (1993) a Hagan et al. (2002) vytvořili model stochastického procesu pro samotný parametr volatility (volvol funkce). Zde je sledován stochastický proces volatility a jeho procesu samotného. Model SABR (stochastic, alfa, beta, rho) navrženým autorem Hagan et al. (2002) je využívám pro konstrukci povrchu implikované volatility, který je empiricky

²² Obvykle jsou sledovány denní, měsíční, čtvrtletní nebo roční data

²³ Volatility smile – grafické zobrazení vztahu implikované volatility a realizační ceny opce se shodným podkladovým aktivem a datem expirace, pojmenován dle tvaru úsměvu, více viz Hull (2009)

²⁴ Další modely představují například zachycení lokální volatility Dupire (1994)

kalibrován prostřednictvím evropských opcí, více viz Dumas et al. (1998) nebo Gatheral (2004). Posledně jmenovaný autor je známý pro metodu lineární parametrizace pro model SVI (stochastic volatility inspired). Tento model je široce oblíben mezi finančními praktiky a účastníky trhu, viz Gatheral (2004).

Výzkum zmíněných stochastických modelu volatility je velmi omezen na empirickou analýzu prostřednictvím opčních kontraktů. Veškerý výzkum v této oblasti je také limitován analýzou pro americké opce, kde se nepodařilo empiricky konstruovat povrch implikované volatility v rámci kalibrace z tržních dat.²⁵

4.4. Determinanty cenové volatility na komoditních trzích

Ceny zemědělských komodit jsou variabilní, neboť produkce a spotřeba jsou proměnlivé. Z ekonomického hlediska můžeme rozlišovat předvídatelnou a nepředvídatelnou variabilitu. Nepředvídatelná variabilita je charakteristická z hlediska šoků. Šoky na straně poptávky a nabídky jsou promítány do cenové variability komodit. Produkce je rozlišována buď kvůli změnám v osázené ploše nebo kvůli změnám ve výnosu, zřejmý je vliv počasí. Spotřeba se mění kvůli změnám příjmů, změnám cen substitutů a ostatních faktorů. Obecně se předpokládá, že nejvýznamnějším zdrojem cenové variability v zemědělství jsou povětrnostní šoky do zemědělských výnosů. Poptávkové šoky, zejména příjmové šoky (Gilbert 2010) a politické šoky hrají důležitou roli.

Trh zemědělských komodit je specifický tím, že zde panuje sezónnost. Agronomické podmínky typu počasí, druhu půdy, ročního období výsevu atd. jsou nedílnou součástí variability ceny na finálním trhu. Producenti se částečně rozhodují dle budoucích výnosů, cenách vstupů určených k produkci očekávaného výstupu. Nedílnou součástí jsou vládní programy na podporu alternativních produkčních činností.

Míra, do jaké se dané výrobní a spotřební šoky promítnou do cenové volatility, závisí na elasticitě nabídky a poptávky. Tato elasticita odráží schopnost výrobců a spotřebitelů reagovat na změny cen komodit. Všeobecně je prokázáno, že tyto elasticity jsou krátkodobě nízké, zejména během sklizně. Producenti mohou sklízet jen to, co zasadí. Spotřebitelé se zdráhají

²⁵ Hlavním problémem pro výzkum spočívá v možnosti uplatnění práva na vypořádání call a put opcí během celé doby platnosti opce, na rozdíl od evropského typu opcí

změnit obvyklé stravovací návyky a v chudých zemích mohou mít jen málo alternativ. Kromě toho může komoditní surovina tvořit pouze malou složku mnoha zpracovaných potravin, což má za následek, že i velké zvýšení cen komodit má malý dopad na ceny finálních produktů (Gilbert, 2010).

Jedním z faktorů, které mají zásadní vliv na cenovou volatilitu je spekulativní efekt jak ze strany institucionálních investorů, tak penzijních fondů (nehovoříme však o tradičních investorech na trhu Futures kontraktů). Otázkou je, jestli existuje přímé kauzální spojení nebo nikoliv. Jsou to právě vysoké ceny zemědělských komodit, které způsobily to, že fondy přešly na investování na trhu derivátů zemědělských komodit nebo naopak. Je zřejmé, že během finanční krize v letech 2006–2008 byl významný nárůst netradičních investorů na trhu zemědělských komodit, jako penzijních fondů zaujímající dlouhé nákupní pozice opčních a futures kontraktů obilních komodit. Tyto investoři také ve stejných letech zdvojnásobili své obchodní pozice na trhu futures a opcí v komoditách kukuřice, pšenice a sója, kde byl patrný nárůst o 30 % (FAO, 2015).

Zastánci negativního a destabilizačního pohledu efektu spekulací na trh komodit zaměřili pozornost na nedávný růst indexu fondu investic do komoditních derivátů²⁶. Objem investic v tomto fondu má za následek růst cen futures kontraktů v posledních letech. Podporou tohoto argumentu může být, že zvyšující se objem investic do komoditního trhu futures je roven růstu poptávky po podkladové komoditě. Jinými slovy, pro každou long pozici je potřeba mít short²⁷ pozici. Dle autorů Irwin a Sanders (2011) se zde nenachází reálné omezení počtu kontraktů, které jsou vytvořené a obchodovatelné za danou cenu.

Všechny transakce na termínových trzích nejsou spekulativní – standardní regulační rozdíl mezi zajištěním, ve kterém se investoři dodavatelského řetězce pokoušejí kompenzovat vystavení riziku prostřednictvím termínových transakcí, a spekulací je, že spekulanti obchodují bez potřeby dodání komodity ve fyzickém objemu. Komoditní termínové trhy obsahují strukturu, ve které se riziko přenáší z komerčních na nekomerční obchodníky, tedy ze zajišťovatelů na spekulanty. Při převzetí tohoto cenového rizika spekulanti poskytují tržní likviditu, která umožňuje zajišťovatelům najít protistrany relativně bez nákladů. Analogicky k pojistným trhům

²⁶ Fond komoditního indexu je finanční produkt, který umožňuje investorů zaujmout pozici při nákupu či prodeji komodity nebo skupiny komodit, bez nutnosti fyzického dodání.

²⁷ Short pozice – krátká pozice, kdy je aktivum prodáváno.

budou spekulanti v souhrnu očekávat zisk a hedgeři zaplatí za tento přenos rizika. Tradiční názor mezi ekonomickými odborníky je, že spekulace mají tendenci se stabilizovat (tj. snížit volatilitu), protože destabilizující spekulace budou nerentabilní, a proto nebudou přetrvávat.²⁸

Gilbert (2010) zdůrazňuje roli poptávky při detekci cen potravin a řada výzkumníků poukázala na rychlý hospodářský růst v Číně a v Asii jako na společnou hybnou sílu změn cen komodit na energetickém trhu. Bude-li růst poptávky stále proměnlivější a rychlejší, povede to také ke zvýšené volatilitě cen potravin.

Vliv environmentálních změn je jedním z důvodů obavy o budoucí variabilitu cen zemědělských komodit. Výzkum, např. Schlenker a kol. (2005) a FAO (2005) naznačuje poškození stávajících pěstebních ploch zemědělských plodin při růstu teplot v budoucnu. Je možné najít jasné příklady specifických kombinací plodin a území jejich růstu. Ty se týkají především produkce v relativně suchých oblastech – produkce obilí ve velké části Austrálie, skotu v oblastech Afriky hraničících se Saharou a produkce potravin v jižní Asii a jižní Africe. Všeobecně se má za to, že globální oteplování může vést k extrémnějším povětrnostním podmínkám, což může vést k větší variabilitě výnosů. V každém případě zůstává otázkou, do jaké míry se zvýšená variabilita výnosů u konkrétních plodin a zemí zobecní na celé spektrum cen potravin.

Zásoby obilných komodit během období od konce minulého tisíciletí klesaly, a to bylo uváděno jako faktor přispívající k prudkému růstu cen v letech 2006–2008. Tento argument je obtížné udržet v jednoduché podobě, protože pokles úrovně zásob byl pomalý a stálý, zatímco růst cen v roce 2007 a v první polovině roku 2008 byl prudký a náhlý. Je zřejmé, že nízké úrovně zásob eliminují schopnost nabídky reagovat na šoky poptávky, které jsou důležité pro generování vývoje cen. Poptávkové a nabídkové šoky jsou zodpovědné za výskyt cenových změn, zatímco úroveň zásob určuje amplitudu výsledných cenových pohybů. Zásoby obilí klesly na nízkou úroveň ze dvou důvodů: 1) komerční uživatelé se snažili ušetřit na zásobách a spoléhali na rychlé a flexibilní dodávky, 2) vlády se při řešení nedostatků v domácí dostupnosti začaly spoléhat více na obchod než na zásoby potravinové bezpečnosti. Oba vývojové trendy jsou charakteristické tím, že udržování zásob je nákladné. Komerční závislost na dodavatelích a

²⁸ Více viz De Long et al., 1990, Gilbert and Morgan, 2010, Huchet-Bourdon, 2010

národní závislost na obchodu poskytují levnější řešení problémů s dostupností, pokud jsou šoky idiosynkratické, a pokud jsou šoky běžné, tak selhávají. Světové vlády v roce 2008 zjistily, že spoléhání se na obchod při zajišťování potravin pravděpodobně selže přesně za těch okolností, kdy je to vyžadováno. Výsledkem je návrat k zásobám jak v obchodně-dodavatelském řetězci, tak na vládní úrovni ve vztahu k potravinové bezpečnosti. Vyšší zásoby obilí by měly zajistit, že budoucí nabídkové a poptávkové šoky budou snadněji absorbovány do ceny komodit (Tadasse et. al, 2016).

Dalšími potenciálními zdroji cenové volatility jsou separátní šoky, které působí z ostatních zemědělských komoditních trhů. V některých případech jsou tyto šoky korelované. Tento stav může nastat, jestliže působí faktory simultánně mezi různými trhy, zvláště pokud jsou tyto vlivy z jiných než zemědělských trhů. Během počátku finanční krize v letech 2007-2008 tento jev nastal, kdy rostly vzájemně ceny zemědělských a nezemědělských komodit (energetické a vzácné komodity). Výzkum autorů Abbot et al. (2009), Mitchell (2009) potvrdil, že tyto faktory jsou obvykle v rostoucí poptávce, růstu ceny ropy a v neposlední řadě také nárůst poptávky po obilovinách jako biopaliv. Významný vliv je potvrzen také v depreciaci dolaru a rozmachu spekulacních aktivit na trhu futures.²⁹

Deaton a Laroque (1992) dokumentovali, že vliv na cenovou volatilitu má také skladování a držení zásob. Tento faktor má za následek eliminaci cenové volatility a pozitivně orientované zešíkmení cenové distribuce. Samotné skladování zásob podstatně snižuje hodnotu cenové volatility, v případě že jsou akumulovány zásoby v době větší nabídky, a naopak drženy v obdobích zvýšené poptávky po nich. V případě, že jsou zásoby malé, relativně malá produkce nebo šoky na straně spotřeby mají velký cenový vliv na kolísání cen. Držení zásob má také za následek výskyt vzorců chování volatilit. Světové zásoby obilí spadly v roce 2006 na minima a způsobily zvýšení cenové volatility v minulé dekádě.

V závislosti na zvolené periodě, zvláště v krátkém období, cenová nestabilita komodit zrychluje případnou politickou a potravinovou krizi (Martin, Anderson, 2012) s generováním cenové nejistoty na trzích. Ve střednědobém horizontu má cenová volatilita negativní vliv na ekonomický růst a úroveň bohatství.

²⁹ Dále také viz Baffes, 2007

Shrnutím uvedených poznatků o faktorech, které ovlivňují cenovou volatilitu lze konstatovat, že významný vliv má poptávka po biopalivech, spekulace na komoditním trhu futures a makroekonomické šoky. Tabulka č. 4 zobrazuje teoretický rámec vlivu faktorů na cenovou volatilitu. Můžeme tento model interpretovat jako dynamické vazby mezi exogenní proměnnými, které se označují jako „kořenové příčiny“ nebo „podmíněné příčiny“. Tyto základní determinanty mají významný vliv na fluktuaci cen komodit. Lze mezi ně řadit například působení extrémního počasí, šoky ceny ropy, produkční šoky nebo poptávkové šoky. Tyto faktory jsou nezávislé a ovlivňují v konečné fázi cenovou volatilitu. Tyto faktory jsou tudíž exogenní, neboť zde neexistuje kauzální vztah mezi trhem zemědělských komodit a faktory způsobující nezávislé šoky, více viz Baffes a Dennis (2013). Tyto šoky pak generují cenový proces a jejich síla záleží v částečném rozsahu na politickém a ekonomickém prostředí.

Tabulka 4: Determinanty cenové volatility

Exogenní šoky	Tržní podmínky a politické prostředí	Cenová volatilita	Endogenní šoky
<ul style="list-style-type: none"> - Vliv počasí - Šoky v cenách ropy - Ekonomický růst a poptávka - Finanční šoky 	<ul style="list-style-type: none"> - Koncentrace produkce, exportu - Nedostatek informací 	<ul style="list-style-type: none"> Akcelerace a dynamika vztahů 	<ul style="list-style-type: none"> - Spekulace - Diskrétní obchodní politiky (zákaz exportu)

Zdroj: zpracováno na základě koncepčního rámce Tadesse, et al. (2016)

Další skupinou, které ovlivňuje cenovou volatilitu je pak časově invariantní prostřední politik a tržních podmínek. Tyto faktory jsou obtížně měřitelné a mohou zahrnovat méně transparentní prostředí komoditních trhů.

Poslední skupinou jsou tzv. vnitřní faktory, ke kterým řadíme například cenovou spekulaci (ovlivněna očekávanou cenou), diskrétní tržní omezení nebo různé arbitrážní podmínky. Někteří autoři Santeramo et al. (2018) naopak zařazují spekulativní aktivity do ryze exogenních faktorů. K této skupině také lze zařadit pokles světových potravinových zásob, např. Cafiero et al. (2011), Mitra a Boussard (2012). K endogenním faktorům se řadí dále i úroveň spotřeby dané komodity, která pozitivně ovlivňuje cenovou volatilitu Ott (2014).

Rozmezí mezi exogenními a endogenními faktory ovlivňující cenovou volatilitu je nepatrné. Můžeme zde pozorovat komplexní a často oboustranné vztahy a interakce mezi těmito faktory. Lze uvést příklad, že výkyvy extrémního počasí podporují finanční investice na trhu komoditních futures. Z empirického hlediska byla mezi proměnnými detekována slabá korelace (UNCTAD, 2011).

Dále se zařazují mezi exogenní proměnné také vlivy počasí s pozitivním korelačním efektem. Uvedený autor zkoumal taky vliv přírodních a technologických katastrof na cenovou volatilitu. I v tomto případě byl potvrzen pozitivní korelační vztah. Obecně proměnná počasí významně ovlivňuje světovou nabídku zemědělských komodit, s následkem nárůstu cen komodit obecně.

Dalším významným faktorem ovlivňující cenovou volatilitu komodit jsou cenové šoky ropy, které ovlivňují významně ceny obilovin, viz Serra a Gill (2012), Tadesse et al. (2014) a Brümmer et al. (2016). V rámci nabídky nárůst cen energetických komodit zvláště ropy působí na nákladovost pro produkci obilovin, jmenovitě na hnojiva, dopravní a skladovací náklady. Růst nákladů má bezprostřední následek v rostoucí tendenci komoditních cen.³⁰ Na druhé straně má tento jev následek i v růstu poptávky po obilovinách využitelných pro energetické účely.³¹ Vzrůstající tendence v cenách biopaliv, zvláště kukuřice, sójové boby nebo jiné obiloviny, je následkem cenových výkyvů na jiných trzích aktiv (Baffes, Hanriotis, 2016). Studie, např. Chen et al., (2010) prokázala významný vliv poptávky po energetických komoditách a jejich vlivu na růst cenové volatility u sledovaných komodit. Tang a Xiong (2012) zkoumali vztah mezi cenou ropy a komoditním trhem prostřednictvím indexu investic. Výsledky podpořily vzrůstající tendenci korelačního vztahu mezi cenou futures zemědělských komodit a cenou ropy.

Dalším aspektem ovlivňujícím cenovou volatilitu komodit je jejich financionalizace. Investoři a hráči na komoditních trzích kvůli diverzifikaci svého portfolia využívají větší objemy investic právě do komodit, respektive do zemědělských komodit. Děje se tak za přispění klesající atraktivity ostatních aktiv či instrumentů. Tento „spouštěč“ představuje jeden z faktorů rostoucího trendů na trzích. Za předpokladu snížení celkového rizika portfolia využívají investoři právě komoditní futures. Hlavním motivem zde přitom není obavy či očekávání

³⁰ Za současného předpokladu poklesu výnosnosti a produkce

³¹ Příkladem může být růst cen barelu ropy nad úroveň 120 USD v roce 2008, s podporou USA a EU přešli farmáři na využívání biopaliv pro energetické účely.

rostoucích cen. Z tohoto úhlu pohledu se stávají komodity atraktivnější pro zahrnutí do investičního portfolia než ostatní aktiva typu nemovitostí, obligací nebo drahých kovů, které investoři považují za rizikové nebo příliš drahé. Dle Tang a Xiong (2012) investoři vědomým přestavováním (rebalancing) svého portfolia posilují efekt přelití volatility mezi komoditními trhy.

4.5.Řízení rizika: koncept Value at Risk

*„Největší benefit metody VaR je v užití strukturované metodologie pro kritické myšlení o riziku.
„(Jorion, 2002)*

Jorion (2002) definuje riziko jako fluktuace neboli volatility neočekávaných výstupů, obecně jako hodnotu aktiv nebo portfolia. Existují různé druhy rizika, široce je poté možno dělit riziko do několika kategorií jako tržní riziko, úvěrové riziko, riziko likvidity a provozní riziko. Jinými slovy, jedná se o riziko, že investice či portfolio ztratí jeho hodnotu kvůli pohybům tržním faktorům jako kapitálů, úrokové míře a měnovému kurzu. Výraz value at risk je využíván, jak pro měření rizika, tak pro risk metric.³²

V rozporu s teorémem Modigliani – Miller je řízení rizika nerelevantní na dokonalém trhu, viz Bartram (2000). Kvantitativní řízení rizika je nástrojem mnoha institucí, jako pojišťovny, banky, penzijní fondy, zajišťovací fondy a další finanční společnosti. Nejpoužívanějším nástrojem pro kvantifikaci tržního rizika je hodnota v riziku (VaR).³³ Hodnota v riziku je definována jako maximální ztráta portfolia za danou dobu s určitou pravděpodobností. Využití metody VaR je široce přijímáno mezi finančními praktiky a investory pro svůj jednoduchý a srozumitelný výpočet. Metoda VaR je také uznávána mezi bankovními regulátory, viz Basel.

³² Risk metric je konceptem kvantifikace rizika s ohledem na míru očekávané ztráty zohledňující volatilitu portfolia, více viz JP Morgan, 1997

³³ Value at risk

Hodnota v riziku může být odhadnuta parametricky (variačně-kovariační matice) nebo neparametricky (historické simulace).

Nechť X je distribuce výnosů a ztrát, poté hodnota v riziku na úrovni $\alpha \in (0,1)$ je nejmenším číslem y takové pravděpodobnosti $Y = -X$, nepřesahující hodnotu y přinejmenším $1 - \alpha$.

Matematicky lze zapsat, že $VaR_\alpha(X)$ je $(1 - \alpha)$ kvantil Y ³⁴

Mezi analytiky a manažery rizika převládají předpoklady, že špatné události podceňují ztráty, zvláště pokud jsou trhy zavřené nebo nejsou likvidní. Tudíž, se nepřijímají výsledky založené na předpokladech správně definovaného rozdělení pravděpodobnosti (Brown, 2004). Phillipe (2006) uvádí, že velká část akademiků preferuje předpoklad dobře-definovaného³⁵ rozdělení dokonce je obvyklý výskyt s širšími okraji na grafu rozdělení pravděpodobnosti. Tento jev vyvolal značnou diskusi mezi teoretiky, viz. Kolman et al. (1998).

Pearson (2002) uvádí, že v extrémních ekonomických situacích je nemožné determinovat ztráty, neboť v tu chvíli nejsou tržní ceny dostupné. Finanční instituce využívající hodnotu v riziku VaR mohou ztratit dokonce více než teoreticky kalkulovanou hodnotu. Hodnoty teoretické ztráty portfolia je konvenčně pozitivním číslem, i když vyjadřuje potencionální ztrátu. Negativní hodnota VaR může implikovat, že profitabilita takového portfolia je více pravděpodobná Crouhy et al. (2001). Dle autora Wilmott (2007) nepředstavuje výpočet maximální možné potencionální ztráty jen jako číslo samotné, ale jako celý komplexní rámec denní periodické analýzy ztráty na základě průběžného cenového porovnání za daný časových horizont.

Frekventistický přístup je založen na dlouhodobé frekvenci VaR strukturálních zlomů, které jsou rovny pravděpodobnosti limitů chyby v náhodné složce. Z toho vyplývá následně, že zlomy v procesu VaR jsou časově invariantní a nezávislé na samotných úrovních. Na druhé straně přístup na základě Bayesovy pravděpodobnosti je založen na informaci a očekáváních v čase neboli subjektivní pravděpodobnosti zlomů VaR procesu na specifické hladině, viz Crouhy (2001).

³⁴ Předpokládáme, že X má parametrickou distribuci pravděpodobnosti

³⁵ Z anglického well-defined

Dalším z důvodů využití VaR procesu jako metriky je kvůli schopnosti zestručnit rizikovost portfolia do téměř jedné hodnoty. Výhodou je jeho následná porovnatelnost vůči ostatním skupin investic, a to dokonce složených z různých aktiv (Darbyshire, 2016).

Používání metody value at risk je dokonce předmětem jisté kontroverze, jelikož v devadesátých letech tato metoda byla uvedena na veřejnost. Do jisté míry vede tato metoda k falešné významnosti hodnoty potenciální ztráty. Dále můžou firmy kalkulovat s hodnotou přemrštěné ztráty a následným pákovým efektem. Hodnocení se dále zaměřuje jen na sledování průměrné hodnoty rozdělení pravděpodobnosti a vede k ignorování okrajů.³⁶

VaR je maximální ztráta, kterou si finanční instituce či účastník trhu může dovolit ztratit v určitém okamžik nebo za určité období. VaR tedy shrnuje riziko, kterému je portfolio nebo obecně účastník trhu vystaven. Metoda VaR spojuje riziko s určitou finanční hodnotou se stanovenou úrovní statistické pravděpodobnosti. Jak je zřejmé, tato definice VaR je přímo použitelná pro výzkum komoditních cen. Pro analýzu rizika metodou VaR lze použít několik metod.

Tyto metody, které vycházejí z historických ex-post informací, lze rozdělit do tří skupin:

- Historická simulace
- Simulační metoda Monte Carlo
- Variančně – kovarianční metody

V rámci standardního historického přístupu musí být odvozeno empirické rozdělení cena se v období před kalkulací mění. Odhadujeme, portfolia VaR z maximální ztráty v tomto rozdělení, spojené s požadovaný percentil statistické pravděpodobnosti. Stejně tak pro simulační metodu Monte Carlo, empirické rozdělení musí být odvozeny pro změnu cen. Za předpokladu, že musí být vygenerována nějaká série pseudonáhodných proměnných, že dodržují stanovené statistické rozdělení. Komparaci využití jednotlivých metod studoval Kuester et al. (2006)

Jakmile je zvolena metoda pro výpočet metody VaR, je třeba posoudit její vhodnost. Backtesting je běžná metoda pro testování platnosti metody VaR, která spočívá v pohledu do

³⁶ Více viz Taleb (2009)

minulosti a kalkulace, kolikrát byly ztráty a portfolia byly vyšší než hodnota VaR. Teoreticky, pokud má vypočítaná hodnota VaR signifikanci $\alpha = 99 \%$, pak by se mělo nacházet v tomto případě 1 % odlehlých hodnot.

4.6. Spillover efekt

Několik nedávných studií zkoumalo, jak šoky ze zpráv z jednoho mezinárodního akciového trhu ovlivňují proces volatility na jiných trzích. V souladu s tím jsou výnosy akciových trhů citlivé jak na rostoucí, tak na klesající výkyvy. Empirická práce zdokumentovala vzorce zranitelnosti zemí vůči volatilitě a identifikovala možné kanály, kterými se šok přenáší. Obchodní vazby, regionální vzorce a makroekonomické podobnosti činí země zranitelnými vůči volatilitě (Dornbusch, Park a Claessens, 2000). Navíc uvolnění kapitálových kontrol mezi trhy, pokrok v Několic nedávných studií zkoumalo, jak šoky ze zpráv z jednoho mezinárodního akciového trhu ovlivňují proces volatility na jiných trzích. V souladu s tím jsou výnosy akciových trhů citlivé jak na rostoucí, tak na klesající výkyvy. Empirická práce zdokumentovala vzorce zranitelnosti zemí vůči volatilitě a identifikovala možné kanály, kterými se šok přenáší. Obchodní vazby, regionální vzorce a makroekonomické podobnosti činí země zranitelnými vůči volatilitě (Dornbusch, Park a Claessens, 2001). Navíc uvolnění kapitálových kontrol mezi trhy, pokrok v počítačové technologii a rychlejší zpracování zpráv z celého světa zvýšili cenovou volatilitu (Booth, Chowdhury, Martikainen a Tse, 1997). Přelévání volatility, známé také jako nákaza³⁷, obvykle vyplývá z běžné vzájemné závislosti mezi tržními ekonomikami. Tato vzájemná závislost znamená, že otřesy, ať už globální nebo místní povahy, se mohou přenášet napříč zeměmi kvůli jejich finančním vazbám. To znamená, že přelévání volatility nebo nákaza se týká šíření narušení trhu z jedné země do druhé, což je proces pozorovaný prostřednictvím společného pohybu cen akcií, směnných kurzů nebo kapitálových toků.

Vztah mezi volatilitou a rizikem byl jedním z hlavních faktorů zájmu o modelování volatility. Pro investory, spotřebitele a tvůrce politik je tedy důležité dobré pochopení původu a hnacích sil mezi tržní korelace a volatility (Baele, 2005). Aktuální efekt přelití šoků volatility je podle něj přelévání volatility ve stejný den, ke kterému by obecně mohlo dojít na akciových trzích ve stejném regionu s překrývající se dobou obchodování. Informace mezi trhy by tak mohly být přenášeny ve stejný den, kdy stále probíhá obchodování. Na základě těchto informací může investor učinit rozhodnutí, které ovlivní daný kapitálový trh. Přelévání volatility, ke kterému dochází mezi kapitálovými trhy v různých regionech, se nazývá přelévání dynamické volatility. Časový rozdíl obchodování se připisuje od začátku a konce obchodování. Jeden kapitálový trh

³⁷ V ang. Contagion

začíná obchodovat, když je druhý uzavřen nebo téměř v době uzavření obchodování. Proto informace z jednoho kapitálového trhu ovlivní druhý kapitálový trh v další obchodní den, takže k přelévání volatility dochází následující den.

V současné době je výzkum spíše zaměřen na analýzu přelévání volatility na finančních trzích v rozvojových zemích. Kanas (2000) se zabývá efektem přelévání volatility mezi úrokovými mírami a cenou akcie v šesti průmyslových zemích – Spojené státy, Spojené království, Japonsko, Německo, Francie a Kanada. Výsledky tohoto výzkumu ukázaly, že ve všech sledovaných státech, kromě Německa, byl zjištěn statisticky významný efekt přelévání volatility z trhu úrokových měr do akciového trhu, ačkoliv reverzní efekt byl vyloučen. Autoři Sarwar et al., (2020) zkoumali efekty přelévání volatility mezi asijskými akciovými trhy a komoditou ropa. Ve větších státech domácí faktory ovlivňují finanční trhy více než zahraniční faktory. Tím pádem vliv volatility mezi akciovým trhem a trhem měn se stává nevýznamný. Autoři Chang et al. (2009) v empirické studii využil GJR-GARCH model. Jejich výsledky indikovaly výskyt asymetrických prahů a kointegrační vztah mezi akciovými a měnovými trhy. Li et al. (2018) zkoumali efekt přelévání volatility mezi akciovými trhy a úrokovými sazbami v Číně na základě metody vlnové (wavelet) analýzy. V rámci výsledku potvrdili fakt, že v rámci různých časových frekvencí obchodování na těchto trzích dochází pouze ke vztahu jednosměrného efektu přelévání volatility mezi těmito trhy, a to z akciového trhu na trh měnový. Pro výzkum v oblasti přelévání volatility, jak bylo zmíněno v předchozích studiích, je omezeno použití metod pro výzkum. Studie se zaměřovali na kointegrační vztahy, impulse-response analýzu a variačně informační dekompoziční model pro vyšetření efektu přelévání volatility.

