

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra ekonomiky



Diplomová práce

Vliv klimatické změny na výnos pšenice v České republice – ekonometrická analýza panelových dat

Jiří Vacek

© 2024 ČZU v Praze

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Jiří Vacek

Ekonomika a management

Název práce

Vliv klimatické změny na výnos pšenice v České republice – ekonometrická analýza panelových dat

Název anglicky

The Impact of Climate Change on Wheat Yields in the Czech Republic – Econometric Analysis of Panel Data

Cíle práce

Hlavním cílem diplomové práce je zhodnotit vliv klimatické změny na výnos pšenice v České republice s využitím odvozeného ekonometrického modelu panelových dat.

Hlavního cíle práce bude dosaženo realizací několika dílčích cílů: (i) zjistit vliv teplot v jednotlivých měsících na výnos pšenice, (ii) určit vliv měsíčních srážek na výnos pšenice; a (iii) zjistit vliv cen zemědělských vstupů a výstupů.

Metodika

Práce bude rozdělena na část teoretickou a empirickou.

V teoretické části práce budou autorem zpracována teoretická východiska důležitá pro dané téma s využitím metody studia dokumentů. Bude zpracována literární rešerše domácích i zahraničních zdrojů týkajících se konstrukce ekonometrických modelů a jejich testování pro ověření použitelnosti modelu. Zároveň bude prozkoumána literatura týkající se pěstování pšenice v České republice.

V empirické části bude odvozen ekonometrický model výnosu pšenice. Následně bude provedena vizuální analýza a tvorba elementární popisné statistiky pro proměnné vstupující do modelu. Model bude odhadnut a následně testován, zda se v něm nenachází heteroskedasticita, autokorelace a nenormální rozdělení, a případně bude dále upravován. Na závěr bude model sklizňové funkce použit v ex-post analýze a simulaci scénářů budoucího vývoje použitých klimatických proměnných.

Doporučený rozsah práce

60 – 70 stran

Klíčová slova

Ekonometrický model, panelová data, pšenice, heteroskedasticita, autokorelace, cenové indexy, teplota, srážky

Doporučené zdroje informací

- CIPRA, Tomáš. *Finanční ekonometrie*. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.
- Český statistický úřad. [online]. Praha: ČSÚ. Dostupné z: <http://www.czso.cz>
- HÁLOVÁ, P.; MACH, J.; ČECHURA, L.; SLABOCH, J. [online]. Climate Change and Sustainability in Czech Wheat Production. Praha: AGRIS on-line Papers in Economics and Informatics, Vol. 13, No. 4, pp. 9-18. ISSN 1804-1930. 2021. Dostupné z <https://doi.org/10.7160/aol.2021.130402>
- HEIJ, C.; BOER, P.; FRANCES, P. H.; KLOEK, T.; DIJAK, H. K. *Econometric methods with applications in business and economics*. New York: Oxford University Press, 2004. ISBN 0-19-926801-0
- JUST, R. E.; POPE, R. D. [online]. Production Function Estimation and Related Risk Considerations. *American Journal of Agricultural Economics* 61, no. 2: 276-84. 1979. Dostupné z <https://doi.org/10.2307/1239732>
- RAY, S. C.; CHAMBERS, R. G.; KUMBHAKAR S. C. *Handbook of Production Economics*. Singapore: Springer Singapore, 2022. 1807 s. ISBN 978-981-10-3454-1
- Státní zemědělský intervenční fond. [online]. Praha: SZIF. Dostupné z <https://www.szif.cz/cs/>
- YUN, Seong D.; GRAMIG, Benjamin M. [online]. Spatial Panel Models of Crop Yield Response to Weather: Econometric Specification Strategies and Prediction Performance. *Journal of Agricultural and Applied Economics*, 54.1: 53-71. 2022. Dostupné z <https://doi.org/10.1017/aae.2021.29>

1906

Předběžný termín obhajoby

2023/24 LS – PEF

Vedoucí práce

prof. Ing. Lukáš Čechura, Ph.D.

Garantující pracoviště

Katedra ekonomiky

Elektronicky schváleno dne 5. 6. 2023

prof. Ing. Lukáš Čechura, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 3. 11. 2023

doc. Ing. Tomáš Šubrt, Ph.D.

Děkan

V Praze dne 31. 03. 2024

Čestné prohlášení

Prohlašuji, že svou diplomovou práci "Vliv klimatické změny na výnos pšenice v České republice – ekonometrická analýza panelových dat" jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu použitých zdrojů na konci práce. Jako autor uvedené diplomové práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušil autorská práva třetích osob.

V Praze dne 31.3.2024

Poděkování

Rád bych touto cestou poděkoval vedoucímu diplomové práce prof. Ing. Lukáši Čechurovi, Ph.D. za trpělivost, vedení a podporu v průběhu psaní diplomové práce a také poskytnutá data. Dále bych rád poděkoval doc. Ing. Ireně Benešové, Ph.D. za přednášky, které zpříjemnily studium nejen mně, ale i mnoha dalším. Poděkování patří i Ing. Tomáši Vackovi, Ph.D., který mě k magisterskému studiu motivoval. Zároveň patří mé poděkování i PhDr. Vladislavu Dudákovi, který mě naučil, jak důležitá je myšlenka. V neposlední řadě bych rád poděkoval své nejbližší rodině za podporu a pochopení během studia, konkrétně Ing. Jozefu Farbárovi, Nikole Vackové a Tereze Vackové. A speciální poděkování patří i mé přítelkyni Natálii Maletínské, která stála při mém boku během celého studia.

Vliv klimatické změny na výnos pšenice v České republice – ekonometrická analýza panelových dat

Abstrakt

Diplomová práce se zabývala vlivem klimatické změny na výnos pšenice v České republice. Cílem práce bylo zjistit vliv průměrných měsíčních teplot, měsíčních úhrnů srážek a cen zemědělských vstupů a výstupů na výnos pšenice v České republice. K analýze byla využita panelová data od roku 1961 a 2022. Ekonometrická analýza proběhla nejprve za pomoci běžné metody nejmenších čtverců a následně byly k odhadu využity fixní efekty. V modelech byly obsaženy lineární i kvadratické tvary. Kvadratické tvary byly do modelu vloženy za účelem zachycení nelineárního vlivu klimatických proměnných na výnos pšenice. Na základě výsledků, bylo zjištěno, že nejvyšší negativní vliv na výnos pšenice měl teplotní průměr května a června. Statisticky významné byly i teplotní průměry podzimních měsíců předcházejícího roku. Tyto měsíce vykazovaly také negativní vliv na výnos pšenice. Pozitivní vliv na výnos pšenice měly teplotní průměry února a března. V případě srážek vykazoval největší negativní vliv měsíc červen a červenec. Statisticky významné parametry druhého řádu měly posilující negativní efekt na výnos pšenice, a to především v případě teplot. Parametry druhého řádu v případě srážek vyjma ojedinělých případů nevykazovaly statistickou významnost. Poměrový ukazatel cenových indexů měl negativní efekt na výnos pšenice. Oproti tomu technologická změna, kterou v modelu představoval časový trend, měl pozitivní efekt na výnos pšenice.

Klíčová slova: ekonometrické modelování, panelová data, pšenice, heteroskedasticita, autokorelace, cenové indexy, teplota, srážky, klimatická změna

Impact of climate change on wheat yield in the Czech Republic – econometric analysis of panel data

Abstract

The thesis dealt with the effect of climate change on wheat yield in the Czech Republic. The aim of the thesis was to determine the effect of average monthly temperatures, monthly precipitation and prices of agricultural inputs and outputs on wheat yield in the Czech Republic. Panel data from 1961 and 2022 were used for the analysis. Econometric analysis was first conducted using ordinary least squares method and then fixed effects were used for estimation. Both linear and quadratic forms were included in the models. Quadratic forms were included in the model to capture the non-linear effect of climatic variables on wheat yield. Based on the results, it was found that the average temperature of May and June had the highest negative effect on wheat yield. The temperature averages of the autumn months of the previous year were also statistically significant. These months also showed a negative effect on wheat yield. Temperature averages in February and March had a positive effect on wheat yield. In the case of precipitation, the months of June and July showed the greatest negative influence. Statistically significant second order parameters had a strengthening negative effect on wheat yield, especially in the case of temperature. The second-order parameters in the case of precipitation did not show statistical significance except in isolated cases. The price index ratio had a negative effect on wheat yield. In contrast, technological change, represented by the time trend in the model, had a positive effect on wheat yield.

Keywords: econometric modelling, panel data, wheat, heteroskedasticity, autocorrelation, price index, temperature, precipitation, climate change

Obsah

1 Úvod.....	13
2 Cíl práce a metodika	15
2.1 Cíl práce	15
2.2 Metodika	15
3 Teoretická východiska	17
3.1 Popisná statistika a časové řady	17
3.1.1 Aritmetický průměr.....	17
3.1.2 Variabilita	17
3.1.3 Časová řada.....	18
3.2 Ekonometrická analýza	20
3.2.1 Postup sestavení ekonometrického modelu	20
3.2.2 Regresní analýza lineární regrese	20
3.2.3 Náhodná složka.....	22
3.2.4 Vícenásobná regrese	23
3.2.4.1 Elasticita	24
3.2.5 BMNČ.....	24
3.2.6 Best linear unbiased estimation (BLUE)	25
3.2.7 Identické a nezávislé rozdělení	26
3.2.8 Statistická verifikace.....	26
3.2.8.1 Testování významnosti parametru pomocí t-testu.....	26
3.2.8.2 Koeficient determinace.....	27
3.2.8.3 Testování významnosti F-test.....	27
3.3 Předpoklady modelu lineární regrese.....	28
3.3.1 Nulový průměr reziduální složky	28
3.3.2 Heteroskedasticita.....	29
3.3.2.1 Důsledky heteroskedasticity pro model.....	29
3.3.2.2 Důvody heteroskedasticity	29
3.3.2.3 Detekce heteroskedasticity	30
3.3.2.4 Řešení heteroskedasticity	30
3.3.3 Autokorelace.....	30
3.3.3.1 Důvody autokorelace.....	30
3.3.3.2 Detekce autokorelace.....	31
3.3.3.3 Důsledky autokorelace	31
3.3.3.4 Řešení autokorelace.....	31

3.3.4	Korelace mezi regresory a reziduální složkou	32
3.3.5	Multikolinearita.....	32
3.3.5.1	Důsledky perfektní multikolinearity.....	32
3.3.5.2	Řešení multikolinearity.....	33
3.4	GLS	33
3.5	Panelová data a jejich odhad	34
3.5.1	Fixed effects – fixní efekty	34
3.5.1.1	Podmínky fixních efektů.....	34
3.5.1.2	Zachycení fixních efektů pomocí heterogenních konstant	35
3.5.1.3	Zahrnutí vlivu času do výpočtu	36
3.5.1.4	Fixní efekty zachycené pomocí průměrů.....	36
3.5.2	Využití metody náhodných efektů	37
3.5.3	Je pro odhad modelů vhodnější RE nebo FE?	38
3.5.3.1	Hausmanův test.....	39
3.6	Produkční funkce.....	39
3.6.1	Zkoumané veličiny krátkodobé produkční funkce.....	40
3.6.2	Tvar a průběh produkční funkce	40
3.6.3	Předpoklady produkční funkce	41
3.7	Zemědělská produkční funkce ve vztahu ke klimatickým změnám.....	41
3.8	Justova a Popeova produkční funkce	42
3.8.1	Odhad modelu JP	42
3.9	Klimatická změna.....	43
3.9.1	Teplota	44
3.9.2	Srážky a sucho	44
3.10	Pšenice v českém prostředí.....	45
3.10.1	Vhodné podmínky pro pěstování	45
3.10.2	Fenologie pšenice v prostředí ČR.....	47
3.11	Již bylo na toto téma napsáno.....	47
4	Vlastní práce	49
4.1	Vývoj klimatických podmínek v České republice	49
4.1.1	Teplota v ČR.....	49
4.1.2	Srážky v ČR	51
4.1.3	Klimatická charakteristika krajů ČR.....	54
4.1.4	Vývoj socioekonomických proměnných.....	54
4.1.5	Rozloha, produkce a výnos pšenice	56
4.2	Ekonometrické modely a jejich specifikace.....	56
4.2.1	Data vstupující do modelů	57
4.2.2	Předpoklady ekonomické verifikace.....	58

4.3	Odhad BMNČ jednotlivých krajů	59
4.3.1	Ekonomická a statistická verifikace	63
4.3.2	Ekonometrická verifikace	68
4.3.3	Celkové hodnocení modelů	69
4.4	Model fixních efektů	69
4.4.1	Ekonometrická verifikace modelu	72
4.4.2	Hodnocení modelů fixních efektů pro celou Českou republiku	72
4.5	Tvorba skupin oblastí pro odhad jednotlivých FE modelů	72
4.5.1	Funkční formy a specifikace	73
4.5.2	Odhad modelů v logaritmickém tvaru a bez logaritmů podle skupin	73
4.5.2.1	Ekonometrická verifikace modelů s a bez logaritmů	74
4.5.2.2	Zhodnocení volby modelu podle funkční formy	75
4.5.2.3	Statistická a ekonomická verifikace modelu fixních efektů bez logaritmů 78	
4.5.3	Just a Popeova specifikace	81
4.5.3.1	Porovnání statistické významnosti parametrů a ekonomická verifikace (FE vs JP FE model)	82
4.5.3.2	Ekonometrická verifikace	83
4.5.4	Zhodnocení modelů a volba konečné specifikace	83
4.6	Aplikace modelu	83
4.6.1	Analýza proměnlivé elasticity	84
4.6.1.1	Teplotní elasticity	84
4.6.1.2	Elasticita srážek	87
4.6.2	Tvorba scénářů modelu	90
5	Výsledky a diskuse	93
5.1	Výsledky OLS modelů	93
5.2	Výsledky modelů fixních efektů	94
5.3	Očekávání v budoucích letech	95
6	Závěr	97
7	Seznam použitých zdrojů	98
8	Seznam obrázků, tabulek, grafů a zkratk	102
8.1	Seznam obrázků	102
8.2	Seznam tabulek	102
8.3	Seznam grafů	102
8.4	Seznam použitých zkratk	103
9	Přílohy	104

9.1	Příloha 1	104
9.2	Příloha 2	105
9.3	Příloha 3	107
9.4	Příloha 4	108
9.5	Příloha 5	110
9.6	Příloha 6	113
9.7	Příloha 7	115

1 Úvod

Zemědělství jako takové bylo vždy ohroženo vnějšími vlivy, a to díky specifickým, které s sebou zemědělské hospodářství nese. Mezi specifické znaky zemědělství patří například dlouhý životní cyklus jednotlivých produktů zemědělství, závislost produkce na rozloze, pozici a kvalitě půdy a v poslední řadě také výrazná závislost zemědělství na klimatických podmínkách. Zemědělská prvovýroba s sebou nese hned několik funkcí. Jedná se o uspokojování základních fyziologických potřeb lidí a zvířat, tvorbu vstupů do zpracovatelského průmyslu, krajiny tvorbu, osídlovací funkci, tvorbu ekosystémů, ochrannou funkci aj. Všechny tyto funkce jsou vždy ohroženy společně se zemědělstvím.

České zemědělství prošlo za posledních sedmdesát let mnoha změnami. I když význam zemědělství za posledních několik dekad plynule oslabuje (příznačný znak pro rozvinuté hospodářství), tak se stále jedná o významnou část české ekonomiky. Mezi změny, které lze sledovat v poslední letech, se řadí například změna přístupů k zemědělské výrobě, změna politického režimu, změna ve využití vstupů do zemědělství a v poslední řadě také změna klimatu, která v posledních letech bývá výrazně akcentována.

Pšenice je významnou obilovinou nejen v České republice, ale i napříč celou Evropou. Společně s rýží a kukuřicí se jedná o nejpěstovanější obilovinu na světě. V České republice čítá pšenice okolo 60 % celkové produkce obilovin a z tohoto důvodu je nutné zkoumat vlivy, které mohou tuto plodinu ohrozit. Aktuálně se největší hrozbou pro pšenici a zároveň i pro zemědělství jako takové jeví klimatická změna.

Technologie, věda a změna v oblasti vstupů do zemědělství jsou faktory, které nejvíce působí proti klimatické změně. Technologie umožňuje efektivnější, rychlejší a kvalitnější setí, sklizeň i hnojení. Věda umožnila šlechtění odolnějších a výnosnějších odrůd. A nakonec vstupy v podobě hnojiv, pesticidů a herbicidů se také podepsaly na vyšších výnosech než ty, které lidstvo doposud znalo.

Oproti tomu působí nepříznivá změna, která začala být pozorována v minulém století, jedná se o změnu klimatu. Udává se, že od průmyslové revoluce stoupla teplota o jeden stupeň celsia a zpomalení nárůstu teploty je v nedohlednu. Odhaduje se, že do konce roku 2050 by se teplota v České republice mohla zvýšit až o sedm stupňů celsia. S rostoucí teplotou vyvstává hned několik otázek. Jaký bude vliv klimatické změny na zemědělství? Povede klimatická změna k využívání jiných plodin než těch, které byly doposud

považovány za tradiční či běžné v daném státě? Jakým způsobem lze modelovat a zachytit tuto změnu?

Aktuálnost a naléhavost tohoto tématu musí být nyní již zřejmá. V oblasti ekonometrického modelování se lze setkat s nárůstem publikační činnosti. Svět ekonometrického modelování usiluje o to, aby dokázal co nejpřesněji modelovat modely vývoje této kritické oblasti a tato snaha je přenesena i do této diplomové práce.

2 Cíl práce a metodika

2.1 Cíl práce

Hlavním cílem diplomové práce je zhodnotit vliv klimatické změny na výnos pšenice v České republice s využitím odvozeného ekonometrického modelu panelových dat. Zjištěné výsledky mohou napomoci porozumět vlivu klimatické změny na výnos pšenice v ČR a zároveň poskytnout představu o budoucích rizicích pokračující klimatické změny.

Hlavního cíle bude dosaženo realizací několika dílčích cílů:

1. zjištění vlivu teplot v jednotlivých měsících na výnos pšenice,
2. určení vlivu měsíčních srážek na výnos pšenice,
3. zjištění vlivu cen zemědělských vstupů a výstupů,
4. verifikace ekonometrického modelu,
5. tvorba ex-post analýzy modelu,
6. simulace scénářů budoucího vývoje použitých klimatických proměnných.

2.2 Metodika

V diplomové práci byla využita data poskytnutá katedrou ekonomiky z Provozně ekonomické fakulty z České zemědělské univerzity. Databáze obsahovala následující data rozdělená podle krajů v České republice od roku 1961 až do roku 2016: výnos pšenice v t/ha, cenový index potravinářské pšenice, cenový index výrobků a služeb vstupujících do zemědělství, teplotní průměry v jednotlivých měsících a celoroční teplotní průměr, úhrny srážek v jednotlivých měsících a roční úhrn srážek. Zdroj těchto dat je ČSÚ a ČHMÚ. Data byla následně prodloužena autorem diplomové práce do roku 2022.

První část diplomové práce porovnává desetileté průměry v případě klimatických dat na konci a na začátku sledovaného období. Následně jsou všechny proměnné vstupující do modelu analyzovány za pomoci trendové funkce a průměrného tempa růstu (teoretické východisko viz kapitola č. 3.1). Trendová funkce byla vytvořena za pomoci aplikace Excel. Následně byl popsán výsledek této analýzy. Ve druhé části byly odhadnuty modely BMNČ (teoretické východisko viz kapitola č. 3.2.5) za pomoci softwaru Gretl. Modely BMNČ prošly statistickou, ekonomickou a ekonometrickou verifikací. Na základě BMNČ byl vytvořen závěr, který udával další směr diplomové práce.

Na základě výsledků BMNČ byly poté vytvořeny dva plně agregované modely fixních efektů (teoretické východisko viz kapitola č.3.5.1) za pomoci softwaru Gretl. Data vstupující

do těchto dvou modelů jsou normalizována na průměru a v případě jednoho model byly ještě logaritmičsky transformovány. Opět byly zhodnoceny výsledky modelu.

V poslední části diplomové práce byly vytvořeny tři skupiny modelů z částečně disagregovaných modelů výše uvedených. Opět proběhla normalizace pomocí průměrů a logaritmičská transformace (transformace proběhla pouze u tří ze šesti modelů). V tomto případě byly pro odhad využity fixní efekty s dummy proměnnými (teoretické východisko viz kapitola č. 3.5.1.2). Na základě ekonometrické a statistické verifikace byly zvoleny modely bez logaritmičské transformace. Na těchto modelech byla následně testována Just a Popeova specifikace (teoretické východisko viz kapitola č. 3.8), která byla statisticky, ekonomicky a ekonometričsky porovnána s modelem bez Just a Popeovy specifikace.

Výsledný model následně prošel ex-post analýzou, která je v této práci především analýzou elasticit. Na závěr práce byly vytvořeny scénáře budoucího vývoje za pomoci funkce modelu.

3 Teoretická východiska

3.1 Popisná statistika a časové řady

V případě zkoumání souboru dat lze použít popisnou neboli elementární statistiku výběrového souboru. Mezi zkoumané vlastnosti statistického souboru patří:

- úroveň,
- variabilita,
- šikmost,
- špičatost (Hindls et al., 2007, str. 29).

Nezákladnější zkoumanou charakteristikou je tedy jeho úroveň. Měření úrovně statistického souboru probíhá na základě průměrů, mezi které se řadí průměry aritmetické, harmonické, geometrické a i kvadratické. Zároveň ke sledování úrovně lze použít i vybrané hodnoty výběrového souboru, které se nazývají modus (hodnota statistického souboru s největším výskytem) a medián (prostřední hodnota pozorování) (Kirk, 2008, str. 68). Průměr by u statistického souboru měl být zjišťován vždy. Modus a medián by měly být použity pouze jako doplňkové ukazatele úrovně. V některých případech toto neplatí (Hindls et al., 2007, str. 30).

3.1.1 Aritmetický průměr

Nejběžnějším a nejpoužívanějším průměrem je průměr aritmetický, který představuje sumu všech hodnot výběrového souboru vydělenou počtem pozorování (Kirk, 2008, str. 64).

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (1)$$

3.1.2 Variabilita

Variabilita statistického souboru představuje její proměnlivost. Tuto proměnlivost lze hodnotit pomocí měr absolutních i relativních. Mezi absolutní míry patří variační rozpětí, rozptyl a směrodatná odchylka.

Variační rozpětí je definováno vzorcem podle Kirk (2008, str. 91-92):

$$R = x_{max} - x_{min}. \quad (2)$$

Variační rozpětí je založeno na krajních hodnotách výběrového souboru. To může být jeho velkou nevýhodou, jelikož odlehlejší extrémní hodnoty mohou silně ovlivnit ono rozpětí (Kirk, 2008, str. 91-92).

Rozptyl měří jednotlivé pohyby hodnot výběrového souboru okolo aritmetického průměru. Může mít proto o něco vyšší informativní hodnotu. Je ovšem třeba dát si pozor na to, že výsledek rozptylu je vyjádřen ve čtvercích použitých jednotek výběrového souboru. To lze vidět v následujícím vzorci pro rozptyl:

$$s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}, \quad (3)$$

(Hindls et al., 2007, str. 35-37).

Nevýhodou rozptylu, tedy to, že výsledek je ve čtvercích daných jednotek, řeší směrodatná odchylka, která je definována jako odmocnina rozptylu:

$$s_x = \sqrt{s_x^2}, \quad (4)$$

(Kirk, 2008, str. 95-96; Hindls et al., 2007, str. 35-37).

V případě, že je zjišťován rozdíl mezi variabilitami mezi dvěma výběrovými soubory, které mají různé měrné jednotky, není vhodné aplikovat absolutní ukazatel, kterým je například rozptyl. Je vhodnější využít relativní ukazatel variability, kterým je variační koeficient. Variační koeficient je podíl mezi směrodatnou odchylkou a průměrem. Variační koeficient je již bezrozměrným číslem, a proto je vhodný pro porovnání dvou rozdílných souborů z hlediska variability (Hindls et al., 2007, str. 42-43).

Vzorec pro variační koeficient podle Hindls et al. (2007, str. 42):

$$V_x = \frac{s_x}{\bar{x}}. \quad (5)$$

3.1.3 Časová řada

Časová řada je typem posloupnosti, kterou lze porovnávat z hlediska věcného a prostorového. Věcná srovnatelnost ČŘ je založena na tom, že ukazatelé jsou v celém sledovaném časovém intervalu obsahově stejné. Pokud je například analyzován index, jehož obsah by se v průběhu časové řady změnil, i když by se nezměnil jeho název, tak by nebylo možné tento ukazatel správně analyzovat a porovnat (Hindls et al., 2007, str. 251).