V následující tabulce (č.5) jsou představeny studie autorů Diebold, F. X. a Yilmaz, K., kteří jsou průkopníky ve studiu vzájemných relací a efektu přelévání volatility:

Tabulka 5: Přehled studií Diebold a Yilmaz

Autoři	Článek	Cíle, Použité metody, data	Výsledky
Diebold, F.X. and Yilmaz, K. (2009)	<i>Measuring Financial Asset Return and Volatility Spillovers, With Application to Global Equity Markets,</i>	Hodnocení volatility spillovers, VAR model (Engle et al., 2005), dekompozice rozptylu, 19 světových akciových indexů	Přelévání výnosů vykazuje jemný růst, přelévání volatility nevykazuje žádné trend
Yilmaz, K. (2010)	<i>"Return and Volatility Spillovers among the East Asian Equity Markets</i>	Hodnocení vzájemné provázanosti skrze akciové indexy výchovní Asie, VAR model, Forecast error variance decomposition, akciové indexy	Indexy vykazují bouřlivé efekty přelévání na akciových trzích ve východní Asii
Diebold, F.X. and Yilmaz, K. (2011)	<i>"Equity Market Spillovers in the Americas,"</i>	Empirická analýza přelévání výnosů a volatility mezi trhy: Argentina, Brazílie, Chile, Mexiko a Spojené státy, VAR model, 5 akciových indexů	Přelévání volatility vykazuje rychlejší průběh než přelévání výnosů
Diebold, F.X. and Yilmaz, K. (2012)	<i>"Better to Give than to Receive: Forecast-Based Measurement of Volatility Spillovers</i>	Hodnocení metodiky založené na modelu VAR, model VAR, forecast-error variance decomposition, akcie, dluhopisy,	V průběhu krize pozitivní vliv volatility na všech sledovaných trzích. Částečné přelévání volatility z trhu

měnové a komoditní dluhopisů do
trhy na americkém ostatních tržů
trhu

Diebold, F.X. and Yilmaz, K. (2014)	<i>On the Network Topology of Variance Decompositions: Measuring the Connectedness of Financial Firms"</i>	Analýza propojení finančními dekompozice rozptylu, akciové trhy USA	tržních mezi trhy, vážené a přímé sítě a propojenost mezi finančními trhy v USA	Dekompozice rozptylu definuje propojenost mezi finančními trhy v USA
Diebold, F.X. and Yilmaz, K. (2016)	<i>Trans-Atlantic Equity Volatility Connectedness: U.S. and European Financial Institutions, 2004-2014</i>	Charakteristika volatility kapitálových výnosů a jejich propojenosti v síti hlavních amerických evropských finančních institucí, dekompozice rozptylu, data z institucí	Během let 2007 až 2008 byl směr propojenosti čistě ze USA do Evropy, ale propojenost tržů se stala v roce 2008 dvou-směrová	
Cotter, J., Hallam, M. and Yilmaz, K. (2017)	<i>"Mixed-Frequency Macro-Financial Spillovers</i>	Vývoj nové metodiky, mixed-frequency modelování, agregace, makroekonomická data	Vysokofrekvenční informace je zachována při využití mixed-frekvenčního přístupu	
Demirer, M., Gokcen U. and Yilmaz, K. (2018)	<i>Financial Sector Volatility Connectedness and Equity Returns</i>	Konstrukce indexu propojenosti volatility, Diebold Yilmaz (2014) metodika,	Statisticky významný podíl rozdílu mezi výnosy firem s pozitivním a negativním	

			finančních institucí z USA	přístupem k finanční propojenosti
Demirer, M., Diebold, F. X., Liu, L. and Yilmaz, K. (2018)	<i>Estimating Global Bank Network Connectedness</i>	Analýza dimenzovaných sítí mezi veřejně obchodovatelnými světovými bankami, LASSO metoda, kapitál bank	Ze statického hlediska má světový bankovní kapitál silnou propojenost v rámci lokality. Z dynamického hlediska tržní propojenost roste během finančních krizí	
Uluceviz, E. and Yilmaz, K. (2018)	<i>Measuring Real-Financial Connectedness in the U.S. Economy</i>	Analýza propojenosti mezi reálným a finančním sektorem americké ekonomiky, ADS index, sektorová data	Finanční trhy generují pozitivně čistou propojenost reálné ekonomiky	
Bilgin, N. M. and Yilmaz, K. (2018)	<i>Producer Price Inflation Connectedness and Input-Output Networks</i>	Analýza transmise produkčních cen, Diebold-Yilmaz index propojenosti, Input-output analýza, Granger kauzalita, ceny výrobců USA	Input-output a inflace jsou silně propojené během hlavních šoků na straně nabídky	
Uluceviz, E. and Yilmaz, K. (2020)	<i>"Measuring Real-Financial Connectedness in the Swiss Economy</i>	Makroekonomické propojení švýcarské ekonomiky, KOF barometer, RAI (index reálné aktivity)	V letech 2008 až 2009 během recese byly šoky transformovány do celé ekonomiky	
Bostanci, G., and Yilmaz, K. (2020)	<i>How Connected is the Global Sovereign</i>	Odhad světové sítě struktury kreditního	Úroveň kreditního rizika a propojenosti	

	<i>Credit Network?"</i>	<i>Risk</i>	rizika, Yilmaz akciové data	Diebold- metodika, a měnové	je vysoká, a je porovnatelná s propojením akciového a měnového trhu
Diebold, F. X. and Yilmaz, K. (2013)	<i>Measuring the Dynamics of Global Business Cycle Connectedness</i>	<i>the</i>	Analýza reálných výstupů pro 6 rozvinutých zemí, rámec měření propojenosti, USA, Francie, Německo, Japonsko, Spojené království, Itálie	reálných propojenosti rozvinutých tržního cyklu. měření propojenosti, USA, Francie, Německo, Spojené státy a Japonska do	Světová propojenost je různorodá v rámci tržního cyklu. Propojenost také koresponduje s transmisí ze Spojených států a Japonska do ostatních států

Zdroj: Vlastní zpracování

Když zhodnotíme výzkum autorů Diebold a Yilmaz, tak můžeme pozorovat, že efekty přelévání cenové volatility jsou použitelné v různých oblastech ekonomické a finanční analýzy. Pro empirickou aplikaci rámcových metod vytvořených autory jsou použity data jak z makroekonomických časových řad, tak datové základny kapitálových a finančních trhů. Nejpoužívanější metodou je analýza pomocí modelu stochastických procesů Vektorové autoregrese (VAR model), rozkladem rozptylů a dynamickou analýzou pomocí metody impulse-response. Výsledky mají uplatnění jak v rozličných oblastech.

4.7. Literární přehled empirických studií o analýze stochastické volatility

V období počátku finanční krize v roce 2008 mnoho autorů diskutovalo na téma cenové variability komodit (Abbot et al., 2008, Mitchell 2008). Nejčastějšími faktory jsou změny na straně nabídky a poptávky. Na poptávkové straně je především rychlý ekonomický růst v asijských státech jako například Čína. Na nabídkové straně jsou naopak faktory v podfinancování investic v zemědělství nebo malé zásoby komodit z minulých let. Tyto studie zjistily však nový faktor ovlivňující cenu zemědělských komodit, a to vzrůstající produkci biopaliv a většímu využití některých zemědělských plodin na jejich výrobu. Autoři Gilbert a Morgan (2010) zdůraznili roli spekulace pomocí derivátových kontraktů na trhu zemědělských produktů. Cenová volatilita komodit může mít na makroekonomické úrovni vliv významný růst chudoby, což je velmi rizikový faktor pro chudší státy. Obecně je tudíž nutnost znalost problematiky cenové volatility z důvodu pomoci při tvoření adekvátních politik a případné tvorby potravinové politiky.

Obecně, ceny potravin jsou citlivé na politické téma a je tedy nepřekvapující, že světové vlády a skupina G20 každoročně projednávají problematiku růstu cenové dynamiky potravin. Dle autorů Martin a Anderson (2012) jsou však tyto opatření je částečně účinná. Z toho vychází, že rostoucí integrace lokálních zemědělských trhů do světových celků či do finančních nástrojů přináší velkou nejistotu ohledně budoucnosti cenového vývoje. Tradiční fundamentální aspekty ovlivňující nabídku a poptávku na zemědělsko-potravinářském trhu mají v tomto případě malou vysvětlující sílu. Cenový vývoj komodit prošel v minulé dekádě nespočet strukturálních šoků a neočekávatelnými vlivy, které je třeba nutně řešit.

Modelování volatility ve finančních časových řadách je předmětem velké pozornosti již od zavedení modelu autoregresivní podmíněné heteroskedasticity (ARCH)³⁸ ve výzkum Engel (1982). Poté však byla velká část této literatury věnována jednorozměrným modelům (Bollerslev, Chou a Kroner, 1992). Zatímco ekonomická integrace mezinárodních trhů se stala jasnou věcí, naopak vztahy mezi volatilitou různých trhů se staly středem zájmu. Bauwens, Laurent a Rombouts (2006) nabízejí několik otázek, které jsou:

³⁸ Autoregressive conditional heteroscedasticity

Vede volatilita velkého trhu k volatilitě ostatních trhů? Přenáší volatilita aktiva na jiné aktivum prostřednictvím jeho podmíněného rozptylu přímo nebo nepřímo prostřednictvím jeho podmíněné kovariance?

Zvyšují inovace nebo šoky z jednoho trhu volatilitu na jiném trhu? Jsou dopady stejné pro negativní a pozitivní šoky?

K zodpovězení těchto otázek byl v literatuře široce používán multivariační model GARCH³⁹ (MGARCH)⁴⁰. Řada výzkumníků studovala integraci akciového trhu mezi rozvinutými zeměmi. Theodossiou a Lee (1993) zkoumají povahu a míru vzájemné závislosti akciových trhů v USA, Japonsku, Velké Británii, Kanadě a Německu pomocí multivariačního GARCH modelu a zjišťují, že na akciových trzích existují statisticky významné přelévání volatilitu z USA na jiné akciové trhy. Karolyi (1995) poskytuje další pohled na krátkodobou dynamiku výnosů a volatilitu mezi americkými a kanadskými akciovými trhy, ale nachází pouze slabé mezi tržní propojení ve výnosech a volatilitě mezi americkými a kanadskými akciovými trhy. Bae a Andrew Karolyi (1994) se zaměřují na společnou dynamiku volatilitu pro japonské a americké akciové trhy v letech 1988 až 1992. Rozšiřují také model GARCH, aby umožnil asymetrické efekty „nežádoucích zpráv“ z mezinárodních trhů.

Většinou výzkum v oblasti přelévání volatilitu je zaměřená na trhy rozvinutých zemí. Kanas (2000) se zabýval výzkumem efektu přelévání volatilitu v oblasti úrokových sazeb a akciového trhu ve vybraných státech – USA, Velká Británie, Japonsko, Německo, Francie a Kanada. Výzkum ukázal, že oproti Německu je statisticky významný efekt přelévání cenové fluktuace v rámci devizového trhu. Chang (2009) se zabýval empirickou studií v oblasti přelévání cenové volatilitu na devizovém a akciovém trhu s využitím modelu GJR-GARCH. Jejich výsledky podpořili hypotézu o kointegračním vztahu mezi těmito trhy. Mnoho autorů se zaměřovalo pouze na vztah mezi akciovým a devizovým trhem. Barbaglia et al. (2020) v nedávné studii řešili vztah mezi zemědělskými komoditami, biopalivy a energetickými komoditami. Datovou základnu zahrnovalo období v letech 2012-2016. Výsledky potvrzují přítomnost efektu přelévání cenové volatilitu mezi komoditami.

Singh et al. (2010) odhadli efekty přelévání volatilitu na 15 akciových trhů v období let 2000 až 2008. Jejich model efektů přelévání volatilitu je založen na rozšířeném AR-GARCH modelu

³⁹ Generalized autoregressive conditional heteroscedasticity

⁴⁰ Multivariační GARCH model

reziduí VAR modelu, viz Bollerslev (1986). V první fázi byl proveden odhad VAR modelu pro všech 15 trhů. Následně byl proveden odhad zvlášť pro každý index AR-GARCH modelu s rozšířením GARCH modelu o rezidua VAR analýzy. Na základě výsledků analýzy exogenní proměnné reprezentují inovace z ostatních trhů v rámci přelévání volatilit. Výsledky analýzy potvrdily silný efekt přelévání volatilit z asijského finančního trhu do trhu evropského a amerického.

Koutmos a Booth (1995) zkoumají vedlejší efekty mezi akciovými trhy v New Yorku, Tokiu a Londýně. Výsledky výzkumu ukázaly, že je přenos volatilit asymetrický a je výraznější v případě špatných zpráv z americké či britského trhu. Kanas (2000) studuje přenosové efekty mezi londýnskými, pařížskými a frankfurtskými akciovými trhy a dochází k závěru, že výnosy a přelévání inovací jsou v době po krachu vyšší. Billio a Pelizzon (2003) zjistili, že přelévání volatilit z výnosů světových indexů se zvýšilo po zavedení EMU (Evropské měnové unie) pro většinu evropských akciových trhů. Christiansen (2007) zkoumá přelévání volatilit z USA a agregovaných evropských trhů aktiv na evropské národní trhy aktiv s inovací začleněním trhů dluhopisů do analýzy.

Hamao, Masulis a Ng (1990) se zabývali přelévání volatilit výnosů akciových trhů v USA a Japonsku, kde zjistili fakt, že existuje přelévání volatilit převážně z newyorského akciového trhu na tokijský akciový trh. Na rozdíl od výsledků většiny studií autoři Lin, Engle a Ito (1994) zjistili, že trhy v New Yorku a Tokiu zažívají pozitivní a významné přelévání volatilit z jiných trhů. Bylo potvrzeno, že mezi zeměmi existuje vzájemná závislost na výnosech a volatilitě. Bekaert a Harvey (1997) zkoumali volatilitu návratnosti na asijských, středomořských a latinskoamerických trzích. První studie zkoumá síly, které určují, proč je volatilita na různých rozvíjejících se trzích odlišná. Autoři výzkumu, že otevřenější ekonomiky v rámci mezinárodního obchodu mají výrazně nižší volatilitu. Jejich výsledky navíc naznačují, že volatilita je silně ovlivněna světovými faktory na plně integrovaných trzích, zatímco na segmentovaných kapitálových trzích je spíše ovlivněna lokálními faktory.

V nedávné minulosti četné výzkumy přinášely poznatky, že spekulativní aktivity na trzích zemědělských komodit a komodit ropy, pomohly usnadnit integraci mezi těmito trhy. Tadesse a kol. (2014) tvrdili, že spekulace jsou endogenním faktorem při určování volatilit cen komodit. Dle Trostleho et al. (2011) vztah mezi rostoucími cenami plodin a ukazuje rostoucí podíl dlouhých pozic držných nekomerčními investory obecnou korelaci, ale nemusí nutně naznačovat žádné kauzální účinky. Gilbert (2010), Gilbert a Morgan (2010) a Irwin a Sanders

(2011) našli omezené důkazy o tom, že spekulace hrají roli při oceňování zemědělských komodit chování.

Nazlioglu et al. (2013) zkoumají transmisi volatility mezi ropou a vybranými zemědělskými komoditami. Ve studii jsou využita denní data od roku 1986 do roku 2011. Výsledky ukazují, že není důkaz efektu přelévání volatility mezi trhem ropy a zemědělskými komoditami před potravinovou krizí.

Na poli studie volatility v rámci vlnové analýzy. Tento koncept je relativně nový a nemá dostatek aplikací v ekonomickém výzkumu v komparaci s tradičními metodami analýzy volatility.

Autoři Jense a Whitcher (2014) zkoumali efekty na trh měnových párů prostřednictvím nestacionárního modelu. Během dlouhého období má proces volatility dlouhou paměť.

Shik Lee (2004) zkoumal světové transmise přelévání na akciových trzích v rámci cen a výnosů. Pro analýzu integrace akciových trhů byla použita metoda vlnové koherence. Jako rozšíření tradiční vlnové koherence byla také využita nová metoda analýzy efektů přelévání na bázi diskrétní vlnové transformace. Tato metoda je lépe aplikovatelná pro zachycení časově variačního procesu. Výsledky přináší zjištění, že existuje důkaz o přenosu šoků volatility ze strany cen indexu Dow Jones na Korejský akciový trh. Tento vztah však nefunguje v opačném směru.

Boubaker a Raza (2017) vyšetřovali přelévání volatility mezi trhem ropy a zeměmi skupiny BRICS. Metody použité k tomuto výzkumu zahrnovaly vlnovou vícerozměrnou metodu s užitím modelu VARMA-GARCH-DCC. Výsledky přinesly důkazy, že cenové procesy lze dekomponovat do více částečných efektů přelévání volatility.

Tiwari et al. (2019) zkoumali ekonomickou a politickou neurčitost a na druhé straně tržní volatilitu. Pro analýzu využili proměnné EPU (index ekonomické a politické neurčitosti) a index volatility VIX a následně metodu založenou na vlnové analýze. Výsledky přinesli zjištění, že mezi indexem volatility VIX a EPU existuje časově variační vztah, které není po většinu času pozitivní.

Ahmed (2022) analyzoval časově frekvenční vztahy mezi trhem dluhopisů a komoditním trhem. Cílem výzkumu byla analýza vzájemných závislostí ve smyslu více momentové

statistické analýzy. Výsledky indikují, že společné pohyby struktur stejných momentů dluhopisů, zlata a energetických komodit vedou k časové a frekvenční závislosti.

Bouri et al. (2020) zkoumali ceny kryptoměn, zlata a komodit jako možnost benefitu bezpečných přístavů. Pro analýzu využili vlnovou koherenci a hodnocení diverzifikace prostřednictvím metody Value at Risk. Bitcoin, zlato, komodity a akcie jsou slabě závislé na různých škálách. Výhoda aspektu diverzifikace kolísá v časově frekvenčním horizontu. Bitcoin představuje nejméně závislou kryptoměnu s výrazným benefitem výkonnosti a použitelností jako bezpečný přístav než komodita zlato.

Autoři Gülerce a Ünal (2016) zkoumali společné pohyby cen energetických komodit. V rámci analýzy dynamických korelací mezi komoditami Crude Oil, ropa Brent, topný olej a elektřina. Pro zjištění vztahů mezi komoditami je použita metoda částečné vlnové koherence (PWC). Výsledky potvrdili významné vztahy mezi proměnnými.

Choi (2020) ve svém výzkumu zkoumala vliv ekonomické neurčitosti, která byla způsobena rozšířením pandemie COVID-19 na odvětví ekonomiky ve Spojených státech. Pro vyšetření vlivu byla použita metoda vlnové koherence a proměnné EPU (ekonomická a politická neurčitost) a měsíční sektorové volatility prostřednictvím indexu S&P 500 (Standard and Poor). Výsledky indikovaly zástupný vliv pandemie COVID-19 na všechny odvětví amerického akciového trhu. Nejvýznamnější vliv měla pandemie na odvětví strojírenství než na ostatní sektory.

5 Empirická část

Empirická část této práce se skládá z několika subkapitol – analýza dat, vlnová koherence a fázová diference, částečná vlnová koherence, determinace režimů volatilit s využitím modelu HMM a efekt přelévání volatilit prostřednictvím modelu TVP-VAR. Před následnou samotnou empirickou částí je provedena analýza dat prostřednictvím korelační matice, popisné statistiky a testování stacionarity. V závěru jednotlivých sub-kapitol je provedena diskuse výsledků s komparací ostatních výsledků.

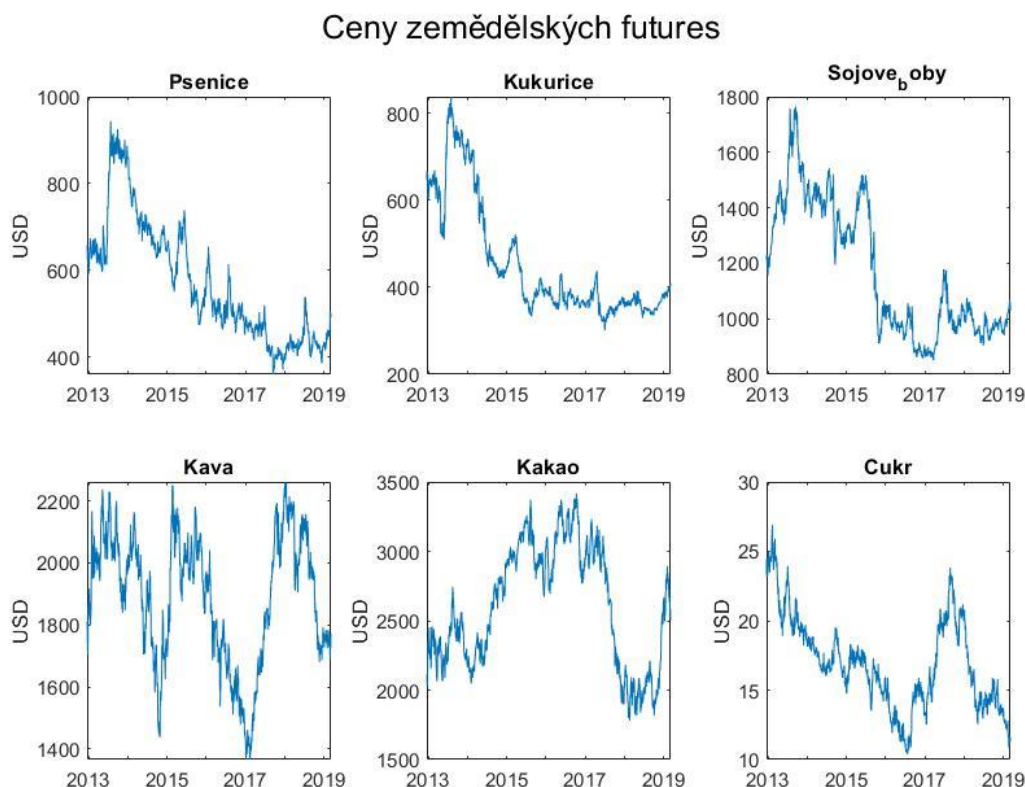
5.1. Analýza dat

Na základě grafické analýzy sledovaných zemědělských komodit jsou zobrazeny výnosy⁴¹ komoditních futures, obrázek č. 3–8. Všechny sledované komodity dle grafické analýzy vykazují vyšší volatilitu během let 2012 až 2020. U pšenice došlo k významným výkyvům v letech 2014, 2016 a 2017. Ostatní komodity jmenovitě kukuřice, sójové boby a cukr byly ovlivněny v rámci fluktuací v roce 2020. Na začátku sledovaného období v roce 2012 nastal nejvyšší růst u cen komodit pšenice, kukuřice a sójových bobů z důvodů počasí ve Spojených státech. Predikce výnosů sklizně z roku 2013 měla vliv na pokles ceny obilí, zvláště pšenice. Na začátku období nastal cenový růst u komodit sójové boby a kukuřice z důvodů predikce zlepšení počasí. V roce 2014 došlo k cenovému šoku u obilnin, kdy byl zahájen konflikt na Ukrajině. Vliv počasí na výnosy v tomto roce měl pozitivní vliv. V druhé polovině sledované období mělo vliv na obilniny počasí, např. sucha v Jižní Americe a Austrálii. Cena cukru rostla z důvodu posilujícího kurzu Brazílského reálu.

Koncem období, a zvláště v roce 2018 ceny zemědělských komodit stagnovaly, a to hlavně vlivem rostoucí světové produkci a světovým zásobám. Na konci období kolem roku 2020 se dostaly světové finanční trhy do tlaku v souvislosti s omezeními v rámci pandemie Covid-19. Na všech trzích v tu dobu začala panovat nejistota a rostoucí efekt spekulací.

⁴¹ Změna ceny v %

Graf 2: Ceny zemědělských komodit




Zdroj: Vlastní zpracování, program Matlab

Na grafu č. 2 jsou zobrazeny časové řady futures cen zemědělských komodit, nejvyšší výkyvy nastaly u komodit kávy a kakaa. Zde došlo k pohybům v rámci rozšířeného cenového pásma. Obě komodity z grafické analýzy se pohybují protichůdně čili inverzně. Komodita sójové boby v rámci cenové dynamiky kopíruje v pohybu na úrovni ceny kávy. Cenový vývoj ve sledovaném období u komodit pšenice a kukuřice ukazuje vzájemný společný kopírující pohyb. Tyto komodity jsou z hlediska nezastupitelných vlastností jako velké objemy obchodů na zemědělských burzách vysoce významné.

Následují grafy změny ceny proměnných v % ve sledovaném období.


Obrázek 3: Změna ceny pšenice v %




Obrázek 4: Změna ceny kukuřice v %




Obrázek 5: Změna ceny sójové boby v %




Obrázek 6: Změna ceny káva v %



Obrázek 7: Změna ceny kakao v %



Obrázek 8: Změna ceny cukr v %



Zdroj: Gretl

Tab. č. 6 zobrazuje hodnoty popisných statistik mezi komoditními futures. Nejvyšší hodnoty odchylky dosahuje komodita kakao. Naopak komoditou s nejmenší směrodatnou odchylkou lze řadit kukuřici a pšenici. Nejvyšší odchylku měla komodita cukr v hodnotě až 3500. Nejvyšších hodnot relativní změny ceny po celé sledované období má komodita káva, kde výkyvy dosahují až 12 %. Komodity kukuřice a kakao měli jednorázové výkyvy způsobené náhlým šokem.