Prostorová srovnatelnost na druhou stranu souvisí s geografickým vymezením. Pokud je porovnáвана územní jednotka, a ta se v určitém čase významně změnila (například

sloučením s jinou územní jednotkou), tak by opět tato časová řada byla obtížně analyzována (Hindls et al., 2007, str. 251).

Úvahu o srovnatelnosti lze následně rozšířit i o časovou a cenovou srovnatelnost. Časová srovnatelnost spočívá v tom, že pokud je využíván intervalový údaj, tak musí být vždy využit stejný časový interval. Cenová srovnatelnost následně souvisí s použitím běžných a stálých cen, které by neměly být v průběhu časové řady zaměňovány (Hindls et al., 2007, str. 251).

Časová řada se může skládat až ze čtyř částí:

- trendové složky (dlouhodobý vývoj časové řady),
- sezónní složky (kolísání okolo trendové složky s periodicitou méně nebo přesně jednoho roku),
- cyklické složky (vychylování s periodicitou delší než jeden rok),
- a z náhodné složky (Hindls et al., 2007, str. 254-255; Peck et al., 2008, str. 122, 127).

Elementární charakteristika časové řady je analyzována za pomoci několika nástrojů. Mezi tyto nástroje patří první diference, druhé diference, tempo růstu, průměrné tempo růstu a průměr (výpočet průměru byl uveden již výše). Vzorce na základě publikace Hindls et al. (2007, str. 253) jsou uvedeny níže.

První diference

$$\Delta_t^1 = y_t - y_{t-1}, t = 2, 3 \dots n \quad (6)$$

Druhá diference

$$\Delta_t^2 = \Delta_t^1 - \Delta_{t-1}^1, t = 3, 4 \dots n \quad (7)$$

Tempo růstu

$$k_t = \frac{y_t}{y_{t-1}}, t = 2, 3 \dots n \quad (8)$$

Průměrné tempo růstu

$$\bar{k} = (k_2 k_3 \dots k_n)^{\frac{1}{n-1}} \quad (9)$$

3.2 Ekonometrická analýza

3.2.1 Postup sestavení ekonometrického modelu

Základem tvorby ekonometrického modelu by měla být solidní ekonomická teorie nebo ekonomický model, který se dá přenést do formy hypotézy nebo hypotéz, jež lze ekonometricky testovat. Nejdříve je sestaven model ekonomický, následně matematický a nakonec ekonometrický. Ekonomický model představuje výše zmíněnou ekonomickou teorii, tedy popis vazeb mezi zkoumanými veličinami, jejich vyčlenění aj. Matematický model poté představuje zápis do funkčního tvaru. Ekonometrický model je následně sestaven za pomoci přidání náhodné složky (Hančlová, 2012, str. 14-15).

Podle Cipry (2013, str. 24) je ovšem ve většině případech nutné se spokojit pouze s určitou aproximací teorie, kterou chceme testovat, jelikož zachytit každý vnější vliv je prakticky nemožné. Následně by měla být sesbírána vhodná data a apriorní informace. Poté, co jsou data sesbírána, tak jsou odhadnuty parametry modelu a model se následně testuje. Model se testuje na to, zdali neobsahuje určité neduhy, které by mohly jeho závěry negativně ovlivnit. Této části se říká verifikace. Verifikace je statistická, ekonometrická a ekonomická (Cipra, 2013, str. 24; Hančlová, 2012, str. 14).

V rámci statistického testování odhadnutého modelu jsou provedeny t-testy a f-testy významnosti. Ekonometrická verifikace představuje ověření předpokladů regresního modelu a hodnotí celkovou funkčnost modelu. Jestliže model neplní své předpoklady, tak se opakuje fáze specifikace modelu. Ekonomická verifikace je založena na ověření funkčnosti modelu z pohledu ekonomické teorie, kdy jsou sledována znaménka jednotlivých parametrů a jejich úroveň. Na základě interpretace je tak hodnocen výsledek modelu vzhledem k očekáváním (Hančlová, 2012, str. 18).

V této fázi lze také dojít k tomu, že model nesplňuje dané požadavky a je na autorovi, aby následně provedl novou specifikaci modelu, popřípadě upravil pouze některé jeho části. Závěrem může být nové zjištění míry vlivu proměnných v modelu, predikce anebo informace, na které může vznikat například politika řešení dané problematiky (Cipra, 2013, str. 25, Maddala et Lahiri, 2002, str. 7).

3.2.2 Regresní analýza lineární regrese

Regresní analýza je jedním ze základních nástrojů ekonometrie. Regrese popisuje vztah nebo průběh dvou a více proměnných, které na sebe působí. Proč je regresní analýza

natolik důležitá? Regresní analýza poskytuje výsledný vztah mezi pozorovanými jevy, a tím pádem poskytuje přirozený základ pro většinu empirických výzkumů či výzkumných otázek (Angrist et Pischke, 2009, str. 34).

Předmětem regresní analýzy je především tvorba regresního modelu. V mnoha případech je uvažován především lineární regresní model. V nejjednodušší podobě se jedná o vztah jedné závisle proměnné a jedné nezávisle proměnné (Stock et Watson, 2020, str. 145-147).

$$Y_i = \beta_0 + \beta_1 * X_i + u_i, \quad (10)$$

Y_i ...představuje závisle proměnnou (také regresand, vysvětlovaná proměnná),

X_i ...představuje nezávisle proměnnou (také regresory, vysvětlující proměnné),


β_0 ...představuje posun na ose y,

β_1 ...představuje parametr nezávisle proměnné, a tedy sklon přímky,

u_i ...představuje náhodnou složku funkce (Stock et Watson, 2020, str. 145-147).

Lze vidět, že na rozdíl od běžné statistické regrese je zde využívána náhodná složka funkce u_i . Statistická funkce většinou využívá pouze deterministickou část funkce, která je definována jako $a_0 + b_1 * X_i$ (Kirk, 2008) a v případě ekonometrického modelu $\beta_0 + \beta_1 * X_i + u_i$.

Obrázek 1: Vyobrazení náhodné složky



Zdroj: vlastní zpracování podle Wooldridge (2002, str. 48)

Náhodná složka funkce představuje odchylku skutečných hodnot od hodnot teoretických stanovených regresní funkcí, a jedná se o stochastickou část funkce. Náhodnou složku pro i -tý člen lze popsat následujícím vztahem podle Wooldridge (2002, str. 48):

$$u_i = Y_i - (\beta_0 + \beta_1 * X_i). \quad (11)$$

Jednoduchou regresi lze zapsat i pomocí matic. Pokud je bráno v úvahu, že máme n – počet pozorování, kdy každé jedno pozorování je definováno právě jednou rovnicí, tak lze zapsat jednotlivé proměnné a parametry pomocí vektorů.

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 * x_1 + u_1 \\ y_2 &= \beta_0 + \beta_1 * x_2 + u_2 \\ &\vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \\ y_n &= \beta_0 + \beta_1 * x_n + u_n \end{aligned} \quad (12)$$

Vektory jednoduché regrese (12) by se daly zapsat jako (zpracováno podle Davidson et MacKinnon, 2021, str. 27):

$$y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} X = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} u = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix} \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}. \quad (13)$$

Výsledný zápis v podobě matic by byl následující (zpracováno podle Davidson et MacKinnon, 2021, str. 27):

$$y = X\beta + u. \quad (14)$$

Hlavní výhodou maticového zápisu je využití při mnohonásobné regresi, kdy je využito více regresorů, a matice tak umožní přehlednější způsob zápisu. V takovém případě matice X může obsahovat velké množství prvků, kdy matice nabývá rozměrů – $n \times k$ (zpracováno podle Russel et MacKinnon, 2021, str. 27):

$$X = \begin{pmatrix} x_{11} & x_{21} & \cdots & x_{k1} \\ x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nk} \end{pmatrix}. \quad (15)$$

3.2.3 Náhodná složka

Proč vlastně něco jako náhodná složka existuje a co vše do ní spadá? Náhodná složka v sobě obsahuje vše, co není zachyceno za pomoci deterministické části. Dougherty (2007, str. 47-48) uvádí, že stochastická složka vzniká na základě následujících vlivů.

1. Opomenutí nezávislé proměnné: nedá se říct, že lze nalézt model, který by dokázal zahrnout veškeré proměnné, a to z mnoha důvodů. Jedním z důvodů může být

obtížná měřitelnost dat. Může se ovšem jednat i o to, že tvůrci modelu nějakou zásadní proměnnou opomenou (Dougherty, 2007, str. 47-48).

2. Agregace proměnných: jedná se o růst náhodné složky z důvodu využívání agregovaných proměnných. Pokud je například využíván k měření budoucí spotřeby spotřebitelů agregovaný souhrnný indikátor důvěry (Dougherty, 2007, str. 47-48).
3. Chybná specifikace modelu: Dougherty (2007, str. 47-48) uvádí, že k tomuto případě může dojít ve chvíli, kdy je model definován pro závislou proměnnou Y a jsou využívána data X , která se týkají stejného období jako je Y , ale správně by měla být použita zpožděná proměnná X , jelikož proměnné X předbíhají závislou proměnnou Y (Dougherty, 2007, str. 47-48).
4. Špatná funkční forma: pokud je využívána lineární funkce a byla by snaha na ní napasovat funkci logaritmickou, ihned bude zřejmé, že se funkce od sebe budou postupně odklánět a dojde ke zvyšování náhodné složky (Dougherty, 2007, str. 47-48).
5. Chyba v měření: jestliže budou využívána data, která mají ve své řadě chybu způsobenou špatným měřením, dojde k růstu náhodné složky. Pokud se tato chyba v měření bude opakovat častěji, dojde ke znemožnění tvorby uspokojivého modelu (Dougherty, 2007, str. 47-48).

3.2.4 Vícenásobná regrese

Na základě jednoduché regrese není těžké dále odvodit vícenásobnou regresi. Vícenásobná regrese je založena na práci se dvěma a více regresory. Maximální počet regresorů není v zásadě stanoven, dokud mají pro model nějaký význam. Funkce pro k – regresorů (Wooldridge, 2002, str. 69):

$$y = \beta_0 + \beta_1 * x_1 + \beta_2 * x_2 + \dots + \beta_k * x_k + u. \quad (16)$$

Model vícenásobné regrese se interpretuje v zásadě stejně, pouze s tím rozdílem, že sklon přímky není určen pouze za pomoci jednoho parametru β , ale nyní působí více parametrů β na daný sklon. Z tohoto důvodu se může parametru β také nazývat „*částečný parametr sklonu*“ (Wooldridge, 2002, str. 69).

V případě parametru β je také nutné klást vyšší důraz na „*ceteris paribus*“. Je vhodné připomenout, že tato podmínka se týká změn v ostatních hodnotách proměnných „ x “ z matice X . Pokud je tedy řečeno, že při změně jedné proměnné „ x “ o jednotku dochází ke

změně hodnoty „y“ o parametr dané proměnné za podmínek „*ceteris paribus*“, je tím myšleno, že ostatní proměnné „x“ z matice X se nemění (Wooldridge, 2002, str. 70).

Předmětem jednoduché regresní analýzy a vícenásobné regresní analýzy je dopracovat se k hodnotám parametrů, na základě kterých je následně možné odhadnout hodnoty „Y“. Toho lze dosáhnout za pomoci běžné metody nejmenších čtverců (BMNČ, v angličtině ordinary least square method = OLS).

3.2.4.1 Elasticita

Ve chvíli, kdy jsou odhadnuty parametry modelu, tak je těžké porovnat vliv jednotlivých parametrů na výsledný model. Z tohoto důvodu jsou využívány elasticity. Elasticita představuje procentuální změnu závisle proměnné při změně nezávisle proměnné o 1 % (Gujarati, 2003, str. 176). Výpočet elasticity na základě Gujarati (2003, str 183) je následující:

$$Elasticita = \frac{dY}{dX} * \frac{X}{Y}. \quad (17)$$

3.2.5 BMNČ

BMNČ je odpovědí na to, jakým způsobem se lze dopracovat k neznámým parametrům. Metoda BMNČ vychází z teorie očekávaných hodnot, kdy lze využít metodu momentů k jejímu odvození, jelikož BMNČ je jejím speciálním případem. Odvození BMNČ pomocí metody momentů je uvedeno v příloze č. 1.

Na základě přílohy č. 1 lze vidět, že za pomoci metody momentů je získána stejná soustava rovnic jako ta, která je používána při BMNČ. V případě klasického odvození BMNČ je tato soustava rovnic získána za pomoci derivace vztahu (tedy minimalizace – od toho název „nejmenší“) nepodmíněné a podmíněné rovnice (Davidson et MacKinnon, 2021, str. 35–36; Stock et Watson, 2020, str. 149).

Vztah uvedený v příloze č. 1, lze přepsat do maticové formy, který představuje přehlednější znázornění výše uvedené soustavy rovnic:

$$\begin{pmatrix} n & \sum_{t=1}^n (x_t) \\ \sum_{t=1}^n (x_t) & \sum_{t=1}^n (x_t^2) \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} = \begin{pmatrix} \sum_{t=1}^n y_t \\ \sum_{t=1}^n (y_t x_t) \end{pmatrix}. \quad (18)$$

Na základě tohoto maticového zápisu speciálního případu jednoduché regrese lze zapsat v maticové podobě rovnici pro vícenásobnou lineární regresi:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}, \quad (19)$$

(Davidson et MacKinnon, 2021 str. 33).

Matice \mathbf{y} má rozměry podle počtu pozorování. Matice \mathbf{X} má rozměry dle počtu pozorování n a podle počtu parametrů k , tedy $(n \times k)$. Matice $\boldsymbol{\beta}$ má rozměr k – podle počtu parametrů (Davidson et MacKinnon, 2021 str. 33).

Pokud je poté přepsán vztah pomocí transponovaných matic, tak získáme následující zápis:

$$X^T y = \begin{pmatrix} \sum_{t=1}^n y_t \\ \sum_{t=1}^n (y_t x_t) \end{pmatrix}, \quad (20)$$

$$X^T X = \begin{pmatrix} n & \sum_{t=1}^n (x_t) \\ \sum_{t=1}^n (x_t) & \sum_{t=1}^n (x_t^2) \end{pmatrix},$$

(Davidson et MacKinnon, 2021 str. 33).

Díky tomuto zápisu (20) je získán maticový tvar rovnice (21), která pokud je upravena pomocí inverzní matice $(X^T X)^{-1}$, tak se změní v rovnici pro odhad parametrů $\boldsymbol{\beta}$ podle Angrist et Pischke (2009, str. 42):

$$X^T y = X^T X \boldsymbol{\beta}, \quad (21)$$

$$\hat{\boldsymbol{\beta}} = (X^T X)^{-1} X^T y.$$

3.2.6 Best linear unbiased estimation (BLUE)

Nestranný odhad (Unbiased)

Odhad je považován za nestranný na základě jeho střední hodnoty, která by měla být stejná jako střední hodnota základního souboru. Pokud by se střední hodnota odhadu nerovnila střední hodnotě základního souboru, byl by odhad považován za vychýlený (podhodnocen, nadhodnocen) (Madalla et Lahiri, 2009. str. 23).

Pomocí očekávané hodnoty lze vyjádřit tento vztah podle (Cipra, 2013, str. 45):

$$E(b) = \boldsymbol{\beta}, \quad (22)$$

kde b je odhad skutečného parametru $\boldsymbol{\beta}$.

Konzistentní odhad

Konzistentní odhad parametru je ten, který s rostoucím počtem vzorků v modelu konverguje ke skutečné hodnotě parametru. V modelech se lze často setkat s tím, že zvolený odhad, který vychází z výběrového souboru, nemusí splňovat požadované vlastnosti. Poté se lze přiklonit k asymptotickému splnění požadovaných vlastností. Asymptotické vlastnosti právě úzce souvisí s konzistentním odhadem, kdy je u asymptotické vlastnosti předpokládáno, že počet pozorování výběrového souboru roste do nekonečna. Poté se hledá vlastnost, která se nazývá asymptotická konzistence, asymptotická nestrannost a asymptotická eficeience (Madalla et Lahiri, 2009, str. 23).

Konzistence je vyjádřena limitním vztahem podle Cipra (2013. str. 46):

$$\lim_{T \rightarrow \infty} P(|b_i - \beta_i| > \delta) = 0. \quad (23)$$

Eficeience odhadu

Eficeience je vlastnost, která je vztažena k ostatním odhadům. Pokud má odhad nejmenší rozptyl oproti ostatním odhadům, tak lze říct, že odhad je eficientní.

V případě, že odhad je zároveň i nestranný, tak lze prohlásit, že odhad splňuje vlastnosti **BLUE** (*Best linear unbiased estimator*).

3.2.7 Identické a nezávislé rozdělení

I.I.D. (Identically and Independently Distributed)

Jedná se o podmínku, na jejímž základě jsou volena náhodná pozorování, která jsou využívána k analýze. Identické rozdělení znamená, že využívaný výběrový soubor volil proměnné ze základního souboru se stejnou pravděpodobností pro všechna pozorování. Nezávislé rozdělení znamená, že pozorování jsou vybírána nezávisle na sobě (Stock et Watson, 2020 str. 158).

3.2.8 Statistická verifikace

3.2.8.1 Testování významnosti parametru pomocí t-testu

T-test je založen na porovnání vypočtené t-hodnoty s tabulkovou t-hodnotou. T-hodnotu získáme na základě vzorce podle Hančlové (2012, str. 42):

$$t_{vyp.} = \frac{\hat{\beta}_i}{\hat{\sigma}_{\hat{\beta}_i}}, \quad (24)$$

kde $\hat{\sigma}_{\hat{\beta}_i}$ je teoretická směrodatná odchylka parametru. Tato hodnota je následně porovnávána s t-hodnotou, která má n-k stupňů volnosti. H_0 říká, že parametr je

nevýznamný, a tedy že je roven nule. Oproti tomu alternativní hypotéza říká, že je různý od nuly. V případě, že vypočtená t-hodnota je vyšší než tabulková t-hodnota, tak je zamítnuta nulová hypotéza a parametr lze prohlásit za významný (Hančlová. 2012, str. 42-43).

3.2.8.2 Koeficient determinace

Koeficient determinace představuje hodnocení shody skutečných dat s jejich odhadnutými hodnotami. Na základě Hančlové (2012, str. 39-40) je vzorec pro koeficient determinace následující:

$$R^2 = \frac{ESS}{TSS} = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (25)$$

kde ESS představuje vysvětlený součet čtverců (Explained Sum of Squares) a TSS představuje úplný součet čtverců (Total Sum of Squares), který se dá také zapsat vzorcem uvedeným níže:

$$TSS = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = RSS + ESS, \quad (26)$$

kde RSS představuje reziduální součet čtverců (Residual Sum of Squares) (Hančlová, 2012, str. 39-40).

Koeficient determinace v podobě uvedené výše má ovšem několik nedostatků. S přibývajícimi proměnnými nikdy neklesá, a pokud není použita úrovněová konstanta, tak nemusí mít žádnou vypovídací hodnotu. Z těchto důvodů lze použít korigovaný (adjustovaný) koeficient determinace, který má následující vzorec podle Hančlové (2012, str. 84):

$$\bar{R}^2 = 1 - \left[\frac{n-1}{n-k} * (1 - R^2) \right]. \quad (27)$$

3.2.8.3 Testování významnosti F-test

Předmětem testování pomocí F-testu je zjištění, zdali jsou parametry společně významné. Na rozdíl od t-testu je tedy zkoumána významnost modelu za pomoci všech parametrů dohromady. Hypotézy pro tento test se dle Gujarati (2003, str. 257) zapisují takto:

$$H_0: \beta_1 = \beta_2 = \beta_k = 0,$$

$$H_A: \beta_1 \neq 0 \cup \beta_2 \neq 0 \cup \beta_k \neq 0.$$

F-hodnota je vypočtena na základě vzorce dle Gujarati (2003, str. 257):

$$F = \frac{ESS/(k-1)}{RSS/(n-k)} \quad (28)$$

a tato hodnota je porovnávána s F-tabulkovou hodnotou $[F_{\alpha}(k-1, n-k)]$.

Jestliže je tedy F-vypočtená hodnota vyšší než F-tabulková hodnota, tak je nulová hypotéza zamítnuta a celkové hodnoty modelu jsou považovány za významné (Gujarati, 2003, str. 257).

3.3 Předpoklady modelu lineární regrese

Proto, aby byl model funkční, je třeba naplnit určité předpoklady. Dle Cipry (2013, str. 40) se jedná o pět následujících bodů:

- 1) suma reziduální složky pro všechna pozorování by měla mít nulový průměr
 $E(u_t) = 0$,
- 2) rozptyl náhodné složky by se v čase neměl měnit, tj. rozptyl náhodné složky by měl být konstantní – měl by být homoskedastický, pokud tomu tak není, tak se jedná o heteroskedasticitu – $var(u_t) = \sigma^2 < \infty$,
- 3) reziduální složky by mezi sebou neměly být korelovány – neměla by se v modelu vyskytovat autokorelace reziduí – $cov(u_t, u_s) = 0$ pro $t \neq s$,
- 4) mezi reziduální složkou a regresory by se neměla vyskytovat korelace –
 $cov(x_t, u_t) = 0$,
- 5) regresory mezi sebou nesmějí mít perfektní multikolinearitu, $h(X) = k$,
- 6) a normální rozdělení reziduální složky z důvodu testování statistických hypotéz (Cipra, 2013, str. 40; 52).

Nyní dojde k rozebrání jednotlivých podmínek a hlubšímu nahlédnutí do jejich problematiky.

3.3.1 Nulový průměr reziduální složky

Tato podmínka vychází z předpokladu, že pokud je správně využita BMNČ, tak by mělo dojít k vyrušení reziduí mezi sebou. To také souvisí s tím, proč je k výpočtu používána metoda nejmenších čtverců, a ne pouze vzdálenosti pozorování k naší teoretické funkci (došlo by k jejich vzájemnému vyrušení). Tato podmínka má také úzký vztah k využití konstanty v modelu. Pokud je využita konstanta, tak je tento předpoklad splněn vždy, jelikož nenulové průměry reziduálních složek se přesunou právě do konstanty. Někdy ovšem

ekonomická nebo finanční teorie nedovoluje využití konstanty. Pokud tomu tak je, může dojít k vychýlení křivky teoretických hodnot (Cipra, 2013, str. 41; Gujarati, 2003 str. 67-68).

3.3.2 Heteroskedasticita

Gujarati (2003, str.387) uvádí překlad slova homoskedasticita následujícím způsobem - (*homo*) stejný, (*skedasticity*) rozptyl. Heteroskedasticita je stav, kdy se v modelu vyskytuje nekonstantní rozptyl reziduální složky. Pokud jsou dány různé časové úseky v časové řadě a byly by vyhodnoceny jejich rozptyly a ty by byly významně různé, tak by bylo zřejmé, že se jedná o heteroskedastická data, která nemají konstantní rozptyl (Stock et Watson, 2020, str. 188-189).

3.3.2.1 Důsledky heteroskedasticity pro model

Jestliže se v modelu vyskytuje heteroskedasticita, tak nelze o odhadu říct, že je nejlepší. Přesněji řečeno je odhad parametrů β stále nestranný a konzistentní, ale již o něm nelze prohlásit, že je nejlepší (Wooldridge, 2002, str. 248, Cipra, 2013, str. 87).

Pokud se v modelu vyskytuje heteroskedasticita, tak to naznačuje, že směrodatná odchylka modelu nedopovídá skutečné hodnotě, kterou se model snaží odhadnout. Pokud tedy směrodatná odchylka vykazuje chybnou hodnotu a stejně tak i směrodatná chyba, tak dochází k tomu, že nelze správně použít konfidenční intervaly testů a běžné statistické testy obecně. To znamená, že t-testy a f-testy nebudou vycházet správně a nebudou validní (Wooldridge, 2002, str. 248-249).

3.3.2.2 Důvody heteroskedasticity

Heteroskedasticita se v některých modelech může vyskytovat přirozeně, a to z podstaty jejich specifikace. Podle Gujarati (2003, str. 389) může mít výskyt heteroskedasticity následující důvody:

1. v některých datových souborech může být znát postupné zlepšování při získávání daných dat, a tím i jejich nižší variabilita,
2. v případě výskytu většího množství odlehlých hodnot,
3. může se vyskytnout v případě špatné specifikace modelu a jeho funkčního tvaru,
4. a v posledním případě může heteroskedasticitu způsobovat přílišná šikmost jednoho či více regresorů (Gujarati, 2003, str. 389-391).

3.3.2.3 Detekce heteroskedasticity

Nejběžnějším způsobem detekce je využití statistických testů. Podle Gujarati (2003, str. 402) lze nalézt heteroskedasticitu i na základě grafického zobrazení odhadnutých hodnot reziduí a teoretických hodnot závislé proměnné. Homoskedasticita by neměla projevovat žádný zavádějící vzorec. To znamená, že by například neměly rezidua vypadat jako lineární nebo kvadratická závislost vzhledem k teoretické hodnotě \hat{Y} . I když se tato metoda nejeví jako naprosto přesná, tak i přesto může být grafické znázornění průběhu reziduí nápomocné v řešení heteroskedasticity. Na základě vizuální analýzy lze určit, proč heteroskedasticita v modelu vzniká, a díky tomu ji následně odstranit (Gujarati, 2003, str. 401-403).

Ne vždy to ovšem jde, a ne vždy je vizuální analýza jednoznačná. Z toho důvodu využíváme statistické testy. Mezi nejběžnější testy patří Breusch-Paganův test, Whiteův test a Glejserův test. Při testování panelových se využívá i Waldův test (poskytovaný softwarem Gretl). V příloze č. 2 lze nalézt postup tvorby jednotlivých testů – vyjma Waldova testu (Gujarati, 2003, str. 411-412; Cipra, 2013, str. 86; Dougherty, 2007, str. 210; Wooldridge, 2002, str. 255–257).

3.3.2.4 Řešení heteroskedasticity

Heteroskedasticita se dá řešit za pomoci její příčiny anebo bývají v literatuře zmiňovány robustní chyby. Postup tvorby robustních chyb pro řešení heteroskedasticity je popsán v příloze č. 3. A posledním možným řešením je nalezení a odstranění důvodů heteroskedasticity, které jsou uvede v kapitole 3.3.2.2.

3.3.3 Autokorelace

Autokorelace je stav, kdy se nachází korelace mezi reziduální složkou u_j a u_s , kdy $j \neq s$. Nejčastěji se s tímto jevem lze setkat u časových řád, například v případě, že v sobě časová řada nemá zachycený autoregresní vztah. Pokud je něco takového v modelu zpozorováno, tak je na místě upozornit, jelikož v reziduální složce se aktuálně nachází něco, co nadefinovaný model nevystihuje (Dougherty, 2007, str. 429-431).

3.3.3.1 Důvody autokorelace

Autokorelace se v modelu vyskytuje z následujících důvodů:

1. v modelu nejsou zachyceny regresory, které obsahují autokorelaci,

2. je nesprávně zachycena dynamika modelu (model by měl například obsahovat zpožděné regresory nebo regresanda),
3. různá pozorování y_s a y_t obsahují něco, co mají společného mimo vystižené regresory,
4. špatná funkční specifikace modelu (Cipra, 2013, str. 94-95).

3.3.3.2 Detekce autokorelace

Autokorelace v modelu může být detekována za pomoci testů autokorelace. Relativně jednoduchým typem testu pro autokorelaci je Durbin-Watsonův test. Nevýhodou tohoto testu je občasná neprůkaznost. Model má zároveň dvě zásadní omezení. Dle Maddala et Lahiri (2009, str. 240) lze tento test použít pouze na model, který obsahuje autokorelace prvního řádu a podle Wooldridge (2002, str. 381) lze tento model použít pouze v případě, že se v modelu nalézají pouze exogenní regresory. Zároveň je nutno podotknout, že test obsahuje i oblast, ve kterém je výsledek testu považován za neprůkazný – poté je třeba použít Breusch-Godfreyův test. V případě panelových dat bývá využíván Wooldridgeův test autokorelace. (Cipra, 2013, str. 97; Dougherty, 2007, str. 436).

Postup testování jednotlivých testů je uveden v příloze č. 4 (Durbin-Watsonův test a Breusch-Godfreyův test).

3.3.3.3 Důsledky autokorelace

Jestliže se v modelu nachází autokorelace, tak nelze prohlásit, že reziduální složka je IID, čímž dochází k narušení předpokladů reziduální složky. Model zůstává nestranným a konzistentním, nedá se o něm ovšem říct, že je nejlepším (model ztrácí eficienci). Autokorelace způsobuje, že kovarianční matice není nejlepší, a tím pádem testy, které jsou na ní závislé, mohou být chybné (Maddala et Lahiri, 2009, str. 250).

Lze také říci, že variabilita výběrového souboru je vychýlená a častokrát i podhodnocená. Koeficient determinace zároveň častokrát vykazuje vyšší hodnoty, než jaké ve skutečnosti jsou (Maddala et Lahiri, 2009, str. 253).

3.3.3.4 Řešení autokorelace

Autokorelace může být řešena za pomoci důvodů, které jsou uvedeny v kapitole 3.3.3.1. Lze tedy provést dodatečnou dynamizaci, vylepšit funkční tvar anebo přidat vhodné regresory. Pokud není známo, který důvod vytváří autokorelaci, tak lze použít první

diference, autoregresní model anebo robustní chyby. Tyto postupy jsou popsány v příloze č. 5.

3.3.4 Korelace mezi regresory a reziduální složkou

Neexistující korelace mezi regresorem a reziduální složkou je podmínka, která bývá ve většině případů naplněna. Tato podmínka je totiž splněna prakticky vždy, pokud je známo, že regresory jsou deterministické. Pro potřeby této práce je třeba říci, že pro případy, kdy se pracuje se stochastickými regresory, které jsou korelovány s rezidui, je velice těžké odhadnout přesný vliv X a u_i . Můžou nastat případy pozitivní i negativní korelace. Pokud jsou stochastické regresory nezávislé na reziduální složce, tak jsou nekorelovány a v odhadu jejich vlivů lze pokračovat oddělně s tím, že je s nimi pracováno jako by stochastické nebyly (Gujarati, 2003, str. 71 a 337).

3.3.5 Multikolinearita

Původní význam multikolinearity byl ve smyslu perfektní multikolinearity, tedy například $cov(x_1, x_2) = 1$; $kdy\ 1,2 = k$. Je zřejmé, že v této podobě nemá matice X plnou hodnost a regresory tím pádem komplikují odhad parametrů. S postupem času ovšem došlo i k definování vysoké multikolinearity, která se pohybuje podle požadavků modelu v intervalu $cov(x_1, x_2) = < 0,8; 1$ (Gujarati, 2003, str. 342-345).

Perfektní multikolinearita způsobuje, že není možné odhadnout beta parametry, a že směrodatná chyba parametrů není konečné číslo.

Jestliže je odhadován model, ve kterém se vyskytuje vysoká multikolinearita, tak by mělo být počítáno s tím, že koeficienty budou mít vysokou směrodatnou chybu σ , to znamená, že odhad nebude moc přesný a bude těžké přesně odhadnout samostatný vztah těchto koeficientů vzhledem k modelu (Cipra, 2013, str. 118; Gurajanti, 2003, str. 344).

3.3.5.1 Důsledky perfektní multikolinearity

Model zůstává BLUE, jak bylo však zmíněno výše, potýká se s vysokou směrodatnou odchylkou a korelací mezi jednotlivými regresory, což vede k nižší přesnosti modelu. To má za následek širší konfidenční intervaly. Vlivem nižší přesnosti dochází k nevýznamnosti t -hodnot, a to vede k označení nevýznamnosti samostatného parametru, což není správné vyhodnocení na základě toho, že parametr může působit významně, ovšem v kombinaci s jiným parametrem. Tento jev je rozeznáván tím, že jsou nevýznamné parametry, ale zato

je velice vysoký koeficient determinace (Gujaranti, 2003, str. 350). Pro utvrzení domněnky o vysoké multikolinearitě lze využít korelační matice, kde korelační vztah mezi dvěma regresory bude vyšší než 0,8 (Cipra, 2013, str. 117-118; Gujaranti, 2003, str. 360).

3.3.5.2 Řešení multikolinearity

Typickým řešením multikolinearity je multikolinearitu **ignorovat**. I když není možné správně odhadnout jednotlivé parametry a jejich významnost, tak celkový odhad modelu v zásadě není špatný. Multikolinearita jen říká, že je třeba obezřetnosti při interpretaci parametrů a zvýšené opatrnosti při vyhodnocování testů (Cipra, 2013, str. 118; Gujaranti, 2003, str. 363).

V případě, že je žádoucí multikolinearitu řešit, tak zbývají následující možnosti, které ve své publikaci uvádí Gujarati (2003, str. 364):

1. využití apriorní informace o vztahu mezi regresními parametry, čímž je myšleno, že je znám vztah mezi dvěma či více parametry (o kolik se změní parametr jedna, pokud se o jednotku změní parametr dvě),
2. využití časové řady v kombinaci s průřezovými daty, to se může týkat i pouze jednoho parametru, který bude upravovat model jako celek,
3. vypuštění proměnné z modelu, to však může vést k zavádějící a špatné specifikaci modelu (*specification bias model*),
4. transformace proměnných za účelem zbavení se multikolinearity, lze tedy převést data do prvních diferencí, anebo je možností využít podíly daných proměnných, to ale může vést ke vzniku autokorelace a heteroskedasticity, ke všemu je ztracena dlouhodobá informace z časové řady a jedno pozorování,
5. přidání nových dat (například prodloužením časové řady, pokud je to možné) nebo použití nového vzorku dat,
6. snížení multikolinearity za pomoci polynomické regrese (Gujarati, 2003, str. 364).

3.4 GLS

Zobecněný model lineární regrese (GLS) má význam v případech, kdy se model potýká s heteroskedasticitou nebo autokorelací. Na rozdíl od OLS, kde v rámci předpokladu o homoskedasticitě je třeba splnit to, že variabilita reziduální složky je konstantní, tak u GLS toto není potřeba, jinými slovy, dokáže se vyrovnat právě například s heteroskedasticitou

(Davidson et MacKinnon, 2021, str. 257). Předpoklad o homoskedasticitě má tedy následující tvar:

$$\text{var}(u_i) = \sigma^2 I. \quad (29)$$

Na druhou stranu v případě heteroskedasticity je variabilita nekonstantní, a má tedy tvar:

$$\text{var}(u_i) = \sigma^2 \Omega, \quad (30)$$

kdy Ω představuje pozitivně definitivní matici (veškeré prvky na diagonále jsou kladná čísla) (Cipra, 2013, str. 82; Davidson et MacKinnon, 2021, str. 258). Tato změna následně dovoluje odhadovat upravený vzorec pro OLS (tedy GLS), který má tvar dle Cipry (2013, str. 82):

$$\hat{\beta} = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} y. \quad (31)$$

Pro samostatnou rozptylovou matici by byl tvar podle Cipry (2013, str. 82):

$$\Sigma_{\hat{\beta}\hat{\beta}} = \text{var}(\hat{\beta}) = \sigma^2 (X' \Omega^{-1} X)^{-1}. \quad (32)$$

3.5 Panelová data a jejich odhad

Panelová data jsou kombinací časových řad a průřezových dat. Model je značen tímto způsobem:

$$y_{it} = \alpha_0 + \beta_1 x_{1,i,t} + \beta_2 x_{2,i,t} + \dots + \beta_k x_{k,i,t} + u_{it}. \quad (33)$$

Y má tedy dva dolní indexy „ i “ a „ t “. „ i “ představuje průřezovou jednotku a „ t “ čas, ve kterém je průřezová jednotka pozorována. Zároveň se v literatuře objevuje zařazení proměnné, které se v angličtině říká „*unobserved effects*“ a v české literatuře „*nepozorovatelné faktory*“ (Wooldridge, 2002, str. 420; Cipra, 2013, str. 200).

$$y_{it} = \alpha_0 + \beta_1 x_{1,i,t} + \beta_2 x_{2,i,t} + \dots + \beta_k x_{k,i,t} + v_i + u_{it}, \quad (34)$$

kde v_i představuje právě ony nepozorovatelné faktory. Tato proměnná zachycuje rozdíly neboli heterogenitu mezi jednotlivými průřezovými jednotkami, a je pro ně vzhledem k času neměnná a fixní. Proto je označena pouze indexem i (Wooldridge, 2002, str. 420; Cipra, 2013, str. 200).

3.5.1 Fixed effects – fixní efekty

3.5.1.1 Podmínky fixních efektů

Pro tento model je také důležité zmínit určité změny v předpokladech modelu. Model předpokládá striktní exogenitu, což znamená, že žádná z vysvětlujících proměnných by

neměla být korelována s reziduální složkou (nezachyceným efektům je to vzhledem k vysvětlujícím proměnným umožněno). Zároveň je třeba pamatovat na to, že homoskedasticita a autokorelace by se v čase neměla vyskytovat – mezi průřezovými jednotkami je to v určitých případech dovoleno (Wooldridge, 2002, str. 442).

Tento předpoklad lze dle Wooldridge (2002, str. 266) zapsat takto:

$$E(u_{it}|x_i, v_i) = 0, t = 1, 2, \dots, T. \quad (35)$$

Další předpoklad hovoří o tom, že v případě, že by se v modelu nacházela proměnná, která je v čase konstantní, nastal by problém s hodnotí matice. Tento předpoklad tedy říká, že v modelu se taková vysvětlující proměnná nemá vyskytovat. Předpoklad je zapsán takto:

$$h[E(\check{X}'_{it}\check{X}_{it})] = K, \quad (36)$$

kde matice \check{X}_{it} představuje matici X, která byla zbavena v čase fixních efektů (toto neplatí pro časové dummy proměnné) (Wooldridge, 2001, str. 269).

Poslední důležitou podmínkou, která zajišťuje vydatnost (eficienci), je:

$$E(u_i u'_i | x_i c_i) = \sigma_u^2 I_T, \quad (37)$$

tento předpoklad říká, že u_{it} by měla mít konstantní rozptyl v čase. V modelu se tedy nevyskytuje heteroskedasticita mezi časovými úseky a neměla by se v něm vyskytovat autokorelace mezi rezidui (Wooldridge, 2001, str. 269).

Zároveň se lze setkat s předpokladem přepsaným do dvou následujících podmínek:

$$\begin{aligned} var(u_{it}|X_i, v_i) &= var(u_{it}) = \sigma_u^2, t = 1, \dots, T, \\ cov(u_{it}u_{is}|X_i, v_i) &= 0, t \neq s, \end{aligned} \quad (38)$$

první podmínka zachycuje heteroskedasticitu a druhá podmínka zachycuje autokorelaci (Wooldridge, 2002, str. 459).

Pokud je použit tento způsob výpočtu, tak je třeba dbát na správný výpočet stupňů volnosti, který v případě modelu s fixními efekty vypadá takto: $NT - N - k$. Lze si všimnout, že je odečteno N. To je způsobeno právě použitím odečtu průměrů fixních efektů v čase, kdy za každé jedno pozorování průřezových jednotek je ztracen jeden stupeň volnosti (Wooldridge, 2002, str. 443).

3.5.1.2 Zachycení fixních efektů pomocí heterogenních konstant

Prvním způsobem, pomocí kterého lze odhadnout rozdíly mezi jednotkami průřezových dat, je zachycení různých hodnot konstanty. Tato technika je založena na využití dummy proměnných, které jsou přiřazeny každé z jednotek modelu. Je třeba pamatovat na to, že je využito $(i - 1)$ dummy proměnných, aby nedošlo k vytvoření

jednotkového vektoru. Pro skupinu, která nemá dummy proměnnou, je konstanta běžnou konstantou modelu. Pro zbytek je konstanta vypočtena jako obecná + koeficient příslušné dummy proměnné (Gujarati, 2003, str. 642-643).

3.5.1.3 Zahnutí vlivu času do výpočtu

Pokud je žádoucí v modelu zachytit i změny, které bychom mohli zahrnout pod vlivy času (například technologické změny), tak pro čas lze také vytvořit dummy proměnnou, a to stejným způsobem jako byla vytvořena dummy proměnná u zachycení heterogenních konstant (přibude tedy t-1 dummy proměnných). Tento způsob zachycení času lze kombinovat s dummy proměnnými pro konstanty (Gujarati, 2003, str. 644).

3.5.1.4 Fixní efekty zachycené pomocí průměrů

Jelikož rozdíly mezi průřezovými jednotkami v podobě nezachycených efektů zhoršují odhad modelu, tak je cílem tvůrce modelu zbavit se nezachycených efektů. Jedním ze způsobů, jak se nezachycených efektů zbavit, je použití průměrných hodnot průřezových jednotek. Tento způsob odstranění proměnné v_i je intuitivně založen na tom, že se v čase její hodnota nemění a není považována za náhodnou. V první fázi jsou tedy vypočteny průměry všech proměnných podle našich průřezových jednotek, a následně jsou tyto průměry odečteny od původních hodnot. Pro příklad je uveden model o dvou proměnných bez konstanty. Původní model a model průměrů má pak tuto podobu dle Wooldridge (2002, str. 441-442).

Původní model

$$y_{it} = \beta_1 x_{1,it} + \beta_2 x_{2,it} + v_i + u_{it} \quad (39)$$

Model průměrných hodnot průřezových jednotek v čase

$$\bar{y}_i = \beta_1 \bar{x}_{1,i} + \beta_2 \bar{x}_{2,i} + v_i + \bar{u}_i \quad (40)$$

Pokud se tyto dvě rovnice zkombinují, vznikne rovnice, která již neobsahuje nezachycený efekt. Tvar této funkce je podle Wooldridge (2002, str. 441-442) následující:

$$y_{it} - \bar{y}_i = \beta_1 (x_{1,it} - \bar{x}_{1,i}) + \beta_2 (x_{2,it} - \bar{x}_{2,i}) + (u_{it} - \bar{u}_i). \quad (41)$$

V případě použití dummy proměnných je třeba je zahrnout do zbavování průměrů. Konstantu není třeba zahrnovat do modelu, jelikož v případě metody „*demeaned fixed effects*“ dochází k odstranění všech v čase konstantních proměnných. Proto není možné do modelu zahrnout proměnné, které jsou v čase fixní, i když pro jednotlivé průřezové jednotky

se liší, což přináší určité omezení modelu (Dougherty, 2002, str. 518; Wooldridge, 2002, str. 441–442).

V případě, že by mezi jednotkami nebyl žádný nezachycený efekt a nebylo by tedy možné předpokládat, že jednotlivé průřezové jednotky nemají žádné pro ně zvláštní charakteristiky, tak není třeba využívat žádné metody fixních efektů, a lze rovnou provést „poolovaný“ odhad modelu (Dougherty, 2002, str. 518).

3.5.2 Využití metody náhodných efektů

Model náhodných efektů (*Random effects*) lze využít v případech, kdy FE nejsou vhodné anebo je třeba zachovat proměnné, které jsou v modelu žádoucí. Příмым příkladem může být model, který má určité proměnné konstantní, a při použití FE by model o tyto proměnné přišel. U REM se předpokládá, že v_i je proměnnou vybranou náhodně ze základního souboru (i když víme, že tato proměnná se váže k heterogenitě průřezových jednotek) (Dougherty, 2002, str. 523). Zároveň lze REM využít za předpokladu, že je složka v_i nekorelována napříč všemi proměnnými a ve všech časových úsecích (FE dovoľoval korelaci v průřezových jednotkách). Dalšími výhodami může být, že do REM již může vstoupit konstanta a je dovoleno použít časové dummy proměnné (Wooldridge, 2002, str. 449).

Model RE lze zapsat následujícím způsobem:

$$y_{it} = \beta_1 x_{1,it} + \beta_2 x_{2,it} + v_i + u_{it}. \quad (42)$$

Lze si všimnout, že model je prakticky shodný s modelem FE. Rozdíl je ovšem v tom, že složka v_i představuje součást náhodné složky, a proto lze model zapsat takto:

$$y_{it} = \beta_1 x_{1,it} + \beta_2 x_{2,it} + w_{it}, \text{ kde } w_{it} = v_i + u_{it}. \quad (43)$$

Tato definice náhodné složky vyvolává určité implikace. Jestliže se v_i nemění v čase, ale pouze v jednotkách průřezových dat, je pak tedy skoro zřejmé, že w_{it} se bude potýkat s korelací mezi časovými úseky (Wooldridge, 2002, str. 449-450).

Pro odhad tohoto modelu se tedy využívá GLS odhad, který by měl být schopen se s autokorelací vypořádat. Za účelem zbavení se autokorelace reziduí je potřeba provést určitou transformaci odhadnutého modelu. Tato transformace je provedena za pomoci λ [lamda], která je definována jako:

$$\lambda = 1 - \left(\frac{\sigma_u^2}{\sigma_u^2 - \sigma_v^2} \right)^{\frac{1}{2}}, \quad (44)$$

následná transformace modelu pomocí lambda vypadá takto:

$$y_{it} - \lambda \bar{y}_i = \beta_0(1 - \lambda) + \beta_1(x_{it1} - \lambda \bar{x}_{i1}) + \dots + \beta_k(x_{itk} - \lambda \bar{x}_{ik}) + (w_{it} - \lambda \bar{w}_i), \quad (45)$$

v tomto modelu bychom se již neměli setkávat s autokorelací. O takto upravených hodnotách x také mluvíme jako o proměnných částečně zbavených průměrů (Wooldridge, 2002, str. 450).

Předpoklady RE modelu tedy drží většinu předpokladů FE, které jsou doplněny o výše zmíněné předpoklady (nekorelovanost s vysvětlujícími proměnnými a předpoklad náhodného výběru v_i) a navíc doplněné o následující:

- v modelu se nevyskytuje perfektní multikolinearita (přirozeně),
- průměr v_i se rovná 0,
- a variabilita v_i je konstantní (tedy homoskedastická) (Wooldridge, 2002, str. 460).

3.5.3 Je pro odhad modelů vhodnější RE nebo FE?

Na základě Gujarati (2003, str. 650) je důležité brát v potaz, že pokud se pracuje s relativně velkým počtem časových období oproti relativně malému počtu průřezových jednotek, tak FEM a REM se od sebe nemusí zásadně lišit. Pokud se je pracováno s menším souborem pozorování, tak je důležité se mezi těmito dvěma modely správně rozhodovat (Gujarati, 2003, str. 650).

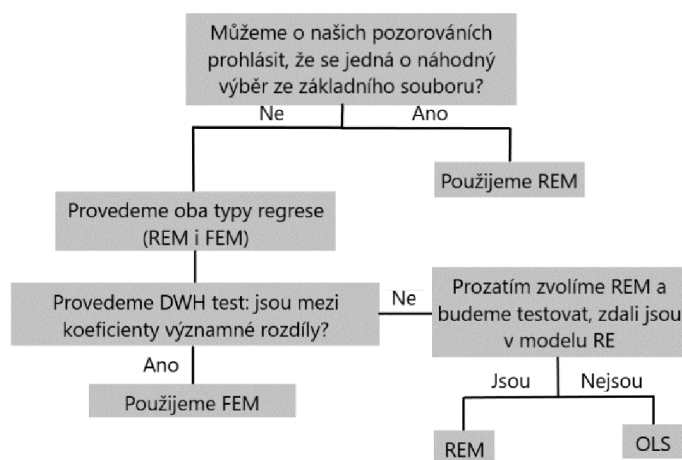
Zároveň Gujarati (2003, str. 650-651) přikládá pár poznatků na základě kterých se lze rozhodovat mezi těmito dvěma modely:

- a) pokud existuje předpoklad, že regresory jsou náhodným výběrem z většího souboru jednotek, tak je vhodnější se přiklánět k REM,
- b) pokud je složka v_i korelována s jednou či více vysvětlujícími proměnnými, tak model RE ztrácí svou nestrannost a je vhodnější použít FEM,

a jako poslední bod, podle kterého se lze orientovat, uvádí, že pokud je počet průřezových jednotek vyšší než počet časových období, tak model REM dokáže být vydatnější než FEM.

Podle Dougherty (2002, str. 527) lze využít jednoduché rozhodovací schéma, které je uvedeno níže.

Obrázek 2: Rozhodovací schéma pro panelová data



Zdroj: vlastní zpracování na základě Dougherty (2002, str. 527)

3.5.3.1 Hausmanův test

Hausmanův test, který testuje rozdíly mezi koeficienty, může být vodítkem k vyřešení konfliktu mezi REM a FEM. H_0 představuje hypotézu, která říká, že mezi koeficienty REM a FEM není významný rozdíl. Pokud H_0 není zamítnuta ($p - hodnota > \alpha = (0,1; 0,5)$), tak lze prohlásit, že v_i je nezávislé na regresorech. To následně umožňuje v případě přijetí nulové hypotézy použít REM. FEM model je za předpokladu přijaté nulové hypotézy konzistentní, ale není nejlepší. Pokud je ovšem zamítnuta H_0 , tak lze přijmout alternativní hypotézu, která říká, že mezi koeficienty je významný rozdíl, a pak je vhodnější použít FEM. REM model bude v tomto případě ztrácet nestrannost, která je ovlivněna nezachycenou heterogenitou (Dougherty, 2003, str. 525-256).