Tabulka 6: Popisné statistiky

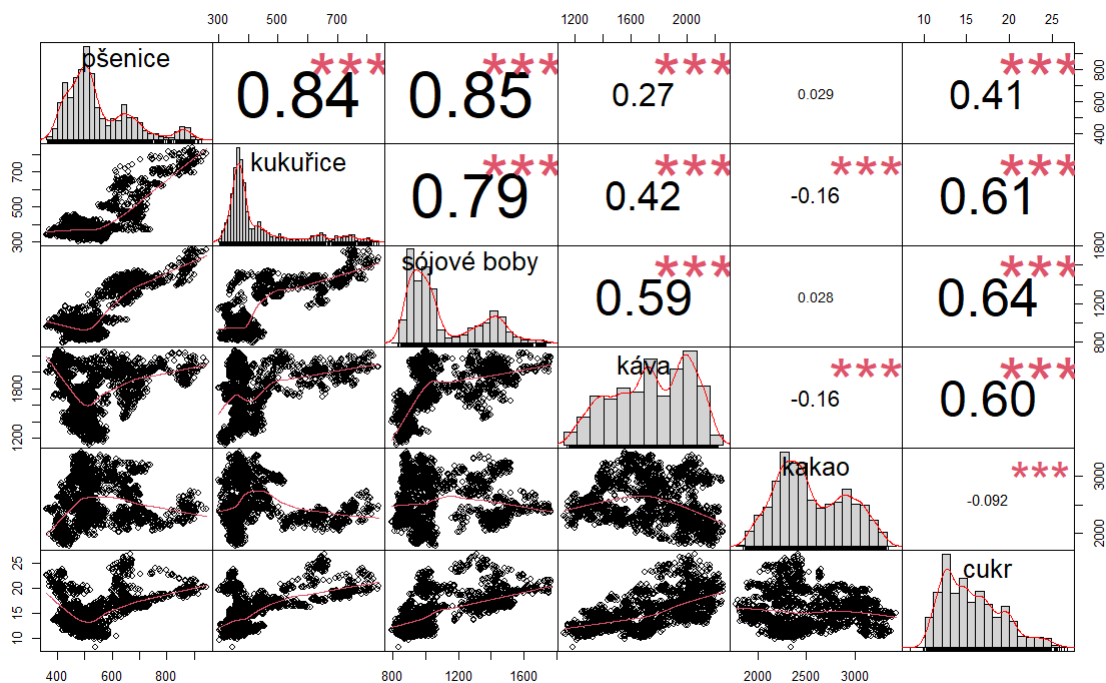
Popisná statistika, za použití pozorování 2012-01-03 - 2020-31-12						
<i>Proměnná</i>	<i>Sřřední hodnota</i>	<i>Medián</i>	<i>S.D.</i>	<i>Min</i>	<i>Max</i>	
pšenice	553,6	516,8	122	361	943,9	
kukuřice	430,3	378,2	120,4	301,5	838,8	
sójové boby	1093	989,8	238,7	791	1765	
káva	1756,4	1762	285,5	1121	2261	
kakao	2545	2462	386,6	1780	3417	
cukr	15,61	14,91	3,508	8,18	26,9	

Zdroj: Vlastní výpočty

Obr. č. 9 zobrazuje korelační koeficienty s hladinami významnosti a rozdělení pravděpodobnosti komoditních cen. Na diagonále se nacházejí kernel⁴² rozdělení pravděpodobnosti všech sledovaných komoditních futures. Lze pozorovat, že žádný data generující proces nedosahuje čistě gausovského rozdělení pravděpodobnosti. U komodity kukuřice je zřetelný dlouhý konec pravého rozdělení dat. V pravé části tabulky na diagonálou se nacházejí korelační koeficienty dle Pearsona se zobrazením hladiny významnosti. Nejvyšší hodnoty (0,85) korelačního koeficientu dosahují komodity pšenice a sójové boby. Dalšími komoditami, které jsou silně korelované, jsou pšenice a kukuřice (0,84) a sójové boby a kukuřice (0,79). Ostatní korelační vztahy jsou sice významné, ale mají slabší korelační vztah. Na spodní straně diagonály levé části tabulky jsou zobrazeny hodnoty korelačního diagramu dvou komodit.

⁴² Neparаметrická metoda sloužící k vyhlazení jádra pro odhad hustoty pravděpodobnosti.

Obrázek 9: Analýza korelací a pravděpodobnostního rozdělení



Zdroj: Vlastní výpočty, R Studio, Poznámka: p-hodnoty (0, 0.001, 0.01, 0.05, 0.1, 1) <=> symboly (“***”, “**”, “*”, “.”)

5.1.1. Testování jednotkového kořene

Pro zjištění přítomnosti jednotkového kořenu v datech jsou využity testy Augmented Dickey Fuller a Phillip – Peron. Haug (2003) hodnotí užití testu Dickey-Fuller zvláště pozitivně v oblasti síly a stability testování na jednotkový kořen v datech. Phillip – Peron test je na druhé straně vhodný na agregovaná data a na vysokofrekvenční časové řady na rozdíl od běžně užívaného testu ADF (Choi, 1992). Z důvodů rozdílných náhledů a přístupů na jednotlivé testy jsou použity oba zmiňované. Výsledky testů pro zjištění přítomnosti jednotkových kořenů ve sledovaných komoditních cenách jsou zobrazeny v tabulce č. 3. Časové řady jsou u všech sledovaných komoditních cen nestacionární, tudíž obsahují jednotkový kořen. Jejich logaritmické výnosy jsou již stacionární.

Provedení testování na stacionaritu časových řad není však vyžadováno pro vlnovou analýzu v časově – frekvenční oblasti a DWT, (Aguilar-Conraria, et al., 2008), nicméně pro další analýzy je toto testování provedeno.

Tabulka 7: Testování jednotkového kořene

Komodita	Test na jednotkový kořen	Testovací statistika
Pšenice	ADF	-47.7303*
	PP	-47.7428*
Kukuřice	ADF	-53.6819*
	PP	-54.0621*
Sójové boby	ADF	-46.5939*
	PP	-46.5982*
Kakao	ADF	-49.0617*
	PP	-49.0569*
Káva	ADF	-49.7318*
	PP	-49.6960*
Cukr	ADF	-2.6376***
	PP	-2.5845***

Poznámka: *, **, *** určují hodnoty významnosti pro úrovně 1 %, 5 % a 10 % respektive

Koncept vlnové analýzy má výhodu v užití nestacionárních dat, které představují ve většině případů vysokofrekvenční finanční časové řady. V tomto případě zde nedochází ke ztrátě informací v datech.

5.2. Diskrétní vlnová transformace (DWT)

Následující sub-kapitola obsahuje výsledky analýzy diskrétní vlnové transformace cenových procesů zemědělských komoditních futures.

Výsledky této sub-kapitoly zodpovídá následující výzkumné podotázky:


- Lze dekomponovat časové řady komoditních cen do nižších škál?
- Jaká komodita vykazuje nejvyšší kolísání vysokofrekvenční volatility?
- Existují u komodit společné cenové sezónní vzorce?

V rámci DWT analýzy jsou dekomponovány časové řady do tří časových škál: d_1 , d_2 a d_3 z důvodu zachycení kratších časových intervalů. Komponent d_1 odpovídá dvěma dnům, komponent d_2 představuje v rámci časové škály 4 dny (odpovídající přibližně obchodnímu týdnu) a d_3 zachycuje kolísání signálu v rozmezí 8 dnů (odpovídající 2 obchodním týdnům, nebo polovině měsíce, respektive).

Komponent d_1 s nejvyšší frekvencí zachycuje krátkodobé kolísání komoditních cen vlivem cenových šoků (transitní efekt), které nastávají v intervalu 2 obchodních dnů. Další komponenty d_2 a d_3 zobrazují v rámci zobrazení viz Obrázek č. 10-13 působení nižších frekvencí na cenové fluktuace (v dlouhém období s permanentním efektem).

Odhady jsou provedeny prostřednictvím funkce Wavelet analyzer v programu MATLAB.

Obrázek 10: DWT – Pšenice




Zdroj: Matlab

Obr. č. 10 zobrazuje dekompozici do třech úrovní ceny pšenice. Nejvyšší kolísavosti v rámci vysokofrekvenční volatility dosahovala cena na začátku sledovaného období v roce 2012, kdy byla během dvou obchodních dnů na trzích pšenice detekována nejvyšší kolísavost. V porovnání s obr. č. 11 docházelo u komodity kukuřice ke stejným krátkodobým cenovým výkyvům přibližně na začátku sledovaného období, tj. v roce 2012. Komponent d_1 již vykazoval období nižší cenové volatility. Nicméně hodnoty v rámci vysokofrekvenčního rozkladu cenového procesu u komodity kukuřice nepřesáhly 5. Větších hodnot volatility dosahovala pšenice, kde během periody čtyřech obchodních dnů přesáhla kolísavost hodnotu 20.

V případě komodity kukuřice velké výkyvy dekomponované na nejnižší období 2-4 obchodních dnů jsou zachyceny významné změny v cenové fluktuaci. Úroveň rozkladu d_1 zachycuje vyšší dynamiku cenových změn v období po finanční krize, tj. po roce 2012.

Obrázek 11: DWT – Kukuřice




Zdroj: Matlab

Na následujícím obr. č 12 je zobrazena dekompozice u komodity sójové boby. Zvláště v první polovině sledovaného období, tj. do roku 2016 zde docházelo k pravidelným vyšším cenovým fluktuacím ve vysokofrekvenčním zobrazení dvou obchodních dnů. Během první poloviny zkoumaného období zde docházelo k výkyvům i 20 avšak spíše z krátkodobého hlediska. V druhé polovině období od roku 2016 docházelo ke klidnějším cenovým výkyvům (úroveň d_2 a d_3).


Po skončení finanční krize komodita sójové boby se chovala v nejvyšších frekvencích na úrovních 2-4 obchodních dnů velmi kolísavě. Zvýšená volatilita se promítla i do nižších frekvencích až do úrovně d_3 .

Obrázek 12: DWT – Sójové boby



Zdroj: Matlab

Obrázek 13: DWT – Kakao




Zdroj: Matlab

Obr. č. 13 zobrazuje dekompozice na frekvenční úrovně u komodity kakao. Vysokofrekvenční analýza v rámci dvou obchodních dnů vykazuje stabilní kolísání volatility. Ke konci

sledovaného období došlo k extrémnímu výkyvu. Tento výkyv může být způsoben zvýšenou spekulací aktivitou nebo chybou v časové řadě. Avšak náhlý výkyv byl absorbován na nižších frekvencích, a to přibližně od 2 obchodních týdnů.

Obrázek 14: DWT – káva




Zdroj: Matlab

Na obr. č. 14 je zobrazena dekompozice u komodity káva. Na úrovni d_1 je evidentní kolísání ve zvýšených hodnotách kolem 20. Komodita káva je více ovlivněna na dvoudenní bázi zvýšenou cenovou volatilitou. Permanentní zvýšené kolísání na vyšších frekvencích by mohlo být využito pro obchodníky strategie scalping, kdy je využívána vyšší volatilita ceny. Další možností je využití při krátkodobých (swingových) obchodech.

Období zvýšené cenové fluktuace zvláště v nejvyšších frekvencích na úrovni dvou obchodních dnů je zachycen po celou délku periody. Při porovnání se samotnou cenou dekompozice signálu na úrovni d_1 přináší velkou volatilitu při dlouhotrvajících trendech na ceně komodity, v případě poklesu nebo růstu ceny.

Obrázek 15: DWT – Cukr



Zdroj: Matlab

Obr. č. 15 zobrazuje dekompozice cenového procesu u komodity cukru. V případě sledovaného období lze pozorovat menší cenovou volatilitu do hodnot 0,5, velmi výjimečně do hodnoty 1. Avšak jsou zde patrné větší cenové výkyvy na konci sledovaného období. Cukr by mohl být zasažen postupným pronikáním externích faktorů, během začátku pandemie Covid-19, do ceny a způsobit její zvýšenou kolísavost.

V rámci DWT analýzy všech cenových procesů v rámci obchodních dnů po celé období lze konstatovat, že největší cenové volatility nastávají na vyšších frekvencích v krátkém období. Všechny sledované komodity vykazují tranzitní efekt (přítomnost cenových šoků na úrovních komponentů d_1 a d_2). V případě komodit pšenice, kukuřice a sójových bobů došlo na začátku období v roce 2012–2013 k výrazné detekci fenoménu shlukování volatility.⁴³ Na vyšších frekvencích v případě komponentů d_1 a d_2 zahrnující obchodní týden pro komoditní futures dochází k tranzitnímu efektu zvláště u pšenice, kukuřice, kakaa a kávy po celé období. Cenový proces kávy je na základě analýzy DWT identifikován jako nejvíce volatilní po celé sledované období.

⁴³ Velké změny fluktuace způsobují pokračování těchto velkých změn, Mandelbrot (1963)

Významné strukturální zlomy jsou detekovány na úrovni nižších frekvencí v rámci globálního efektu mezi komoditami pšenice, kukuřice a cukr. V krátkém období (vyšších frekvencí) u všech komodit je obtížné provést cenovou predikovatelnost. Ke stejnému zjištění došli autoři Yang et al. (2016), kteří ve svém výzkumu potvrdili výhodu užití střednědobých nebo dlouhodobých period. Na vyšších frekvencích je patrná větší korelace komodit. Na základě provedené DWT analýzy existuje nejvíce podobných vzorců cenových pohybů u komodit pšenice a kukuřice, zvláště v období dvou obchodních dnů. Komodita cukr byla nejvíce zasažena začátkem a průběhem pandemie Covid-19 během roku 2020.

V případě komodit, u kterých došlo v nejvyšších frekvencích v rámci 2 obchodních dnů, je možné jejich využití při tvorbě spekulativních strategií. Nicméně zvýšené cenové volatility přináší i významné riziko.

5.3. Vlnová koherence

V této subkapitole jsou prezentovány výsledky získané skrze komplexní vlnovou analýzu, jmenovitě vlnovou koherenci, fázovou diferenci, vlnové spektrum a vlnovou entropii. Nejprve budou vyšetřovány vztahy mezi jednotlivými komoditními futures a následně bude provedena komparace mezi cenovým chováním a volatilitami. V dalším kroku bude zjištěna vhodnost časové řady mezi sledovanými komoditami pro prediktivní účely.

Výsledky této kapitoly zodpoví výzkumné otázky vztahující se k této oblasti:


- Existuje mezi sledovanými komoditami kauzalita a vzájemná propojenost prostřednictvím společných pohybů?
- Jaká je hodnota vlnové koherence mezi komoditami?
- Je relace mezi cenami komoditních futures a volatilitou cyklická či anticyklická?
- Je mezi sledovanými komoditami pozitivní nebo negativní cenový vztah?⁴⁴

Výstupem vlnové koherence je graf, který je rozdělen kónickou křivkou zobrazující oblast kónické influence⁴⁵. V oblasti kónické influence jsou hodnoty odhadu vlnové koherence významné na hladině 5 %. Oblast influence je důležitá z hlediska detekce hraničních efektů, které vznikají v důsledku omezeného rozsahu časové řady. Aguiar-Conraria a Soares (2011) připomínají důležitost správné a pečlivé detekce těchto hraničních oblastí v grafu kónické influence. Území kónické influence je značně zkresleno, neboť časové řady představují konečný omezený počet pozorování. Právě tyto hraniční efekty jsou ovlivněny detekcí vlnových režimů vně kónické influence.

⁴⁴ Vlnová analýza v rámci dekompozice na frekvenční a časovou oblast je schopna detekovat dlouhodobé a krátkodobé vztahy mezi proměnnými, více viz Torrence a Compo, 1998).

⁴⁵ Cone of influence (Col)

Obrázek 16: Vlnová koherence – kukuřice a pšenice



Zdroj: vlastní výpočty, R Studio

Obrázek č. 16 zobrazuje vlnovou koherenci mezi futures cenou pšenice a kukuřice. Mezi danými proměnnými existuje anticyklický vztah v letech 2017 až 2019. Cena kukuřice je zpožděná proměnná mezi těmito roky. Je potvrzen vztah koherence na vyšší úrovních 64–120 s vlivem kukuřice na pšenici.⁴⁶ Na začátku sledovaného období je prokázán vztah společného pohybu obou komodit, avšak vzájemná závislost poté vymizela. Na nižších škálách není potvrzen vzájemný vztah.

Je zjištěním, že obě sledované komodity jsou od roku 2014 do 2020 propojené vzájemnou souvislostí. Na vyšších vlnových pohybech je sledovaný vztah na hranici cyklického a anticyklického vztahu (2014–2016). V tomto případě není jasné, která komodita může ovlivnit cenu druhé a naopak. Pro dlouhodobé investory, kteří by se měli držet strategie buy and hold⁴⁷, nejsou tyto komodity vhodné.

Od roku 2018 až do konce období, tj. v roce 2020 lze pozorovat mezi pšenicí a kukuřicí anticyklický vztah, tudíž mezi proměnnými je detekována negativní koherence. Lze konstatovat, že mezi komoditami pšenicí a kukuřicí za sledované období docházelo k různými

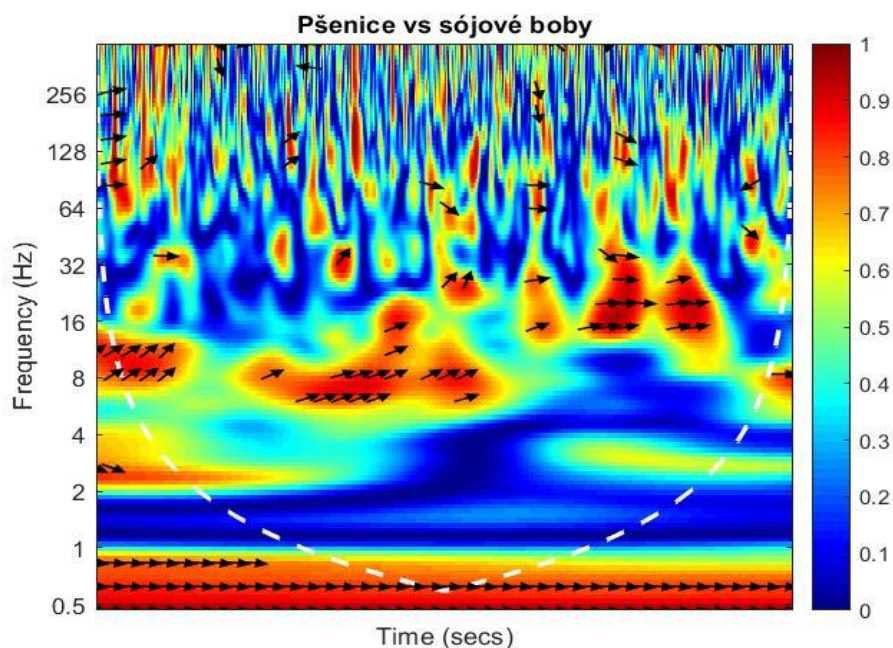
⁴⁶ Pšenice představuje lag proměnnou

⁴⁷ Buy and hold – obch. strategie spekulující na růst ceny.

interakcím spíše na vyšších hodnotách škály (na vyšších vlnových úrovních). Toto zjištění z časového a frekvenčního hlediska je vhodnou informací pro investory, kteří spekulují či obchodují na komoditních trzích, že v dlouhém období lze detekovat vztah čistě neurčitý mezi cenami futures kontraktů na pšenici a kukuřici.

Následující obr. č. 17–19 pro odhad využito škálování podle období 2012-2020, které odpovídá periodě 0-2.

Obrázek 17: Vlnová koherence – pšenice a sójové boby




Zdroj: vlastní zpracování, program MATLAB

Na obrázku č. 17 je zobrazena mapa vlnové koherence v podobě korelace mezi komoditami pšenice a sójové boby v časově frekvenční oblasti v letech 2012 až 2020. Mezi sledovanými proměnnými je silný fázový vztah na středních frekvencích (8–32) v průběhu celého období. Významně silným koherentním vztahem je pak fázový pozitivní vztah na nízkých frekvencích, a to v průběhu celého období. V tomto fázovém pohybu cenová dynamika pšenice je globálním transmitterem informace v rámci vztahu dvou komodit. Podle výsledků v dlouhém období

existuje silný pozitivní koherentní vztah v časové a frekvenční oblasti. Nicméně nízké frekvence představující globální efekt jsou značně ovlivněné konečným pozorováním.

Na středních frekvencích je zjištěn leading vztah pšenice/sójevé boby, ve kterém je cenová dynamika pšenice ve vedoucím vztahu vůči druhé komoditě. Směrové šipky na obr. č. zobrazují menší ostrovy cyklického vztahu. Oblasti, kde je detekován určující cenový vztah, nejsou významné z hlediska velikosti, tudíž ve vyšších periodách nelze doporučit tyto komodity zařadit do investičního portfolia.

Obrázek 18: Vlnové koherence – pšenice a cukr

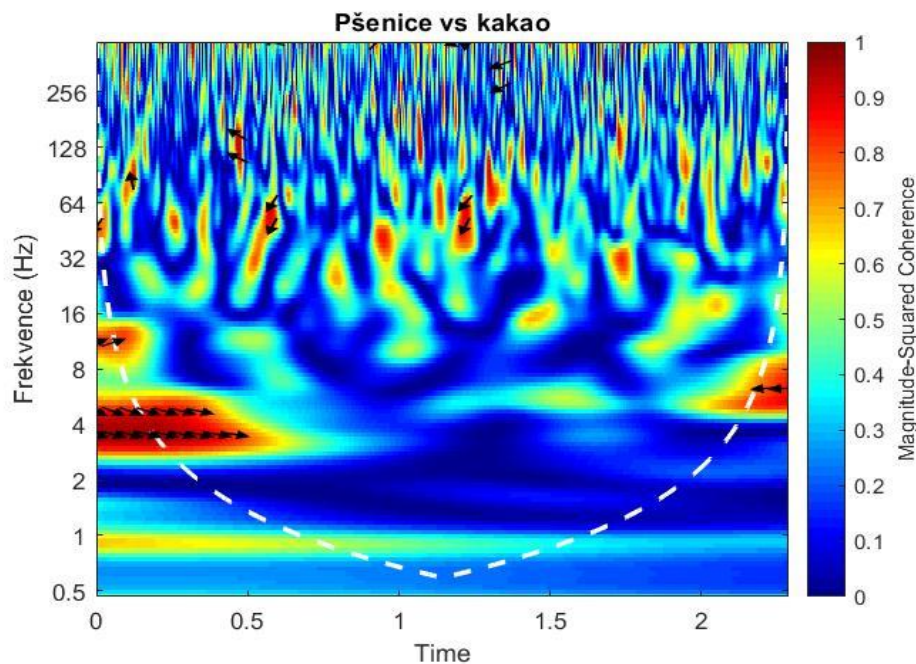


Zdroj: vlastní zpracování, MATLAB

Na obrázku č. 18 je zobrazena mapa vlnové koherence mezi komoditními futures pšenice a cukr. Dle odstínu barvy na koherentní mapě obě komodity nemají potvrzený významný vztah, neboť převažují v mezích kónické influence studené barvy. Na začátku období v roce 2012 došlo na nižších frekvencích v rozmezích 8–30 Hz ke zpožděnému anticyklickému vztahu mezi pšenicí a cukrem. V rámci globálních frekvencí není detekován významný cenový vztah. E vyšších frekvencích je v celém období pásmo téměř nulového korelačního vztahu. Toto zjištění

přináší implikaci pro spekulanty využívající právě krátkodobých obchodů. V rámci dlouhodobých investičních strategií jsou komodity pšenice a cukr převážně nekorelované, tudíž jejich výhodou je vyšší užitek z diverzifikace portfolia.

Obrázek 19: Vlnová koherence – pšenice a kakao




Zdroj: vlastní zpracování, MATLAB

Na obrázku č. 10 je zachycen koherentní vztah mezi komoditní cenou pšenice a kakaem. Na nízkých frekvencích (4-8 Hz) je detekován cyklický fázový vztah, a to jen na začátku období mezi roky 2012 a 2014. Cena komoditních futures pšenice ovlivňovala v delším období z globálního hlediska cenu kaka. Nicméně tento vztah na základě slábnoucí silně červené barvy postupně slábnul až vymizel. Na nižších frekvencích méně než 2 Hz není zachycen žádný dlouhodobý koherentní vztah. Investiční implikací je tudíž benefit v podobě diverzifikace pro dlouhodobé investory mezi oběma komoditami.

Cenový vztah mezi komoditami nedetekuje významné vzájemné souvislosti mezi pšenicí a kakaem. V rámci vysokých frekvencí na základě cenových vztahů jsou detekovány neurčité krátkou časovou dobu trvající úseky silnějšího koherentního vztahu.

Obrázek 20: Vlnová koherence – pšenice a káva




Zdroj: vlastní výpočty R Studio

Obrázek č. 20 zobrazuje vlnovou koherenci mezi komoditními futures pšenice a káva. Mezi proměnnými není detekován významný vztah nebo vzájemná souvislosti v rámci celého období mezi roky 2012–2020. Na vyšších hodnotách periody (v dlouhém období) neexistuje vzájemná závislost. Nicméně i přesto lze nějakou vzájemnou závislost pozorovat, a to v roce 2012, kdy byl prokázán vzájemný cenový vztah mezi pšenicí a kávou. V tomto případě komodita káva v pozitivním smyslu ovlivňovala pšenici. Mezi sledovanými komoditami neexistuje dlouhodobý vztah. Není zde prokázána kauzalita v rámci vyšších period (frekvencí).

Mezi pšenicí a kávou není prokázán na vyšších škálách (periodách) globálního vztahu žádný časově frekvenční vztah. Z výsledků je potvrzena neexistence cenových dlouhodobých vztahů, tudíž v rámci ekonomických implikací zde je prostor pro možnou diverzifikaci obou komodit obsažených v portfoliu za předpokladu dlouhodobých obchodních horizontů.

Následující obr. č. 21-19;21-22; 24-30 mají škálování podle období 2012-2020, které odpovídá periodě 0-2, a frekvenční zobrazení.

Obrázek 21: Vlnová koherence – pšenice a sójové boby




Zdroj: vlastní zpracování, MATLAB

Na obrázku č. 21 je zobrazena koherentní mapa časově frekvenčních vlnových signálů mezi komoditami kukuřice a sójové boby. Jako u případu cenového vztahu mezi pšenicí a sójovými boby je zde zobrazen silný vztah mezi cenami v rámci rozmezí 2012–2020. Tento vztah je silně cyklický na velmi nízké frekvenci (0,5 – 1 Hz). Tyto komodity jsou ve fázovém pozitivním společném pohybu. Jejich vzájemný cenový pohyb je charakteristický produkcí globálních informačních toků v dlouhém období.

Tento fakt, který staví komodity kukuřice a sójové boby do stejné ne-li totožné pozice jako v případě pšenice a sójových bobů je založen na světové roli a objemů mezinárodních transakcí s pšenicí, kukuřice a sójovými boby.

Na nižších frekvencích 4-16 Hz existuje anticyklický neboli proti-fázový vzájemný cenový pohyb mezi komoditami. Kukuřice je právě v tomto období mezi roky 2014 až 2016 zpožďující se komoditou.

Obrázek 22: Vlnová koherence – kukuřice a kakao



Zdroj: Vlastní zpracování, MATLAB


Mapa vlnových koherencí (obr. č. 22) zobrazuje korelační vztah mezi komoditami kukuřicí a kakao. V rámci obecných cenových kauzálních vlivů není zde potvrzena významná kauzalita v obou směrech. Na nízkých frekvencích mimo kónickou influenci lze pozorovat anticyklický vztah, který je zachycen jen v první polovině sledované období, respektive do roku 2016.

Na vyšších frekvencích jsou zobrazeny menší úseky silnějších koherencí nicméně jejich životnost je krátkodobá. U obou komodit není prokázán krátkodobý ani dlouhodobý vztah s delším trváním.

Vysvětlení neexistence významného vztahu mezi komoditami kukuřice a kakao může být v oblasti malých efektů přelévání cenových fluktuací a pohybů na mezinárodních komoditních burzách. V neposlední řadě je komodita kukuřice specifická na zajištění základních výživových

návyků. Kakao je spíše řazeno jako komodita typu „softies“, jenž není určena primárně pro základní výživu. Na nižších frekvencích dochází k silnějšímu korelačnímu vztahu, nicméně v druhé polovině období a po roce 2016 tento koherentní vztah značně slábne.

Obrázek 23: Vlnové koherence – kukuřice a káva

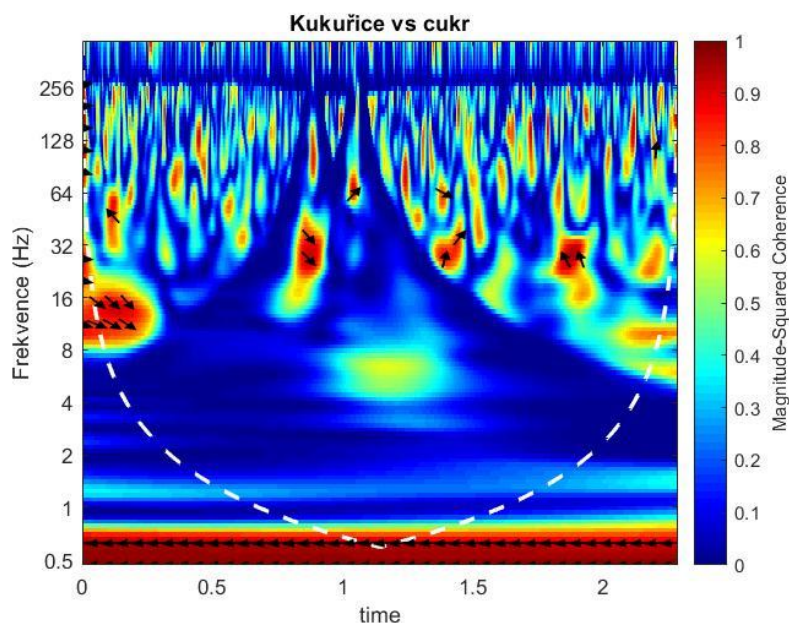


Zdroj: vlastní výpočty, R studio

Obrázek č. 23 zobrazuje cenový vztah mezi komoditami kukuřice a káva. V rámci analýzy vlnové koherence není prokázán cenový vztah delší než 1 rok. V tomto roce zde došlo k jednostrannému cenovému vztahu a to pozitivnímu. Komodita káva významně ovlivňovala komoditu kukuřice. Na úrovních 16-64 Hz existují malé efekty cenových vztahů, nicméně lze konstatovat, že u sledovaných komodit kukuřice a káva nedochází k víceletým cenovým vzájemným vztahům. Mezi roky 2014–2015 došlo na škálových úrovních 80 až 240 k významnému korelačnímu vztahu na hodnotě téměř 80 %. V tomto roce došlo k střednědobé závislosti obou komodit.