3.6 Produkční funkce

Produkční funkce vyjadřuje vztah vstupů k určitému výstupu. Produkční ve svém nejjednodušším tvaru vyjadřuje vztah jednoho faktoru k danému jednomu výstupu. Ve své složitější podobě poté vztah dvou a více faktorů k danému výstupu. Tyto dvě varianty lze zapsat do funkčního tvaru:

$$y = f(x),$$

$$y = f(x_1, x_2, \dots, x_n),$$

kdy y představuje množinu výstupů a proměnné x představují výrobní faktory (Brčák et al., 2020, str. 128; Chambers, 1989, str. 8).

Základní myšlenkou produkční funkce je, že pro jakoukoliv kombinaci vstupů x existuje jednočíselný výsledek v podobě y . Tato myšlenka souvisí s tím, že za všech okolností je předpokládán maximální výsledek produkční funkce při daných vstupech, tedy většinou není uvažována neefektivní produkce (Chambers, 1989, str. 7-8).

Produkční funkce dělíme na krátkodobé a dlouhodobé. Krátkodobé se vyznačují tím, že některé její součásti jsou fixní. Podle Brčáka et al. (2020) může mít produkční funkce tyto charakteristiky:

- a. alespoň jeden výrobní faktor,
- b. firmy nemění odvětví - tzn. je uvažován fixním počtem firem,
- c. existuje fixní náklad.

Pro dlouhodobé funkce známe zase tyto charakteristiky:

- a. veškeré uvažované výrobní faktory jsou variabilní,
- b. firmy mohou z odvětví odcházet - tzn. je jich variabilní počet,
- c. existují jen variabilní náklady (Brčák et al., 2020, str. 130; Hořejší et al., 2010, str. 164).

3.6.1 Zkoumané veličiny krátkodobé produkční funkce

Při zkoumání produkční funkce jsou nejčastěji sledovány veličiny, které na základě svých hodnot dokážou určit, v jaké části produkční funkce se nachází určitá míra produkce (např. v jaké fázi – viz níže). Mezi zkoumané veličiny řadíme celkový produkt, průměrnou produkci, mezní produkci a elasticitu. Více o těchto veličinách v příloze 6.

3.6.2 Tvar a průběh produkční funkce

Za pomoci čtyř výše zmíněných veličin lze určit tvar a průběh produkční funkce, který je rozdělován do tří fází.

První fáze produkční funkce je ohraničena maximem mezního produktu. To znamená, že s přibývajícím variabilním faktorem se zvyšuje produkce rychleji než vstup. Průměrný produkt je také rostoucí. Tato fáze trvá, dokud nedosáhne inflexního bodu, který je ohraničen právě maximem mezního produktu. V inflexním bodě přechází funkce z progresivní části do fáze degresivní. Jde o racionální případ (Brčák et al., 2020, str. 140-141; Hořejší et al., 2010, str. 167-168).

Druhá fáze je ohraničena maximem mezního produktu a maximem průměrného produktu. Od konce druhé fáze již průměrný produkt klesá. Lze si také všimnout, že

průměrný produkt ve svém maximu protíná mezní produkt. Jedná se již o neracionální případ (Brčák et al., 2020, str. 140-141; Hořejší et al., 2010, str.168-169).

Třetí fáze je v rozmezí maxima průměrného produktu a bodu, ve kterém se mezní produkt rovná nule. To znamená, že mezní produkt i průměrný produkt je zde klesající. Od konce třetí fáze by již produkce klesala právě kvůli meznímu produktu, který se rovná nule. Jedná se opět o iracionální fázi (Brčák et al., 2020, str. 140-141; Hořejší et al., 2010, str.168-169).

3.6.3 Předpoklady produkční funkce

Produkční funkce by měla splňovat určité předpoklady, tyto předpoklady jsou popsány v rámci publikace Chambers (1989). Chambers (1989, str. 8-14) uvádí následující předpoklady:

- a) monotonicita – přibývajících vstupů by nikdy neměli snižovat výstup produkční funkce,
- b) různé kombinace vstupů schopné produkovat určitý výstup by měly vyobrazovat křivku v konvexním tvaru,
- c) dodržení podmínky klesající mezní produkce (jelikož se tento předpoklad pře s předpokladem „b“, tak se tento předpoklad v případě analýzy produkční funkce vykládá jako nezvyšující se příbytek produkce za použití dalšího vstupu),
- d) pozitivní výstup je vyjádřen bez vzácných zdrojů a zároveň produkční funkce nesmí obsahovat vstupy, bez kterých může být výstup i tak vytvořen,
- e) v případě použití vstupů musí vždy existovat výstup (produkce je neprázdnou množinou),
- f) produkční funkce je vždy nezáporná, konečná a má reálnou hodnotu, pro každý vstup, který je nezáporný a konečný,
- g) produkční funkce je spojitá a poslední podmínkou je, že funkce může být dvakrát derivována v každém svém bodě.

3.7 Zemědělská produkční funkce ve vztahu ke klimatickým změnám

Základní podoba produkční funkce ve vztahu ke klimatickým změnám je určena specifickými „výrobními faktory“, které lze definovat takto:

$$y = f(H, P, S, L), \quad (46)$$

kdy H představuje („heat“) neboli teplo, kterému je rostlina vystavena, P představuje („precipitation“) srážky na daném území, S představuje („soil“) půdní charakteristiky a L představuje ostatní faktory, které nejsou zachyceny v předchozích faktorech (lze do tohoto výrobního faktoru zařadit agregované vstupy, makroekonomické a socioekonomické faktory, technologii a jiné) (Yun et Gramig, 2022, str. 1).

3.8 Justova a Popeova produkční funkce

Za účelem odhadu produkční funkce v zemědělství byla vytvořena produkční funkce od autorů Just a Pope, která dokáže zahrnout jak socio-ekonomické proměnné tak i klimatické proměnné (Cabas et al., 2010, str. 601).

Hlavní motivací tvorby této produkční funkce je špatně odhadovaná mezní variabilita vstupů, která působí na výstup. Just a Pope definovali jako základní problém klasických produkčních funkcí (např. Cobb-Douglasova) mezní variabilitu vstupů, která v tomto případě může nesprávně zachytit působení vstupů (více o mezní variabilitě v Just et Pope (1978)). Pokud je v zemědělství uvažováno, že se zvyšováním použitých hnojiv zároveň zvyšuje variabilita produkce, tak lze předpokládat, že se jedná o nesprávné zachycení skutečnosti, a to samé může platit i pro použití pesticidů aj. Na základě této úvahy tedy vznikla upravená produkční funkce, která se skládá ze dvou funkcí.

$$y_t = f(X) + h^{\frac{1}{2}}(X)\varepsilon \quad (47)$$

Díky této funkci působí efekty průměrů a variability nezávisle na sobě. V této podobě můžou vstupy zvyšovat i zároveň snižovat variabilitu, což je v souladu s postuláty Just et Pope (1978, str. 69). Lze tedy odhadovat modely, kdy hnojiva mohou s růstem jejich užívání snižovat variabilitu produkce.

3.8.1 Odhad modelu JP

Odhadnout model je možné pomocí GLS a most likelihood estimation. MLE se nejčastěji používá pro modely s menším množstvím pozorování a tato metoda není v této práci popsána. Odhad pomocí GLS probíhá ve třech krocích. V prvním kroku je proveden odhad modelu pomocí metody OLS. Tím je získána odhadnutá reziduální složka. Nyní je vzata ona reziduální složka a následně je umocněna na druhou. Je provedena druhá OLS, kde je reziduální složka na druhou z první OLS v závislosti na původní matici X. Odmocněná odhadnutá reziduální složka z druhého kroku je následně vložena zpět do funkce v podobě vah s původními determinanty (v podobě matice Ω) a opět je provedena

regrese pomocí OLS (Cabas et al., 2010, str. 601). Druhou možností je vložit teoretickou hodnotu odmocněných reziduí zpět do funkce v podobě dalšího parametru, tak jako je uvedeno ve funkci výše a tento způsob odhadu byl využit v práci Halová et al. (2021).

3.9 Klimatická změna

Klimatická změna je v posledních letech stále více debatována a zkoumána ve většině oblastech ekonomie a zemědělství. Tato změna je typicky prezentována v souvislosti se skleníkovými plyny, které lidstvo v hojné míře produkuje. Může se jednat o CO₂ (oxid uhličitý), CH₄ (metan) anebo N₂O (oxid dusný). Klimatická změna v souvislosti s makroekonomií i mikroekonomií může mít různé následky. I když se tato diplomová práce zabývá především mikroekonomií, ekonometrickým měřením a zemědělstvím v České republice, je vhodné představit si i makroekonomické implikace (Jiménez, 2023, str. 2).

Klimatická změna může přinést zásadní změny v zemědělských postupech ve všech pěstitelských oblastech s tím, že některé oblasti jsou změnám vystaveny dříve a více a některé zase méně. Jedná se tedy především o změny v jednotlivých lokalitách než globální změny. Aktuálně se hovoří o stanoveném teplotním limitu, který je vhodné nepřekračovat. Tímto limitem je nárůst teploty o 1,5 stupňů celsia od předindustriálního období. Předindustriální období je typicky definováno jako časový interval mezi roky 1850-1900. Publikace Jiménez et al. (2023, str. 2) udává, že s růstem teploty o jeden stupeň celsia by stoupla četnost výskytu teplotních extrémů 2,8krát. Na základě aktuálního vývoje produkce GHG (Green House Gasses) je zhruba 50 % pravděpodobnost, že bude stanovená hranice 1,5 stupně celsia překonána již v roce 2032. To by následně znamenalo, že výskyt extrémních teplot se zvýší až o dvojnásobek (5,6 stupně celsia) (Jiménez, 2023, str. 2).

Klimatická změna je sledována především ve dvou základních oblastech, které mají vliv na zemědělství. Je to růst variability srážek a častější setkávání se s teplotními extrémy. U srážek je možné sledovat i další změny, které nebyly zmíněny výše:

1. růst intenzity srážek,
2. růst frekvence srážek, kterým je půda vystavena,
3. a změna v tom, kdy začne a skončí deštné období v tropických oblastech (Jiménez et al., 2023, str. 2).

Klimatické změny mohou mít následně negativní efekt na zemědělskou produkci, pro kterou jsou výše zmíněné faktory hlavními vstupy. To může vést k růstu vysušených oblastí, k vyšší variabilitě zemědělské produkce, k nižší kvalitě zemědělské produkce a k úplnému

zamezení pěstování specifických plodin v určitých oblastech. Tyto negativní efekty mohou následně vést k lokálnímu růstu chudoby, hladomoru a nerovnosti mezi pěstitelskými oblastmi (což následně může vést k cenovým poklesům a růstům) (Jiménez et al., 2023, str. 2).

Zároveň můžou pěstitelské oblasti přecházet na jiné plodiny a odrůdy, než které byly dosavadně užívány. Tato situace může nastat v závislosti na poklesu výnosnosti plodiny s rostoucí teplotou. Většina ekonometrických modelů se ovšem zaměřuje na plodiny jednotlivě a neuvažují přechod farmáře na jiné plodiny. Tento přechod je například důležitý zahrnout v případě modelování výnosnosti farem v peněžní podobě, kdy je vhodné změnu odrůdy brát v úvahu (Deschenes et Greenstone, 2007, str. 359).

3.9.1 Teplota

V rámci teploty se lze podle Evropské komise (2024) zaměřit na budoucí zvyšování teploty a vyšší výskyt vysokoteplotních extrémů. Zároveň by mělo docházet ke snižování frekvence výskytu nízkoteplotních extrémů. Změna teploty s sebou přináší změny v rozšíření rostlin, ve fenologii rostlin (např. změna životního cyklu) a ve výši výskyt chorob a škůdců (Evropská komise, 2024).

Expertní stanovisko Akademie věd ČR (AV, 2020) uvádí odhadovanou klimatickou změnu, které na základě EURO-CORDEX modelů předpokládá nárůst teploty na území ČR o 2 stupně celsia oproti teplotnímu průměru mezi roky 1981-2010 (AV, 2020).

3.9.2 Srážky a sucho

V případě kombinace nárůstu vysokoteplotních maxim a nižšího úhrn srážek (a jiného srážkového vzorce), lze očekávat nárůst délky období sucha a jejich závažnosti (Evropská komise, 2024).

V ČR se podle Akademie věd ČR (AV, 2020) lze setkat s nevýznamnou změnou co se týče dlouhodobého průměru srážek. Vznik suchých období je tedy dán spíše nárůstem teploty než poklesem srážek. AV ČR ovšem zaznamenává změnu v nárůstu dní s významnými srážkami (dny se srážkami alespoň 10 mm). Lze tedy pozorovat vyšší frekvenci dní s významnými srážkami, což může do budoucna znamenat vyšší riziko přívalových povodní (AV, 2020).

3.10 Pšenice v českém prostředí

Pšenice je rostlinou z rodu lipnicových. V ČR se nejčastěji vyskytuje pšenice obecná, která je pěstována jako ozim i jařina. Lze se setkat s formami, které se vyznačují červenou nebo bílou barvou klasu a dále se dělí dle osinatosti. V ČR se jedná většinou o bílý klas bez osin (Tichá et Vyzínová, 2016).

Pšenice se využívá k výrobě mouky, ze které se následně tvoří další produkty jako jsou těstoviny, pečivářské produkty, kroupy a jiné. Jako vedlejší produkt známe otruby, které jsou využívány v krmivářství (Tichá et Vyzínová, 2016).

Pšenice v České republice má významné postavení hlavně z důvodu jejího zastoupení mezi obilninami vysetými v České republice a mezi zemědělskými plodinami vůbec. Z obilniny je pšenice na prvním místě v osevní ploše, kdy pšenice ozimá byla vysazena na 801 578 ha v roce 2022. Plodinou, která je v tomto žebříčku na druhém místě, je ječmen jarní, který zaujal 211 890 ha osevní plochy (ČSÚ, 2022). V České republice se nejčastěji využívá pšenice ozimá, jejíž výsev je možný již v září (Zimolka et al., 2005, str. 29) a v menším množství pšenice jarní, jejíž výsev je možný již v březnu. Nižší výskyt pšenice jarní je dán její vyšší citlivostí na vnější podmínky, kterými jsou chlad a teplo (Zimolka et al., 2005, str. 116). Ozim bývá na druhou stranu citlivější na choroby pat a stébel. Pšenice ozimá vzchází při teplotách okolo 15 stupňů celsia a při dostatku vláhy během sedmi až devíti dní a roste do té doby, než teploty klesnou k hodnotám čtyř až pět stupňů. Zimu přežívá díky mrazu vzdornosti, která funguje zhruba do mínus osmnácti až pětadvaceti stupňů. Při pěstování pšenice je třeba dát si pozor na vhodné zařazení do osevního postupu z důvodu zhoršování půdních vlastností (Tichá et Vyzínová, 2016).

3.10.1 Vhodné podmínky pro pěstování

Podle publikace Zimolka et al. (2005, str. 17) je míra variability výnosu pšenice ovlivněna stanovištěm a počasím daného roku až z 25 % s tím, že počasí v daném roce ovlivňuje variabilitu výnosu více než půdní stanoviště i přes značnou citlivost pšenice ke svému stanovišti (která je dána slaběji vyvinutým kořenovým systémem).

Mezi půdy, do kterých není vhodné pšenici sázet, patří půdy písčité, kyselé (pod 6,2 pH) anebo trvale zamokřené. Vnější vlivy, které mohou mít zásadní dopad na pšenici, se liší podle jejího stanoviště. V řepařských a kukuřičných oblastech hraje hlavní roli úhrn srážek za vegetační období a jinde tuto roli přejímá především teplota ve finálních fázích vývoje

(specificky – období sklizně). To podle všeho ovlivňuje stabilitu výnosu více než výsevek, hnojení a stanoviště (Zimolka et al. 2005, str. 17).

Na základě publikace Zimolka et al. (2005, str. 17) lze oblasti rozdělit dle vhodnosti pro pěstování pšenice a dělení je následující.

Velmi vhodné oblasti:

- teplota – teplé až velmi teplé,
- vlhkost – suché až velmi suché,
- průměrná teplota (jarní a letní) – 14-17 °C,
- úhrn srážek – 250 – 350 mm,
- jižní Morava a severozápadní Čechy,
- výrobní oblast – kukuřičná, teplá, a suchá řepařská (Zimolka et al., 2005, str. 17).

Vhodné:

- teplota – poměrně až dostatečně teplé,
- vlhkost – mírně až převážně suché,
- průměrná teplota (jarní a letní) – 13-15 °C,
- úhrn srážek – 350–400 mm (Morava), 350 mm (Čechy),
- výrobní oblast – obilnářská a řepařská,
- půdní typ – hnědozemě, nivní půdy, rendziny, černozemě (Zimolka et al., 2005, str. 17).

Méně vhodné:

- teplota – mírně až poměrně teplé,
- vlhkost – mírně vlhké až mírně suché,
- průměrná teplota (jarní a letní) – 12-14 °C,
- úhrn srážek – 400-500 mm na Moravě, v Čechách i méně mm,
- půdní typ – podzolové a hnědozemě (Zimolka et al., 2005, str. 17).

Nevhodné:

- teplota a vlhkost – chladné a vlhčí,
- průměrná teplota (jarní a letní) – 11-13 °C,
- srážkový úhrn – nad 500 mm,
- půdní typ – většinou podzolový (Zimolka et al., 2005, str. 17).

3.10.2 Fenologie pšenice v prostředí ČR

Fenologie neboli nauka o vývoji pšenice je důležitá z důvodu přesného modelování. Prášil et al. (2019) rozlišuje tři základní vývojové fáze, a to fázi vegetativní, reprodukční a fázi zrání. Určení počátku jednotlivých fází není možné přesně podle měsíců. Určení těchto fází provádí Prášil et al. (2019) podle stupnice BBCH, kdy určujícím znakem přechodu rostliny z fáze vegetativní (od zasetí) do fáze reprodukční je to, že rostlina začne tvořit dvojité hrbolky. Tato fáze se většinou začíná objevovat u raných výsevů již během března. Plná zralost a možnost sklizně nastupuje v průběhu června, kdy v červenci a v srpnu již dochází ke sklizním (Prášil et al., 2019).

Z výše uvedeného vyplývá, že klima v období reprodukční fáze zásadně ovlivňuje finální výnos pšenice. Co ovšem nebývá často uvedeno je význam srážek a teplot v období podzimních měsíců, a tedy v období vegetativním, které lze pozorovat ihned po setí pšenice.

Na základě Váňová et al. (2021) byla pozorována významnost podzimních srážek a podzimních teplot. Podzimní srážky významně ovlivňují hustotu porostu. Pokud jsou srážky v podzimním období nedostatečné a teploty nadprůměrné, tak lze pozorovat nižší hustotu porostů.

3.11 Již bylo na toto téma napsáno

V této kapitole jsou popsány již vytvořené ekonometrické práce, které se zabývají problematikou klimatické změny a vlivem na výnos pšenice v ČR i v zahraničí.

V České republice bylo toto téma zkoumáno ve studii Hálková et al. (2021). V případě této práce byla zkoumána panelová data od roku 1961-2018 podle regionů v České republice. V práci byly zahrnuty proměnné pro technologickou změnu, input/output indexy a klimatické proměnné. Technologická změna měla pozitivní efekt na sklizeň, oproti spíše negativním efektům klimatických proměnných, které jsou v případě tohoto modelu specifikovány na měsíční bázi (duben až červenec). V práci byla použita Just a Popova produkční funkce. Klimatické proměnné vykazují nelinearitu, a z toho důvodu, byl pro odhad nelineárních klimatických proměnných v jednotlivých měsících použit kvadratický tvar proměnných. Druhý řád proměnných je něco, co se používá v zásadě běžně v modelech zabývajících se produkčními funkcemi.

Shayanmehr et al. (2020) zkoumali vliv sucha, klimatické změny a oblastí, kde se pěstuje pšenice bez zavlažování v západním a východním Ázerbájdžánu. Pro klimatické proměnné studie využívá Statistical Downscaling Model. V případě této publikace je

porovnáván lineární a nelineární model (kvadratické proměnné). V obou případech je použita Just a Popeova specifikace modelu, která je odhadnuta za pomoci FGLS. Model obsahuje následující proměnné: sezónní minima a maxima teploty, sezónní srážky, sezónní sucho, obdělávanou plochu a časový trend. Zajímavostí je rozdílnost výsledků na základě podoby modelu. Minimální teplota má negativní vliv na průměr výnosu pšenice v podobě lineárního modelu, a naopak v nelineárním modelu má pozitivní vliv. U maximální teploty je tomu opačně v obou případech. Výsledkem modelu od Shayanmehra et al. (2020) je také to, že do budoucna lze očekávat růst variability výnosnosti pšenice, která je závislá na dešti.

Holman et al. (2011) oproti dvěma výše uvedeným studiím nevyužívá kvadratický tvar klimatických proměnných, ani cenové indexy. Oproti tomu popisuje vliv teploty a srážek v jednotlivých měsících po celou dobu produkčního cyklu pšenice. Podle Miao et al. (2016) může být tento odhad zkreslený z důvodu nevyužití právě cenových indexů, kdy tato skutečnost může výrazně podhodnotit vliv klimatických proměnných.

Autor Miao et al. (2016) ve své publikaci bere v potaz cenový index hnojiv, GDD (growing degree days), teplotní odchylky ve specifických měsících, dny s extrémními teplotami a časový trend. K odhadu jsou v této práci použity instrumentální proměnné z důvodu možné endogenity. Zároveň je v jejich odhadu zachycena prostorová autokorelace.

4 Vlastní práce

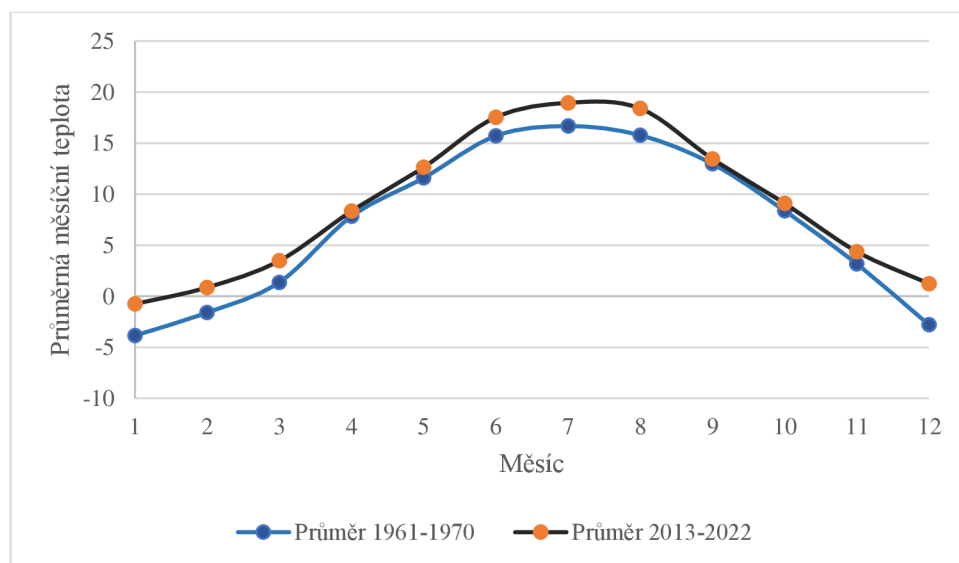
Ekonometrický model sestaven v následujících kapitolách se bude skládat ze sady proměnných, které budou nejdříve zkoumány a analyzovány. Pro základní vzhled do problematiky jsou nejdříve zobrazeny jednotlivé proměnné graficky a dále jsou zobrazeny jejich elementární statistické vlastnosti. Proměnnými jsou klimatické a socioekonomické proměnné. Mezi klimatické proměnné patří především měsíční průměrné teploty a měsíční úhrny srážek. Mezi socioekonomické proměnné patří cenové indexy vstupů a výstupů zemědělství. Práce je založena na datech, která byla poskytnuta autorovi diplomové práce Katedrou ekonomiky z Provozně ekonomické fakulty České zemědělské univerzity.

4.1 Vývoj klimatických podmínek v České republice

4.1.1 Teplota v ČR

Pro sledování vývoje klimatických změn v České republice jsou použita data z Českého hydrometeorologického ústavu, která jsou shromážděna v časových řadách od roku 1961 do roku 2022. V této kapitole jsou použity průměrné měsíční teploty na celém území České republiky. Sledování vývoje klimatu v ČR je založeno na zhodnocení rozdílu mezi desetiletými průměry na začátku a na konci sledovaného období, tato data jsou zpracována graficky i v podobě tabulky.