V případě vztahů mezi cenou kukuřice a kávou zde není potvrzena vzájemná souvislost a ani dlouhodobá závislost.

Obrázek 24: Vlnové koherence – kukuřice a cukr

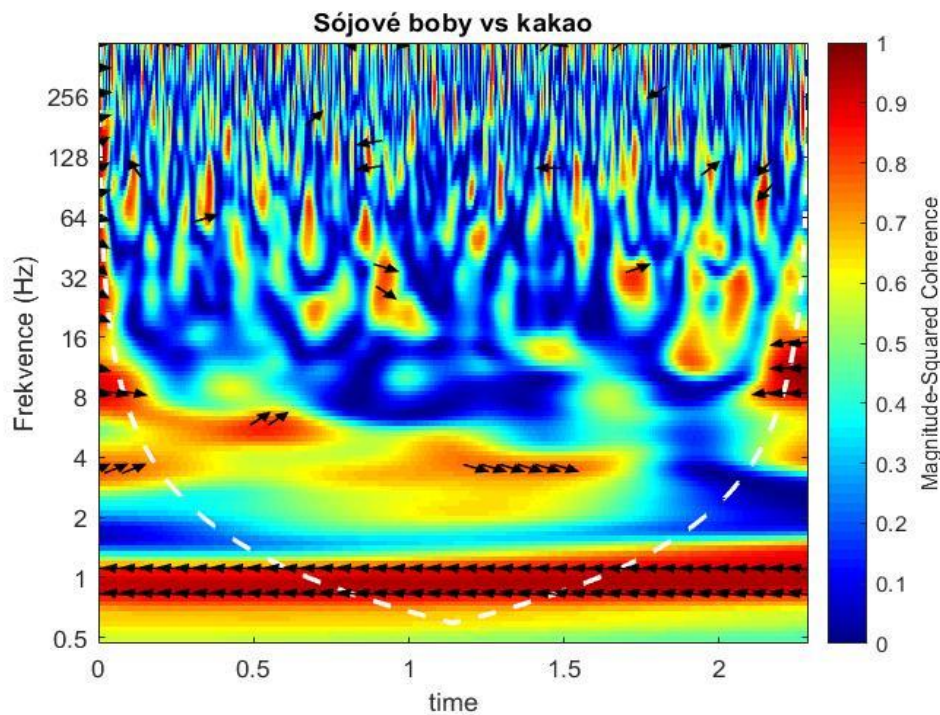


Zdroj: vlastní zpracování, MATLAB

Obrázek č. 24 zobrazuje vzájemný koherentní vztah prostřednictvím mapy vlnové analýzy mezi komoditami kukuřice a cukr. Na frekvencích 8-32 Hz na začátku sledovaného období v roce 2012 je zde detekován pozitivní vztah cyklického typu mezi komoditami. V průběhu období mezi 2012–2020 je zde výskyt menších úseků silnějších vzájemných vztahů, nicméně tyto vztahy nemají dlouhou životnost a postupně mizí. Teplejší barvy indikují vyšší korelační vztahy, zvláště na začátku periody od roku 2012 a následně kolem roků 2014, 2016 a 2018. tyto vyšší korelační závislosti neměli dlouhého trvání přibližně 3 měsíce a na středních frekvencích. Jednalo se o krátkodobé cenové výkyvy v souvislosti s přírodními šoky.

Z hlediska nižších frekvencí po hodnotu 1 Hz můžeme pozorovat významný anticyklický vztah mezi komoditami v rámci celého období. Na těchto frekvencích dochází ke globálnímu přenosu informačních šoků mezi časovými řadami v dlouhém období. Když se zvyšuje či snižuje cena kukuřice, tak dochází k opačnému efektu u ceny cukru.

Obrázek 25: Vlnové koherence – sójové boby a kakao




Zdroj: vlastní zpracování, MATLAB

Mezi cenami sójových bobů a kakaa existuje silný vztah ve více směrech, viz obr. č. 25. Na nižších frekvencích z globálního hlediska přenosu cenové informace je detekován pozitivní korelační závislost v cyklickém směru. Silnější korelace jsou na nižších frekvencích na hodnotách 2 – 16 Hz.

Na nejnižším frekvencích je zachycen signál mezi komoditami v rámci negativního směru. Změna ceny sójových bobů má za následek opačnou změnu ceny u komodity kakao. Tento jev je zachycen v celém sledovaném období mezi roky 2012–2020.

Sójové boby a kakao jsou v průběhu času významně ovlivněné. Nelze z výsledků prokázat vedoucí či zpožděný cenový vztah. V nejnižších frekvencích kolem 1 Hz existuje dlouhodobý silný vztah.

Obrázek 26: Vlnové koherence – sójové boby a káva

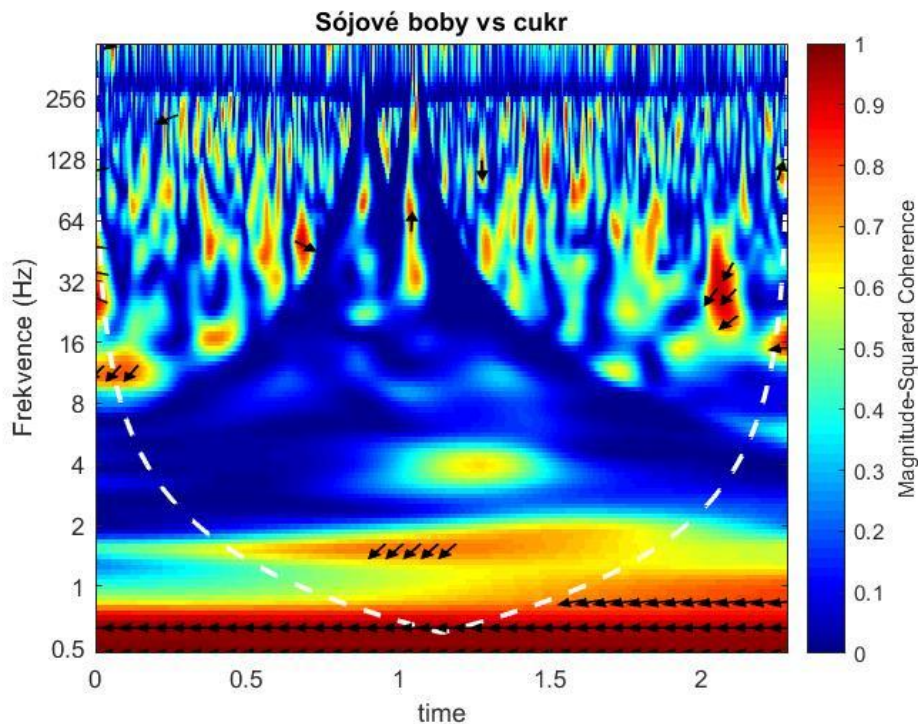


Zdroj: vlastní zpracování, MATLAB

V rámci cenového vztahu mezi sójovými boby a kávou neexistuje vyšší korelační závislost na nižších frekvencích, konkrétně v rozmezí 1–2 Hz, viz obr. č. 26. Zde dochází k pozitivnímu globálnímu přenosu cenových relací mezi komoditami. Sójové boby jsou v tomto případě vedoucí komodita nad cenou kávy. Obecně lze konstatovat, že zde existuje silnější koherentní vztah na nízkých frekvencích po celou dobu sledovaného období. Nižší frekvence u časově frekvenčního vztahu sójových bobů a kávy determinují globální vztah v hodnotách vyšší než 0,8.

Vztah mezi sójovými boby a kávou je permanentní. Toto zjištění je v souladu s rolí obou komodit při produkci sójové kávy, která je produkována prostřednictvím sójových a kávových bobů. V relaci mezi komoditami hraje roli i sentiment na trhu, neboť užitím futures kontraktů dochází k realizaci obchodů dříve, než dojde k samotné sklizni.

Obrázek 27: Vlnová koherence – sójové boby a cukr




Zdroj: vlastní zpracování, MATLAB

Na obrázku č. 27 je zobrazen koherentní vztah mezi cenou sójových bobů a cenou cukru. Z oblastí studených modrých barev lze detekovat místa, kde nedošlo v určitých obdobích k žádnému vzájemnému vztahu, a to mezi roky 2015 a 2016. V mapě jsou pozorovány jako vrcholy modré barvy.

Na nízkých frekvencích, konkrétně mezi 1 a 2 Hz je detekován negativní vzájemný vztah. Cenová dynamika sójových bobů je v tomto případě zpožděná oproti cukru. Na nejnižších frekvencích je významný dlouhodobý globální cenový vztah. Tento vztah je ovlivněn konečným počtem pozorování, nicméně implikuje vyšší korelační závislost globálnějšího typu.

Obrázek 28: Vlnové koherence – kakao a káva

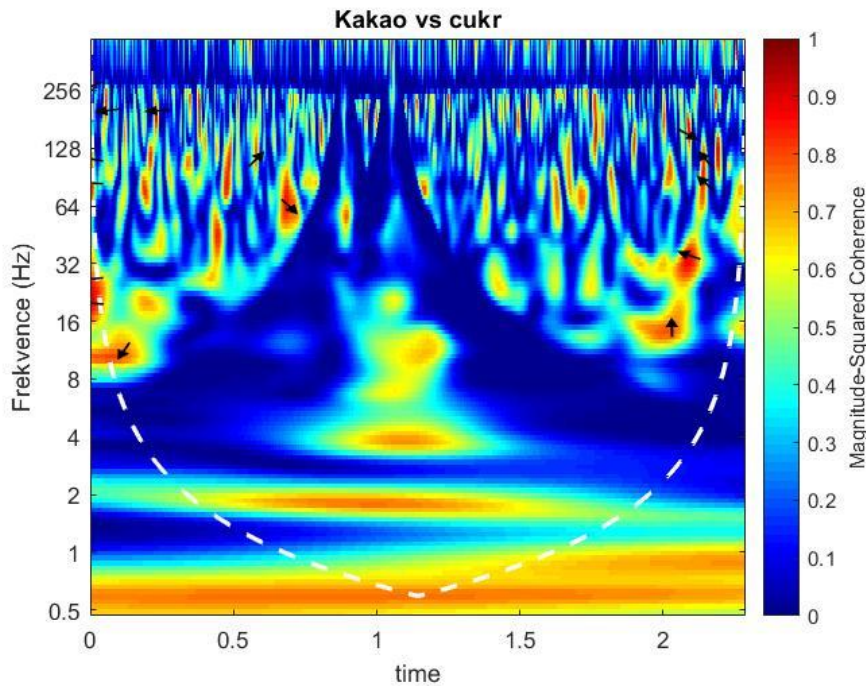


Zdroj: vlastní zpracování, MATLAB

Od roku 2015 je zde detekován vzájemný vztah, a to na nižších frekvencích (2-4 Hz), kde dochází k negativnímu chování obou časových řad, viz obr. č 28. Na těchto frekvencích může docházet ke globálnímu přenosu cenových informací, nicméně podle neexistence významně silných oblastí s dokonalou koherencí v tomto případě tomu tak není.

V druhé polovině sledovaného období konkrétně od roku 2015 zde dochází k vzájemnému pohybu obou cen komodit. Na vyšších frekvencích jsou značně rozptýlené oblasti se středně vysokou koherencí. Podle analýzy vlnové koherence je zde prokázán nevýrazný globální vztah obou komodit. Obě komodity mají fundamentální důvod jejich cenové propojenosti, nicméně krátkodobé silnější korelace jsou založené spíše na sezónních vlnách.

Obrázek 29: Vlnové koherence – kakao a cukr




Zdroj: vlastní zpracování, MATLAB

Komodity kakao a cukru jsou ze své podstaty navzájem propojené. V rámci analýzy nejsou mezi komoditami detekovány významné fázové ani leading/lag oblasti, kde dochází k vzájemným souvislostem, viz obr. č. 29. Několik oblastí s neurčitými dlouhodobějšími směry se nachází na vyšších frekvencích, kde nedochází k dlouhodobému globálnímu cenovému přenosu.

Na základě zjištění vlnové koherence nejsou cenové procesy obou komodit ve významných vzájemných relacích. Tento fakt může být potvrzen různými specifikami kakaa a cukru, jinými produkčními procesy, mírou substituce mezi komoditami a celkovou mezinárodní nepropojeností trhů.

Obrázek 30: Vlnové koherence – káva a cukr



Zdroj: vlastní zpracování, MATLAB

Na základě oblastí s přítomností vysoké korelace je mezi komoditami káva a cukr detekována silná negativní relace značící cenový anticyklický vztah mezi komoditami. Tento jev se vyskytuje na nižších frekvencích, tudíž je zde existence globálního dlouhodobého cenového vztahu v celém sledovaném období mezi roky 2012-2020. Z oblasti kónické influence vystupuje silný korelační vztah kolem hodnoty 90 % korelačních závislostí. Tento vztah působí na nižších frekvencích, tudíž mezi komoditami existuje silná permanentní vazba.

Silný dlouhodobý vztah je podpořen na vyšších frekvencích, kde dochází ke krátkodobému tranzitnímu přenosu informací mezi komoditami. Tento vztah je vysvětlen „symbiotickým chováním“ mezi kávou a cukrem. Fundamentální základy této propojenosti souvisí s klimatem v Brazílii. Zvláště koncem května dochází k prudkým dešťům v Brazílii, a tudíž je poté ovlivněna i cenová volatilita obou komodit.

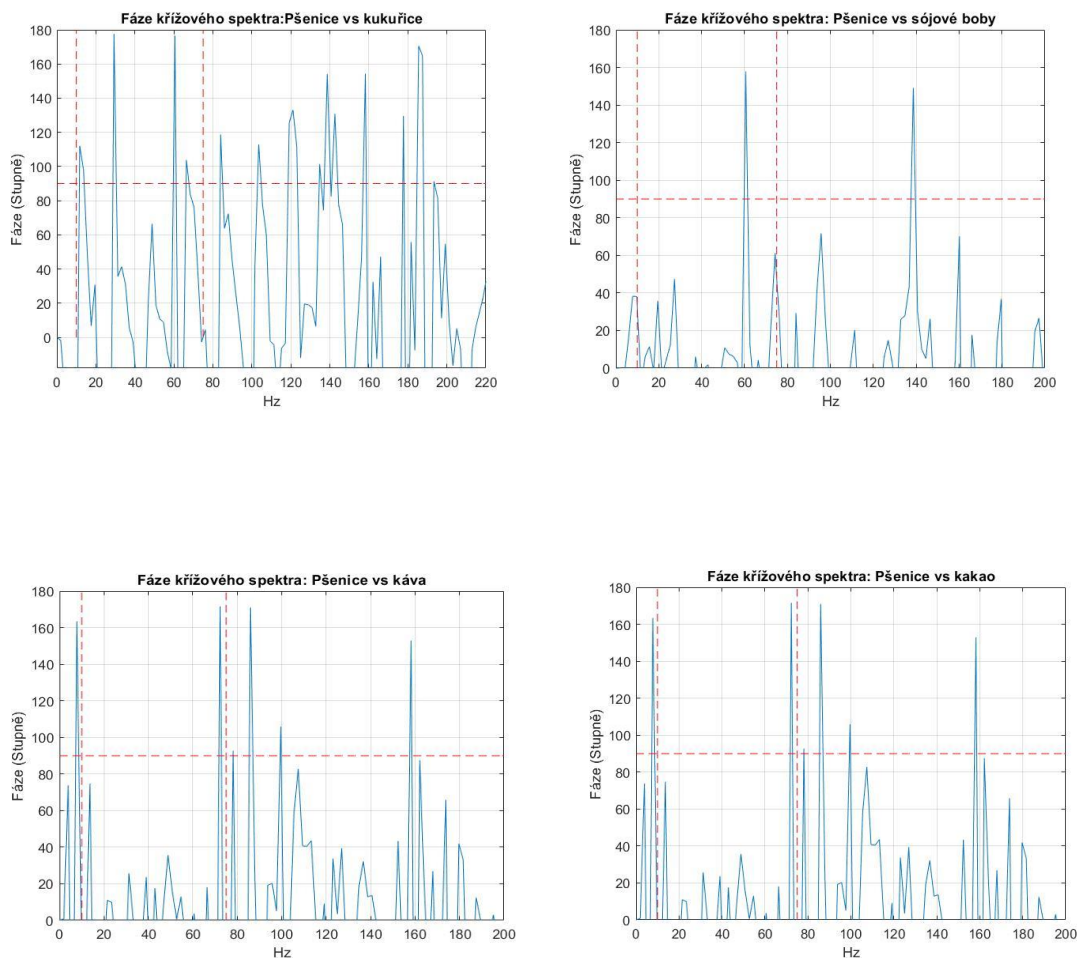
5.4. Testování vlnových fázových diferencí a koherencí volatilit

V této subkapitole je analyzován fázový křížový vztah značící lead/lagged závislost. Dále, jsou analyzovány společné pohyby volatilit dvou komodit.









Obrázek č. 31 zahrnuje všechna zobrazení fázových křížových spekter u všech uvažovaných vztahů mezi cenami zemědělských komodit.⁴⁸ Tento nástroj identifikuje koherentní oscilace na úrovních 10 a 75 Hz frekvenčního spektra. Fourierovo křížové spektrum je složeno z vertikální červené přímky detekující úrovně 10 a 75 Hz, a horizontální přímky identifikující úhel 90°.




Analýza vlnových křížových spekter je informativním doplňkem k metodě vlnových koherencí detekující fázové chování obou signálů (Grinsted et al., 2004).

Obrázek 31: Vlnové křížové spektra



⁴⁸ Signal Processing Toolbox MATLAB





Zdroj: vlastní výpočty, odhad v programu MATLAB

Významnost oscilací fázového procesu mezi dvěma komoditami je různá. Mezi komoditami pšenice a sójovými boby není objem oscilací významný. Jinými slovy jejich společné chování obou cenových procesů není na těchto frekvencích potvrzeno. U komodit sójové boby a kakao není pozorováno mnoho společných oscilačních procesů. Pšenice a sójové boby nemají potvrzen společný vztah, kdy mohou předcházet či se zpoždovat vůči sobě navzájem. Naopak je zde potvrzen společný vztah mezi komoditami pšenice a kukuřice, kdy dochází k silnému vztahu, na začátku období více anticyklickému a během spíše nejasnému. Na nižších frekvencích vztah obou komodit silněji osciluje. Ekonomická implikace spočívá v potvrzení korelačního vztahu, a tudíž vyloučením obou komodit pro portfolia v rámci safe haven⁴⁹

Fourierova kvadratická koherence identifikuje oscilace na frekvencích 10 a 75 Hz. Do 90° jsou křížové fáze cyklické. U komodit pšenice, kukuřice; pšenice, cukr; kukuřice, cukr; sójové boby, cukr a kakao, cukr jsou významné anticyklické vztahy, které oscilují od začátku až po konec sledovaného období. V rámci vztahu pšenice a sójových bobů jsou detekovány na frekvencích 60 a 140 Hz náhlý přechod do anticyklického vztahu, nicméně tento vztah neměl dlouhé trvání. Na střednědobých úrovních došlo ke stavu, kdy sójové boby byly předcházející pšenici.

⁴⁹ safe haven – bezpečný přístav

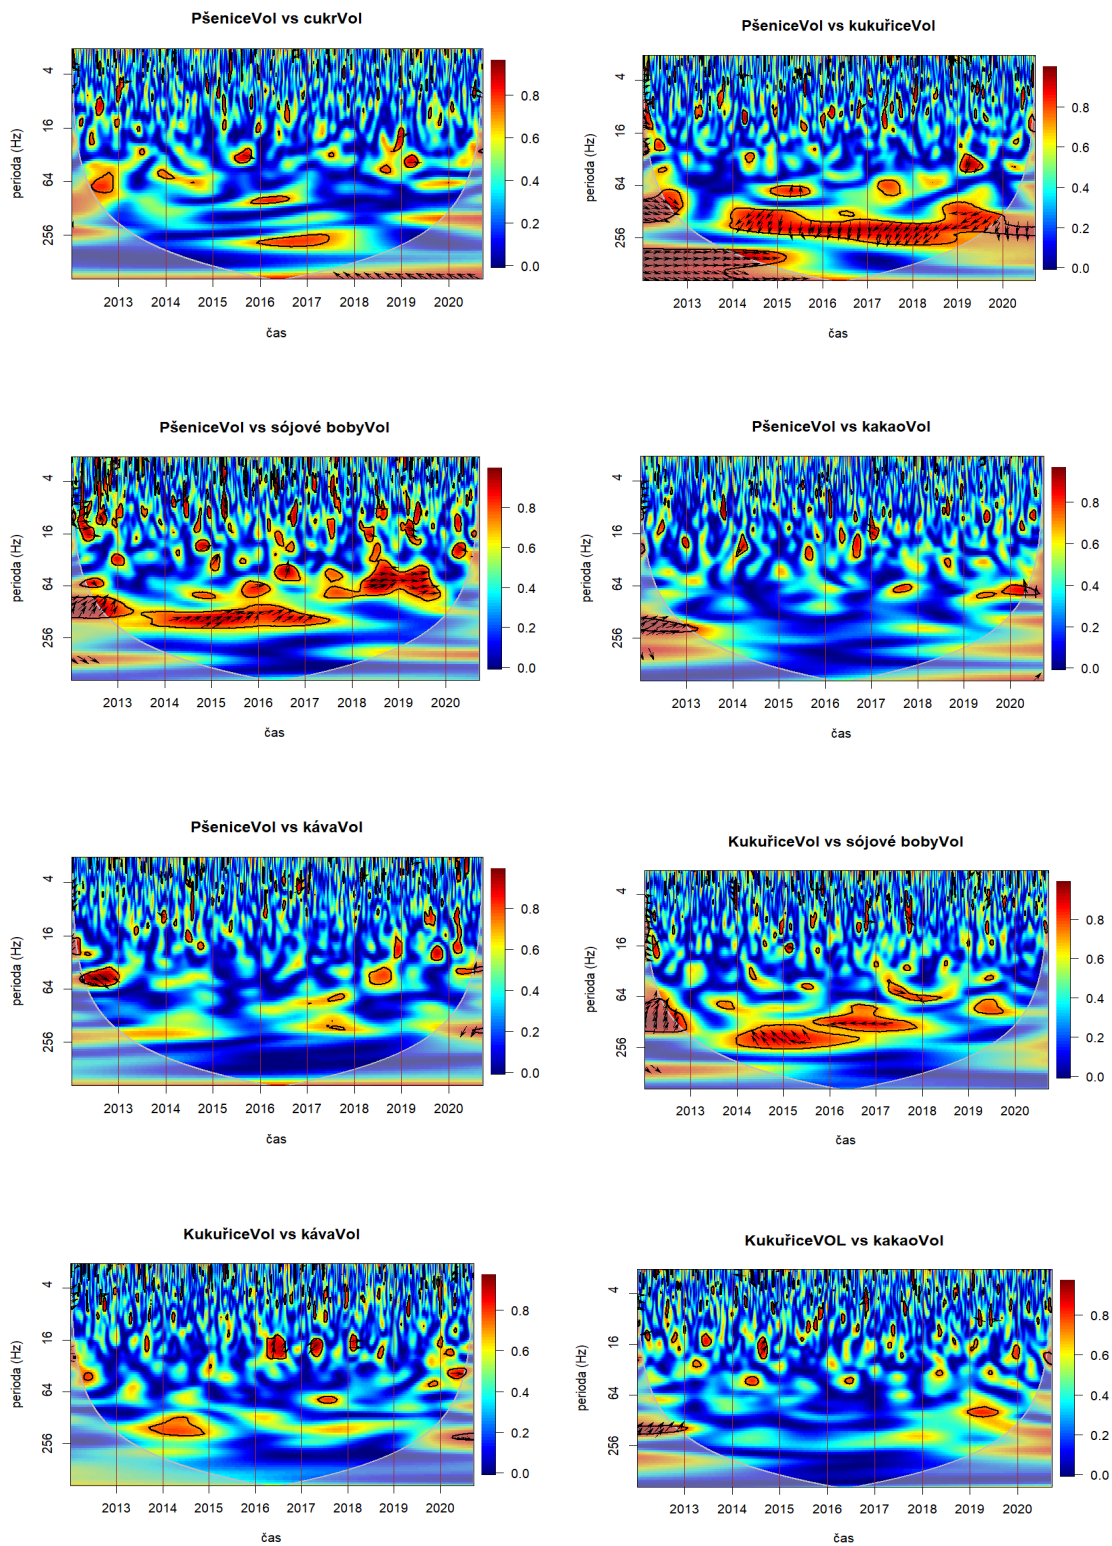
Podobného vztahu fází křížového spektra docházelo u komodit sójové boby a kakao, kdy většinu času je předcházející komoditou sójové boby. Symetrický vztah fázových křížových oscilací mají komodity kakao a cukr. Ve sledovaném období u těchto komodit dochází k vyrovnanému lead/lagged vztahu, kdy se obě komodity střídají v předcházení či zpoždování. Ceny komodity, které předcházejí jiné komoditě, mají implikace v ekonomické a investiční oblasti. Tvůrci politik můžou sledovat cenové vývoje jiné komodity s determinujícím benefitem pro druhou komoditu v rámci párového porovnání. Většinu času od 2012 do roku 2020 jsou cyklicky předcházející komodity pšenice a sójové boby.








Ve sledovaném období mezi roky 2012 a 2020 jsou zachyceny statisticky významné společné koherentní pohyby cenových fluktuací (viz obr. č. 32). Není uvažován vztah mezi cenou komodity a její volatilitou, neboť by tento vztah měl za následek narušení vzájemných časově-frekvenčních vztahů.

Porovnáním jednotlivých volatilit mezi sledovanými komoditami má za následek zjištění vzájemných souvislostí mezi samotnými cenovými fluktuacemi na různých frekvencích v dlouhém a krátkém období.

Vzájemné cenové fluktuace pšenice a kukuřice na středních a vyšších frekvencích jsou zachyceny prostřednictvím vyšší vlnové korelace. Mezi frekvencemi 60–250 Hz probíhá v rámci celého sledovaného období statisticky významná koherence. Na základě zjištění křížové spektrálních fázových frekvencí je možno pozorovat statisticky významné fázové závislosti cenových volatilit, a to neutrálních a převážně anticyklických mezi oběma komoditami. Cenová fluktuace pšenice je ovlivněna cenovou volatilitou kukuřice v rozmezí 2014–2019. U komodit pšenice a kukuřice je potvrzena vysoká korelace na nízkých frekvencích v jejich cenových fluktuacích. Jejich cenové volatility jsou v rámci 150–250 obchodních dnů na sebe silně korelovány.

Obrázek 32: Vlnové koherence volatilit





Zdroj: vlastní zpracování, R-Studio

Na základě vlnové koherentní analýzy existuje nejvyšší sílu koherence u cenových fluktuacích na trhu pšenice a kukuřice (PšeniceVol; kukuřiceVol), respektive na střednědobých frekvencích (100-200 Hz). Vlnové korelace mezi těmito komoditami determinují významné transientní přenosy, které jsou v neurčitěm směru. Jinými slovy cenová kolísavost má přechodný charakter.

Na trzích sójových bobů a kakaá (Sójové bobyVol; KakaoVol) došlo mezi roky 2015-2020 ke zvýšené koherenci. Zde v rámci vyšších frekvencí (od 250 Hz) byl zaznamenán krátkodobý vzájemný vztah cenových fluktuací.


Existuje koherentní vztah na velmi vysokých frekvencích (od 300 Hz) u cenových volatilit kávy a cukru (KávaVol; CukrVol). Zde v rámci již CoI oblasti docházelo k neurčitěmu směru působení. Tradingové aktivity jako spouštěč cenových dynamik jsou na těchto trzích spíše dlouhodobého charakteru než krátkodobého. V rámci porovnání nelze konstatovat, že by jen na základě tradingové činnosti docházelo k dlouhodobými výkyvům na zmiňovaných trzích.

Odchyly mezi cenovými procesy a volatilitami komodit nejsou významné. V rámci investičních implikací neexistují benefity případné arbitráže, využívající rozdílnost volatilit a cen.

5.5. Částečná vlnová koherence na trhu pšenice a kukuřice

Pro robustní identifikaci korelace vysokofrekvenčních časových řad s eliminací další proměnné je využita metoda částečné vlnové koherence (PWC), Ng a Chan (2012). Analýza je zaměřena pouze na trh pšenice a kukuřice, který byl na základě vlnové koherence potvrzen jako nejvýznamnější. Při aplikaci PWC metody je vyloučen vliv třetích proměnných v cenovém vztahu kukuřice a pšenice. Tato analýza představuje testování robustnosti předchozích analýz v sub-kapitolách 5.3. a 5.4., kdy je potvrzen silný koherentní vztah mezi pšenicí a kukuřicí.

Obrázek 33: Částečná vlnová koherence – pšenice a kukuřice



Zdroj: Vlastní zpracování, R Studio

Poznámka: Na ose X je čas t , osa y obsahuje periodu v rámci frekvencí

V dlouhém období (na vyšších frekvencích)⁵⁰ lze pozorovat významný vliv ostatních proměnných po odstranění efektů jednotlivých dalších komodit (viz obr. č. 33). V rámci celého období má nejvýznamnější vliv neuvažování komodit kakao a cukr v rámci perzistentního efektu na cenových vztah kukuřice a pšenice. V případě determinace lead/lag vztahu mezi komoditami pšenice a kukuřice s vyloučením ostatních proměnných zde není jednoznačně potvrzen cenový vztah. Nicméně se nacházejí v oblasti se zvýšenou frekvencí oblasti anticyklického vztahu, tudíž komodita kukuřice ovlivňuje komoditu pšenice.

Podobné vzory koherentního chování pšenice a kukuřice jsou patrné v delším období kolem 200–250 obchodních dnů po vyloučení vlivu trhů cukru, kávy a kakaa. Tyto komodity jsou

⁵⁰ Opakujících se cyklických vzorců v kratším období

potvrzeny v rámci testování robustního koherentního vztahu mezi kukuřicí a pšenicí jako významně vylučitelné z cenových procesů testovaných komodit.

Období zkoumání v letech 2012-2020, během něhož globální zemědělské trhy prošly zásadními proměnami, které byly způsobeny spojením klimatických změn, složitostí dodavatelských řetězců a geopolitických ohlasů. Složitost a propojenost těchto faktorů se sbíhala a vytvářela komplexní vztahy mezi cenami různých komodit

Během těchto let se objevil zřetelný trend – ceny zemědělských komodit vykazovaly tendenci pohybovat se v tandemu, což je jev široce zkoumaný v odborné literatuře. Tento jev je patrný z empirických pozorování cenových korelací mezi komoditami, např. pšenice, kukuřice a sójové boby. Tento sdílený a společný pohyb cen lze přičíst společným vlivům na produkci, jako je proměnlivost klimatu, kdy projevy extrémních přírodních jevů, jako jsou sucha a povodně, mohou významně ovlivnit více plodin současně.

Klíčovou dynamikou, která posiluje propojenost cen zemědělských komodit, je globalizace obchodu a finančních trhů obecně. Posílení přeshraničního obchodu podpořilo výraznější vazby mezi trhy. Tato zvýšená propojenost je zřejmá, když cenové výkyvy v jednom regionu se přelévají na rychlé dopady v jiných regionech, což má vliv na provázanost globálních dodavatelských řetězců a obchodních sítí.

Zkoumané období je charakteristické množstvím přírodních jevů, kdy velká sucha a nečekané záplavy výrazně narušily produkci plodin napříč kontinenty. Výsledné výkyvy v nabídce vyvíjely společný tlak na ceny komodit a vyzdvihovaly důraz na jejich zranitelnost vůči nepředvídaným environmentálním šokům.

Proměnlivá dynamika poptávky představovala další prvek ve složité struktuře cenové provázanosti na komoditních trzích. Vyvíjející se spotřebitelské preference spolu s prudkým růstem populace v rozvíjejících se ekonomikách měly za následek změny ve spotřebních návycích. Tyto změny měly dopad na komodity, jako je maso a mléčné výrobky, a odrazilo se tak v poptávce po krmných plodinách, jako je kukuřice a sója. Tato poptávka je pozorovatelná v rámci cenových strukturálních změn. Tento propojený vztah mezi poptávkou a nabídkou je základem složité vzájemné závislosti mezi různými zemědělskými odvětvími (Tilman et al., 2011).

Geopolitické události měly také znatelný vliv na dlouhodobé vazby cen zemědělských komodit. Případy obchodních restrikcí a zákazů vývozu vyvolaly poruchy napříč globálními dodavatelskými řetězci, a tím vyvolaly vlnový efekt v dynamice cen komodit.

Na základě výsledků vlnové koherence byla prokázána vzájemná souvislost mezi komoditami pšenice a kukuřice v dlouhém a krátkém období. V rámci cenových vztahů je prokázána časově frekvenční závislost na vyšších frekvencích, tudíž je zde detekován vztah krátkodobého charakteru

Z analýzy frekvenčních vztahů lze pozorovat propojenosti tranzitního přenosu cenových informací mezi zkoumanými komoditními futures. Kukuřice a pšenice jsou již v předchozím zkoumání vysoce propojené, jak na úrovni cen, tak na úrovni jejich volatilit. Komodity jako cukr a káva vykazují v krátkodobém trendu silnou korelaci v časově frekvenční oblasti. Lze potvrdit, že tyto komodity jsou vhodné pro dlouhodobější investiční aktivity, jelikož nejsou náchylné ke společným pohybům nebo vzorcům cenových procesů.

Jednotlivé komodity jsou zde z dlouhodobého cenového koherentního vývoje propojeny a jsou zde striktně odděleny od vlivu dalších zemědělských komodit. Z provedené časově frekvenční analýzy bylo mimo jiné zjištěno, že u vztahu mezi komoditami pšenice a kukuřice je přítomen i transientní (krátkodobý) efekt. Na základě zjištění, zda cenový proces působí oboustranně je možné potvrdit, že výskyt takového efektu je prokázán pouze u cenového vztahu mezi pšenicí a kukuřicí. U zbylých komodit je směr jednostranný, respektive anticyklický.

Vzájemnost a koherence cenových volatilit na různých trzích globálního (permanentního) charakteru je potvrzena v časově frekvenční oblasti pro komodity kukuřice, pšenice, sójové boby a kakao. Mezi vztahem cenových volatilit komodit cukru a kávy a ostatními komoditami neexistuje efekt přelévání. V rámci vlnové analýzy mezi pšenicí a kukuřicí je možné pozorovat koherentní závislost i na vyšších frekvencích (krátkodobého) efektu. Cenová fluktuace je zde ovlivněna více cyklickými šoky, které se pravidelně opakují. Logickým vysvětlením zde může být i rozsah zahraničního obchodu s danými komoditami, neboť se jedná o komodity s největší poptávkou. Propojenost sójových bobů, pšenice, kukuřice a kakaa potvrzuje jejich obecnou povahu potřeby.

Volatilita cen jednotlivých komodit při kratších frekvencích je velmi kolísavá a rychle se vytrácí, detekovány oblasti s rychlým střídáním různých volatilit. Dlouhodobější vztahy vyšší korelace se vytvořily po roce 2014, což souvisí s opožděním po cenové krizi komodit, respektive finanční krizi.

Výsledky jsou konzistentní s výzkumem Zelingher a Makowski (2023), kteří zařadili kukuřici a pšenici mezi nejvíce ovlivňující komodity mezi trhy.

5.6. Determinace a simulace režimů volatilit

Pro detekci a kategorizaci jednotlivých úrovní (režimů) cenových volatilit u komoditních futures je použito metody skrytých markovských modelů (HMM). Aplikace těchto modelů vychází z formy „unsupervised learning“.⁵¹ Hlavním účelem je popsat dynamiku střídání režimů volatilit v rámci různých skrytých stavů. Otázkou je kolik stavů lze simulovat. Odpověď na tuto otázku závisí na charakteru a povahy dat. V rámci užití denních zavíracích cen komoditních futures jsou období relativního klidu trvající i rok a více.⁵² Na trzích poté vznikají krátkodobé korekce nebo šoky, které vytvářejí oblasti s vyšší cenovou volatilitou nebo naopak s volatilitou nižší.

Použití skrytých Markovových modelů při určování režimů volatilit cen zemědělských komodit nabízí cenné poznatky pro řízení rizik, obchodní strategie a rozhodování v zemědělském sektoru. Určením měnicích se vzorců volatilit umožňují HMM zúčastněným stranám efektivněji se orientovat ve složitých situacích na zemědělských trzích. Zmíněné modely mají potenciál zlepšit pochopení ohledně dynamiky trhu a usnadnit informovanější a přizpůsobivější tvorbu obchodní strategie.

Pochopení režimů volatilit je klíčové pro řízení rizik. Skryté Markovské modely pomáhají kvantifikovat pravděpodobnost vstupu do obchodní pozice na komoditních trzích během období vysoké volatilit, což umožňuje účastníkům trhu přijmout preventivní opatření k zajištění proti potenciálním ztrátám. Producenti mohou na základě předpovězeného režimu volatilit upravit strategie výsadby a sklizně, zatímco investoři mohou optimalizovat alokaci portfolia s cílem řízení obchodní pozice vůči riziku.

Modely HMM přispívají investorům a obchodníkům k formulaci obchodních strategií, které se přizpůsobují měnicím se tržním podmínkám a samotné struktuře trhu. Obchodníci a tradeři mohou pomocí modelů přepínání režimů volatilit upravovat své pozice⁵³ a úrovně rizika podle zjištěného režimu volatilit. Například v období vysoké volatilit mohou obchodníci budovat

⁵¹ Unsupervised learning: V rámci strojového učení (Machine learning) je tato forma známá jako „učení bez učitele“ nezávisí na trénovacích datech.

⁵² Totéž platí i pro trh Equities

⁵³ Position sizing – úprava velikost pozice na finančním trhu při obchodování fin. derivátů nebo CFD kontraktů

strategie, které zahrnují opce nebo jiné deriváty na ochranu před nepříznivými cenovými pohyby.

V oblasti oceňování opčních kontraktů jsou modely HMM významné tím, že zahrnují změny režimu volatility. Tradiční modely předpokládají konstantní volatilitu, což je u zemědělských komodit často nereálné.⁵⁴ Oceňování opcí na základě HMM zohledňuje měnící se volatilitu, což vede k přesnějšímu oceňování opcí a dalších finančních derivátů.

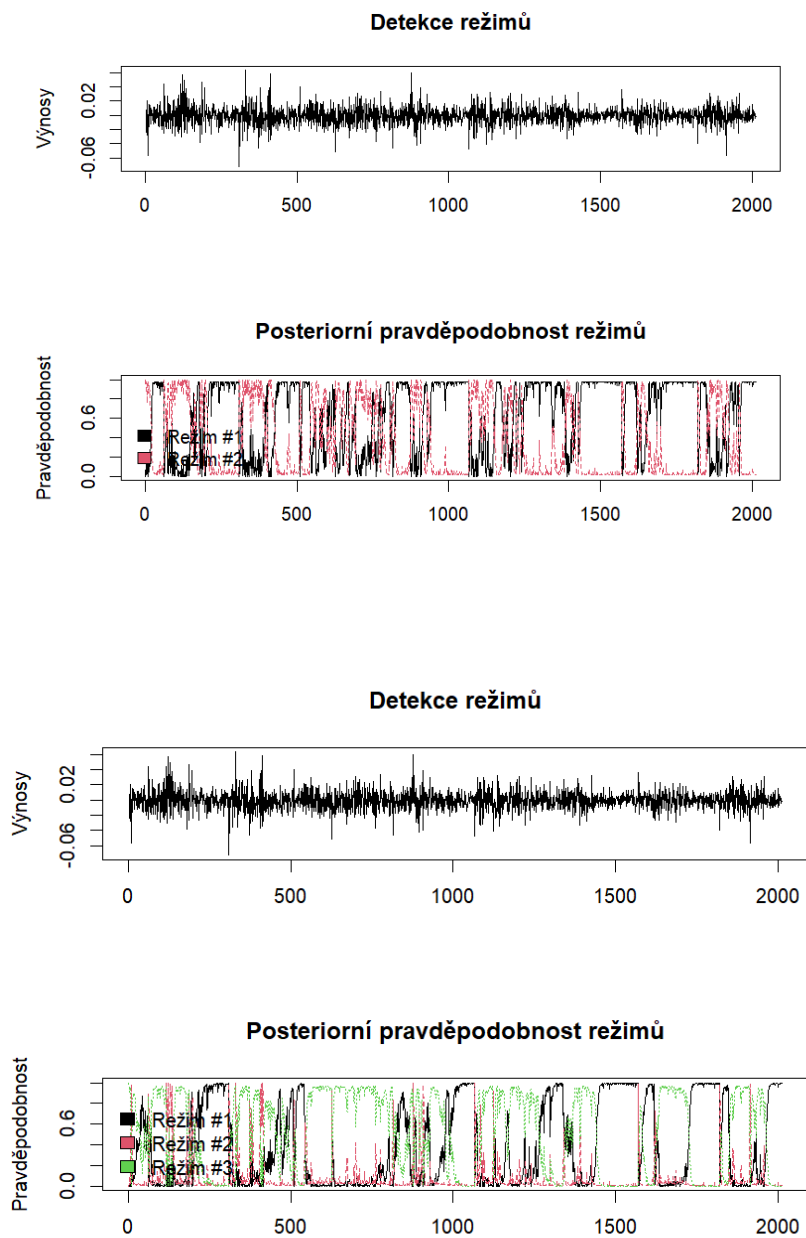
Na výsledcích (Obr. 34-39) jsou zobrazeny úrovně režimů volatility v rámci HMM, respektive skrytých režimů volatilit jednotlivých komodit.⁵⁵ Pro simulaci jsou využity 2 a 3 stavy modelu neboli režimy cenových volatilit komoditních futures cen. *Režim 1* je období nízké volatility a *Režim 2* je poté období vysoké cenové volatility. V tomto případě hovoříme o 2režimové simulaci cenových volatilit. Pro účely 3režimové simulace v rámci skrytých stavů modelu jsou uvažovány: *Režim 1* jako období nízké volatility, *Režim 2* jako období střední volatility a *Režim 3* jako období vysoké volatility.

V rámci dvou-režimové simulace se střídaly období s nízkou a vysokou volatilitou přibližně po půl roce, kdy byla změna posteriorní pravděpodobnosti zřetelná, více viz obr. č. 34. Během roku 2015 docházelo k obdobím relativně volatilním, neboť se ve zvýšené míře střídaly dva režimy. V po-krizovém období, tj. po roce 2012 se období střídání volatilit projevilo na větší pravděpodobnosti v podobě režimu 2, kdy Spojené státy zažily velká období sucha, které se projevilo v růstu cen kukuřice na komoditních trzích. Při simulaci 3 režimů se v letech 2012–2013 více střídali jen 2 úrovně a to režim 2 a režim 3. Po roce 2013 vzrostla posteriorní pravděpodobnost i u režimu 1. Období sucha bylo charakteristické na komoditním trhu kukuřice přepínáním jen těchto dvou období střední až vysoké cenové volatility. V letech 2014-2015 byla zvýšená posteriorní pravděpodobnost u režimu 3 značící dynamickou fluktuaci cen. Po roce 2017 docházelo na trhu futures kukuřice k pravidelnému střídání přibližně kvartálně výskytu režimu 1 jako období nízké volatility.

⁵⁴ Black-Scholes model oceňování opcí a ostatní modely stochastické volatility, více viz Hull (1997)

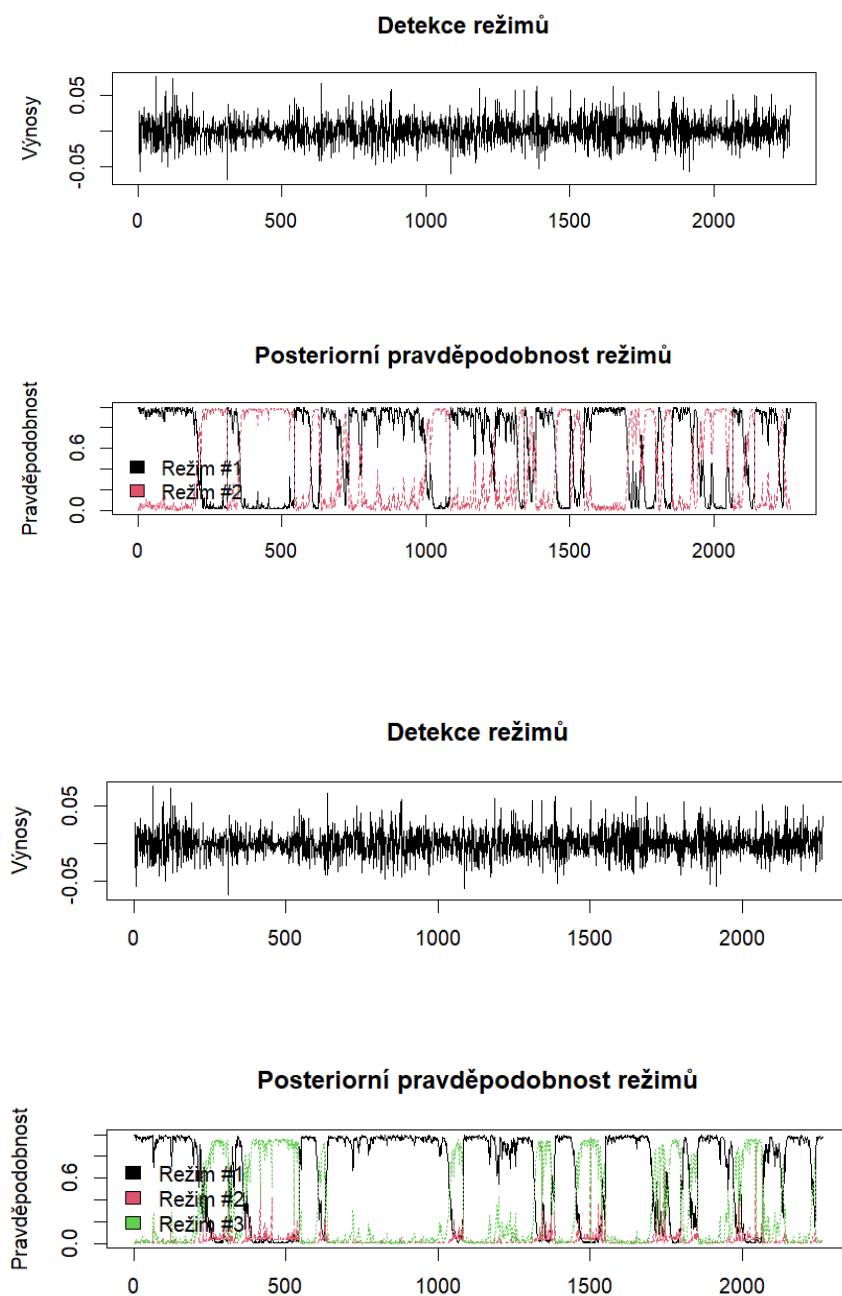
⁵⁵ Časová řada je v rozmezí 2012–2020 zobrazena na ose X pomocí posloupnosti 0-2000, kde jednotka představuje jeden obchodní den.

Obrázek 34: Skryté Markovské modely, kukuřice



Zdroj: R-Studio

Obrázek 35: Skryté Markovské modely, pšenice



Zdroj: R-Studio

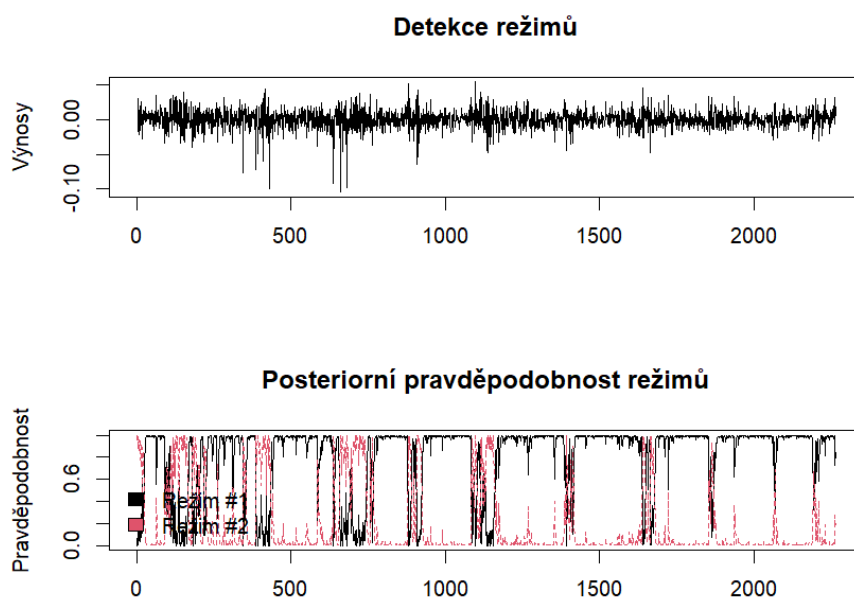
Obr. č. 35 zobrazuje skryté markovské modely trh futures pšenice v rámci simulace dvou režimu řešících nízkou a vysokou volatilitu. Po roce 2012 dochází k výrazné posteriorní pravděpodobnosti režimu 1, který v delších obdobích přelévá a střídá se s režimem 2. Během roku 2015 docházelo k rychlejšímu přepínání obou režimů. V tomto období docházelo k vyšším


turbulencím na trhu pšenice a více posteriorní pravděpodobnosti se přiřazovalo oběma režimům.

V rámci simulace více režimů s přidáním neutrálního (středního) režimu volatilitu po roce 2012 měl nejvyšší míru pravděpodobnosti režim 1, což ukazuje na období nízké volatilitu. Zajímavým zjištěním je, chování režimů 2 a 3 po roce 2013, kdy mezi nimi probíhá kopírování jejich střídání. V případě cenové fluktuace ve zvýšených cenových turbulencích nastává režim 3. V tomto případě je střední režim absorbován a je mu přiřazena menší pravděpodobnost výskytu. V roce 2015 trh pšenice se dostal do „mírné“ fluktuačního cenového pásma, tudíž během celého roku měl nejvyšší pravděpodobnost režim 1 vyjadřující nízkou volatilitu. Poté již nejvyšší stupeň fluktuace v režimu 3, který se střídal přibližně po čtvrtletích absorboval „střední“ režim 2.

Lze konstatovat, že sentiment na trhu futures pšenice v rámci 3režimní simulace neočekával „střední rychlost“ cenové volatilitu. V rámci střídání skrytých stavů nebyla přiřazena posteriorní pravděpodobnost režimu 2.

Obrázek 36: Skryté Markovské modely, sójové boby





Zdroj: R-Studio

Modelovány jsou dvou-režimové a tři režimové modely skrytých stavů (obr. č. 36) Po roce 2012 docházelo k výraznému střídání dvou režimů volatilit – období nízké a vysoké cenové fluktuace. Tento jev byl zapříčiněn přírodními jevy, a to suchem na středozápadě v USA. V roce 2014 docházelo k vyššímu střídání obou režimů, které však trvalo přibližně půl roku. Období po roce 2015 na trhu sójových bobů lze označovat jako relativně klidné, neboť posteriorní pravděpodobnost byla nejvyšší právě pro období nízké cenové fluktuace.

V rámci tří režimní analýzy s přidáním „mírného“ období cenové fluktuace nastalo cenové absorbování vysoké volatility právě režimem 2. V průběhu sledovaného období byly na trhu sójových bobů výkyvy v podobě absorpčního střídání režimu 3 a režimu 2, nicméně období s vysokou volatilitou bylo menší než s mírnou. Přiřazená posteriorní pravděpodobnost pro režim 2 nepřesáhla hodnoty 0,6.

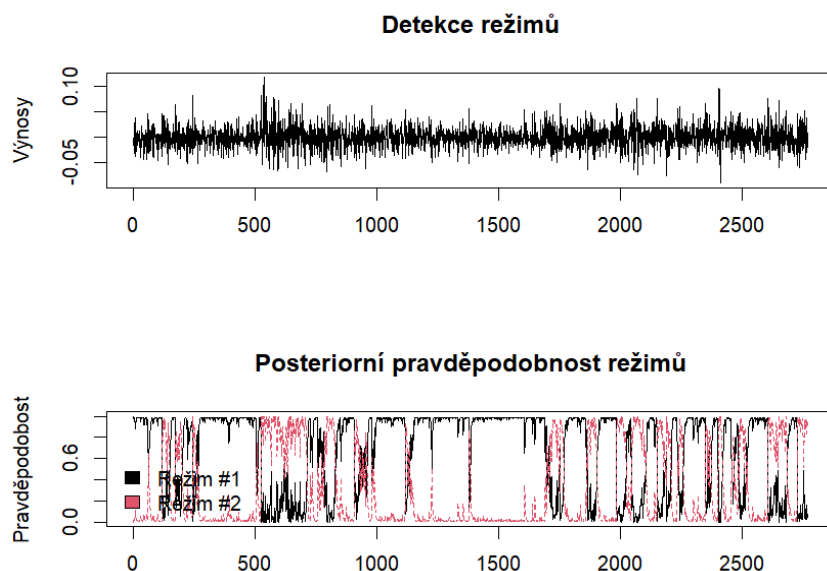
Sentiment na trhu sójových bobů z hlediska investorů neodpovídal rizikovému chování účastníků na trhu. Zdrojem vyššího cenového kolísání by mohla být poptávka, která avšak nebyla tak významná a nemohla být příčinou vyšší volatility na trhu. Nepříznivé podmínky v USA během roku 2012 způsobily na futures trhu sójových bobů rychlé střídání všech režimů volatilit.