Graf 1: Rozdíl mezi desetiletými průměry měsíčních teplot



Zdroj: vlastní zpracování na základě dat z ČHMI

Z grafu 1 je patrné, že v případě teplot dochází mezi desetiletými průměry k určité změně. Změnu v teplotním průměru lze pozorovat především v letních a v zimních měsících.

Oproti tomu v jarních a podzimních měsících nedochází k tak výraznému rozdílu mezi průměry. Pro přesnější popis hodnot sledovaných v grafu je uvedena následující tabulka 1.

Tabulka 1: Porovnání desetiletých teplotních měsíčních průměrů na začátku a konci období


Měsíc [celsius]	Průměr 1961-1970	Průměr 2013-2022	Rozdíl mezi průměry
TM1	-3,86	-0,76	3,1
TM2	-1,6	0,86	2,46
TM3	1,36	3,47	2,11
TM4	7,83	8,34	0,51
TM5	11,59	12,64	1,05
TM6	15,72	17,54	1,82
TM7	16,67	18,95	2,28
TM8	15,77	18,39	2,62
TM9	12,97	13,45	0,48
TM10	8,37	9,09	0,72
TM11	3,16	4,37	1,21
TM12	-2,8	1,23	4,03
TM_Year	7,1	8,94	1,84

Zdroj: vlastní zpracování na základě dat z ČHMI

Podle tabulky 1 lze vidět, že v měsíci lednu, únoru, březnu, červenci, srpnu a prosinci docházelo k největším změnám. V těchto měsících se zvýšila průměrná hodnota v desetiletém období o více než dva stupně celsia. Největší změnu lze zaznamenat v prosinci, kdy se průměrná teplota mezi dvěma desetiletými průměry zvýšila o 4,03 stupně celsia. Průměrná roční teplota na celém území ČR se zvýšila o 1,84 stupně celsia. Nejvyšší teploty lze nalézt v červnu, červenci a v srpnu, přičemž průměrné teploty v těchto měsících v období mezi lety 2013-2022 dosahovaly průměrně 17,54 °C, 18,95 °C a 18,39 °C. Nejnižší teploty lze nalézt v zimních měsících, konkrétně v prosinci, lednu a v únoru, kdy byly jejich průměrné hodnoty v letech 2013-2022 1,23 °C, -0,76 °C a 0,86 °C.

V následujícím grafu 2 byla zobrazena průměrná roční teplota v celém sledovaném období. Byl zároveň vytvořen trend průměrné roční teploty, který je také zobrazen v grafu 2.

Graf 2: Lineární trend průměrné roční teploty v ČR



Zdroj: vlastní zpracování na základě dat z ČHMI

Z grafu 2 je patrné, že má průměrná roční teplota rostoucí trend. Parametr časové řady je 0,0338. To znamená, že se teplota v České republice zvyšuje o 0,0338 stupně celsia ročně za podmínky ceteris paribus. R^2 má v tomto případě hodnotu 0,4812. Hodnota R^2 pod 0,5 je způsobena výraznou oscilací teploty okolo trendové funkce. Průměrné tempo růstu je 0,25 %, což vyplývá z průměrného koeficientu růstu s hodnotou 1,0025. Na základě trendu a průměrného tempa růstu lze očekávat nárůst průměrné roční teploty i v budoucích letech.

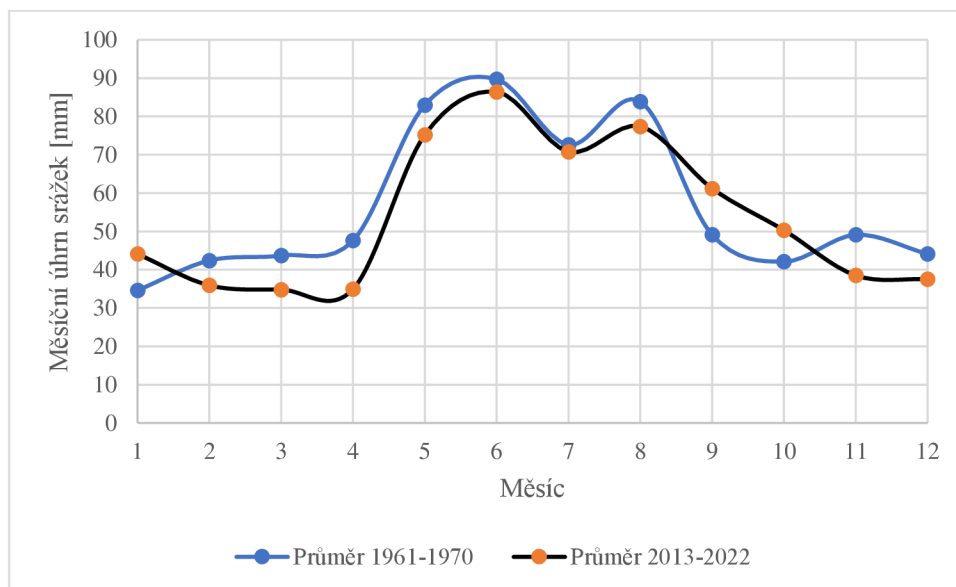
Nejnižší průměrnou roční teplotou bylo 6,3 stupňů celsia. Tuto teplotu ČHMI zaznamenal ve třech letech, a to v roce 1962, 1980 a 1996. První ze dvou nejchladnějších let se nachází v první polovině sledovaného období.

Nejvyšší průměrná roční teplota za sledované období byla ve výši 9,6 stupňů celsia (v roce 2018). Všeobecně lze prohlásit, že veškeré nejvýznamnější teplé roky (tj. roky s průměrnou roční teplotou nad 9 stupňů celsia) lze nalézt v posledních dvaceti dvou letech sledovaného období (tedy v letech 2000-2022). Toto zjištění je v souladu s AV (2020).

4.1.2 Srážky v ČR

Na grafu 3 lze vidět rozdíly mezi desetiletými průměry úhrnů srážek v jednotlivých měsících. Z těchto dat byla následně vytvořena tabulka 2, kde jsou přehledně zobrazeny jednotlivé hodnoty.

Graf 3: Rozdíl mezi desetiletými průměry měsíčních úhrnů srážek v mm



Zdroj: vlastní zpracování na základě dat z ČHMÚ

Tabulka 2: Porovnání desetiletých měsíčních průměrů úhrnu srážek na začátku a na konci sledovaného období

Měsíc [celsius]	Průměr 1961-1970	Průměr 2013-2022	Rozdíl mezi průměry
SM1	34,6	44,1	9,5
SM2	42,4	35,9	-6,5
SM3	43,7	34,8	-8,9
SM4	47,6	34,9	-12,7
SM5	83,0	75,2	-7,8
SM6	89,7	86,4	-3,3
SM7	72,6	70,8	-1,8
SM8	83,9	77,4	-6,5
SM9	49,1	61,2	12,1
SM10	42,1	50,3	8,2
SM11	49,1	38,5	-10,6
SM12	44,1	37,5	-6,6
SM_year	681,9	647,5	-34,4

Zdroj: vlastní zpracování na základě dat z ČHMÚ

Lze vidět, že v případě srážek nedochází k tak výrazné změně jako u průměrných teplot. S přihlédnutím ke grafu 3 a tabulce 2 lze pozorovat mírný pokles mezi oběma desetiletími. Tento výsledek se v zásadě shoduje s tvrzením AV (2020).


K největšímu nárůstu srážek došlo v lednu a v září. V lednu se srážky zvýšily o 9,5 mm a v září o 12,1 mm. Naopak nejvyšší pokles lze sledovat v listopadu a dubnu, kdy

v případě listopadu docházelo v průměrné hodnotě v letech 2013-2022 k poklesu o 10,6 mm oproti rokům 1961-1970 a v případě dubna docházelo k poklesu o 12,7 mm.

Nejnižším ročním úhrnem srážek bylo 504 mm. Toto množství srážek bylo pozorováno v roce 2003. Druhé nejnižší množství srážek bylo pozorováno v roce 2018, kdy bylo naměřeno 522 mm. Oproti tomu největší množství srážek bylo pozorováno v roce 2010, kdy byla naměřena hodnota 867 mm a v roce 2002, kdy byla naměřena hodnota 855 mm. Na základě výše uvedených výsledků tedy nelze říci, že dochází k nárůstu či k poklesu srážek mezi jednotlivými polovinami sledovaného období tak, jako tomu bylo v případě teplot.

Následně byl z ročního úhrnu srážek v České republice od roku 1961 do roku 2022 vytvořen graf 4, který opět obsahoval trendovou funkci. Tato trendová funkce vykazuje mírně rostoucí tendenci s hodnotou parametru 0,2037. Při porovnání parametru trendové funkce úhrnu srážek a tabulky 2 lze vidět, že průměr mezi oběma desetiletími poklesl, což je v nesouladu s očekáváním, které vyvstalo na základě trendového parametru. Následně byl vypočítán koeficient tempa růstu průměrných ročních srážek, který vyšel ve výši 0,99954. Tento výsledek poukazuje na meziroční snižování úhrnu srážek o 0,001 %, což koresponduje s poklesem srážek ve sledovaném období v letech 1961-2022. Tempo růstu potvrzuje výsledek z porovnání desetiletých průměrů. Využití trendové funkce v tomto ohledu nebylo vhodné, a to vzhledem k R^2 , který má hodnotu 0,0019. Je tedy vhodnější se k hodnocení srážek na základě trendové funkce nepřiklánět.

Graf 4: Vývoj ročního úhrnu srážek za sledované období na území ČR



Zdroj: vlastní zpracování na základě ČHMÚ

4.1.3 Klimatická charakteristika krajů ČR

Nejteplejším krajem České republiky na základě průměrné roční teploty za sledované období v letech 1961-2022 je Jihomoravský kraj s průměrem 8,88 stupně celsia. Nejvyšších průměrných ročních teplot následně dosahovala Praha a Středočeský kraj (8,57 stupně celsia). Nejchladnějším krajem byl naopak kraj Karlovarský (6,75 stupně celsia) společně s Libereckým krajem (7,35 stupně celsia). V případě rozptylu ročního teplotního průměru dosahoval nejvyšší hodnoty Jihomoravský kraj (0,82 °C²) a kraj Vysočina (0,81 °C²). Nejnižší rozptyl měl kraj Jihočeský 0,72 °C² a následně Liberecký a Olomoucký kraj s hodnotou okolo 0,74 °C².


Nejvyšším množstvím průměrného ročního úhrnu srážek ve sledovaném období 1961-2022 se vyznačoval Liberecký kraj s hodnotou 845,68 mm, po kterém následoval Moravskoslezský kraj s hodnotou 802,18 mm. Nejnižším množstvím srážek se vyznačoval naopak kraj Jihomoravský (546,42 mm) a následně kraj Středočeský s Prahou (586,89 mm). Nejvyšší rozptyl ročního úhrnu srážek měl ve sledovaném období Liberecký kraj s hodnotou 17807,09 mm². Druhý nejvyšší rozptyl je pozorován v Moravskoslezském kraji, který byl ve výši 13074,44 mm². Naopak nejnižší rozptyl lze nalézt v Jihomoravském kraji (6172,05 mm²) a na Vysočině (7 485,48 mm²).

4.1.4 Vývoj socioekonomických proměnných

Mezi socioekonomické proměnné jsou v této práci zahrnuty dva specifické cenové indexy. Prvním cenovým indexem je index vstupů výrobků a služeb do zemědělství a druhým je cenový index potravinářské pšenice. Zdrojem dat je databáze poskytnutá Katedrou ekonomiky z Provozně ekonomické fakulty ČZU, která byla vytvořena na základě dat z ČSÚ. Je třeba mít na paměti, že indexy cen nepředstavují nominální ceny daného roku. Pokud jsou porovnávány indexy cen, tak lze prohlásit, který rok oproti referenčnímu roku vykazoval nárůst anebo pokles ceny. Referenčním rokem pro oba cenové indexy je rok 2000.

Data cenových indexů byla nejdříve zpracována v podobě grafů. Následně byl vyhodnocen trend cenových indexů a průměrné tempo růstu.

Graf 5: Cenové indexy vstupů a výstupů



Zdroj: vlastní zpracování na základě dat z Českého statistického úřadu

Na základě grafu 5 lze pozorovat velice pozvolný růst cenového indexu pšenice mezi lety 1961 až 1989. Velice mírný růst lze pozorovat i v případě cenového indexu vstupů do zemědělství v období od roku 1961 do roku 1992. Zvláštností je, že rok prudkého nárůstu indexů se mezi těmito dvěma indexy liší. Autor diplomové práce pro tuto skutečnost nenalezl žádné vysvětlení. Nicméně je zřejmé, že po zániku ČSSR došlo ke zvýšení tempa růstu i variability cenových indexů. V celém období od roku 1961 až do roku 2022 má trend u obou cenových indexů kladný parametr. Kladný parametr znamená, že s každým dalším rokem se cenový index pšenice zvyšuje o 0,019 a cenový index vstupů do zemědělství o 0,022, oboje za podmínky *ceteris paribus*.

Tabulka 3: Trendová analýza cenových indexů

Proměnná	Konstanta	Parametr	R ²
IC_Pšenice	-37,566	0,019	0,758
IC_Vstupy	-43,205	0,022	0,929

Zdroj: vlastní zpracování na základě dat z ČSÚ

Průměrné tempo růstu v případě cenového indexu vstupů do zemědělství bylo 3,2 % ročně, cenový index pšenice oproti tomu roste pouze o 2,9 % (na základě průměrného tempa růstu) ve sledovaném období. Průměrné tempo růstu mezi časovými intervaly 1961–1990 a 1991–2022 se lišilo zhruba o 1 p.b. v případě vstupů do zemědělství a v případě pšenice o 2 p.b. Na základě trendové funkce i průměrného tempa růstu lze prohlásit, že ve sledovaném období od roku 1961 až do roku 2022 cenový index vstupů do zemědělství vykazoval vyšší růst.

4.1.5 Rozloha, produkce a výnos pšenice

Ve sledovaném období od roku 1961 do roku 2022 byl největším pěstitelem pšenice Středočeský kraj. Průměrná osevní plocha ve Středočeském kraji v tomto období byla 157 030,93 hektarů. Druhým krajem s nejvyšším průměrem osevní plochy byl Jihomoravský kraj s průměrem 106 030,86 ha. Třetí nejvyšším průměr osevní plochy měl Jihočeský kraj s hodnotou 72 592,20 ha. Oproti tomu nejmenší průměrnou osevní plochu za sledované období měla Praha (3 391,22 ha), Karlovarský kraj (11 758,55 ha) a kraj Liberecký (13 710,99 ha).

Průměrná osevní plocha v ČR v jednotlivých letech za sledované období měla rostoucí tendenci. To vyplývá z trendové funkce s kladným parametrem, a také z průměrného tempa růstu, které bylo 1,03 % ročně. Celkově tedy osevní plocha pšenice v ČR za sledované období zaznamenávala nárůst. Největší osevní plocha využita pro pšenici byla v roce 2000 (970 434,73 ha), po tomto roce následoval celkem razantní propad, který dosáhl svého dna v roce 2003 při hodnotě 648 390 ha (celkový propad byl 33,19 % oproti roku 2000). Takto nízká hodnota byla v České republice pozorována naposledy v roce 1967.

Produkce pšenice vykazuje oproti průměrné osevní ploše vyšší variabilitu, a to z toho důvodu, že je ovlivněna větším množstvím faktorů. Produkce je ovlivněna jak cenou, tak i klimatickými proměnnými (nepředpokládá se, že by farmáři ve sledovaném období měnili plodinu z důvodu změny klimatu). Produkce vykazuje rostoucí charakter, to je dáno přírůstkem osevní plochy, ale pravděpodobně i zlepšujícími se technologiemi.

Výnosnost neboli počet tun pšenice na jeden hektar má rostoucí charakter. Od roku 1961 do roku 2022 vzrostl průměrný výnos pšenice z 2,78 t/ha na 6,1 t/ha. Průměrné tempo růstu bylo ve výši 1,3 %, což svědčí o intenzifikaci pěstitelství pšenice. Kladné tempo růstu může být vysvětleno nárůstem vstupů do zemědělství, vylepšenou technologií sklizně a pěstování, anebo použitím vhodnějších/lepších odrůd pšenice. Nejvyšší průměrný výnos na hektar v ČR má Olomoucký kraj (4,64 t/ha) a následně Praha (4,79 t/ha). Nejhorší průměrný výnos na hektar ve sledovaném období má kraj Karlovarský (3,87 t/ha) a kraj Liberecký (4,00 t/ha).

4.2 Ekonometrické modely a jejich specifikace

V této kapitole jsou vytvořeny ekonometrické modely zjišťující vliv socioekonomických a klimatických proměnných na výnos pšenice v ČR.

Klimatické proměnné zařazené do modelu jsou měsíční průměrné teploty a měsíční úhrny srážek podle krajů v ČR, které jsou uvedeny v kapitolách výše. Cílem modelů je zhodnotit vliv jednotlivých proměnných na výnos pšenice v ČR. Při tvorbě modelů jsou základním kamenem klimatické proměnné, které jsou voleny na základě studie Prášil et al. (2019) a studie Váňová et al. (2021) popsané v teoretické části této práce. Jelikož je v ČR především pěstována pšenice ozimá (viz výše – jedná se zhruba o 79 % v roce 2022), je třeba do modelu v případě klimatických proměnných zařadit zpožděné proměnné. Do modelu jsou zařazeny zpožděné proměnné od září do listopadu. V případě cenových indexů bude v modelu pracováno také se zpožděnou proměnnou (t-1), jelikož autor diplomové práce předpokládá, že rozhodovací proces o setí pšenice nastává o rok dříve, než je rok sklizně, a to na základě cen, které jsou v onom zpožděném roce.

4.2.1 Data vstupující do modelů

Do modelu vstupují data, která jsou shromážděna za roky 1961-2022. Data od roku 1961 do roku 2016 byla autorovi diplomové práce poskytnuta panem prof. Ing. Lukášem Čechurou, PhD. z Katedry ekonomiky z Provozně ekonomické fakulty ČZU. Tato data byla vytvořena z databází ČSÚ a ČHMÚ. Data od roku 2016–2022 byla doplněna autorem diplomové práce ze stejných zdrojů.

Výnos pšenice na jednom hektaru půdy v tunách (**závisle proměnná**):

- v modelu je použita souhrnná proměnná pro pšenici ozimou a pšenici jařinu.

Klimatické proměnné vstupující do modelu:

- průměrné měsíční teploty zpožděné o jeden rok od září do listopadu,
- průměrné měsíční teploty od února do července,
- měsíční úhrn srážek (v mm) zpožděný o jeden rok od září do listopadu,
- měsíční úhrn srážek (v mm) od února do července.

Poměr cenového indexu potravinářské pšenice a vstupů do zemědělství:

- zpožděná proměnná tvořená cenovým indexem ceny pšenice děleného cenovým indexem vstupů do zemědělství.

Technologická změna:

- technologickou změnu v modelu představuje časový trend.

4.2.2 Předpoklady ekonomické verifikace

Teplota v podzimních měsících – (září až listopad) – na základě studie Holman et al. (2011) lze předpokládat negativní vliv teploty v podzimních měsících. Vlivem vyšší teploty v podzimních měsících dochází k většímu růstu pšenice. Významně vzešlá pšenice je následně náchylnější k poškození mrazem v zimních měsících. Lze očekávat negativní vliv teplot v podzimních měsících. Zároveň vysoká teplota může vést k vyššímu vysychání půdy a následnému snížení hustoty porostů podle Váňová et al. (2021).

Srážky v podzimních měsících – (září až listopad) – na základy studie Váňová et al. (2021) lze očekávat pozitivní vliv srážek v podzimních měsících na výnos pšenice. Srážky v podzimních měsících mohou zajistit hustší porost pšenice, a tedy i následný vyšší výnos. Tento předpoklad potvrzuje i studie Holman et al. (2011).

Teploty od února do března – Holman et al. (2011) uvádí, že efekt jarních měsíců může být různý. Prvním efektem je ukončení dormance a následná vyšší náchylnost pšenice k vymrzání. Zároveň se tímto způsobem prodlužuje životní cyklus pšenice (pokud není ukončen vysokou teplotou dříve). Proto lze očekávat pozitivní vliv teplotních průměrů v únoru a březnu.

Srážky od února do března – Holman et al. (2011) uvádí, že srážky v únoru a březnu by měly mít pozitivní efekt na výnos pšenice.

Teploty od dubna až do července – práce Yang et al. (2019) popisuje negativní vliv teplot na výnos pšenice od dubna do července. Toto očekávání se částečně shoduje se studií Hálová et al. (2021), kde byl výjimkou měsíc červen.

Srážky od dubna do července – Holman et al. (2011) uvádí, že srážky od května do července již nezvyšují výnos pšenice. Lze tedy očekávat jen negativní vliv srážek od května do července, kdy může dojít k vymokání nebo k vyšší náchylnost k chorobám vlivem srážek. Oproti tomu srážky v dubnu by měly mít pozitivní vliv na výnos pšenice.

Kvadratické tvary teplotních a srážkových proměnných – v práci je očekávána nelinearita teplotních a srážkových proměnných. Tato nelinearita bude zachycena za pomoci kvadratických tvarů. Tyto kvadratické tvary by měly kopírovat konkávní tvar – je tedy očekáván negativní vztah parametru vzhledem k závislé proměnné.

Časový trend – v případě časového trendu je očekáván pozitivní vliv. Lepší technologie, lepší odrůdy, lepší osevnické postupy – to vše by mělo být zahrnuto v časovém trendu. Bude zároveň využit kvadratický tvar této proměnné. I u kvadratického tvaru je

očekávan pozitivní vliv na závisle proměnnou na základě studie Hállová et al. (2021) a Miao et al. (2016).

Poměrový ukazatel cenových indexů – na základě publikace Miao et al. (2016) lze očekávat pozitivní i negativní efekt poměrového ukazatele. Negativní efekt představuje skutečnost, kdy dochází k rozšiřování pšenice vlivem rostoucího cenového indexu pšenice i na pole, která pro pěstování pšenice nejsou natolik vhodná. Pozitivní vliv by následně představoval stav, kdy roste poměrový ukazatel vlivem snižující se ceny vstupů. V tomto případě farmáři mohou více intenzifikovat a lze očekávat vyšší výnos pšenice na jeden hektar.

4.3 Odhad BMNČ jednotlivých krajů

Výše uvedené předpoklady tvoří motivaci pro tvorbu sklizňové funkce, která v sobě obsahuje všechny měsíce ze životního cyklu pšenice, vyjma prosince a ledna. Tato sklizňová funkce je uvedena ve vzorci níže.

$$\begin{aligned}
 1. fce y_t &= \alpha_0 + \beta' X_t + \theta P_W_ratio_1 + \delta t + \varepsilon_t \\
 2. fce y_t &= \alpha_0 + \beta' X_t + \theta P_W_ratio_1 + \delta t + \varepsilon_t \\
 &\vdots \\
 &\vdots \\
 &\vdots \\
 14. fce y_t &= \alpha_0 + \beta' X_t + \theta P_W_ratio_1 + \delta t + \varepsilon_t
 \end{aligned}
 \tag{48}$$

Matice X_t v modelech představuje klimatické regresory, kterými jsou měsíční úhrny srážek (v modelech značeno jako „SM“) a průměrné měsíční teploty (v modelech značeno jako „TM“) v daném kraji. Specifickými regresory jsou měsíce předcházejícího roku od září do listopadu (TM9_1, TM10_1, TM11_1 a zároveň SM9_1, SM10_1, SM11_1). Jedná se o zpožděné proměnné, jelikož je vycházeno z předpokladu, že tyto měsíce mají vliv na výnos pšenice následujícího roku. Nezpžděné proměnné daného roku, které jsou obsaženy v X_t , představují měsíce od února až do července (TM2, ..., TM7 a SM2, ..., SM7) v případě teplot i srážek. Měsíce prosinec a leden v modelech nejsou využity, jelikož žádný z modelů nevykazoval statistickou významnost pro tyto měsíce a na základě literatury by neměly mít zásadní vliv na výnos pšenice. Zpožděná proměnná $P_W_ratio_1$ v modelech představuje poměr cenového indexu pšenice a cenového indexu vstupů ($\frac{CI_{pp}}{CI_{vz}}$, kde CI_{pp} = cenový index potravinářské pšenice a CI_{vz} = cenový index vstupů do zemědělství). Proměnná t představuje časový trend. Celkový počet proměnných včetně konstanty je $k = 20$. Počet období byl $T = 62$, ale jelikož jsou v modelech využity zpožděné proměnné, tak se počet

období snížil na $T = 61$. Rozměr matice regresů je tedy $T \cdot k = 1\,220$ pozorování. Modely mají v této podobě 41 stupňů volnosti.