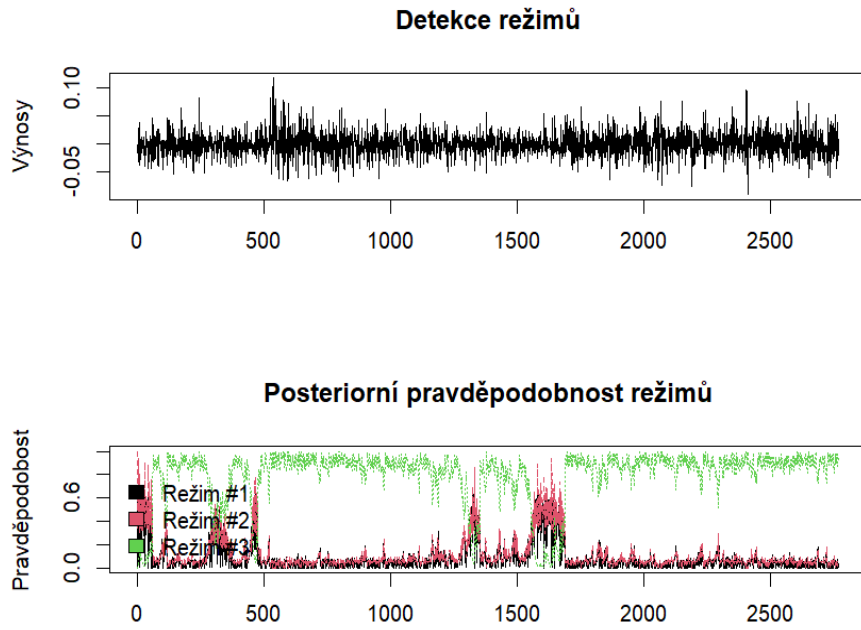
Střídání dvou období po roce 2012 bylo přerušeno obdobím relativního klidu a výskytem režimu nízké volatility, viz obr. č. 37. Během roku 2014 se přepínání obou režimů zrychlilo a nastala na trzích nejistota spojená s vyšší volatilitou. Během konce roku 2014 a začátkem 2015 bylo vystřídané období nízké volatility obdobím poměrně rychlejších ve střídání dvou režimů. Tento stav pokračoval až do konce sledovaného časového úseku.

Zahrnutím dalšího režimu do modelu lze konstatovat, že režim 1 absorboval „střední“ režim 2. V celém období přiřazovala posteriorní pravděpodobnost vyšší hodnoty vždy režimu 3, a to období vyšších cenových fluktuací. V roce 2015 došlo k nečekanému přepnutí na režimy 1 a 2, tudíž do období s nižší volatilitou. Po zbytek období do roku 2020 pokračoval režim 3 s mírnými odchylkami od vyšších hodnot posteriorní pravděpodobnosti.

Tržní sentiment pro investory byl v tomto období více rizikový s krátkodobým přepnutím do oblastí s nižší cenovou fluktuací. Komodita káva je více závislá na přírodních podmínkách, a tudíž promítnutí vysoké volatility do cenového procesu futures není ojedinělé.


Obrázek 37: Skryté Markovské modely, káva






Zdroj: R-Studio

Obrázek 38: Skryté Markovské modely, kakao





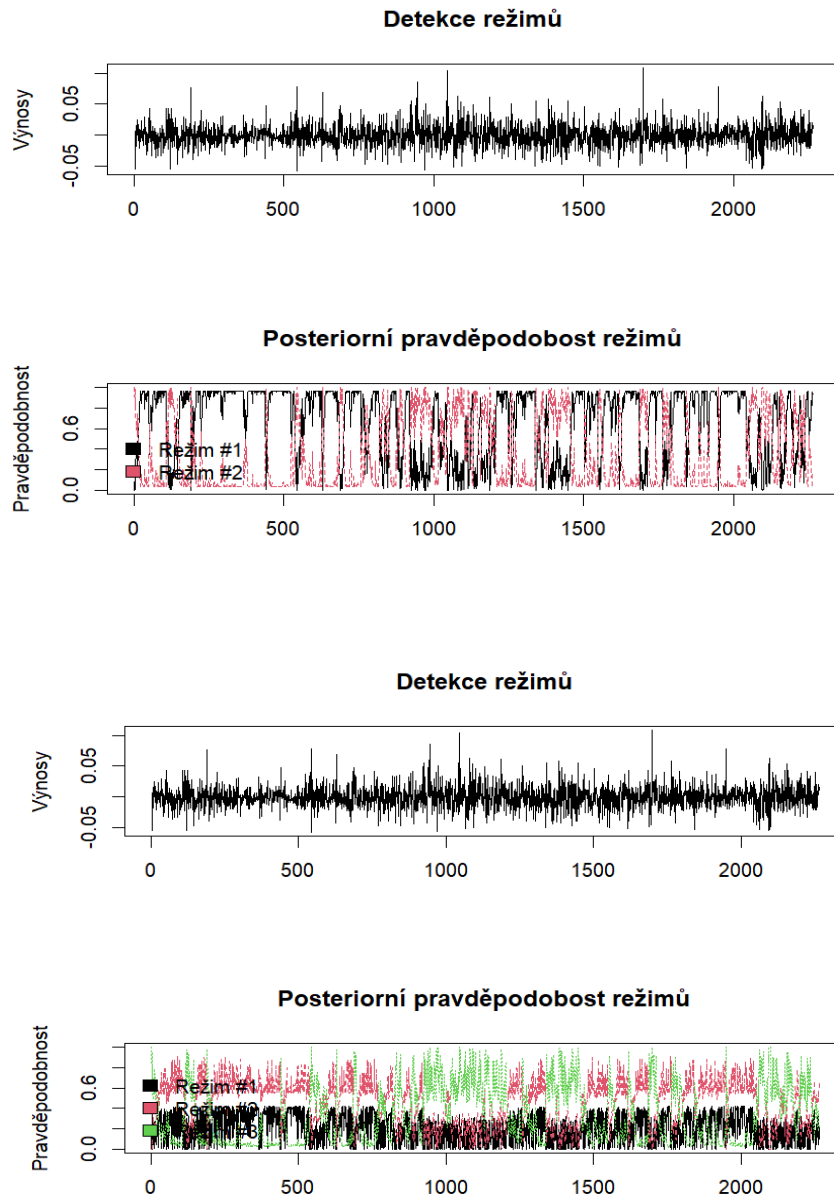
Zdroj: R-Studio

Na obr. č 38 jsou modelovány volatilit u komodity kakao. V rámci dvou-režimové simulace v roce 2012 nastoupil trend zvýšené volatilit v podobě režimu 2. Jedná se o období, kdy docházelo ke stabilizaci finančních trhů. V letech 2014 a také po roce 2015 až do konce sledovaného období docházelo na trhu kávy ke stabilními střídáním obou režimů. Zvláště v druhé části sledovaného období nejvyšší hodnot pravděpodobnosti dosahoval režim vyšší volatilit. V rámci simulace se na trhu futures kakaa střídaly turbulentní období s rychlým střídáním obou režimů s následnými obdobími nestřídání, avšak s převahou režimu detekující vysokou volatilitu.

V případě tří režimového modelu je přidání dalšího režimu představující „mírnou“ volatilitu rozdílné. V celém průběhu sledovaného období měl právě největší zastoupení režim s mírnou volatilitou. K narušení trvající charakteru mírné volatilit pro kakao došlo v letech 2013–2015, kdy došlo k významnému zvýšení pravděpodobnosti pro režim nízké volatilit. V tomto turbulentním období došlo k většímu výskytu režimů vysoké volatilit, která se rychle přepínala s režimem 1. Po roce 2015 se futures ceny stabilizovaly vlivem menší cenové fluktuace komoditních spotových cen. U futures kontraktů kakaa představuje mírná volatilita trvalejšího chování.

Komodity káva a kakao jsou silně závislé na externích podmínkách jako je sucho, či dlouhotrvající období dešťů.

Obrázek 39: Skryté Markovské modely, cukr



Zdroj: R Studio

V rámci dvou-režimové simulace je na cukerním futures trhu převážně zastoupeno dynamické střídání období vysoké a nízké volatility (viz obr. č. 39). Během let 2013–2014 dochází k převaze režimu 1, avšak již další rok nastupuje turbulentní období střídání režimů. Kolem

roku 2016 převažuje na cukerním trhu zastoupení režimu 2. Obecně řečeno, po většinu sledovaného období panuje na trhu nízká volatilita s výjimkou dynamického střídání obou režimů.

V případě tří režimové simulace je zajímavé zjištění v oblasti velmi dynamického a pásmového chování všech tří režimů. Všechny režimy jsou v určitých pásmech posteriorní pravděpodobnosti a chovají se v závislosti na cenovém procesu. Období nízké volatility představované režimem 1 velmi zřídka nastává. Hodnota pravděpodobnosti nepřesáhne 0,5. U „neutrální“ hodnoty volatility dochází k trvalejšímu působení prostřednictvím vyšších hodnot pravděpodobnosti. V letech 2015-2017 se režim 2 dostal k nízkým hodnotám pravděpodobnosti výskytu. V tomto období zde převládala vysoká volatilita představující režim 2. U režimu 3 lze pozorovat časté přepínání s režimem vysoké volatility.

U detekce režimů a struktury volatility lze shrnout, že u komodity cukr převládala spíše neutrální volatilita s občasnými šoky v podobě přítomnosti volatility vysoké.

Sentiment na trhu cukerních futures kontraktů na základě zjištění v podobě skrytých stavů a režimů se jeví jako neutrální, kdy převládají investoři a obchodníci s povahou rizikově neutrální. Nicméně i na tomto trhu dochází k náhlým šokům. Přepínání jednotlivých režimů volatility zde není tolik časté, přestože se zde v menším rozsahu střídají „mírné“ období s obdobím vysoké volatility.

Volatilita cen na trzích komoditních futures v letech 2012-2020 byla ovlivněna řadou faktorů, které odrážejí složitou dynamiku a propojenost světového zemědělství a finančních trhů. Nejvýznamnějšími faktory určující změnu režimů je vliv počasí a přírodních jevů. Problematické jsou stavy sucha nebo časté záplavy, které mají významný vliv na produkci daných komodit. U většiny komodit docházelo koncem sledovaného období, tj. mezi roky 2018-2019 k rychlejšímu přepínání zvláště ve dvou-režimové simulace, a to vlivem Brexitu.

Zjištěním, které potvrdí vhodnost zvolených režimů, je v propojenosti režimů a logaritmických výnosů. S blízkými hodnotami logaritmických výnosů blízko 0 dochází k častější pravděpodobnosti výskytu režimů s nízkou hodnotou cenové volatility.

Výsledky simulace a determinace režimů pomocí HMM potvrzují, že režimy jsou silně závislé na struktuře emisních pravděpodobností. V rámci jednotlivých úrovní spjaté s režimy jsou stavy závislé na jednotlivých komoditách.

Komoditní futures kakaava představují pro tvorbu investiční strategie v rámci režimu s averzním chováním k riziku jako vhodnou složku uvažovaného portfolia, neboť skryté stavy generovaly trvalou pravděpodobnost neutrálního režimu cenové fluktuace. Aplikovat lze komoditní futures kakaava do portfolií do portfolií typu buy and hold, nebo ryze kontrariánských, kdy se očekává návrat k typické ceně.

Analýza jednotlivých režimů volatilit prostřednictvím modelu HMM přináší výhodu v detekci jejich skrytých stavů. U komodit pšenice a sójových bobech jsou režimy významnější (Luo, J., et al.; 2022).

5.7 Analýza spillover efektů volatility a vzájemné propojenosti

V rámci této kapitoly jsou analyzovány efekty přelévání volatility mezi komoditami a vzájemné propojenosti. Celá kapitola je založena na přístupu Diebold-Yilmaz (2009; 2012) vzájemné propojenosti popsanému v metodické části. V první části je provedena analýza úplného vzorku konektivit a přelévání volatilit, následně jsou zjištěny výsledky v rámci čisté dynamického spillover efektu u jednotlivých komodit. Na konci kapitoly jsou popsány komentáře k celkovému síťovému grafu párových vztahů transmise.

Tato kapitola má za cíl zodpovědět následující výzkumné otázky v oblastech:

- Existuje mezi komoditami efekt přelévání volatility?
- Která komodita je nejvýznamnější příjemce volatility?
- Která komodita je nejvýznamnějším transmitterem volatility?

5.7.1. Analýza úplného vzorku přelévání volatility

Tato sub-kapitola je založená na analýze pomocí výsledků z tabulky společných vzájemných propojených vztahů mezi všemi trhy a s celým trhem jako celek.

Tab. č. 7 zobrazuje úplný vzorek hodnot DY přelévání volatility a vzájemné propojenosti. Jedná se o vzájemné vztahy příjemce/transmitterů volatility. Komodity kukuřice, pšenice, káva a

kakao jsou příjemci volatility z ostatních trhů. Naopak komodita sójové boby je kladnou hodnotou ve výši 6,79 % v roli transmittera volatility do ostatních trhů. Komodita cukr představuje s 0,46 % také transmittera. Hodnota 62,49 % představuje výši celkového indexu přelévání mezi všemi komoditami. Na diagonále jsou zobrazeny hodnoty přelévání volatility v rámci jedné komodity. Nejsilněji je zasažena komodita kukuřice s 92 %. Z výsledků analýzy také vyplývá, že 17,71 % variancí v ceně pšenice je způsobeno kvůli volatilitě ostatních komodit. Lze konstatovat, že je pšenice velmi náchylná ve variabilitě cen z ostatních komoditních trhů. Další komoditou, která je ovlivněna šoky z ostatních trhů jsou sójové boby s 11,72 %. Naopak nejmenší vliv na variace z ostatních trhů má komodita kakao s hodnotou 7,74 %.

Tabulka 8: Úplný vzorek spillover efektů

	Pšenice	Kukuřice	Sójové boby	Káva	Kakao	Cukr	FROM
Pšenice	82.29	1.81	11.18	1.75	1.24	1.74	17.71
Kukuřice	2.11	91.71	1.77	1.11	1.24	2.05	8.29
Sójové boby	5.35	1.63	88.28	1.31	1.56	1.86	11.72
Káva	1.86	1.65	1.73	91.23	1.67	1.86	8.77
Kakao	1.47	1.13	2.20	1.73	92.26	1.21	7.74
Cukr	1.67	1.75	1.63	1.70	1.51	91.74	8.26
TO	12.46	7.97	18.50	7.61	7.23	8.72	62.49
NET	-5.25	-0.32	6.79	-1.17	-0.51	0.46	

Zdroj: R Studio

Menší efekt v podobě přelévání volatility zahrnují komodity kukuřice, káva, cukr a kakao. Tuto skupinu komodit lze přiřadit k méně ohroženým cenovými šoky z ostatních trhů. V případě přenosu neboli vysílání šoků volatility dochází k nejvyššímu 18,5% přelévání z trhu sójových bobů do ostatních trhů v rámci sledovaného systému komodit. Pšenice vykazovala přibližně 12,5 % přenosu jejich šoků do ostatních trhů. Naopak k nejmenšímu přenosu šoků volatility docházelo u komodity kakao, kávy a kukuřice. Toto zjištění je v souladu s výzkumem Bonato, M. (2019), který zjistil, že nejvíce propojenými komoditami jsou pšenice, kukuřice a sójové boby.

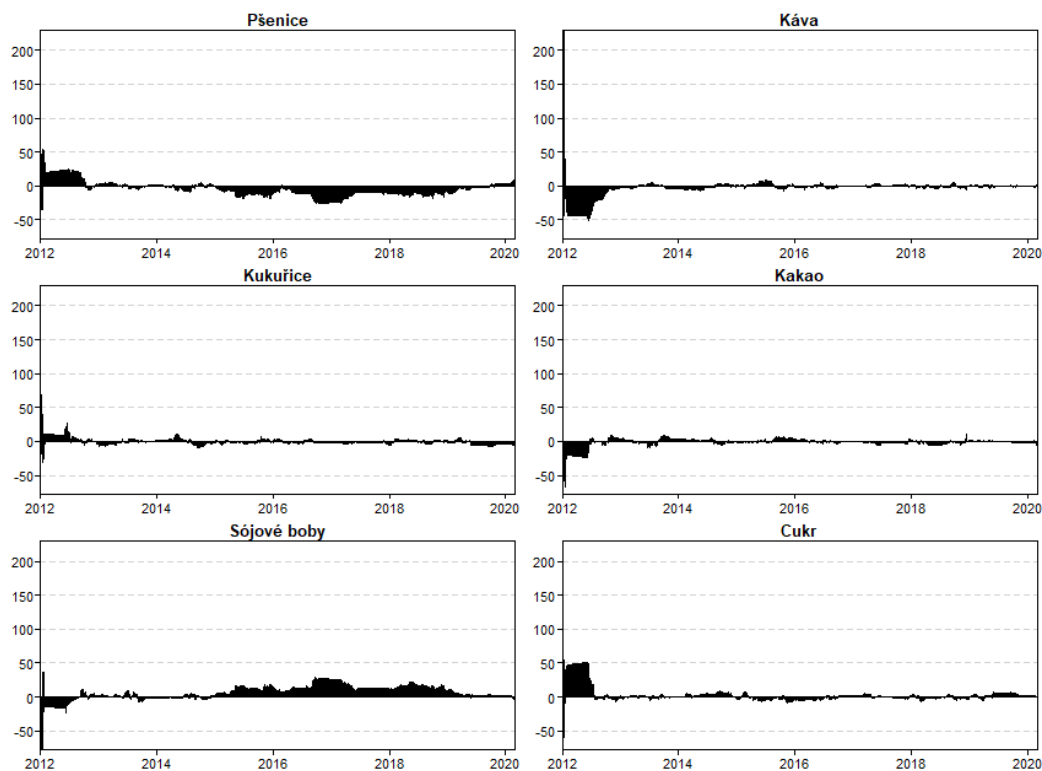
V rámci párového porovnání úplného vzorku efektů přelévání volatility mezi komoditami nejvyšších hodnot 5,35 % dosahují sójové boby a pšenice, kde je v rámci systému z trhu pšenice přeléváno na trh sójových bobů takové množství cenové fluktuace, respektive rizika. Naopak z trhu sójových bobů je asymetricky distribuováno více než 11 % efektů volatility. Hodnoty nad 2 % dosahuje přelévání z trhu pšenice na trh kukuřice, z trhu sójových bobů do trhu kakaa a cukru do kukuřice.

5.7.2. Dynamická a síťová analýza přelévání volatility

V rámci této sub-kapitoly jsou analyzovány párové vztahy, celkový index přelévání a síťovou propojenost jednotlivých komodit. V souvislosti s dynamickým zobrazením symetričnosti efektů přelévání šoků volatility je vyhodnocen index přelévání a jeho změny v čase.

Následuje analýza směrové propojenosti trhu, viz obr. č. 40., kde jsou zobrazeny hodnoty celkové propojenosti a přelévání volatility u jednotlivých komodit. Komodita pšenice je významným příjemcem volatility během celého sledovaného období. Naopak komodita sójové boby do ostatních trhů přelévá své cenovou fluktuace. Na začátku období v roce 2012 docházelo k rychlým fluktuacím u všech komodit mezi příjemcem a transmitere volatilit. U komodity pšenice docházelo po roce 2014 k trendovému a soustavnému poklesu ceny. V tomto období docházelo k nárůstu hodnot celkovému indexu propojenosti všech komodit do záporných hodnot. Ze zjištění tudíž plyne, že s poklesem ceny docházelo k poklesu hodnoty celkového směrové indexu u komodity pšenice do záporných hodnot a setrvání po celou zbývající dobu pozorování.

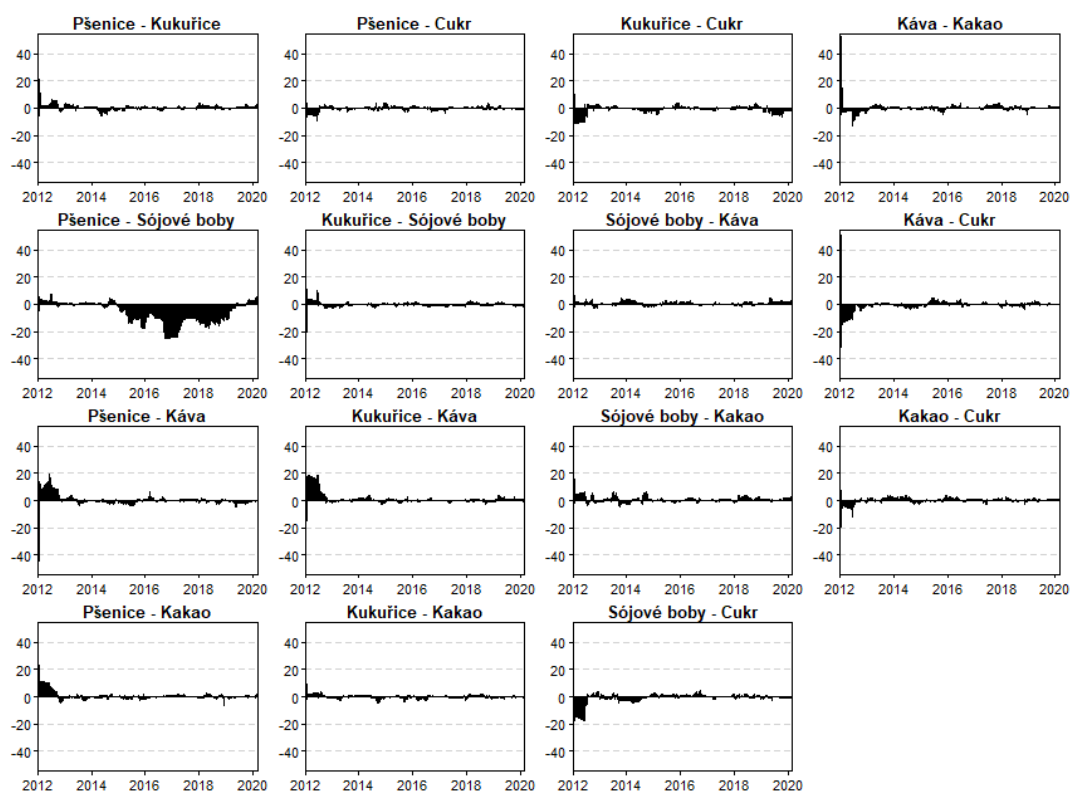
Obrázek 40: Směrová propojenost sítě



Poznámka: Výsledky jsou založeny na modelu TVP-VAR se dvěma zpožděními, určenými podle AIC, a 100denním horizontem předpovědi. Černá oblast představuje výsledky rozšířené společné konektivity. Čistá volatilita vysílací proměnné (kladná) a přijímací (záporná) v časově proměnlivém procesu; R-Studio

Sledované komodity a jejich propojenost jsou založeny na modelu, který předpokládá časovou závislost. Určením komodity, která je primárně vysílací proměnnou do systému lze implikovat její nezranitelnost vůči okolnímu riziku na trhu zemědělských komodit. Káva představuje komoditu jako náchylnou k přijímání šoků v post-krizovém období. Po roce 2012, kdy docházely projevy a efekty finanční krize přelévání dosahovalo až 40 % z ostatních trhů v síti. Naopak cukr představuje komoditu, kterou v post-krizovém období moc šoků volatility z ostatních trhů komodit nezasáhlo. Naopak volatilita cukru se přelila ve výši téměř 50 % do první poloviny roku 2012.


Obrázek 41: Čistá párová propojenost sítě



Poznámka: Výsledky jsou založeny na modelu TVP-VAR se dvěma zpožděními, určenými podle AIC, a 100denním horizontem předpovědi. Čistá volatilita vysílací proměnné (kladná) a přijímací (záporná) v časově proměnlivém procesu; R-Studio

Nejvýznamnějším komoditním párem je pšenice a sójové boby, kde dochází v průběhu let 2015 až 2020 k negativnímu vztahu se silným napojením pšenice jako příjemce cenových fluktuací, viz obr. č. 41. V čistém párovém porovnání docházelo k nejvyšším hodnotám zvláště po roce 2015 přelévání rizika z trhu sójových bobů na trh pšenice. V post-krizovém období po roce 2012 docházelo k půlročním pozitivním efektům přelévání rizika z trhu pšenice na trh kávy, z trhu kukuřice na trh kávy a z trhu pšenice na trh kakaa. Na začátku roku 2012 a do konce prvního kvartálu byly přelity šoky volatilita z trhu cukru na trh kávy.

Obrázek 42: Celkový index přelévání




Poznámka: Výsledky jsou založeny na modelu TVP-VAR se dvěma zpožděními, určenými podle AIC, a 100denním horizontem předpovědi. Celkový efekt přelévání volatility, vysílací proměnné (kladná) a přijímací (záporná) v časově proměnlivém procesu; R-Studio

Obrázek č. 42 zobrazuje celkový index přelévání a propojenosti všech komodit v systému. Vývoj indexu představoval klesající trend po celou dobu pozorování. Na začátku období index vykazoval kladných hodnot až 70 %, které se postupně snížily na hodnoty pod 20 % celkové propojenosti. Lze konstatovat, že mezi komoditami došlo k výraznému snížení propojení a přelévání volatility. Na konci období v roce 2020 se hodnota indexu ustálila. Vyšší hodnoty celkového indexu propojenosti všech trhů indikují silnější výskyt spillover efektů. Po roce 2012 zaznamenal index TCI vysokých hodnot, které však během roku značně poklesly, tj. doznívání finanční krize a dluhových pastí v Evropě. Asymetrického chování z dlouhodobějšího poklesu dosáhl v roce 2019, kdy panovala nejistota na všech trzích kolem Brexitu.

Z ekonomických implikací mají výsledky vliv na přelévání rizika mezi zemědělskými komoditami na uzavřeném trhu bez dosahu na ostatní trhy.

Obrázek 43: Propojení sítě komodit



Poznámka: Obrázek zobrazuje strukturu konektivity šoků na základě TVP-VAR se dvěma zpožděními určenými podle AIC a 100denním horizontem předpovědi. Jsou zde modré a žluté uzly označující vysílající, resp. přijímající volatilitu. Velikost uzlu určuje velikost stupně vysílání nebo přijímání. Podle tloušťky šipek lze analyzovat vliv dvou proměnných.

Síťové propojení všech komodit zobrazuje spojnice s komoditami, viz obr. č. 43. Nejvýznamnějším vztahem je mezi komoditami pšenice a sójové boby. Zde je potvrzen silný vztah bez směrových ukazatelů, tudíž je zde přijímací/vysílací vztah vyrovnán přes párovou analýzu propojenosti. Ostatní komodity nejsou významně propojeny. Komodity kukuřice, káva, kakao a pšenice jsou charakteristické, že přijímají transmise šoků, nicméně významný vztah existuje jen u komodity pšenice, která je propojena se sójovými boby. Modrými uzly jsou označeny cukr a sójové boby jako vysílací komodity šoků volatility. Cukr, káva, kakao a kukuřice představují nejméně významnými komoditami vystaveny transmisí šoků danou velikostí jednotlivých uzlů.

Z uvedených zjištění lze konstatovat, že závislá propojenost komodit a jejich vztahu, který přelévá riziko, je indikátorem pro investiční rozhodnutí. Ostatní komodity mají méně významný vliv a nejsou tak silně propojené mezi sebou. Bonato, M. (2019) ve svém výzkumu zkoumal efekty přelévání a celkovou propojeností mezi trhy zemědělských komodit a došel k závěrům, že nejvíce korelované byly komodity patřící do obilnin. Nejvýznamnějším vztahem

je mezi komoditami pšenice a sójové boby. Zde je potvrzen silný vztah bez směrových ukazatelů, tudíž je zde přijímací/vysílací vztah vyrovnán přes párovou analýzu propojenosti. Ze studie Diebold a Yilmaz (2010) je ve výhodnější pozici vysílací komodita než naopak. V rámci síťové propojenosti jednotlivých komodit párové porovnání potvrdilo, že mezi komoditními futures existují velké rozdíly, kdy nedošlo k zachycení vztahu u všech proměnných.

Využití konektivity založené na modelu TVP-VAR eliminuje ztráty informací nebo potřebu užití klouzavého okna (Balcilar et al, 2021). Časově variační faktor v modelování přelévání volatility mezi jednotlivými komoditami implikuje, že lze lépe pozorovat proměnlivost a variaci.

Výsledky párového a celkového propojení sítě přelévání volatility má vliv na hodnocení rizika. V případě, že není riziko zpracováno v rámci vnitřních autoregresních procesů šoků volatility, tak postupuje do dalších navázaných trhů. Z hlediska tvorby investičního portfolia založeném na vztahu futures kontraktů pšenice a sójových bobů je potřeba uvažovat asymetrický vztah mezi těmito komoditami. Investiční implikace spočívá v zařazení jak pšenice, tak sójových bobů do uvažovaného portfolia, kdy dochází ke „zrušení“ protichůdných šoků volatility.