V níže uvedených tabulkách jsou zobrazeny odhady vypočtené pomocí běžné metody nejmenších čtverců v softwaru Gretl. Jedná se o 14 odhadů modelů pro všechny kraje v České republice. Všechny proměnné vstupující do modelu byly zmíněny výše. Kromě parametrů jednotlivých proměnných a jejich p-hodnot jsou v tabulce uvedeny i testy ekonometrické verifikace. Jedná se o test heteroskedasticity, normality a autokorelace reziduí. Na konci tabulky je uveden adjustovaný koeficient determinace.

Tabulka 4: Výsledky odhadů jednotlivých OLS modelů pro jednotlivé kraje - 1. část

Proměnná	Kraj													
	Praha		Středočeský		Jihočeský		Plzeňský		Karlovarský		Ústecký		Liberecký	
	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota
const	7,6786	0,0009 ***	9,0334	<0,0001 ***	10,2994	<0,0001 ***	11,0001	<0,0001 ***	6,2256	0,0002 ***	6,4751	0,0011 ***	5,7221	0,0022 ***
TM2	0,0114	0,735	0,0504	0,0835 *	0,0221	0,3557	0,0219	0,4353	0,0410	0,1796	0,0264	0,4419	0,0112	0,7196
TM3	0,0744	0,116	0,0317	0,3677	0,0188	0,556	0,0471	0,1752	0,0548	0,1376	0,0748	0,0847 *	0,0594	0,1092
TM4	-0,0161	0,7807	-0,0410	0,32	-0,0484	0,252	-0,0113	0,7919	0,0101	0,8198	-0,0206	0,6909	0,0142	0,7881
TM5	-0,0757	0,196	-0,0708	0,1245	-0,0493	0,2653	-0,1307	0,0073 ***	-0,0824	0,0855 *	-0,1128	0,04 **	-0,0809	0,1165
TM6	-0,1294	0,0369 **	-0,1438	0,0047 ***	-0,1823	<0,0001 ***	-0,1549	0,0012 ***	-0,0386	0,4263	-0,1083	0,0576 *	-0,0403	0,4351
TM7	-0,0759	0,2238	-0,1035	0,0485 **	-0,0405	0,3806	-0,0639	0,2192	-0,0693	0,1565	-0,0583	0,2752	-0,0199	0,7056
TM9_1	-0,0475	0,4715	0,0261	0,6274	-0,0773	0,0996 *	-0,0910	0,0722 *	-0,0410	0,4255	-0,0004	0,9943	-0,0373	0,5358
TM10_1	0,0429	0,4883	0,0604	0,1817	-0,0462	0,2761	0,0146	0,7665	0,0229	0,6266	0,0436	0,4153	-0,0211	0,6598
TM11_1	0,0561	0,2791	0,0463	0,2926	0,0120	0,7422	0,0189	0,6553	0,0088	0,8435	0,0361	0,4788	0,0414	0,3381
SM2	0,0015	0,8041	-0,0037	0,4129	0,0034	0,2664	0,0006	0,8424	-0,0014	0,6375	-0,0009	0,8357	-0,0017	0,4973
SM3	-0,0030	0,5223	-0,0088	0,0203 **	-0,0065	0,0217 **	-0,0059	0,0497 **	-0,0071	0,0119 **	-0,0060	0,1293	-0,0034	0,1702
SM4	0,0061	0,2402	0,0019	0,6276	-0,0045	0,1205	-0,0030	0,395	0,0034	0,3603	0,0089	0,0489 **	-0,0018	0,6229
SM5	0,0014	0,6561	0,0006	0,8024	-0,0017	0,4754	-0,0020	0,3653	0,0002	0,9372	0,0056	0,0735 *	-0,0021	0,3945
SM6	-0,0013	0,6793	-0,0009	0,7157	-0,0047	0,0128 **	-0,0028	0,2534	0,0010	0,6962	0,0016	0,6309	-0,0019	0,4212
SM7	-0,0047	0,0696 *	-0,0028	0,1467	-0,0056	0,0051 ***	-0,0051	0,0165 **	-0,0039	0,0945 *	-0,0028	0,2389	-0,0027	0,1192
SM9_1	0,0025	0,4865	-0,0047	0,0872 *	-0,0002	0,9309	0,0000	0,9978	-0,0014	0,6528	0,0039	0,2853	-0,0014	0,5594
SM10_1	-0,0004	0,9219	-0,0041	0,1626	-0,0062	0,014 **	-0,0054	0,022 **	-0,0012	0,6026	0,0018	0,567	-0,0030	0,1148
SM11_1	0,0043	0,3948	0,0028	0,5168	-0,0015	0,6908	-0,0025	0,4427	-0,0018	0,5083	0,0035	0,3455	0,0019	0,4329
P_W_ratio_1	-0,3509	0,5426	-0,8145	0,0765 *	-0,6790	0,1018	-0,9439	0,0358 **	-0,7790	0,1022	-0,9787	0,0692 *	-0,2339	0,6278
T	0,0623	<0,0001 ***	0,0558	<0,0001 ***	0,0671	<0,0001 ***	0,0588	<0,0001 ***	0,0654	<0,0001 ***	0,0604	<0,0001 ***	0,0586	<0,0001 ***
Breush-Pagan	0,9903 (***)		0,7246 (***)		0,5377 (***)		0,8897 (***)		0,7173 (***)		0,7739 (***)		0,9670 (***)	
Normalita	0,1974 (***)		0,3486 (***)		0,2906 (***)		0,6343 (***)		0,1617 (***)		0,2698 (***)		0,2624 (***)	
Autokorelace	0,1662 (***)		0,8130 (***)		0,5010 (***)		0,5355 (***)		0,7263 (***)		0,1491 (***)		0,0200 (*)	
Adj. R2	0,7705		0,8520		0,8869		0,8544		0,8807		0,8421		0,8411	

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Tabulka 5: Výsledky odhadů jednotlivých OLS modelů pro jednotlivé kraje - 2. část

Proměnná	Kraj													
	Královehradecký		Pardubický		Vysočina		Jihomoravský		Olomoucký		Zlínský		Moravskoslezský	
	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota	Parametr	P-hodnota
const	9,4559	<0,0001 ***	9,5632	<0,0001 ***	9,7791	<0,0001 ***	14,3550	<0,0001 ***	11,9099	<0,0001 ***	14,7368	<0,0001 ***	11,3885	<0,0001 ***
TM2	0,0211	0,4546	0,0192	0,4406	0,0244	0,381	0,1022	0,0011 ***	0,0654	0,0236 **	0,0585	0,0516 *	0,0605	0,0162 ***
TM3	0,0304	0,3479	0,0136	0,6571	0,0266	0,4559	-0,0169	0,6616	-0,0130	0,7134	0,0111	0,7701	0,0152	0,63 **
TM4	-0,1027	0,0212 **	-0,0656	0,1265	-0,0367	0,4144	-0,1246	0,0145 **	-0,0671	0,1982	-0,0528	0,342	-0,0047	0,9163
TM5	-0,0362	0,3755	-0,0798	0,05 **	-0,0678	0,1416	-0,1127	0,0447 **	-0,0896	0,0963 *	-0,1382	0,0339 **	-0,1270	0,0194
TM6	-0,1836	0,0001 ***	-0,1666	0,0004 ***	-0,1993	0,0002 ***	-0,2663	<0,0001 ***	-0,2277	<0,0001 ***	-0,2402	0,0001 ***	-0,1583	0,0047 **
TM7	-0,0608	0,1965	-0,0587	0,2031	-0,0557	0,2869	0,0707	0,2048	-0,0053	0,9215	-0,0193	0,7715	-0,0469	0,4374 ***
TM9_1	0,0000	0,9995	-0,0096	0,833	-0,0269	0,604	-0,0790	0,1706	0,0054	0,9257	-0,0367	0,564	-0,0429	0,4621
TM10_1	-0,0330	0,4459	-0,0179	0,6617	0,0018	0,971	-0,0939	0,0823 *	-0,0159	0,7401	-0,0390	0,4424	0,0048	0,9197
TM11_1	0,0319	0,3769	0,0199	0,5612	0,0072	0,8508	-0,0207	0,6185	0,0017	0,9655	-0,0247	0,5614	-0,0303	0,439
SM2	-0,0045	0,0916 *	-0,0032	0,3033	-0,0027	0,4901	0,0082	0,0692 *	-0,0044	0,2417	-0,0020	0,5753	-0,0001	0,9799
SM3	0,0018	0,466	0,0006	0,8296	-0,0029	0,3847	-0,0031	0,4597	0,0001	0,9887	-0,0021	0,5384	-0,0043	0,1979
SM4	-0,0030	0,4422	-0,0035	0,3189	-0,0022	0,5588	-0,0089	0,0326 **	-0,0051	0,1733	-0,0064	0,0698 *	-0,0069	0,0109
SM5	-0,0020	0,3978	-0,0029	0,1979	-0,0029	0,2695	0,0001	0,9682	-0,0052	0,0532 *	-0,0044	0,1021	-0,0018	0,3744 **
SM6	-0,0028	0,168	-0,0037	0,057 *	-0,0011	0,6442	-0,0065	0,0211 **	-0,0064	0,0071 ***	-0,0076	0,0011 ***	-0,0064	0,0011
SM7	-0,0051	0,003 ***	-0,0054	0,0005 ***	-0,0047	0,0364 **	-0,0041	0,0703 *	-0,0025	0,114	-0,0028	0,1188	-0,0035	0,0054 ***
SM9_1	0,0014	0,4894	0,0009	0,6518	0,0018	0,4623	0,0081	0,004 ***	0,0024	0,3377	0,0030	0,2527	-0,0019	0,3792 ***
SM10_1	-0,0041	0,0344 **	-0,0018	0,3841	0,0008	0,7859	0,0006	0,8577	-0,0016	0,5013	-0,0016	0,5379	-0,0021	0,3732
SM11_1	0,0029	0,3046	0,0024	0,4293	0,0033	0,3802	0,0040	0,3165	0,0001	0,976	-0,0029	0,4032	-0,0041	0,2194
P_W_ratio_1	-0,3136	0,4698	-0,3731	0,3852	-0,9054	0,0661 *	-2,0506	0,0004 ***	-1,2619	0,0157 **	-1,9862	0,0011 ***	-1,0433	0,0149
T	0,0626	<0,0001 ***	0,0623	<0,0001 ***	0,0573	<0,0001 ***	0,0351	0,0001 ***	0,0482	<0,0001 ***	0,0462	<0,0001 ***	0,0588	<0,0001 **
Breush-Pagan	0,0013		0,0223 (*)		0,0753 (**)		0,1162 (***)		0,0035		0,0245 (*)		0,7798 (***)	
Normalita	0,0083		0,0178 (*)		0,2860 (***)		0,1507 (***)		0,0334 (*)		0,1153 (***)		0,6978 (***)	
Autokorelace	0,1850 (***)		0,1919 (***)		0,0054		0,7509 (***)		0,3218 (***)		0,1224 (***)		0,6372 (***)	
Adj. R2	0,8539		0,8648		0,8255		0,8000		0,8216		0,8193		0,8785	

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

4.3.1 Ekonomická a statistická verifikace

Podzimní měsíce (zpožděné proměnné)

Většina teplotních proměnných v případě podzimních měsíců předchozího roku v modelech nevykazovala statistickou významnost. Statistickou významnost vykazují parametry v kraji Jihočeském, Plzeňském a Jihomoravském. Jihočeský a Plzeňský kraj měl významný parametr v měsíci září na hladině významnosti $\alpha = 0,1$, jedná se tedy o relativně slabou významnost a v obou krajích se jednalo o zápornou hodnotu parametru. Oproti tomu v Jihomoravském kraji byl významný měsíc říjen, opět se slabou významností na hladině významnosti $\alpha = 0,1$. V Jihomoravském kraji byl parametr opět záporný, a tedy vliv teploty v měsíci říjnu měl negativní efekt na výnos pšenice. Ve výše zmíněných krajích, kde byl parametr významný, **byl parametr v souladu s ekonomickým předpokladem**. Interpretace těchto významných parametrů je následující. Jestliže v měsíci září stoupne průměrná měsíční teplota o 1 stupeň celsia, tak v Jihočeském kraji klesne výnos pšenice o 0,077 t/ha za podmínky *ceteris paribus*. Pokud stoupne teplota v Plzeňském kraji o jeden stupeň celsia v měsíci září, tak dojde k poklesu výnosu pšenice o 0,091 tuny na hektar za podmínky *ceteris paribus*. V případě Jihomoravského kraje, pokud dojde ke zvýšení teploty o 1 stupeň celsia v měsíci říjnu, dojde k poklesu výnosu pšenice 0,094 tuny na hektar za podmínky *ceteris paribus*.

Srážky v podzimních měsících vykazují vyšší významnost než průměrné teploty v podzimních měsících. V měsíci září vyazuje významnost kraj Středočeský a Jihomoravský. Kraj Středočeský měl parametr významný na hladině významnosti $\alpha = 0,1$, oproti tomu kraj Jihomoravský měl parametr pro měsíc září významný na hladině významnosti $\alpha = 0,01$. V kraji Středočeském nabývá parametr záporné hodnoty. V Jihomoravském kraji nabývá parametr kladné hodnoty. Významnost v říjnu vyazuje kraj Jihočeský, Plzeňský a Královehradecký. Ve všech těchto krajích nabývá parametr záporných hodnot. **Pouze parametr v Jihomoravském kraji v měsíci září je v souladu s ekonomickým předpokladem**.

Interpretace výše uvedených parametrů vypadá následovně. Pokud se zvýší srážky v měsíci září o jeden milimetr, tak dojde ke snížení výnosu pšenice na jeden hektar o 0,005 tuny ve Středočeském kraji, oproti tomu v Jihomoravském kraji dojde ke zvýšení výnosu pšenice na jeden hektar o 0,008 tuny (vždy za podmínky *ceteris paribus*). Srážky v měsíci říjnu vykazují negativní hodnotu parametru, což znamená, že jestliže dojde k nárůstu srážek

v tomto měsíci, dojde k poklesu výnosu pšenice o 0,006 t/h (v Jihočeském kraji), o 0,005 t/ha (v Plzeňském kraji) a o 0,004 t/ha (v Královohradeckém kraji) za podmínky *ceteris paribus*.

Jarní měsíce včetně února – teplotní proměnné

Měsíc únor v případě teploty byl významný především v moravských krajích a následně také v kraji Středočeském. Ve všech těchto krajích měl parametr kladnou hodnotu, a proto byl v **souladu s ekonomickým předpokladem**. Ve Středočeském a Zlínském kraji byl parametr významný na hladině významnosti $\alpha = 0,1$. V kraji Olomouckém a Moravskoslezském byl parametr významný na hladině významnosti $\alpha = 0,05$ a v kraji Jihomoravském na hladině významnosti $\alpha = 0,01$. Tyto výsledky udávají, že jestliže teplota stoupne o jeden stupeň celsia, tak se výnos pšenice v tunách na jeden hektar zvýší o 0,1022 t/ha v Jihomoravském kraji, o 0,065 t/ha v Olomouckém kraji, o 0,059 ve Zlínském kraji, o 0,060 v Moravskoslezském kraji a o 0,050 ve Středočeském kraji, vždy za podmínky *ceteris paribus*.

V případě teploty byl měsíc březen významný pouze v Ústeckém kraji, a to na hladině významnosti $\alpha = 0,1$. Zde byl parametr kladný, a proto lze konstatovat, **že byl v souladu s ekonomickým předpokladem**. Parametr říká, že pokud se v Ústeckém kraji v měsíci březnu zvýší teplota o jeden stupeň celsia, dojde ke zvýšení výnosu pšenice o 0,075 tuny na hektar za podmínky *ceteris paribus*.

Měsíc duben byl významný pouze v kraji Královohradeckém a Jihomoravském. V obou krajích se jednalo o významnost na hladině významnosti $\alpha = 0,05$. Oba parametry vykazovaly zápornou hodnotu. Tato skutečnost **je v souladu s ekonomickým předpokladem**. Jestliže stoupne teplota v Královohradeckém kraji o jeden stupeň celsia, dojde ke snížení výnosu pšenice o 0,103 tuny na hektar za podmínky **ceteris paribus**, oproti tomu dojde v Jihomoravském kraji ke snížení výnosu pšenice 0,125 tuny na hektar za podmínky *ceteris paribus*.

V měsíci květnu převládala významnost na hranici významnosti $\alpha = 0,05$, tato hranice byla překonána v kraji Ústeckém, Pardubickém, Jihomoravském, Zlínském a Moravskoslezském. V Plzeňském kraji byla dokonce překonána hranice významnosti $\alpha = 0,01$. Oproti tomu hranici významnosti 0,1 překonal kraj Karlovarský a Olomoucký. Ve všech krajích byl parametr záporný, a **to je v souladu s ekonomickou verifikací**. Interpretace parametrů v kraji Plzeňském, Karlovarském, Ústeckém, Pardubickém, Jihomoravském, Olomouckém, Zlínském a Moravskoslezském je v závislosti na pořadí

následující. Pokud se zvýší teplota o jeden stupeň celsia v uvedeném kraji, tak dojde ke snížení výnosu pšenice o 0,131 t/ha, o 0,082 t/ha, o 0,113 t/ha, o 0,081 t/ha, o 0,080 t/ha, o 0,113 t/ha, o 0,080 t/ha, o 0,138 t/ha a o 0,127 t/ha. To vše za podmínky ceteris paribus.

Jarní měsíce včetně února – srážkové proměnné

V únoru byly srážky významné pouze v Královehradeckém kraji, a to na hladině významnosti alfa = 0,1 se záporným parametrem. **Je tedy v nesouladu s ekonomickým předpokladem.**

Březen byl úspěšnější, konkrétně se jednalo o významnost v kraji Středočeském, Jihočeském, Plzeňském a Karlovarském, kde byly parametry významné na hranici významnosti alfa = 0,05. V těchto krajích je interpretace v závislosti na pořadí výše uvedeném následující. Jestliže dojde ke zvýšení srážek v daném kraji o jeden milimetr, dojde k poklesu výnosu pšenice o 0,009 t/ha, 0,006 t/ha, 0,006 t/ha a o 0,007 t/ha, to vše za podmínky ceteris paribus. Tyto parametry **nejdou v souladu s ekonomickým předpokladem.**

Parametr pro srážky v měsíci dubnu byl statisticky významný pouze v kraji Ústeckém, Jihomoravském a Moravskoslezském, konkrétně na hladině významnosti alfa = 0,05. Parametr byl kladný pouze v **Ústeckém kraji, a pouze zde není v souladu s ekonomickým předpokladem.** Interpretace v závislosti na pořadí uvedeném výše je následující. Jestliže dojde ke zvýšení srážek v Ústeckém kraji o jeden mm, dojde ke zvýšení výnosu pšenice o 0,009 t/ha za podmínky ceteris paribus. V případě ostatních krajů, pokud dojde ke zvýšení srážek o jeden mm, dojde ke snížení výnosu pšenice o 0,009 t/ha a o 0,006 t/ha za podmínky ceteris paribus. Srážky v měsíci dubnu byly také statisticky významné na slabé hranici významnosti alfa = 0,1 v kraji Zlínském. I zde je parametr v souladu s ekonomickým předpokladem a interpretace by byla obdobná krajům uvedeným výše.

Měsíc květen byl slabě významný na hladině významnosti alfa = 0,1 pouze v kraji Ústeckém a Olomouckém. V kraji Ústeckém nabývá parametr kladné hodnoty a **není v souladu s ekonomickým předpokladem.** V kraji Olomouckém nabýval parametr záporných hodnot a **je v souladu s ekonomickým předpokladem.** Jestliže se srážky v Ústeckém kraji zvýší o jeden milimetr, tak dojde ke zvýšení výnosu pšenice o 0,006 t/ha za podmínky ceteris paribus. Jestliže dojde ke zvýšení srážek o jeden mm v Olomouckém kraji, tak dojde ke snížení výnosu pšenice o 0,005 t/ha za podmínky ceteris paribus.

Letní měsíce – teplotní proměnné

Měsíc červen byl významný ve většině krajích, a ke všemu se jednalo o vyšší hladinu významnosti $\alpha = 0,01$. Této hladiny významnosti dosahoval parametr v kraji Středočeském, Jihočeském, Plzeňském, Královehradeckém, Pardubickém, Vysočina, Jihomoravském, Olomouckém, Zlínském a v Moravskoslezském. V těchto krajích je interpretace následující v závislosti na pořadí. Pokud dojde ke zvýšení teploty v daném kraji o jeden stupeň celsia, tak výnos pšenice klesne o 0,144 t/ha, 0,182 t/ha, 0,155 t/ha, 0,183 t/ha, 0,166 t/ha, 0,199 t/ha, 0,266 t/ha, 0,227 t/ha, 0,240 t/ha a o 0,158 t/ha, a to ve všech případech za podmínky *ceteris paribus*. V kraji Praha má parametr významnost pouze na hranici $\alpha = 0,05$ a v kraji Ústeckém pouze na hladině významnosti $\alpha = 0,1$. Ve všech krajích, kde je parametr statisticky významný, se vyskytuje záporná hodnota, což znamená, že **parametry jsou v souladu s ekonomickou verifikací**.

Měsíc červenec nabývá významnosti pouze v případě Středočeského kraje. Parametr nabývá záporných hodnot, a proto **je v souladu s ekonomickým předpokladem**. Jestliže se teplota ve Středočeském kraji zvýší o jeden stupeň celsia v měsíci červnu, dojde ke snížení výnosu pšenice o 0,103 t/ha za podmínky *ceteris paribus*.

Letní měsíce – srážkové proměnné

Srážky v měsíci červnu nabývaly významnosti na hladině významnosti $\alpha = 0,01$ opět především v moravských krajích, konkrétně v kraji Olomouckém, Zlínském a Moravskoslezském. Interpretace v těchto krajích je v závislosti na pořadí uvedeném výše následující. Jestliže se srážky zvýší o jeden mm v daném kraji za měsíc červen, tak dojde ke snížení výnosu pšenice o 0,006 t/ha, 0,008 t/ha a o 0,06 t/ha za podmínky *ceteris paribus*. Významnosti na hladině $\alpha = 0,05$ nabýval parametr pro srážky v měsíci červnu v kraji Jihočeském a Jihomoravském. Opět by tedy v závislosti na růstu srážek docházelo ke snižování výnosu pšenice. Ke snižování výnosu pšenice by docházelo i v kraji Pardubickém, kde byl parametr významný pouze na hladině významnosti $\alpha = 0,1$. Ve všech těchto případech **jsou parametry v souladu s ekonomickým předpokladem**.

V červenci byly srážky významné v kraji Jihočeském, Královehradeckém, Pardubickém a Moravskoslezském na hladině významnosti $\alpha = 0,01$. V Plzeňském kraji a na Vysočině byla významnost parametru pouze na hladině $\alpha = 0,05$. Nejnižší významnost ($\alpha = 0,1$) byla poté v Praze, Karlovarském kraji a Jihomoravském kraji. Ve všech krajích parametry vykazovaly nepřímou závislost, a proto **jsou v souladu s ekonomickým předpokladem**. Interpretace v krajích s významnými parametry na hladině významnosti

alfa = 0,01 je v závislosti na výše uvedeném pořadí následující. Jestliže dojde ke zvýšení srážek o jeden milimetr, dojde ke snížení výnosu pšenice o 0,006 t/ha, 0,005 t/ha, 0,005 t/ha a o 0,004 t/ha za podmínky *ceteris paribus*.

Poměrový ukazatel cenových indexů

Poměrový ukazatel cenových indexů je statisticky významný na hladině významnosti alfa = 0,01 v kraji Jihomoravském a Zlínském. Na hladině významnosti alfa = 0,05 se pohybovaly parametry v kraji Plzeňském, Olomouckém a Moravskoslezském. Na nejslabší hladině významnosti alfa = 0,1 se nacházejí parametry z kraje Středočeského, Ústeckého a Vysočiny. Ve všech krajích se jedná o nepřímou závislost, a směr závislosti tedy **odpovídá ekonomickému předpokladu stanoveného podle Miao et al. (2016)**. Interpretace je vytvořena pouze pro významné parametry na hladině významnosti alfa = 0,01. Jestliže dojde ke zvýšení poměrového ukazatele cenových indexů o jednotku, dojde ke snížení výnosu pšenice o 2,051 t/ha v Jihomoravském kraji za podmínky *ceteris paribus* a o snížení výnosu pšenice o 1,986 t/ha ve Zlínském kraji za podmínky *ceteris paribus*.

Časový trend

Časový trend byl významný ve všech krajích na hranici významnosti alfa = 0,01. Ve všech případech se jednalo o přímou závislost, která je v souladu s ekonomickým předpokladem. S každým dalším rokem dochází ke zvyšování výnosu pšenice v rozmezí od 0,035 t/ha (Jihomoravský kraj) do 0,067 t/ha (Jihočeský kraj) za podmínky *ceteris paribus*. Ostatní kraje se pohybují v rozmezí uvedeného intervalu.

F-test a adjustovaný koeficient determinace

F-test ve všech modelech poukázal na celkovou významnost parametrů, kdy p-hodnota nabývala vždy hodnoty nižší než hladina významnosti alfa = 0,01 i přesto, že některé modely měly velice nízké množství významných parametrů (např. Praha). Adjustovaný koeficient determinace poukázal na vysokou míru vysvětlení variability závislé proměnné regresory. Nejnižší hodnota adjustovaného koeficientu determinace byla v Praze, kde byla ve výši 0,77. Oproti tomu nejvyšší hodnota byla pozorována v Karlovarském kraji s hodnotou ve výši 0,89. Ostatní kraje se pohybovaly mezi výše uvedenými hodnotami.

4.3.2 Ekonometrická verifikace

Homoskedasticita

Pro posouzení přítomnosti heteroskedasticity byl použit Breusch-Paganův test a byly definovány dvě hypotézy, které jsou následující:

H₀: model obsahuje konstantní rozptyl chyb (homoskedasticita),

A: model neobsahuje konstantní rozptyl chyb (heteroskedasticita).

Většina modelů vykazuje konstantní rozptyl chyb na hladině významnosti $\alpha = 0,1$, a tyto modely tedy procházejí ekonometrickou verifikací. Dále lze pozorovat modely, které přijímají nulovou hypotézu na hladině významnosti $\alpha = 0,05$ (p -hodnota = $(0,1;0,05)$) a také procházejí ekonometrickou verifikací, i když s menší silou. V tomto intervalu se pohybuje p -hodnota kraje Vysočina. Kraje, jejichž test pro heteroskedasticitu měl p -hodnotu nižší než hladinu významnosti $\alpha = 0,05$, nejsou považovány za ekonometricky verifikovatelné. Do této skupiny spadá Královehradecký, Pardubický, Olomoucký a Zlínský kraj.

Autokorelace

Pro testování autokorelace reziduí byl použit Breusch-Godfreyův test a opět byly stanoveny následující hypotézy:

H₀: model neobsahuje autokorelaci,

A: model má korelovaná rezidua mezi jednotlivými časovými úseky.

Podmínku absence autokorelace na hladině významnosti $\alpha = 0,1$ splňuje většina modelů. Výjimkou je model pro Vysočinu a Liberecký kraj, ve kterých p -hodnota nedosahovala ani hodnoty hladiny významnosti $\alpha = 0,05$, a proto je v modelech předpokládána autokorelace.

Normalita

Pro posouzení normality reziduí byly stejně jako v předchozích případech definovány následující hypotézy:

H₀: model obsahuje normální rozdělení reziduí,

A: model neobsahuje normální rozdělení reziduí.

Nenormalita byla vyvrácena ve většině modelech. Výjimkou byl kraj Královehradecký, Pardubický a Olomoucký, kde se p -hodnota pohybovala pod hladinou významnosti $\alpha = 0,05$.

Multikolinearita

V rámci posouzení multikolinearity byla využita korelační matice. Na základě zjištěných výsledků lze konstatovat, že se v modelech nevyskytovala vysoká multikolinearita. Nejvyšší korelace napříč modely byla ve výši 0,72, která byla nalezena mezi časovým trendem a proměnnou pro cenové indexy.

4.3.3 Celkové hodnocení modelů

OLS modely byly ve většině případech ekonometricky verifikovatelné a zároveň lze vidět, že modely mají v zásadě dobrou vysvětlovací schopnost.

Do modelů by bylo vhodné vložit kvadratické tvary jednotlivých klimatických proměnných. Z literatury je totiž známo, že takto modelovaná výnosová funkce nedostatečně zachycuje nelinearitu klimatických proměnných. Tím by se bohužel zdvojnásobilo množství regresorů z $k = 21$ na $k = 38$, což by v případě časové řady, která čítá $T=62$, výrazně omezilo stupně volnosti a nejeví se to jako vhodná možnost. Z tohoto důvodu budou v dalších kapitolách vytvořeny modely s použitím panelových dat.

4.4 Model fixních efektů

Použití fixních efektů je jednou z možných variant, jak využít panelová data modelu, která jsou do určité míry heterogenní. Fixní efekty lze využít ve dvou podobách, a obě jsou pro model sklizňové funkce použitelné. Prvním typem je využití dummy proměnných pro odhad jednotlivých konstant průřezových jednotek. Dalším typem je poté odebrání průměrů jednotlivých průřezových jednotek, kterým je docíleno „homogenity“ napříč průřezovými jednotkami. Druhým typem modelu, který zachycuje heterogenitu, jsou náhodné efekty (*random effects*). Tento model není v práci využit, a to proto, že modely v této DP pracují s dlouhou časovou řadou. Halová et al. (2021) ve své publikaci uvádí, že ve chvíli, kdy se pracuje s dostatečně dlouhou časovou řadou, není mezi FEM a REM modely rozdíl.

Nyní budou odhadnuty dva ekonometrické modely za pomoci odebrání průměrů průřezových jednotek. Data jsou výrazně heterogenní, proto je potřeba využít právě fixních efektů oproti „poolování“. „Poolování“ si klade za předpoklad, že průřezové jednotky nemají specifické znaky. To by například znamenalo, že půdní podmínky jsou ve všech krajích stejné. Je známo, že toto tvrzení je nepravdivé, a proto je potřeba použít FE anebo RE odhad.

První model bude odhadnut a specifikován ve formě logaritmické s tím, že klimatické proměnné a časový trend jsou i v kvadratické podobě. Využitá data jsou nejdříve

logaritmicky transformována a následně jsou normalizována za pomoci odečtení průměru daných proměnných napříč celým souborem. Nutno dodat, že některé proměnné byly z pohledu logaritmizace problematické. Proměnné pro teplotní průměry za měsíc únor a listopad obsahovaly záporné hodnoty. Nebylo tedy možné tyto hodnoty transformovat do logaritmické podoby a jsou tedy pouze normalizovány pomocí průměru.

Druhý model je bez logaritmické transformace. Opět jsou ovšem normalizovány proměnné pomocí průměru.

Obecně zapsaný model:

$$y = konst. + \alpha'x + \beta'x^2 + \gamma P_W_Ratio_1 + \delta t + \delta_2 t^2 + \varepsilon, \quad (49)$$

kde x představuje vektor klimatických proměnných. V modelu jsou použity zpožděné srážky a průměrné teploty minulého roku od září do listopadu včetně. Poté jsou v modelu nezpožděné klimatické proměnné od února do července. Takto by mělo být zachyceno celé růstové období pšenice ozimé od zasetí po sklizeň. Vynechány jsou pouze měsíce prosinec a leden. Těmto proměnným náleží vektor parametrů α' . Dále jsou v modelu čtverce klimatických proměnných (oproti předchozímu modelu jsou přidány $sq_TM9_1, \dots, sq_TM7, sq_SM9_1, \dots, sq_SM7$), těmto proměnným náleží vektor parametrů β' . Vektor $P_W_Ratio_1$ představuje poměrovou proměnnou cenových indexů zpožděnou o jeden rok (vysvětleno výše), tomuto vektoru náleží parametr γ . Vektor t obsahuje časový trend a k němu náleží parametr δ . Poslední proměnnou vstupující do modelu je kvadratický časový trend t^2 , této proměnné náleží parametr δ_2 .

Tabulka 6: Výsledný odhad modelů FE pro ČR

Odhady FEM		Logaritmický model			Bez logaritmické transformace		
Proměnná		Parametr	P-hodnota		Parametr	P-hodnota	
Teplotní klimatické proměnné	Konstanta	0,0717	<0,0001	***	0,4021	<0,0001	***
	TM2	0,0038	0,0391	**	0,0460	<0,0001	***
	TM3	0,0100	<0,0001	***	0,0341	0,0005	***
	TM4	-0,0647	0,0047	***	-0,0414	0,0008	***
	TM5	-0,2633	<0,0001	***	-0,1026	<0,0001	***
	TM6	-0,4881	<0,0001	***	-0,1550	<0,0001	***
	TM7	-0,3001	<0,0001	***	-0,0632	<0,0001	***
	TM9_1	-0,0165	0,7023		-0,0272	0,0536	*
	TM10_1	-0,0601	0,0108	**	-0,0171	0,1439	
	TM11_1	-0,0029	0,2739		0,0005	0,9595	
	sq_TM2	-0,0003	0,5588		-0,0003	0,8654	
	sq_TM3	-0,0012	0,0859	*	-0,0051	0,0750	*
	sq_TM4	-0,0346	0,4775		0,0011	0,7523	
	sq_TM5	-0,5866	0,0002	***	-0,0147	0,0015	***
	sq_TM6	-0,9761	0,0002	***	-0,0211	<0,0001	***
	sq_TM7	-1,9818	<0,0001	***	-0,0244	<0,0001	***
	sq_TM9_1	-0,3423	0,0921	*	-0,0137	0,0083	***
	sq_TM10_1	-0,2206	<0,0001	***	-0,0211	<0,0001	***
sq_TM11_1	-0,0045	<0,0001	***	-0,0143	0,0004	***	
Srážkové klimatické proměnné	SM2	-0,0027	0,7047		-0,0016	0,0952	*
	SM3	-0,0237	0,0035	***	-0,0013	0,1619	
	SM4	-0,0276	0,0016	***	-0,0018	0,0581	*
	SM5	0,0152	0,1561		0,0005	0,5058	
	SM6	-0,0518	<0,0001	***	-0,0038	<0,0001	***
	SM7	-0,0959	<0,0001	***	-0,0054	<0,0001	***
	SM9_1	0,0129	0,0951	*	0,0013	0,0471	**
	SM10_1	-0,0287	<0,0001	***	-0,0010	0,2344	
	SM11_1	0,0083	0,2607		0,0011	0,1828	
	sq_SM2	0,0113	0,0559	*	0,0000	0,5352	
	sq_SM3	-0,0629	<0,0001	***	0,0000	0,1590	
	sq_SM4	-0,0193	0,0008	***	-0,0001	<0,0001	***
	sq_SM5	-0,0140	0,2037		0,0000	0,0105	**
	sq_SM6	-0,0570	0,0009	***	0,0000	0,2907	
	sq_SM7	-0,0208	0,0083	***	0,0000	0,0226	**
	sq_SM9_1	0,0073	0,4359		0,0000	0,6241	
	sq_SM10_1	-0,0368	<0,0001	***	0,0000	0,0325	**
	sq_SM11_1	-0,0004	0,4144		0,0000	0,5590	
Index cen	P_W_Ratio_1	-0,1758	<0,0001	***	-1,1534	<0,0001	***
Trend	t	0,3860	<0,0001	***	0,0572	<0,0001	***
	sq_t	0,0732	<0,0001	***	0,0001	0,1690	

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

4.4.1 Ekonometrická verifikace modelu

Tabulka 7: Ekonometrická verifikace

Test	Verifikace	1. model	2. model
Heteroskedasticita	Waldův test	<0,0001	<0,0001
Test normality	Normalita	<0,0001	0,0009
Autokorelace	Wooldridgeův test	0,5563	0,0104

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Modely se potýkaly s problémy v ekonometrické verifikaci. Heteroskedasticita se vyskytovala v obou modelech. P-hodnota v případě heteroskedasticity byla výrazně pod hladinou významnosti $\alpha = 0,01$. To samé bylo shledáno i v případě normality. Autokorelace v modelu č. 1 byla vyvrácena na hladině významnosti $\alpha = 0,1$. Oproti tomu model č. 2 se potýkal s problémy a na hladině významnosti $\alpha = 0,05$ nebyla autokorelace vyvrácena.

Multikolinearita není v modelu zásadně řešena, a to z toho důvodu, že v modelu se nacházejí kvadratické formy klimatických proměnných, které přirozeně vykazují vysokou multikolinearitu. V tomto případě je třeba si uvědomit propojenost klimatických proměnných s jejich kvadratickými tvary, a takto k nim přistupovat. **Proměnné prvního řádu mezi sebou nemají vysokou multikolinearitu.**

4.4.2 Hodnocení modelů fixních efektů pro celou Českou republiku

Přestože modely měly dobrou vysvětlivací schopnost ($LSDV R^2 = 0,88$) a zároveň v nich bylo možné nalézt více než polovinu významných proměnných, nebyly ekonometricky verifikovatelné. V modelech se vyskytovala heteroskedasticita, autokorelace i nenormalita. Dále tedy nebylo s celkovým modelem pro Českou republiku pracováno.

Využití fixních efektů se jeví jako příliš restriktivní opatření vůči heterogenitě jednotlivých krajů. Z tohoto důvodu by bylo vhodné vytvořit skupiny krajů na základě určité podobnosti, díky kterým by bylo možné odhadnout FEM model pro tyto jednotlivé skupiny. Pokud budou skupiny vhodně sestaveny, lze pomocí tohoto způsobu dojít k verifikovatelnosti modelů.

4.5 Tvorba skupin oblastí pro odhad jednotlivých FE modelů

Na základě OLS, klimatických a půdních podmínek si lze povšimnout určité podobnosti mezi skupinami krajů. Na základě těchto podobností jsou vytvořeny tři skupiny. **První skupina** obsahuje Jihočeský, Plzeňský a Karlovarský kraj. **Druhá skupina** obsahuje

Jihomoravský, Zlínský kraj a Moravskoslezský. **Třetí skupina** obsahuje Prahu, Středočeský a Ústecký kraj.

4.5.1 Funkční formy a specifikace

Následně jsou vytvořeny dvě funkční formy modelů. Model s logaritmickou transformací a model bez logaritmické transformace. Z těchto dvou funkčních forem je poté vybrána funkční forma, která vykazuje vhodnější vlastnosti pro další postup. V modelech pro odhad tří skupin byly využity dummy proměnné pro zachycení heterogenity (na rozdíl od plně agregovaných modelů, kde byly odebrány fixní efekty pomocí průměrů).

Po zvolení vhodné funkční formy bude odhadnuta specifikace typická pro zemědělské výnosové funkce. Just a Popeova specifikace. Tato specifikace bude porovnána s modely běžných fixních efektů. Poté je zvolena specifikace, která bude použita pro aplikaci scénářů.

4.5.2 Odhad modelů v logaritmickém tvaru a bez logaritmů podle skupin

Byly odhadnuty skupinové modely pomocí LSDV FE. Modely byly odhadnuty ve dvou funkčních formách, první funkční formou je forma logaritmická s kvadratickými tvary (proměnné normalizovány průměrem) a model bez logaritmické transformace (proměnné normalizovány průměrem) s kvadratickými tvary. Hlavním hodnotícím kritériem pro volbu funkční formy je schopnost regresorů vysvětlit závislé proměnné. To znamená, že je využit adjustovaný koeficient determinace. Dalším kritériem je verifikovatelnost modelu. Byly tedy vytvořeny 3 skupiny modelů se dvěma funkčními formami. Funkční forma, která dosahovala vyššího koeficientu determinace a zároveň byla lépe verifikovatelná, byla následně zvolena pro další práci.

Tabulka 8: Adjustovaný koeficient determinace pro tři modely ve dvou funkčních specifikacích

Skupina	1. skupina		2. skupina		3. skupina	
Ukazatel	s ln	bez ln	s ln	bez ln	s ln	bez ln
Adj. R ²	0,9032	0,9089	0,9106	0,8797	0,8622	0,8851

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Na základě tabulky č. 8 lze vidět, že vysvětlovací schopnost byla u dvou ze tří modelů vyšší v případě specifikace bez logaritmické transformace oproti logaritmické funkci.

Tabulka 9: *Ekonometrická verifikace modelů s logaritmy*

Test	Verifikace	1.skupina	2.skupina	3.skupina
Waldův test	Heteroskedasticita	0,4270	0,7695	0,0011
Test normality	Normalita	0,0011	0,1208	0,0000
Wooldridgeův test	Autokorelace	0,2437	0,7206	0,1709

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Tabulka 10: *Ekonometrická verifikace modelů bez logaritmů*

Test	Verifikace	1.skupina	2.skupina	3.skupina
Waldův test	Heteroskedasticita	0,7536	0,5572	0,1201
Test normality	Normalita	0,8703	0,1511	0,0666
Wooldridgeův test	Autokorelace	0,1610	0,4415	0,1908

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

4.5.2.1 Ekonometrická verifikace modelů s a bez logaritmů

Heteroskedasticita

Na základě tabulek č. 9 a 10 lze říci, že heteroskedasticita nebyla v případě modelů bez logaritmické transformace přítomna ani v jednom z modelů. Nulová hypotéza byla tedy přijata na hladině významnosti $\alpha = 0,1$. Naopak v případě logaritmicky upravené funkce byla heteroskedasticita vyvrácena pouze u dvou modelů. Alternativní hypotéza byla přijata v případě skupiny číslo tři. Skupina číslo tři má tedy nekonstantní rozptyl chyb.

Normalita

Hypotéza o normálním rozdělení chyb v souboru byla přijata u modelu bez logaritmické transformace u skupiny č. 1 a 2 na hladině významnosti $\alpha = 0,1$. V případě skupiny číslo 3 byla hypotéza o normálním rozdělení přijata na hladině významnosti $\alpha = 0,05$.

Logaritmicky upravené modely měly s normalitou o poznání větší problém. Nulová hypotéza byla přijata pouze v případě modelu pro skupinu č. 2. V případě skupiny č. 1 a 2 p-hodnota nepřekročila hladinu významnosti $\alpha = 0,05$, a proto v případě těchto dvou skupin byla přijata alternativní hypotéza o nenormálním rozdělení.

Autokorelace

Nulová hypotéza o nepřítomnosti autokorelace reziduí byla přijata ve všech modelech na hladině významnosti $\alpha = 0,1$.

Multikolinearita

Vysoká multikolinearita byla pouze mezi kvadratickými proměnnými a jejich původními proměnnými. V případě těchto proměnných není multikolinearita vnímána jako problematická, jelikož je známo, že nezávislé proměnné působí na závisle proměnnou v modelu společně. Mezi ostatními proměnnými nebyla nalezena vysoká multikolinearita.

4.5.2.2 Zhodnocení volby modelu podle funkční formy

Hodnoty adjustovaného koeficientu determinace vyšly ve prospěch specifikace bez logaritmické transformace, kdy dva ze tří modelů mají vyšší hodnotu adjustovaného koeficientu determinace než v případě logaritmické specifikace. Výsledky ekonometrické verifikace vyšly také ve prospěch modelů bez logaritmické transformace. V rámci specifikace modelů bez logaritmické transformace vyšly všechny tři modely příznivě v případě homoskedasticity. Oproti tomu v logaritmické specifikaci se pouze u dvou modelů vyskytovala homoskedasticita. Normalita reziduí se v případě logaritmické specifikace vyskytovala u jednoho ze tří modelů. Oproti tomu tři ze tří modelů specifikovaných bez logaritmické transformace měly normalitu v pořádku.

Celkově se tedy modely bez logaritmické transformace z pohledu adjustovaného koeficientu determinace i z pohledu ekonometrické verifikace jeví jako vhodnější pro další použití. V následující části budou vyobrazeny výsledky odhadnutých modelů a bude provedena statistická, ekonomická a ekonometrická verifikace.

Tabulka 11: Odhad modelů fixních efektů bez logaritmické transformace – 1. skupina a 2. skupina

Odhady FEM		1. skupina			2. skupina		
Proměnná	Parametr	P-hodnota		Parametr	P-hodnota		
	Konstanta	0,539592	0,0001	***	0,8237	<0,0001	***
Teplotní klimatické proměnné	TM2	0,0347	0,0478	**	0,0848	<0,0001	***
	TM3	0,0510	0,0156	**	0,0093	0,6655	
	TM4	-0,0243	0,3428		0,0000	0,999	
	TM5	-0,1233	<0,0001	***	-0,1558	<0,0001	***
	TM6	-0,1149	<0,0001	***	-0,2144	<0,0001	***
	TM7	-0,0569	0,0409	**	-0,0267	0,367	
	TM9_1	-0,0558	0,0486	**	-0,0557	0,0937	*
	TM10_1	-0,0202	0,4116		0,0060	0,8228	
	TM11_1	-0,0077	0,7494		0,0051	0,8449	
	sq_TM2	0,0018	0,6786		-0,0008	0,8419	
	sq_TM3	-0,0032	0,6344		-0,0094	0,1091	
	sq_TM4	0,0027	0,7604		-0,0073	0,4031	
	sq_TM5	-0,0108	0,3834		-0,0271	0,0078	***
	sq_TM6	-0,0347	0,0005	***	-0,0196	0,0312	**
	sq_TM7	-0,0349	0,002	***	-0,0220	0,0364	**
	sq_TM9_1	-0,0289	0,0217	**	-0,0263	0,0406	**
	sq_TM10_1	-0,0119	0,2551		-0,0412	0,0002	***
sq_TM11_1	-0,0252	0,0235	**	-0,0156	0,0568	*	
Srážkové klimatické proměnné	SM2	0,0013	0,4725		-0,0028	0,2571	
	SM3	-0,0031	0,0921	*	-0,0026	0,2656	
	SM4	-0,0031	0,1284		-0,0070	0,0008	***
	SM5	-0,0003	0,8735		-0,0012	0,523	
	SM6	-0,0042	0,002	***	-0,0071	<0,0001	***
	SM7	-0,0070	<0,0001	***	-0,0037	0,0016	***
	SM9_1	-0,0001	0,9592		0,0014	0,3206	
	SM10_1	-0,0034	0,0484	**	0,0002	0,9248	
	SM11_1	0,0008	0,6781		-0,0011	0,6104	
	sq_SM2	-0,0001	0,0149	**	0,0001	0,2815	
	sq_SM3	0,0000	0,9653		-0,0001	0,1126	
	sq_SM4	-0,0001	0,1515		0,0000	0,5687	
	sq_SM5	0,0000	0,4836		0,0000	0,297	
	sq_SM6	0,0000	0,5377		0,0000	0,3662	
	sq_SM7	0,0000	0,0679	*	0,0000	0,7165	
	sq_SM9_1	0,0001	0,1116		0,0000	0,856	
	sq_SM10_1	0,0000	0,3448		0,0000	0,8647	
sq_SM11_1	0,0000	0,8622		0,0000	0,9211		
Index cen	P_W_Ratio_1	-1,3211	<0,0001	***	-1,6807	<0,0001	***
Trend	t	0,0611	<0,0001	***	0,0461	<0,0001	***
	sq_t	0,0004	0,0208	**	-0,0004	0,0648	*
Dummy	DV_1	-0,0026	0,9709		-0,0242	0,8322	
	DV_2	-0,6416	<0,0001	***	-0,4003	0,0057	***

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Tabulka 12: Odhad modelů fixních efektů bez logaritmické transformace – 3. skupina

Odhady FEM		3.skupina		
Proměnná	Parametr	P-hodnota		
	Konstanta	0,4130	0,0117	**
Teplotní klimatické proměnné	TM2	0,0286	0,1334	
	TM3	0,0771	0,0027	***
	TM4	-0,0687	0,0208	**
	TM5	-0,0959	0,0034	***
	TM6	-0,1396	<0,0001	***
	TM7	-0,0506	0,1026	
	TM9_1	-0,0770	0,0415	**
	TM10_1	-0,0047	0,8766	
	TM11_1	0,0116	0,6648	
	sq_TM2	0,0012	0,8111	
	sq_TM3	0,0011	0,8922	
	sq_TM4	0,0114	0,2693	
	sq_TM5	-0,0239	0,1147	
	sq_TM6	-0,0261	0,0295	**
	sq_TM7	-0,0322	0,0101	**
	sq_TM9_1	-0,0333	0,0248	**
	sq_TM10_1	-0,0323	0,021	**
	sq_TM11_1	-0,0262	0,0272	**
Srážkové klimatické proměnné	SM2	0,0023	0,4181	
	SM3	0,0022	0,4511	
	SM4	0,0013	0,6488	
	SM5	0,0028	0,1622	
	SM6	-0,0041	0,0153	**
	SM7	-0,0062	<0,0001	***
	SM9_1	0,0004	0,8369	
	SM10_1	0,0002	0,9258	
	SM11_1	0,0034	0,1638	
	sq_SM2	-0,0003	0,0174	**
	sq_SM3	0,0000	0,691	
	sq_SM4	0,0000	0,8687	
	sq_SM5	0,0000	0,5008	
	sq_SM6	0,0000	0,2981	
	sq_SM7	0,0000	0,6063	
	sq_SM9_1	0,0002	<0,0001	***
	sq_SM10_1	0,0000	0,5832	
	sq_SM11_1	0,0001	0,5337	
Index cen	P_W_Ratio_1	-1,5188	<0,0001	***
Trend	t	0,0562	<0,0001	***
	sq_t	0,0006	0,0009	***
Dummy	DV_1	-0,2255	0,0022	***
	DV_2	-0,7173	<0,0001	***

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Tabulka 13: Odhad modelů fixních efektů bez logaritmické transformace – výsledky adjustovaného koeficientu determinace a směrodatné chyby regrese

Hodnotící kritérium	1. skupina	2. skupina	3. skupina
Adj. R ²	0,9089	0,8797	0,8851
Směrodatná chyba regrese	0,3606	0,3982	0,3995

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

4.5.2.3 Statistická a ekonomická verifikace modelu fixních efektů bez logaritmu

V rámci statistické a ekonomické verifikace v této kapitole jsou hodnoceny pouze významné parametry modelu. **Veškeré parametry pro proměnné prvního řádu jsou hodnoceny na celkovém průměru souboru a představují elasticity na průměru souboru.**

Teplotní proměnné prvního řádu

Únor byl významný v případě první a druhé skupiny. Parametr představuje elasticitu na průměru souboru a z tohoto důvodu je jeho interpretace následující: jestliže dojde ke zvýšení nezávislé teplotní proměnné pro únor o 1 %, dojde ke zvýšení závislé proměnné o 0,04 % v případě skupiny č. 1 a v případě skupiny č. 2 o 0,09 %, v obou případech za podmínky *ceteris paribus*. Březen byl statisticky významný ve skupině číslo 1 a 3. Ve skupině číslo 2 březen nebyl statisticky významný. Interpretace měsíce března by byla stejná jako v případě února. Únor vykazuje ve všech modelech přímou závislost, která **není v souladu s ekonomickým předpokladem**. Březen také vykazuje přímou závislost, ale v tomto případě **je tento typ závislosti v souladu s ekonomickým předpokladem**.