Dle Hamadi et al. (2017) docházelo k obousměrnému přelévání volatility mezi trhy sójových bobů a pšenicí. Nicméně převažovalo větší přelévání na trh pšenice než naopak. Fundamentální šoky a spekulativní efekty mají významnější vlivy spíše ve směru toku na trhy obilnin. Přelévání volatility mezi sójovými boby a pšenicí má permanentní strukturu. Pomocí párové síťové analýzy byla potvrzena obousměrná struktura mezi zmíněnými komoditami. V rámci období doznívání finanční krize, a zvláště po roce 2012 kukuřice byla transmitterem šoků volatility spíše na trhy energetických komodit. Na základě výsledků párového porovnání komodit se tento jev potvrdil.

Mezi komoditami sójové boby a pšenice dochází ke snížení výhod diverzifikace. Pro institucionální investory nebo zemědělské producenty tento stav znamená vyšší náklady na řízení rizika v delším časovém období. Správci portfolií by měli spíše uvažovat ostatní komodity, mezi kterými neprobíhá nijak významný přenos rizika. Z výsledků také vyplývá, že zde existuje v rámci čistého nenulového přenosu rizika silný asymetrický efekt mající vliv na trh pšenice.

6 Politické a investiční implikace

Investoři a tvůrci politik musí vypracovat komplexní strategie řízení rizik, aby zmírnili nepříznivé dopady kolísavých cen zemědělských komodit. Tyto strategie mohou zahrnovat vytvoření hedgeových fondů, fondů na podporu udržitelného klimatu a strategii pro ochranu producentů a farmářů před zvýšenou kolísavostí na zemědělských komoditních trzích.

Pro implementaci strategie v rámci udržitelnosti a na potravinové bezpečnosti by vlády a lokální tvůrci politik měli zaměřit na jednotlivé oblasti podpory:

- *Obchodní politika:* Ze výsledků analýzy vyplývá, že zemědělské komodity představují specifický systém fungování a přelévání nestability v cenách uvnitř propojenosti všech sledovaných trhů. Silný efekt transmise šoků cenové volatility je potvrzen u komodit pšenice a sójových bobů, kde je pšenice v roli příjemce, a naopak sójové boby jsou silným transmitterem. Pro tvůrce obchodních politik je důležité zohledňovat silnou roli základních zemědělských komodit a jejich cenové šoky, které se přelévají.
- *Inovace, výzkum a vývoj:* Světové společenství a zemědělské organizace by se měli zaměřit na permanentní zemědělský výzkum jako například zlepšení výnosů plodin, nové zásady zemědělských postupů a celková udržitelnost zemědělského sektoru. Celkové snížení tvorby šoků má eliminační efekt na cenovou volatilitu a tím roste zajištění potravinové bezpečnosti. Nejvýznamnější šoky volatility, které se přelévají jsou ze strany trhu sójových bobů.

Z hlediska implikací pro investory a tvůrce obchodních strategií lze nalézt na základě výsledků výzkumu možné nástroje:

- *Diverzifikace*⁵⁶: Na základě provedených koherentních analýz a cenových vztahů mezi komoditami je možné využít nástroj rozložení do různých aktiv či komodit v rámci portfolia. Cílem je eliminace rizika, které souvisí s volatilitou portfolia jako celku. Implikace jsou diskutované níže, kde je vytvořeno teoretické investiční komoditní portfolio.
- *Dlouhodobá investiční strategie*: Strategie, které jsou zaměřené na dlouhodobý růst v rámci globálního prostředí, nejsou postihnuté krátkodobými nebo přirozenými cenovými výkyvy. Výsledek analýz implikuje neexistenci žádné ze sledovaných komodit, která splňuje podmínku dlouhodobého (hodnotového) růstu v čase.
- *Řízení rizika*: V rámci aplikace skrytých režimů volatilit je možné rozpoznat různé druhy režimů, které jsou nepozorovatelné za normálních okolností. Analýza období nízké a vysoké volatility přispívá k rozhodnutí o vstupu a výstupu z obchodů. Přítomnost režimu se zvýšenou volatilitou eliminuje snahu o vstup do tendujícího trhu. Z výsledků analýzy propojenosti vyplývá, že komodita sójové boby má bezpečné postavení, neboť je silným transmitterem rizika mezi sledovanými komoditami. Naopak komodita pšenice, je zde determinována jako silný příjemce rizika.

Následuje zobrazení investiční simulace na základě časově frekvenční koherentní analýzy prostřednictvím investičního horizontu 150–252 obchodních dnů:

$$pšenice = \begin{cases} cukr, kakao, káva; zahrnutí v portfoliu \\ 0; jinak \end{cases}$$
$$kukuřice = \begin{cases} cukr, kakao, káva; zahrnutí v portfoliu \\ 0; jinak \end{cases}$$

⁵⁶ Diverzifikace investic znamená rozložení do různých tříd aktiv či komodit s cílem snížení směrodatné odchylky jednotlivých skupin v celkovém portfoliu aktiv.

Ekonomickou implikací pro investory, kteří využívají ve svých portfoliích kontrakty futures skládající se ze zemědělských komodit, je možnost zahrnutí komodit pšenice společně s ostatními komoditami při eliminaci rizika vzájemné korelace s komoditou kukuřice. Tato implikace vychází z potvrzeného vzorku silné korelace mezi oběma komoditami. Pokud jsou v uvažovaném investičním portfoliu zařazeny tyto komodity spolu, tak platí stav 0, který představuje absenci diverzifikace, tudíž je portfolio vystavené úplnému riziku kolísání.

Analýza přelévání volatility mezi jednotlivými trhy přináší zajímavý pohled pro možnou diverzifikaci rizika. Teoretické diverzifikované portfolio zařazení jednotlivých komoditních futures je pak navrženo jako:

$$portfolio_{Div} = \begin{cases} p\text{šenice, sójové boby}; 1 \\ 0; jinak \end{cases}$$

Při splnění výše uvedených podmínek v rámci 1 je asymetrické přelévání absorbováno v rámci diverzifikovaného portfolia. Ostatní analyzované komodity nemají významný vliv.

Řízení portfolia představuje jeden z nejdůležitějších činností investičních manažerů a traderů. Pro investiční příležitosti je nutné determinovat počet režimů. Simulace skrytých stavů na Z výsledků časově frekvenčních koherentních vztahů vyplývá, že nejsilnějšího korelačního vztahu je dosaženo na v delších časových horizontech, tj. více mezi 150–252 obchodních dnů v jednom roce. Na základě analýzy přecházejícího/zpožděného vztahu je obtížné určit jednoznačný dlouhodobý vztah mezi komoditami, nicméně u komodit pšenice a kukuřice v delším období je možné detekovat, že pšenice předchází cenu kukuřice. Budování investiční portfolií na základě skrytých Markovských modelů přináší pohled to dvou a tří-režimových stavech volatility a využití na trhu zemědělských komodit. komoditních trzích přinesla zjištění, že logaritmické výnosy jsou silně korelované s úrovněmi volatilit. Determinace různých režimů volatilit pomocí HMM přináší možnost zajištění proti trendům panujícím na trzích či externím šokům. Praktická implikace HMM přináší investorům využít znalosti období nízké, neutrální či vysoké volatility na komoditních trzích v případě specifických znalostí pro každou komoditu.

7 Závěr

Disertační práce je zaměřená na komplexní analýzu cenové volatility na trzích futures zemědělských komodit. Literární rešerše poskytuje přehled o samotných trzích zemědělských komodit, metod měření cenové volatility, efektů přelévání a celkovém obraze týkající se volatility jako takové. Empiricky je práce pojata jako souhrn několika na sebe navazujících částí výzkumu volatilit na komoditních trzích. Nejprve je provedena analýza vlnových transformací pro zachycení rozdílnosti škál dekomponovaného signálu komoditních cen s vlivem na koherentní a fázové vztahy. Na tuto kapitolu navazuje výzkum jednotlivých režimů volatilit prostřednictvím alternativních metod strojového učení. V souvislosti s užitím těchto metod jsou zachyceny nepozorované stavy cenových fluktuací. Poslední částí výzkumu navazující na režimy volatilit je analýza efektů přelévání volatility, respektive šoků rizika, které jsou nepříznivé pro komoditní ceny zvláště pro investory a zemědělské producenty.

Na základě empirické analýzy disertační práce byly zodpovězeny následující otázky:

1) *Ve kterých obchodních periodách dochází k vyšším cenovým variacím u jednotlivých zemědělských komodit?*

V rámci analýzy DWT byla detekovaná perioda s nejvyšší výkyvy od 2–4 obchodních dní, na základě denních dat. Komodita káva představuje nejvyšší cenovou variabilitu během sledovaného období. Po roce 2012 docházelo k významným výkyvům ceny na trhu kukuřice, kde v rámci úrovně d_1 byly zaznamenány nejvyšší hodnoty škálové fluktuace.

2) *Na jakých frekvencích jsou zemědělské komodity mezi sebou korelované?*

Z dlouhodobého vztahu spíše na úrovních 150–250 Hz, a to mezi kávou a cukrem. U komodit pšenice a kukuřice převažuje střednědobý koherentní vztah.

3) *Existuje mezi zemědělskými komoditami globální nebo tranzitní efekt?*

U většiny sledovaných komodit převládá vztah globální na vyšších periodách, který podléhá více střídání. Nejvýznamnější globální vztah je detekován mezi komoditami káva a cukru. Tento vztah fundamentálně odpovídá střídáním klimatu v Brazílii. Naopak nevýznamné koherentní vztahy byly potvrzeny u komodit pšenice a kakao.

4) *Které zemědělské komodity jsou párově předbíhající a zpoždované?*

U komodit pšenice a kukuřice je zjištěn nejasný vztah na střednědobých až dlouhodobých škálách. Jasně detekován je vztah mezi cukrem a kávou na nejvyšších globálních úrovních, kde cukr dominuje kávě. V rámci fázové diference byl potvrzen i anticyklický vztah mezi zmíněnými komoditami, ve kterém se ceny obou komodit pohybují o rozdíl $\pi/2$.

5) *V jaké frekvenci se mění posteriorní pravděpodobnosti režimů volatility na komoditních zem. trzích?*

U komodit pšenice a kukuřice dochází ke stabilním a stacionárním změnám. Stálejší chování režimů je detekováno u komodity sójové boby. Nejrychlejší dynamiku má střídání posteriorních pravděpodobností u komodity cukr, kde dochází ke střídání režimů neutrální a vyšší volatility. Naopak nejpomalejší dynamika střídání režimů je u komodity kakao.

7) *Které zemědělské komodity jsou vysílající a přijímající šoky volatility?*

Významnou komoditou, co předává šoky volatility jsou sójové boby. Naopak přijímající komoditou je komodita pšenice. Sójové boby předávají spillover efekty volatility ve výši více než 11 %, naopak pšenice vysílá jen 5 % efektů. Ostatní komodity vysílají či přijímají spillover efekty v rozmezí 1 % - 2 % šoků.

Pro zjištění, zda se ceny a volatility komodit pohybují společně jsou aplikovány metody vlnové transformace a dekompozice signálu do časově frekvenční oblasti. Samotné užití metod založených na Fourierově transformaci má přidanou hodnotu v ekonomickém výzkumu, neboť původně tyto nástroje byly aplikovány na fyzikálně-přírodní oblasti.

Analýza DWT finančních časových řad přináší výhody v oblasti dekompozice vysokofrekvenčních časových řad a detekci změn ve variabilitě, a to zvláště u volatilních komodit. V rámci nižších period obchodních dní (2 dny) jsou detekovány společné vzorky strukturálních změn. Vliv krize po roce 2012 byl promítnut do ceny cukru, kde došlo k větším odchylkám v cenovém procesu.

Na základě výsledků vlnové koherence byla prokázána vzájemná souvislost mezi komoditami pšenice a kukuřice v dlouhém a krátkém období. Významnější cenové vztahy byly nalezeny zvláště u komodit pšenice a kukuřice, kde docházelo v průběhu celého sledovaného období k cenovým závislostí. Pšenice a kukuřice jsou i na základě robustního testu částečné vlnové koherence komodity s vyšší mírou korelace s vyloučením vlivu ostatních uvažovaných komodit. V rozmezí 2012–2020 jsou komodity pšenice a sójové boby cyklicky předcházející ostatním komoditám.

V rámci determinace různých režimů cenových volatilit v cenovém procesu u jednotlivých komodit je simulováno pomocí metody skrytých Markovských modelů v rámci strojového učení bez učitele přepínání stavů s různými stupni cenové volatility. Komodita kakao a káva vykazuje v rámci 3režimového modelu HMM permanentně vyšší hodnoty posteriorní pravděpodobnosti ve sledovaném období. U střídání režimů pásmového charakteru u komodity cukr je zjištěno, že zde dochází k trvalejší přítomnosti režimu s vyšší volatilitou. Naopak posteriorní pravděpodobnost přiřazuje režimu s nižší volatilitou nízké hodnoty.

Výsledky v oblasti vzájemné propojenosti komodit DY analýzy lze konstatovat, že nejvýznamnější vztah mezi příjímáním a vysíláním komoditním trhem byl detekován mezi pšenicí a sójovými boby. Pšenice je významným příjemcem rizik, naopak sójové boby jsou významným transmitterem rizika. Ostatní komodity nepředstavují významné vztahy. V rámci všech sledovaných komodit je zaznamenán index přelévání v hodnotě 68 %. Tato analýza přináší implikaci, že bezpečnější postavení má komodita sójové boby, která významně vysílá rizikové fluktuace.

Jedním z nejčastějších důvodů vzájemného efektu v obou směrech mezi trhy kukuřice a pšenice by mohl být také smysl potravinové bezpečnosti, respektive potravinové politiky. Je to proto, že pšenice je nejdůležitější komoditou používanou pro lidskou výživu.

Zemědělský sektor hraje klíčovou roli při zajišťování potravinové bezpečnosti, obživy a ekonomické stability států na celém světě. V posledních letech však trh se zemědělskými komoditami sužuje vysoká míra volatility, která je způsobena nesčetnými faktory, jako je změna klimatu, geopolitické napětí, narušení dodavatelského řetězce a měnící se preference spotřebitelů. Empirické zjištění proto přináší pohled do dynamického prostředí komoditních trhů nové poznatky o cenové volatilitě a souvislostech mezi samotnými zemědělskými komoditami. Kombinací komplexních metod byly zjištěny nové vazby zemědělských komodit na ostatní trhy v systému futures zemědělských komodit.

8 Seznam zdrojů

1. Abbott, P. C., Hurt, C., & Tyner, W. E. (2008). What's driving food prices? (No. 741-2016-51224).
2. Abel, M. E. (1966). Price discrimination in the world trade of agricultural commodities. *American Journal of Agricultural Economics*, 48(2), 194-208.
3. Aguiar-Conraria, L., & Soares, M. J. (2011). Oil and the macroeconomy: using wavelets to analyze old issues. *Empirical Economics*, 40, 645-655.
4. Ahmend, W. M. (2022) On the higher-order moment interdependence of stock and commodity markets: a wavelet coherence analysis. *The Quarterly Review of Economics and Finance*, 83, 135-151.
5. Akansu, A. N. (1992). Richard A. Haddad. Multiresolution Signal Decomposition.
6. Akansu, A. N., & Medley, M. (1999). MPEG audio coding. In *Wavelet, Subband and Block Transforms in Communications and Multimedia* (pp. 207-253).
7. Alberg, D., Shalit, H., a Yosef, R., (2008). Estimating stock market volatility using asymmetric GARCH models: A Clarification. *Applied Financial Economics*. 18(15), 1201-1208. DOI: 10.1080/09603100701604225. ISSN 0960-3107.
8. Alquist, R., Kilian, L., & Vigfusson, R. J. (2013). Forecasting the price of oil. In *Handbook of economic forecasting* (Vol. 2, pp. 427-507). Elsevier.
9. Antonakakis, N., Chatziantoniou, I., & Gabauer, D. (2020). Refined measures of dynamic connectedness based on time-varying parameter vector autoregressions. *Journal of Risk and Financial Management*, 13(4), 84.
10. Ardila, D., & Sornette, D. (2016). Dating the financial cycle with uncertainty estimates: a wavelet proposition. *Finance Research Letters*, 19, 298-304.
11. Assa, Hirbod, Elton P. HSU, Peter LAURENCE, Cheng OUYANG a Tai-Ho WANG. Financial engineering in pricing agricultural derivatives based on demand and volatility: Joint Summary Report1,2. *Agricultural Finance Review*. 2016, 76(1), 42-53.
12. Babcock, B. A., Fabiosa, J. F. The Impact of Ethanol and Ethanol Subsidies on Corn Prices: Revisiting History. *CARD Policy Briefs*. Center for Agricultural and Rural Development, 2011, 11(5).
13. Baele, L. (2005). Volatility spillover effects in European equity markets. *Journal of Financial and Quantitative Analysis*, 40(2), 373-401.
14. Baffes, J. (2007). Oil spills on other commodities. *Resources Policy*, 32(3), 126-134.

15. Baffes, J., & Dennis, A. (2013). Long-term drivers of food prices (p. 6455). Washington, DC, USA: World Bank.
16. Baffes, J., & Hanriotis, T. (2016). What explains agricultural price movements?. *Journal of Agricultural Economics*, 67(3), 706-721.
17. Bai, Xuezheng, Jeffrey Russel, R., a George C. Tiao, (2003). Kurtosis of GARCH and stochastic volatility models with non-normal innovations: A Clarification. *Journal of Econometrics*. 114(2), 349-360. DOI: 10.1016/S0304-4076(03)00088-5. ISSN 03044076.
18. Balcilar, M., Gabauer, D., & Umar, Z. (2021). Crude Oil futures contracts and commodity markets: New evidence from a TVP-VAR extended joint connectedness approach. *Resources Policy*, 73, 102219.
19. Barbaglia, L., Croux, C., & Wilms, I. (2020). Volatility spillovers in commodity markets: A large t-vector autoregressive approach. *Energy Economics*, 85, 104555.
20. Bartram, S. M. (2000). Corporate risk management as a lever for shareholder value creation. *Financial Markets, Institutions & Instruments*, 9(5), 279-324.
21. Barunik, Jozef and Kocenda, Evzen and Vacha, Lukas, Asymmetric Volatility Connectedness on Forex Markets (July 27, 2016). *Journal of International Money and Finance*, Vol. 77C, 2017, Available at SSRN: <https://ssrn.com/abstract=2815151>
22. Baur, Dirk G., (2011). "Explanatory mining for gold: Contrasting evidence from simple and multiple regressions," *Resources Policy*, Elsevier, vol. 36(3), pages 265-275.
23. Bauwens, L., Laurent, S., & Rombouts, J. V. (2006). Multivariate GARCH models: a survey. *Journal of applied econometrics*, 21(1), 79-109.
24. Bekaert, G., Erb, C. B., Harvey, C. R., & Viskanta, T. E. (1997). What matters for emerging equity market investments. *Emerging markets quarterly*, 1(2), 17-46.
25. Bekaert, Geert a Guojun WU. Asymmetric Volatility and Risk in Equity Markets. *Review of Financial Studies*. 2000, 13(1), 1-42.
26. Bellemare, M. F. (2015) "Rising food prices, food price volatility, and social unrest", *American Journal of Agricultural Economics*, Vol. 97, No. 1, pp. 1-21. ISSN 0002-9092. DOI 10.1093/ajae/aau038.
27. Benavides, G. (2004) "Price Volatility Forecasts for Agricultural Commodities: An Application of Historical Volatility Models, Option Implied and Composite Approaches for Futures Prices of Corn and Wheat".
28. Béné, C., Barange, M., Subasinghe, R., Pinstrip-Andersen, P., Merino, G., Hemre, G. I. and Williams, M. (2015) "Feeding 9 billion by 2050—Putting fish back on the menu", *Food Security*, Vol. 7, No. 2, pp. 261-274. ISSN 1876-4517.

29. BenSaïda, A., Litimi, H., & Abdallah, O. (2018). Volatility spillover shifts in global financial markets. *Economic Modelling*, 73, 343-353.
30. Bera, A. K., & Higgins, M. L. (1993). ARCH models: properties, estimation and testing. *Journal of economic surveys*, 7(4), 305-366.
31. Bilgin, N. M., & Yilmaz, K. (2018). Producer price inflation connectedness and input-output networks. Available at SSRN 3244645.
32. Billio, M., & Pelizzon, L. (2003). Contagion and interdependence in stock markets: Have they been misdiagnosed?. *Journal of economics and business*, 55(5-6), 405-426.
33. Black F., Cox, J. C., (1973), Valuing corporate securities: some effects of bond indenture provisions. *Journal of Political Economy*. 81(3), 637-654.
34. Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of political economy*, 81(3), 637-654.
35. Bliemel, F. (1973). Theil's Forecast Accuracy Coefficient: A Clarification. *Journal Of Marketing Research*, 10(4), 444-. DOI: 10.2307/3149394. ISSN 00222437.
36. Bollerslev, T. (1986) "Generalized Autoregressive Conditional Heteroskedasticity". *Journal of Econometrics*. Vol. 35 (May), pp. 14359.
37. Bonato, M. (2019). Realized correlations, betas and volatility spillover in the agricultural commodity market: What has changed?. *Journal of International Financial Markets, Institutions and Money*, 62, 184-202.
38. Booth, G. G., Chowdhury, M., Martikainen, T., & Tse, Y. (1997). Intraday volatility in international stock index futures markets: meteor showers or heat waves?. *Management Science*, 43(11), 1564-1576.
39. Bostanci, G., & Yilmaz, K. (2020). How connected is the global sovereign credit risk network? *Journal of Banking & Finance*, 113, 105761.
40. Boubaker, H., & Raza, S. A. (2017). A wavelet analysis of mean and volatility spillovers between oil and BRICS stock markets. *Energy Economics*, 64, 105-117.
41. Bouchet – Hourdon. (2011) „ Agricultural Commodity Price Volatility“, An Overview, OECD
42. Bouri, E., Kristoufek, L., & Azoury, N. (2022). Bitcoin and S&P500: Co-movements of high-order moments in the time-frequency domain. *Plos one*, 17(11), e0277924.
43. Brümmer, B., Korn, O., Schlußler, K., Jaghdani, T. J., & Saucedo, A. (2016). Volatility in the after-crisis period: A literature review of recent empirical research. *Agricultural Markets Instability*, 15-28.

44. Bulla, J. (2006). Application of hidden Markov models and hidden semi-Markov models to financial time series.
45. Cafiero, C., & Wright, B. D. (2011). The empirical relevance of the competitive storage model. *Journal of Econometrics*, 162(1), 44-54.
46. Cappé, O. (2011). Online EM algorithm for hidden Markov models. *Journal of Computational and Graphical Statistics*, 20(3), 728-749.
47. Cipra., T. (2013) „Finanční ekonometrie“ ISBN: 978-80-86929-93-4
48. Claessens, S., Dornbusch, R., & Park, Y. C. (2001). Contagion: Why crises spread and how this can be stopped. *International financial contagion*, 19-41.
49. Cohen, M. X. (2019). A better way to define and describe Morlet wavelets for time-frequency analysis. *NeuroImage*, 199, 81-86.
50. Corbet, S., Larkin, C., & Lucey, B. (2020). The contagion effects of the COVID-19 pandemic: Evidence from gold and cryptocurrencies. *Finance Research Letters*, 35, 101554.
51. Cotter, J., Hallam, M., & Yilmaz, K. (2017). Mixed-frequency macro-financial spillovers.
52. Cox, John C., Jonathan E. Ingersoll a Stephen A. Ross. A Theory of the Term Structure of Interest Rates: A new theory. *Encyclopedia of Quantitative Finance*. Chichester, UK: John Wiley, 2010, 120(1), 1-20.
53. CRB Commodity Yearbook 2013: CRB Commodity Yearbook. 1. Chicago: Commodity Research Bureau, 384n. 1. ISBN 9780910418928.
54. Crouhy, M., Galai, D., & Mark, R. (2001). Prototype risk rating system. *Journal of banking & finance*, 25(1), 47-95.
55. Čermák, M., Malec, K., & Maitah, M. (2017). Price volatility modelling–wheat: GARCH model application. *AGRIS on-line Papers in Economics and Informatics*, 9(665-2018-3592), 15-24.
56. Darbyshire, R., Measham, P., & Goodwin, I. (2016). A crop and cultivar-specific approach to assess future winter chill risk for fruit and nut trees. *Climatic Change*, 137, 541-556.
57. Daubechies, I. (1988). Orthonormal bases of compactly supported wavelets. *Communications on pure and applied mathematics*, 41(7), 909-996.
58. De Angelis, L., & Paas, L. J. (2013). A dynamic analysis of stock markets using a hidden Markov model. *Journal of Applied Statistics*, 40(8), 1682-1700.
59. De Long, J. B., Shleifer, A., Summers, L. H., & Waldmann, R. J. (1990). Noise trader risk in financial markets. *Journal of political Economy*, 98(4), 703-738.

60. Deaton, A., & Laroque, G. (1992). On the behaviour of commodity prices. *The review of economic studies*, 59(1), 1-23.
61. Demir, E., Simonyan, S., García-Gómez, C. D., & Lau, C. K. M. (2021). The asymmetric effect of bitcoin on altcoins: evidence from the nonlinear autoregressive distributed lag (NARDL) model. *Finance Research Letters*, 40, 101754.
62. Demirer, M., Diebold, F. X., Liu, L. and Yilmaz, K. (2018)
63. Demirer, M., Gokcen, U., & Yilmaz, K. (2019). Financial sector volatility connectedness and equity returns. Available at SSRN 3099738.
64. Diebold, F. X., & Yilmaz, K. (2009). Measuring financial asset return and volatility spillovers, with application to global equity markets. *The Economic Journal*, 119(534), 158-171.
65. Diebold, F. X., & Yilmaz, K. (2012). Better to give than to receive: Predictive directional measurement of volatility spillovers. *International Journal of forecasting*, 28(1), 57-66.
66. Diebold, F. X., & Yilmaz, K. (2013). Measuring the dynamics of global business cycle connectedness.
67. Diebold, F. X., & Yilmaz, K. (2014). On the network topology of variance decompositions: Measuring the connectedness of financial firms. *Journal of econometrics*, 182(1), 119-134.
68. Diebold, F. X., & Yilmaz, K. (2015). Trans-Atlantic equity volatility connectedness: US and European financial institutions, 2004–2014. *Journal of Financial Econometrics*, 14(1), 81-127.
69. Ding, Z., & Granger, C. W. (1996). Modeling volatility persistence of speculative returns: a new approach. *Journal of econometrics*, 73(1), 185-215.
70. Douc, R., Moulines, E., Stoffer, D., S., (2014) „Nonlinear Time Series-Theory, Methods and Applications with R Examples.“ CRC Press, UK (A Chapman: 978-1-4665-0225-3 pages 531. *Journal of Time Series Analysis*. 35(6), 640-641. DOI: 10.1111/jtsa.12087. ISSN 01439782.
71. Dumas, B., Fleming, J., & Whaley, R. E. (1998). Implied volatility functions: Empirical tests. *The Journal of Finance*, 53(6), 2059-2106.
72. Dupire, B. (1994). Pricing with a smile. *Risk*, 7(1), 18-20.
73. Dymski, G. A. (2005). Financial globalization, social exclusion and financial crisis. *International review of applied economics*, 19(4), 439-457.
74. Emanuel, David C. a James D. Macbeth. Further Results on the Constant Elasticity of Variance Call Option Pricing Model. *The Journal of Financial and Quantitative Analysis*. 1982, 17(4), 533-.

75. Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the econometric society*, 987-1007.
76. Engle, R. F. a Yoo, B., S. (1987) "Forecasting and Testing in Co-Integrated Systems". *Journal of Econometrics*. Vol. 35 (May), pp. 14359. ISSN: 143 – 159
77. Engle, R. F., & Kroner, K. F. (1995). Multivariate simultaneous generalized ARCH. *Econometric theory*, 11(1), 122-150.
78. Fang, WenShwo, Stephen M. Miller a ChunShen Lee, (2008). Cross-Country Evidence on Output Growth Volatility: Nonstationary Variance and Garch Models“. *Scottish Journal of Political Economy*. 55(4), 509-541. DOI: 10.1111/j.1467-9485.2008.00464.x. ISSN 00369292.
79. FAO (2005) *The State of Food Insecurity in the World 2005*. Rome. Farmdoc: University of Illinois at Urbana, Champaign [online]. College of Agricultural, Consumer and Environmental Sciences: Illinois, US, 2015 [2015-01-12]. Available at: <http://www.farmdoc.illinois.edu/>.
80. Firouzi, S., & Wang, X. (2019). A comparative study of exchange rates and order flow based on wavelet transform coherence and cross wavelet transform. *Economic Modelling*, 82, 42-56.
81. Food Agricultural Organization (FAO) (2015) "The state of food insecurity in the world 2015: meeting the 2015 international hunger targets: taking stock of uneven progress“. *Advances in Nutrition*, 2015. [Online]. Available: <http://ambassadors-env.com/en/files/a-i4646e.pdf> [Accessed: 25 Nov. 2021].
82. Franses, P. H. and Van Dijk, D. (1996), Forecasting stock market volatility using (non-linear) Garch models. *J. Forecast.*, 15: 229–235. doi:10.1002/(SICI)1099-131X(199604)15:3<229::AID-FOR620>3.0.CO;2-3
83. Fuller, Thomas C. *The First Hla Workshop of the Americas: Joint Summary Report*1,2. *Tissue Antigens*. 1976, 8(1), 55-60.
84. Gallegati, M. (2014), "Making leading indicators more leading: A wavelet-based method for the construction of composite leading indexes", *OECD Journal: Journal of Business Cycle Measurement and Analysis*, vol. 2014/1,
85. Gao, Jianwei. Optimal investment strategy for annuity contracts under the constant elasticity of variance (CEV) model. *Insurance: Mathematics and Economics*. 2009, 45(1), 9-18.
86. Gatheral, J. (2004). A parsimonious arbitrage-free implied volatility parameterization with application to the valuation of volatility derivatives. Presentation at *Global Derivatives & Risk Management*, Madrid, 0.

87. Gatheral, Jim, Elton P. HSU, Peter LAURENCE, Cheng OUYANG a Tai-Ho WANG. Asimptotics of Implied Volatility in Local Volatility models: Joint Summary Report1,2. *Mathematical Finance*. 2012, 22(4), 591-620.
88. Geman, Helyette a Yih Fong SHIH. Modeling Commodity Prices under the CEV Model. *The Journal of Alternative Investments*. 2009, 11(3), 65-84
89. Geman, Hélyette, Vu-Nhat NGUYEN, Li YANG, Cheng OUYANG a Tai-Ho WANG. Soybean Inventory and Forward Curve Dynamics: Joint Summary Report1,2. *Management Science*. 2005, 51(7), 1076-1091.
90. Gilbert, C. L. (2006). Trends and volatility in agricultural commodity prices. *Agricultural commodity markets and trade: new approaches to analyzing market structure and instability*, 31-60.
91. Gilbert, C. L., & Morgan, C. W. (2010). Food price volatility. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 365(1554), 3023-3034.
92. Giudici, P., & Abu Hashish, I. (2020). A hidden Markov model to detect regime changes in cryptoasset markets. *Quality and Reliability Engineering International*, 36(6), 2057-2065.
93. Glosten, L. R., Jagannathan, R., & Runkle, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *The journal of finance*, 48(5), 1779-1801.
94. Grinsted, A., Moore, J. C., and Jevrejeva, S.: Application of the cross wavelet transform and wavelet coherence to geophysical time series, *Nonlin. Processes Geophys.*, 11, 561–566, <https://doi.org/10.5194/npg-11-561-2004>, 2004.
95. Gülerce, M., & Ünal, G. (2016). Using wavelet analysis to uncover the co-movement behavior of multiple energy commodity prices. *International Journal of Wavelets, Multiresolution and Information Processing*, 14(06), 1650047.
96. Gutierrez, L. (2013). Speculative bubbles in agricultural commodity markets. *European Review of Agricultural Economics*, 40(2), 217-238.
97. Hamadi, H., Bassil, C., & Nehme, T. (2017). News surprises and volatility spillover among agricultural commodities: The case of corn, wheat, soybean and soybean oil. *Research in International Business and Finance*, 41, 148-157.
98. Hamao, Y., Masulis, R. W., & Ng, V. (1990). Correlations in price changes and volatility across international stock markets. *The review of financial studies*, 3(2), 281-307.
99. Hansen, Lars Peter. Large Sample Properties of Generalized Method of Moments Estimators. *Econometrica*. 1982, 50(4), 1029-.
100. Hansen, P. R. and Lunde, A. (2005) „A forecast comparison of volatility models: does anything beat a GARCH(1,1)?“. *J. Appl. Econ.*, 20: 873–889. doi:10.1002/jae.800

101. Heston, S. L. (1993). A closed-form solution for options with stochastic volatility with applications to bond and currency options. *The review of financial studies*, 6(2), 327-343.
102. Huchet-Bourdon, M. (2011) "Agricultural Commodity Price Volatility", OECD Food, Agriculture and Fisheries Papers No. 52, June 2011. [Online]. Available: <http://dx.doi.org/10.1787/5kg0t00nrthc-en> [Accessed: June 5, 2023].
103. Hull, J. (2003). "Options, futures". 5th ed. Upper Saddle River: Prentice Hall, c. Prentice Hall finance series. ISBN 01-300-9056-5.
104. Hull, J. (2009). Solutions Manual [to Accompany] Options, Futures, and Other Derivatives. Pearson Education.
105. Hull, J. C. (1997). Options, futures. and Other Derivative Securities.
106. Chan, K. C., G. Andrew Karolyi, Francis A., Longstaff and Anthony B. Sanders. An Empirical Comparison of Alternative Models of the Short-Term Interest Rate: Joint Summary Report 1,2. *The Journal of Finance*. 1992, 47(3), 1209-1227
107. Chang, C. L., & McAleer, M. (2009). Daily tourist arrivals, exchange rates and volatility for Korea and Taiwan. *Exchange Rates and Volatility for Korea and Taiwan (November 12, 2009)*.
108. Chang, C. L., McAleer, M., & Tansuchat, R. (2009). Volatility spillovers between returns on crude oil futures and oil company stocks. Available at SSRN 1406983.
109. Chen, Jilong (2016) Pricing derivatives with stochastic volatility. PhD thesis, University of Glasgow.
110. Chen, S. (2010). Modelling the dynamics of commodity prices for investment decisions under uncertainty. PhD thesis
111. Chevallier, Commodities and Fundamental Value. *The Economics of Commodity Markets*. Chichester, UK: John Wiley, 2013, , 169.
112. Chkili, W., Hammoudeh, S., & Nguyen, D. K. (2014). Volatility forecasting and risk management for commodity markets in the presence of asymmetry and long memory. *Energy Economics*, 41, 1-18.
113. Choi, S. Y. (2020). Industry volatility and economic uncertainty due to the COVID-19 pandemic: Evidence from wavelet coherence analysis. *Finance Research Letters*, 37, 101783.
114. Chong, C. W., Ahmad, M. I. and Abdullah, M. Y. (1999) „Performance of GARCH models in forecasting stock market volatility“. *J. Forecast.*, 18: 333–343. doi:10.1002/(SICI)1099-131X(199909)18:5<333::AID-FOR742>3.0.CO;2-K
115. Chou, R. Y., & Kroner, K. F. (1992). ARCH modeling in finance. *Journal of Econometrics*, 52(1-2), 5-54.

116. Christiansen, C. (2007). Volatility-spillover effects in European bond markets. *European Financial Management*, 13(5), 923-948.
117. Christie, A. The stochastic behavior of common stock variances Value, leverage and interest rate effects. *Journal of Financial Economics*. 10(4), 407-432.
118. Chui, C. K. (1992). *An introduction to wavelets* (Vol. 1). Academic press.
119. IMF, O., & UNCTAD, W. (2011). *Price volatility in food and agricultural markets: Policy responses*. FAO: Roma, Italy.
120. Iqbal, F., Mukherjee, K., Baah, M., E., Nortey, N. N. E., (2010). M-estimators of some GARCH-type models; computation and application: an autoregressive conditional heteroscedastic (ARCH) models. *Statistics and Computing*. 20(4), 435-445. DOI: 10.1007/s11222-009-9135-x.
121. Irwin, S. H., & Sanders, D. R. (2011). Index funds, financialization, and commodity futures markets. *Applied Economic Perspectives and Policy*, 33(1), 1-31.
122. Javed, F., Mantalos, P. (2013) „GARCH-Type models and the performance of information criteria“, In *Communications in Statistics: Simulation and Computation* 42(8). p.1917-1933. ISSN 0361-0918
123. Jensen, M. J., & Whitcher, B. (2014). Measuring the impact intradaily events have on the persistent nature of volatility. In *Wavelet Applications in Economics and Finance* (pp. 103-129). Cham: Springer International Publishing.
124. Jones, C. S. (2003). The dynamics of stochastic volatility: evidence from underlying and options markets. *Journal of econometrics*, 116(1-2), 181-224.
125. Jorion, P. (2002). How informative are value-at-risk disclosures?. *The Accounting Review*, 77(4), 911-931.
126. Kanas, A. (2000). Volatility spillovers between stock returns and exchange rate changes: International evidence. *Journal of business finance & accounting*, 27(3-4), 447-467.
127. Karolyi, G. A. (1995). A multivariate GARCH model of international transmissions of stock returns and volatility: The case of the United States and Canada. *Journal of Business & Economic Statistics*, 13(1), 11-25.
128. Kassouri, Y., Bilgili, F., & Kuşkaya, S. (2022). A wavelet-based model of world oil shocks interaction with CO2 emissions in the US. *Environmental Science & Policy*, 127, 280-292.
129. Kassouri, Y., Bilgili, F., & Kuşkaya, S. (2022). A wavelet-based model of world oil shocks interaction with CO2 emissions in the US. *Environmental Science & Policy*, 127, 280-292.
130. Ker, SAM and Ardhyula, *Modelling Regime-Dependent Agricultural Commodity Price Volatilities*. 2016. Institute White Paper - 2016.2.

131. Klotz, P., Lin, T.C., Hsu, S.-H. Global commodity prices, economic activity and monetary policy: The relevance of China. *Resources Policy*, 2014, 42, pp. 1-9. ISSN: 0301-4207. DOI: 10.1016/j.resourpol.2014.08.001
132. Kluwer, Rua, A., & Nunes, L. C. (2009). International comovement of stock market returns: A wavelet analysis. *Journal of Empirical Finance*, 16(4), 632-639.
133. Kolman, J., Onak, M., Jorion, P., Taleb, N., Derman, E., Putnam, B., ... & Rozsypal, J. (1998). Roundtable: the limits of VaR. *Derivatives Strategy*.
134. Koutmos, G., & Booth, G. G. (1995). Asymmetric volatility transmission in international stock markets. *Journal of international Money and Finance*, 14(6), 747-762.
135. Krane, J. A refined approach: Saudi Arabia moves beyond crude (2015) *Energy Policy*, 82 (1), pp. 99-104. DOI: 10.1016/j.enpol.2015.03.008
136. Kristoufek, Ladislav a Guojun Wu. Leverage effect in energy futures. *Review of Financial Studies*. 2000, 13(1), 1-42.
137. Kritzman, M., Page, S., & Turkington, D. (2012). Regime shifts: Implications for dynamic strategies (corrected). *Financial analysts journal*, 68(3), 22-39.
138. Krolzig, H. M. (1997). The markov-switching vector autoregressive model. In *Markov-Switching vector autoregressions* (pp. 6-28). Springer, Berlin, Heidelberg.
139. Kroner, K. F., Kneafsey, K. P. and Claessens, S. (1995), Forecasting volatility in commodity markets. *J. Forecast.*, 14: 77–95. doi:10.1002/for.3980140202
140. Kuester, K., Mittnik, S., & Paolella, M. S. (2006). Value-at-risk prediction: A comparison of alternative strategies. *Journal of Financial Econometrics*, 4(1), 53-89.
141. Kuşkaya, S., & Bilgili, F. (2020). The wind energy-greenhouse gas nexus: The wavelet-partial wavelet coherence model approach. *Journal of Cleaner Production*, 245, 118872.
142. Lee, D., D., Faff, R. W. (2009) „Corporate Sustainability Performance and Idiosyncratic Risk: A Global Perspective“. *Financial Review*. 44(2), 213-237. DOI: 10.1111/j.1540-6288.2009.00216.x. ISSN 07328516.
143. Li, K., Wang, X., Xu, Y., & Wang, J. (2016). Lane changing intention recognition based on speech recognition models. *Transportation research part C: emerging technologies*, 69, 497-514.
144. Li, X., Su, C. W., Chang, H. L., & Ma, J. (2018). Do short-term international capital movements play a role in exchange rate and stock price transmission mechanism in China?. *International Review of Economics & Finance*, 57, 15-25.

145. Lin, W. L., Engle, R. F., & Ito, T. (1994). Do bulls and bears move across borders? International transmission of stock returns and volatility. *Review of financial studies*, 7(3), 507-538.
146. Lin, W. L., Engle, R. F., & Ito, T. (1994). Do bulls and bears move across borders? International transmission of stock returns and volatility. *Review of financial studies*, 7(3), 507-538.
147. Lindström, Erik a Fredrik Regland. Modeling extreme dependence between European electricity markets. *Energy Economics*. 2012, 34(4), 899-904.
148. Linetsky, Vadim a Rafael Mendoza. Constant Elasticity of Variance (CEV) Diffusion Model: A new theory. *Encyclopedia of Quantitative Finance*. Chichester, UK: John Wiley, 2010, 120(1), 1-20.
149. Louis: Economic Research, 2016 [2016-03-02]. Available at: <https://research.stlouisfed.org/fred2/>, (Accessed on 10.11.2023).
150. Luo, J., Klein, T., Ji, Q., & Hou, C. (2022). Forecasting realized volatility of agricultural commodity futures with infinite Hidden Markov HAR models. *International Journal of Forecasting*, 38(1), 51-73.
151. Lütkepohl, H. (2013). Vector autoregressive models. In *Handbook of Research Methods and Applications in Empirical Macroeconomics* (pp. 139-164). Edward Elgar Publishing.
152. Maghyreh, A., & Abdoh, H. (2021). The impact of extreme structural oil-price shocks on clean energy and oil stocks. *Energy*, 225, 120209.
153. Mallat, S. G. (1989). A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, 11(7), 674-693.
154. Mallat, S. G. (1989). Multifrequency channel decompositions of images and wavelet models. *IEEE Transactions on Acoustics, speech, and signal processing*, 37(12), 2091-2110.
155. Mallat, S. G. (1989). Multiresolution approximations and wavelet orthonormal bases of $L^2(R)$. *Transactions of the American mathematical society*, 315(1), 69-87.
156. Mandelbrot, B., 1963. The Variation of Certain Speculative Prices. *The Journal of Business*. 36(4), 394-. DOI: 10.1086/294632. ISSN 0021-9398.
157. Maneesoonthorn, O. W. (2015) „High-Frequency Financial Econometrics, by Yacine Aït-Sahalia and Jean Jacod (Princeton University Press, Princeton, NJ, 2014)“, pp. xxiv + 659. *Econ Rec*, 91: 542–544. doi:10.1111/1475-4932.12228

158. Martikainen, T., & Tse, Y. (1997). Intraday volatility in international stock index futures markets: meteor showers or heat waves?. *Management Science*, 43(11), 1564-1576.
159. Martin, W., & Anderson, K. (2012). Export restrictions and price insulation during commodity price booms. *American Journal of Agricultural Economics*, 94(2), 422-427.
160. Martins-Filho, C., Yao, F., & Torero, M. (2018). Nonparametric estimation of conditional value-at-risk and expected shortfall based on extreme value theory. *Econometric Theory*, 34(1), 23-67.
161. Matalgah, M. M., & MacDougall, S. (1997). IEE Proceedings: Vision, Image and Signal Processing. *IEEE SIGNAL PROCESSING MAGAZINE*.
162. Merton, R. C. (1973). An intertemporal capital asset pricing model. *Econometrica: Journal of the Econometric Society*, 867-887.
163. Mitchell, J., Keane, J., & Coles, C. (2009). Trading up: How a value chain approach can benefit the rural poor. London: COPLA Global: Overseas Development Institute.
164. Mitra, S., & Boussard, J. M. (2012). A simple model of endogenous agricultural commodity price fluctuations with storage. *Agricultural economics*, 43(1), 1-15.
165. Musunuru, N., S. Haigh, M., Leatham, D., J. (2014) "Modeling Price Volatility Linkages between Corn and Wheat: A Multivariate GARCH Estimation" *International Advances in] Economic Research*. 20(3), 269-280. DOI: 10.1007/s11294-014-9477-9.
166. Mutascu, M. I., Albuлесcu, C. T., Apergis, N., & Magazzino, C. (2022). Do gasoline and diesel prices co-move? Evidence from the time–frequency domain. *Environmental Science and Pollution Research*, 29(45), 68776-68795.
167. Najand, M. (2002) „ Forecasting Stock Index Futures Price Volatility: Linear vs. Nonlinear Models“. *The Financial Review*. 37(1), 93-104. DOI: 10.1111/1540-6288.00006. ISSN 0732-8516.
168. Nazlioglu, S., Erdem, C., & Soytas, U. (2013). Volatility spillover between oil and agricultural commodity markets. *Energy Economics*, 36, 658-665.
169. Ng, E. K., & Chan, J. C. (2012). Geophysical applications of partial wavelet coherence and multiple wavelet coherence. *Journal of Atmospheric and Oceanic Technology*, 29(12), 1845-1853.
170. Øksendal, Anders, Chongfeng Wu, Li YANG, Cheng OUYANG a Tai-Ho WANG. Irreversible investment problems: Joint Summary Report1,2. *Finance and Stochastics*. 2000-2-1, 4(2), 223-250.

171. Olowe, R., A. (2009) “Modelling Naira/Dollar Exchange Rate Volatility: Application of GARCH and asymmetric Models. *International Review of Business Research Paper* 5: 377 - 398.
172. Omane-Adjepong, M., & Alagidede, I. P. (2019). Multiresolution analysis and spillovers of major cryptocurrency markets. *Research in International Business and Finance*, 49, 191-206.
173. Onour, I. A., Sergi, B. S. (2012) “Modeling and Forecasting Volatility in the Global Food Commodity Prices” (Modelování a Prognózování Volatility Globálních cen Potravinářských Komodit), *Agricultural Economics - Czech*, Vol. 57, No. 3, pp. 132–139.
174. Onour, Ibrahim Ahmed and Sergi, Bruno S. 2011. Modeling and Forecasting Volatility in the Global Food Commodity Prices [Modelování a Prognózování Volatility Globálních cen Potravinářských komodit]. *Agricultural Economics*, Vol. 57, No. 3, pp. 132-139
175. Ott, H. (2014). Extent and possible causes of intrayear agricultural commodity price volatility. *Agricultural Economics*, 45(2), 225-252.
176. Parkinson, M. (1980). The extreme value method for estimating the variance of the rate of return. *Journal of business*, 61-65.
177. Pearson, N. D., & Smithson, C. (2002). VaR: The state of play. *Review of Financial economics*, 11(3), 175-189.
178. Persson, L. (2021). Modelling regime shifts for foreign exchange market data using hidden Markov models.
179. Pesaran, M.H. and Shin, Y. (1998) An Autoregressive Distributed-Lag Modelling Approach to Cointegration Analysis. *Econometrics and Economic Theory in the 20th Century: The Ragnar Frisch Centennial Symposium*, 31, 371-413. DOI: <http://dx.doi.org/10.1017/CCOL0521633230.011>
180. Qi, X., Jiang, J., Cui, X., & Yuan, D. (2020). Moldy peanut kernel identification using wavelet spectral features extracted from hyperspectral images. *Food Analytical Methods*, 13, 445-456.
181. Quaicoe, Techie, Michael, Twenefour, Frank B K, M. Baah, Emmanuel, Nortey, Ezekiel N N, (2015). Modeling variations in the cedi/dollar exchange rate in Ghana: an autoregressive conditional heteroscedastic (ARCH) models. *SpringerPlus*. 4(1), -. DOI: 10.1186/s40064-015-1118-0. ISSN 2193-1801

182. Rapsomanikis, G., & Muger, H. (2011). Price transmission and volatility spillovers in food markets of developing countries. In *Methods to analyse agricultural commodity price volatility* (pp. 165-179). New York, NY: Springer New York.
183. Reider R. (2009) „Volatility forecasting I: GARCH models“, New York: Courant Institute of Mathematical Sciences, New York University. Retrieved 14 January 2014, from http://cims.nyu.edu/~almgren/timeseries/Vol_Forecast1.pdf
184. Rubbaniy, G., Khalid, A. A., Rizwan, M. F., & Ali, S. (2022). Are ESG stocks safe-haven during COVID-19?. *Studies in Economics and Finance*, 39(2), 239-255.
185. Rubinstein, J. H., D. A. THOMAS a Stephen A. ROSS. A variational approach to the Steiner network problem: A new theory. *Annals of Operations Research*. Chichester, UK: John Wiley, 1991, 33(6), 481-499.
186. Said E. Said, and David A. Dickey. “Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order.” *Biometrika*, vol. 71, no. 3, 1984, pp. 599–607. JSTOR.
187. Sanders, D. R., & Irwin, S. H. (2011). The impact of index funds in commodity futures markets: A systems approach. *The Journal of Alternative Investments*, 14(1), 40.
188. Santeramo, F. G., Carlucci, D., De Devitiis, B., Seccia, A., Stasi, A., Viscecchia, R., & Nardone, G. (2018). Emerging trends in European food, diets and food industry. *Food Research International*, 104, 39-47.
189. Sargan, J. D. The Estimation of Economic Relationships using Instrumental Variables. *Econometrica*. 1958, 26(3), 393.
190. Sarris, A. (2012). Trade-related policies to ensure food (rice) security in Asia. In *The rice crisis* (pp. 61-87). Routledge.
191. Shehzad, K., Bilgili, F., Zaman, U., Kocak, E., & Kuskaya, S. (2021). Is gold favourable than bitcoin during the COVID-19 outbreak? Comparative analysis through wavelet approach. *Resources Policy*, 73, 102163.
192. Sherif, M. (2020). The impact of Coronavirus (COVID-19) outbreak on faith-based investments: An original analysis. *Journal of Behavioral and Experimental Finance*, 28, 100403
193. Shik Lee, H. (2004). International transmission of stock market movements: a wavelet analysis. *Applied Economics Letters*, 11(3), 197-201.

194. Scholes, Myron. The Pricing of Options and Corporate Liabilities. *Journal of Political Economy*. 1973, 81(3), 637-654.
195. Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*, 48(1), 1–48.
196. Singh, P., Kumar, B., & Pandey, A. (2010). Price and volatility spillovers across North American, European and Asian stock markets. *International Review of Financial Analysis*, 19(1), 55-64.
197. Susmel, R., & Engle, R. F. (1994). Hourly volatility spillovers between international equity markets. *Journal of international Money and Finance*, 13(1), 3-25.
198. Tadasse, G., Algieri, B., Kalkuhl, M., & Von Braun, J. (2016). Drivers and triggers of international food price spikes and volatility. *Food price volatility and its implications for food security and policy*, 59-82.
199. Taleb, N. N., Goldstein, D. G., & Spitznagel, M. W. (2009). The six mistakes executives make in risk management. *Harvard Business Review*, 87(10), 78-81.
200. Tang, K., & Xiong, W. (2012). Index investment and the financialization of commodities. *Financial Analysts Journal*, 68(6), 54-74.
201. Theodossiou, P., & Lee, U. (1993). Mean and volatility spillovers across major national stock markets: Further empirical evidence. *Journal of financial Research*, 16(4), 337-350.
202. Tillman, J. A. (1973) "The Efficiency of Taking First Differences in Regression Analysis: A Note." *Economic and Social Review* 4.4. 543.
203. Tilman, D., Balzer, C., Hill, J., & Befort, B. L. (2011). Global food demand and the sustainable intensification of agriculture. *Proceedings of the national academy of sciences*, 108(50), 20260-20264.
204. Torrence, C., & Compo, G. P. (1998). A practical guide to wavelet analysis. *Bulletin of the American Meteorological society*, 79(1), 61-78.
205. Torrence, C., & Compo, G. P. (1998). A practical guide to wavelet analysis, *B. Am. Meteorol. Soc.*, 79, 61–78.
206. Torrence, C., & Webster, P. J. (1999). Interdecadal changes in the ENSO–monsoon system. *Journal of climate*, 12(8), 2679-2690.
207. Tulley, E., Lucey, B.M., 2007. A power GARCH examination of the gold market. *Research in International Business and Finance* 21, 316-325.

208. Udejaja, Elias A. (2019) "Measuring Dynamic Return and Volatility Connectedness among Nigerian Financial Markets," *CBN Journal of Applied Statistics (JAS)*: Vol. 10: No. 2, Article 6.
209. Uluceviz, E., & Yilmaz, K. (2020). Real-financial connectedness in the Swiss economy. *Swiss Journal of Economics and Statistics*, 156(1), 1-20.
210. Val, F., Pinto, A., C., F. and Klotzle, M., C. (2014) "Volatilidade e Previsão de Retorno com Modelos de Alta Frequência e GARCH: Evidências para o Mercado Brasileiro". *Revista Contabilidade*. Vol. 25(65), 189-201. DOI: 10.1590/S1519-70772014000200008. ISSN 1808-057x.
211. Viterbi, A. J. (1976). Error control for data communication. *ACM SIGCOMM Computer Communication Review*, 6(1), 27-37.
212. Wang, Y. C., J. Yoshitani a K. Fukami, (2005). Stochastic multiobjective optimization of reservoirs in parallel: A Clarification. *Hydrological Processes*. 19(18), 3551-3567. DOI: 10.1002/hyp.5845. ISSN 0885-6087.
213. Willmot, G. E. (2007). On the discounted penalty function in the renewal risk model with general interclaim times. *Insurance: Mathematics and Economics*, 41(1), 17-31.
214. Yang, G., Zhang, Y., Yang, J., Ji, G., Dong, Z., Wang, S., ... & Wang, Q. (2016). Automated classification of brain images using wavelet-energy and biogeography-based optimization. *Multimedia Tools and Applications*, 75, 15601-15617.
215. Yang, J., Haigh, M., S., and Leatham, D., J. (2001) "Agricultural liberalization policy and commodity price volatility: a GARCH application", *Applied Economics Letters*. Vol. 8(9), 593-598. DOI: 10.1080/13504850010018734. ISSN 1350-4851.
216. Yilmaz, K. (2010). Return and volatility spillovers among the East Asian equity markets. *Journal of Asian Economics*, 21(3), 304-313.
217. Yu, J. (2005). On leverage in a stochastic volatility model. *Journal of Econometrics*, 127(2), 165-178.
218. Zelingher, R., & Makowski, D. (2023). Investigating and forecasting the impact of crop production shocks on global commodity prices. *Environmental Research Letters*, 19(1), 014026.
219. Zhang, Y., Yao, T., He, L., (2015) "Forecasting crude oil market volatility: can the Regime Switching GARCH model beat the single-regime GARCH models?" Papers 1512.01676, arXiv.org.
220. Zhao, C., He, M., & Zhao, X. (2004, November). Analysis of transient waveform based on combined short time Fourier transform and wavelet transform. In 2004 International

Conference on Power System Technology, 2004. PowerCon 2004. (Vol. 2, pp. 1122-1126). IEEE.

221. Zilberman, D., Hochman, G., Rajagopal, D., Sexton, S., Timilsina, G. The impact of biofuels on commodity food prices: Assessment of findings (2013) *American Journal of Agricultural Economics*, 95 (2), pp. 275-281. DOI: 10.1093/ajae/aas037
222. Zivot, E. (2008) "Practical Issues in the Analysis of Univariate GARCH models", *Handbook of Financial Time Series*, Springer, New York