Duben je významný pouze ve třetí skupině a vykazuje nepřímou závislost. Interpretace je následující: jestliže dojde ke zvýšení proměnné pro duben o 1 %, dojde ke snížení závislé proměnné o 0,07 % za podmínky *ceteris paribus*. Výsledek dubna **je v souladu s ekonomickým předpokladem**.

Následující dva měsíce vykazují nejvyšší statistickou významnost a také elasticitu na průměru souboru. Jedná se o květen a červen. Ve všech třech skupinách se jedná o významný parametr s nepřímou závislostí, která **je v souladu s ekonomickým předpokladem**. Interpretace je následující: jestliže se zvýší nezávislá proměnná pro měsíc květen o 1 %, dojde ke snížení výnosu pšenice na průměru ve skupině č. 1 o 0,12 %, ve skupině č. 2 o 0,16 % a ve skupině č. 3 o 0,10 % za podmínek *ceteris paribus*. Červen je následně interpretovatelný stejným způsobem jako měsíc květen. Zajímavým poznatkem je, že

elasticita pro měsíc červen je vyšší oproti elasticitě pro květen v případě skupiny č. 2 a č. 3, ale ne v případě skupiny č. 1.

Měsíc červenec je významný pouze ve skupině č. 1, kde vykazuje nepřímou závislost, která **je v souladu s ekonomickým předpokladem**. Jestliže dojde ke zvýšení teploty v červenci nad průměr souboru o 1 %, dojde ke snížení výnosu pšenice na jednom hektaru půdy o 0,06 %.

Ze všech teplotních zpožděných proměnných prvního řádu je významné pouze září, a to jen ve skupině č. 1 a č. 3. V těchto skupinách vykazuje parametr nepřímou závislost, která **je v souladu s ekonomickým předpokladem**. Jestliže dojde ke zvýšení proměnné pro měsíc září o 1 %, dojde k poklesu výnosu pšenice na hektar o 0,06 % ve skupině č. 1 a 0,08 % ve skupině č. 3, za podmínky *ceteris paribus*.

Teplotní proměnné druhého řádu

Pro proměnné druhého řádu platí, že čím více se zvyšuje teplota nad průměr souboru, tím větší je dopad na výnos pšenice. Všechny teplotní parametry pro proměnné druhého řádu, které jsou statisticky významné, vykazují nepřímou závislost. **Tato závislost je v souladu s ekonomickým předpokladem**, jelikož průběh tohoto funkčního tvaru by měl být konkávní. Parametry tedy vyjadřují vztah, kdy čím vyšší je nárůst teploty nad průměr souboru, tím výraznější negativní efekt na výnos pšenice tento parametr má.

Ve všech skupinách vykazují únor, březen a duben daného roku statistickou nevýznamnost. Oproti tomu měsíc květen posiluje negativní dopad parametru prvního řádu ve třetí skupině na výnos pšenice. Zde se již nelze bavit o elasticitě na průměru souboru, ale pouze o posilujícím efektu dané proměnné na elasticitu průměru souboru.

Posilující efekt negativního dopadu června a července vykazují parametry ve všech třech skupinách.

Posílení negativního efektu parametrů prvního řádu lze sledovat i u kvadratických zpožděných proměnných v případě první skupiny, kdy je tento efekt statisticky významný v případě září a listopadu. Druhá skupina zaznamenává také posilující negativní efekt, ale pouze v případě září a října. Třetí skupina vykazuje posilující negativní efekt ve všech třech měsících.

Proměnné úhrnů srážek prvního řádu

Parametry pro měsíc červen a červenec všeobecně vykazují nejvyšší elasticitu na průměru souboru a zároveň i statistickou významnost napříč všemi skupinami. Interpretace pro jednotlivé skupiny těchto parametrů je následující: jestliže v červnu dojde ke zvýšení

srážek nad průměr souboru o 1 %, dojde ke snížení výnosu pšenice na průměru souboru o 0,004 % (1. skupina), o 0,007 % (2. skupina) a o 0,004 % (3. skupina) za podmínky *ceteris paribus*. Interpretace pro měsíc červenec je obdobná. V tabulce č. 11 lze vidět, že elasticita v červenci je vyšší než v červnu v případě 1. a 2. skupiny. Tato **nepřímá závislost v červnu a červenci je v souladu s ekonomickým předpokladem**.

Další parametry jsou statisticky významné jen ojediněle, a pouze v některých skupinách. Třetí skupina (kromě těch, které byly uvedeny výše) nevykazuje statistickou významnost jiných parametrů pro srážky prvního řádu. První skupina vykazuje statistickou významnost parametru pro říjen. Tento parametr vykazuje nepřímou závislost, a **proto není v souladu s ekonomickým předpokladem**. Dalším ojedinělým případem je statistická významnost parametru pro duben ve druhé skupině. Ani tento parametr **není v souladu s ekonomickým předpokladem**.

Proměnné úhrnů srážek druhého řádu

Parametry pro proměnné druhého řádu vykazovaly všeobecně menší významnost než v případě teplotních parametrů. V případě skupiny č. 2 nebyl ani jeden parametr statisticky významný. V případě skupiny č. 1 a č. 3 byl statisticky významný parametr pro únor. Parametr pro únor vykazuje nepřímou závislost, **je tedy v souladu s ekonomickým předpokladem**. Opět tento parametr vyjadřuje skutečnost, že s rostoucími srážkami nad průměr souboru dochází k posilujícímu negativnímu efektu s rostoucím množstvím srážek. Parametr pro kvadratickou proměnnou měsíce září předcházejícího roku byl významný ve skupině č. 3. Jednalo se opět o nepřímou závislost, a ta **je v souladu s ekonomickým předpokladem**.

Poměrový ukazatel cenového indexu prvního řádu

Jelikož se jedná o proměnné v prvním řádu, tak se opět jedná o elasticitu na průměru souboru. Ve všech případech se jedná o nepřímou závislost, která je v souladu s interpretací parametru podle Miao et al. (2016). V závislosti na pořadí by byla interpretace následující. Jestliže dojde ke zvýšení poměrové ukazatele cenových indexů o 1 %, dojde ke snížení výnosu pšenice na průměru souboru o 1,32 % (v případě skupiny č. 1), o 1,68 % (v případě skupiny č. 2) a o 1,52 % (v případě skupiny č. 3) za podmínky *ceteris paribus*.

Časový trend prvního a druhého řádu

V případě časového trendu prvního řádu lze v tabulkách č. 11 a 12 vidět statisticky významnou přímou závislost ve všech skupinách. Tato závislost **je v souladu s ekonomickým předpokladem**. Opět se jedná o první řád, a tento parametr tedy s každým

rokem vyjadřuje procentuální zlepšení výnosu pšenice na hektar. Nejvyšší hodnotu této elasticity měla skupina č. 1. Interpretace pro první skupinu je následující: s každým rokem dochází ke zvýšení výnosu pšenice na hektar o 0,06 %. Parametr druhého řádu byl významný v první a třetí skupině a v obou případech měl posilující pozitivní charakter k pozitivnímu parametru prvního řádu.

Konstanty a interpretace dummy proměnných

Ve skupinách byly použity dummy proměnné, díky kterým je nyní možné určit konstanty pro jednotlivé kraje ve skupině. Tyto jednotlivé konstanty jsou uvedeny v tabulce níže. Konstanty představují výnos pšenice na hektar za předpokladu, že na závisle proměnnou nepůsobí žádné jiné vlivy (s ohledem na průměr souboru). Ve skupině č. 1 a 2 lze vždy u dvou krajů pozorovat velice podobné hodnoty konstant. Nejrozličnější konstanty má následně skupina č. 3, což se dalo očekávat vzhledem ke zvoleným krajům v této skupině.

Tabulka 14: Výpočet konstant pro jednotlivé kraje ve skupině

1. skupina		2. skupina		3. skupina	
Kraj	Konstanta	Kraj	Konstanta	Kraj	Konstanta
Jihočeský	0,5396	Jihomoravský	0,8237	Praha	0,4130
Plzeňský	0,5370	Zlínský	0,7994	Středočeský	0,1875
Karlovarský	-0,1020	Moravskoslezský	0,4520	Ústecký	-0,3043

Zdroj: vlastní zpracování na základě výsledku ze softwaru Gretl

4.5.3 Just a Popeova specifikace

Jelikož je pracováno s panelovými daty, tak lze aplikovat další typy a specifikace odhadu modelů. V této diplomové práci je aplikována specifikace modelu podle Justa a Popea.

Model s Just a Popeovou specifikací je následující:

$$y = konst. + \alpha'x + \beta'x^2 + \gamma P_W_ratio_1 + \delta t + \delta_2 t^2 + h(x)^{1/2}. \quad (50)$$

Pro tvorbu Just a Popeovy specifikace byla použita metodika z publikace Hálková et al. (2021). Odhad specifikace proběhl nejdříve odhadem OLS modelu s regresory, které byly využity v původním skupinovém FEM odhadu bez logaritmické transformace. Následně byla rezidua modelu vzata a umocněna na druhou. Tato umocněná rezidua jsou odhadnuta za pomoci původních regresorů. Odhadnuté (teoretické) hodnoty reziduí byly následně odmocněny a přesunuty do matice X. V některých případech byla teoretická hodnota reziduí z druhého kroku záporná, a jelikož odmocnina ze záporného čísla neexistuje, byly záporné hodnoty nahrazeny číslem 0,0001. Tento způsob úpravy záporných hodnot se zdá být

vhodnější oproti odebrání pozorování, ve kterých se záporné hodnoty objevují (tento způsob například aplikuje software Gretl, pokud je úprava proměnných prováděna kompletně v tomto softwaru). Odhad modelu je uveden v příloze 7 společně s adjustovaným koeficientem determinace. Model bude v následující kapitole porovnán s modely, které využívají pouze fixní efekty ke svému odhadu.

4.5.3.1 Porovnání statistické významnosti parametrů a ekonomická verifikace (FE vs JP FE model)

Hodnocena bude pouze změna významnosti při posunu nad nebo pod hladinu $\alpha = 0,05$.

Parametry pro skupinu č. 1

Použití Justovy a Popeovy specifikace v případě skupiny č. 1 vedlo ke snížení významnosti u několika parametrů, a to u parametrů pro průměrné teploty v měsíci září předcházejícího roku, následně u parametrů pro teploty v únor, červenci a v kvadratické podobě v listopadu. Z pohledu srážek došlo ke snížení významnosti v měsíci červnu, říjnu předcházejícího roku a také u parametru pro kvadratickou proměnnou úhrnu srážek v únoru. Celkově tedy došlo ke snížení počtu statisticky významných parametrů o sedm parametrů. Směr a velikost parametrů zůstaly prakticky nezměněny u všech významných proměnných.

Parametry pro skupinu č.2

Just a Popeovy specifikace ztratila významnost parametru konstanty oproti klasickému FEM modelu. Parametr pro teplotní proměnnou v měsíci říjnu předcházejícího roku naopak nabyl významnosti oproti modelu bez JP specifikace. Směr významných parametrů zůstává při použití Justovy a Popeovy specifikace nezměněný.

Parametry pro skupinu č. 3

I ve třetí skupině došlo ke ztrátě významnosti u několika parametrů. Významnosti opět pozbyl parametr pro konstantu jako v předešlých dvou skupinách. Dále o významnost přišly parametry pro kvadratické tvary teplotních proměnných v šestém a devátém měsíci. Parametry pro srážkové proměnné pozbyly významnosti v šestém měsíci a v druhém měsíci s kvadratickým tvarem. Celkově došlo ke ztrátě významnosti u pěti proměnných z celkových čtyřiceti. Ke změně směru působení parametrů nedošlo v případě žádného významného parametru.

Adjustovaný koeficient determinace

Koeficient determinace neprošel větší změnou. Lze vidět nepatrné změny v řádu tisícin ve prospěch Just a Popeovy specifikace – jedná se o nepatrné zlepšení ve skupině číslo 2. Toto zlepšení je nicméně natolik nepatrné, že na něj není brán zřetel. Oproti tomu si lze povšimnout, že došlo ke zvýšení směrodatné chyby regrese v případě všech modelů (opět o velice nepatrnou hodnotu).

4.5.3.2 Ekonometrická verifikace

Tabulka 15: Ekonometrická verifikace Just a Pope

Test	Verifikace	1. skupina	2. skupina	3. skupina
Waldův test	Heteroskedasticita	0,7433	0,5739	0,1532
Test normality	Normalita	0,8753	0,1295	0,1167
Wooldridgeův test	Autokorelace	0,0873	0,3207	0,1744

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Z pohledu ekonometrické verifikace došlo ke zlepšení normality ve třetí skupině. Nicméně tato změna není považována za výrazně zlepšující vzhledem ke snížení adjustovaného koeficientu determinace a ztrátě významnosti některých parametrů.

4.5.4 Zhodnocení modelů a volba konečné specifikace

Na začátku této kapitoly byly sestaveny plně agregované modely. Modely vykazovaly významnost parametrů, nicméně byly ekonometricky neverifikovatelné, a proto bylo od celkové agregace upuštěno. Byly sestaveny tři modely, které představovaly tři skupiny různých krajů v ČR. Jednalo se tedy o částečnou disagregaci původních modelů. Na základě vysvětlovací schopnosti modelu byla stanovena finální specifikace, kterou byla podoba modelu bez logaritmické transformace. Následně byly odhadnuty modely Just a Popeovy specifikace. Tyto modely s JP specifikací nedosahovaly lepších výsledků v porovnání s běžným modelem fixních efektů panelových dat. Tato skutečnost vedla k tomu, že jsou v práci dále využívány modely s fixními efekty pro tři skupiny.

4.6 Aplikace modelu

Pro aplikaci modelů byl zvolen pouze jeden model. Tímto modelem byl model FE pro první skupinu krajů, která v sobě zahrnuje kraj Jihočeský, Plzeňský a Karlovarský. Nejprve byla provedena ex-post analýza, která je založena na sledování změn elasticity při posunu


nad nebo pod průměr zkoumané proměnné. Na závěr byly vytvořeny elasticity modelu, které jsou využity k tvorbě různých scénářů budoucího vývoje.

4.6.1 Analýza proměnlivé elasticity

4.6.1.1 Teplotní elasticity


Data v modelech byla centralizována za pomoci průměru. To znamená, že proměnné prvního řádu představují elasticity na průměru souboru. Po derivaci funkcí modelů jsou získány funkce, které vystihují změnu elasticity v závislosti na změně teploty od průměru souboru.

Graf 6: Elasticita proměnné TM2



Zdroj: vlastní zpracování

Graf 7: Elasticita proměnné TM3

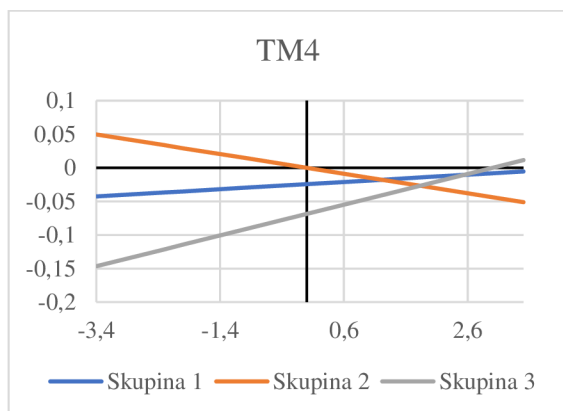


Zdroj: vlastní zpracování

TM2: Na základě grafu 6 pro proměnnou TM2 lze pozorovat pozitivní efekt teploty na nárůst elasticity u skupiny 1 a 3. Sklon funkce elasticity je nejvyšší ve skupině č. 1. Nejvyšší elasticitu na průměru souboru lze pozorovat u skupiny č. 2 s hodnotou 0,085 %.

TM3: Na základě grafu 7 pro proměnnou TM3 lze pozorovat negativní efekt růstu teploty na elasticitu v případě skupiny č. 1 a 2. Největší sklon u funkce elasticity lze pozorovat v případě skupiny č. 2. Nejvyšší elasticitu na průměru souboru lze pozorovat u skupiny č. 3 s hodnotou 0,077 %.

Graf 8: Elasticita proměnné TM4




Zdroj: vlastní zpracování

TM4: Na základě grafu 8 pro proměnnou TM4 lze pozorovat pozitivní efekt růstu teploty na elasticitu v případě skupiny č. 1 a 3. Oproti tomu skupina č. 2 vykazuje opačný jev. Největší sklon přímky lze pozorovat v případě skupiny č. 3. Graf také zobrazuje nejvyšší elasticitu na průměru, která patří skupině č. 3 s hodnotou $-0,07\%$.


TM5: Na základě grafu 9 pro proměnnou TM5 lze pozorovat negativní efekt růstu teploty na elasticitu u všech skupin. Přímka s největším sklonem je u skupiny č. 2. Zároveň zde můžeme pozorovat, že elasticita na průměru souboru je v případě skupiny číslo dva také nejvyšší, a to s hodnotou elasticity na průměru souboru $-0,16\%$. Přestože na průměru souboru má skupina č. 1 vyšší elasticitu než skupina č. 3, tak lze pozorovat, že při teplotě $TM5 = -1,04$, dojde k překonání elasticity skupiny č. 1 skupinou č. 3.

Graf 9: Elasticita proměnné TM5



Zdroj: vlastní zpracování


Graf 10: Elasticita proměnné TM6



Zdroj: vlastní zpracování

TM6: Na základě grafu 10 pro proměnnou TM6 lze pozorovat negativní efekt růstu teploty na elasticitu u všech skupin. Nejvyšší elasticitu na průměru souboru má v tomto případě skupina č. 2 s hodnotou $-0,21\%$. Tento graf ovšem znázorňuje zajímavou skutečnost, kdy nejvyšší sklon funkce elasticity má skupina č. 1. To znamená, že s rostoucí

Graf 11: Elasticita proměnné TM7

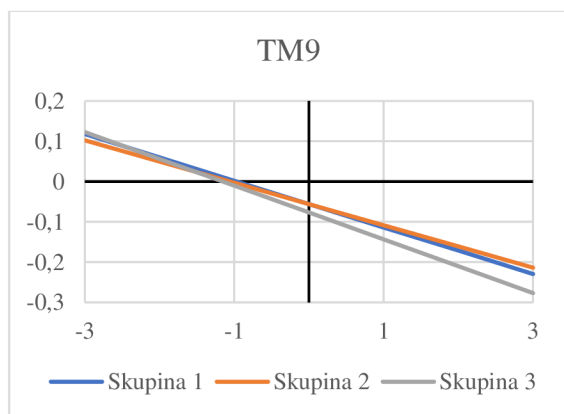


Zdroj: vlastní zpracování

hodnotou teploty nad průměr souboru dojde v určitém bodě (TM6 = 3,45) k překonání záporné elasticity skupiny č. 2.


TM7: Na základě grafu 11 pro proměnnou TM7 lze pozorovat negativní efekt růstu teploty na elasticitu u všech skupin. Největší sklon přímky elasticity má skupina č. 1. Zároveň má skupina č. 1 nejvyšší elasticitu na průměru souboru s hodnotou -0,056 %. U přímk lze pozorovat podobný průběh přímek s tím, že nejmenší rychlost změny elasticity vykazuje skupina č. 2.

Graf 12: Elasticita proměnné TM9



Zdroj: vlastní zpracování

Graf 13: Elasticita proměnné TM10




Zdroj: vlastní zpracování

TM9: Na základě grafu 12 pro proměnnou TM9 lze pozorovat negativní efekt růstu teploty na elasticitu u všech proměnných. Nejvyšší sklon přímky elasticity má skupina č. 3. U této proměnné má skupina č. 3 také nejvyšší elasticitu na průměru.

TM10: V případě grafu 13 pro proměnnou TM10 lze pozorovat negativní efekt růstu teploty na elasticitu u všech proměnných. Nejvyšší sklony přímky elasticity má skupina č. 2. Nejvyšší elasticitu na průměru souboru lze pozorovat v případě skupiny č. 1 s hodnotou -0,02 %. V případě TM10 lze pozorovat nejpomalejší změnu elasticity v případě skupiny č. 1.

Graf 14: Elasticita proměnné TM11




Zdroj: vlastní zpracování

TM11: V případě grafu 14 pro proměnnou TM11 lze pozorovat negativní efekt růstu teploty na elasticitu u všech proměnných. Nejvyšší sklon přímky elasticity má skupina č. 3. Tato skupina má také nejvyšší elasticitu na průměru souboru s hodnotou 0,01 %. Opět lze pozorovat nejnižší sklon v případě skupiny č. 2.

4.6.1.2 Elasticita srážek

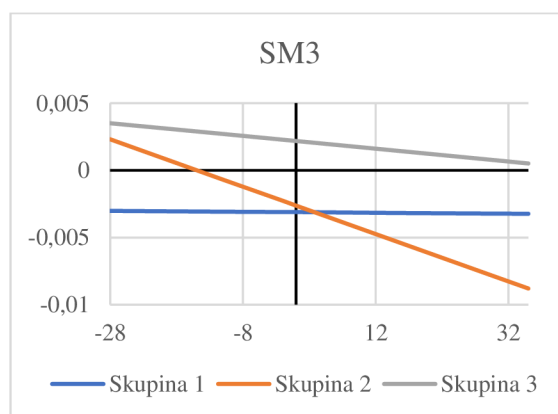
Obdobně jako v případě teploty byly vytvořeny elasticity srážek. Následující grafy představují změnu elasticity v závislosti na růstu či poklesu srážek od průměru souboru. Osa y představuje elasticitu a osa x představuje změnu úhrnu srážek od průměru v daném měsíci.

Graf 15: Elasticita proměnné SM2



Zdroj: vlastní zpracování

Graf 16: Elasticita proměnné SM3




Zdroj: vlastní zpracování

SM2: Na základě grafu 15 pro proměnnou SM2 lze pozorovat negativní efekt růstu srážek na elasticitu u skupiny č. 1 a 3. Nejvyšší elasticitu na průměru má skupina č. 2 a nejvyšší sklon v tomto případě má skupina číslo tři. Nejmenší změnu citlivosti při změně srážek vykazuje skupina č. 2.


SM3: Na základě grafu 16 pro proměnnou SM3 lze pozorovat negativní efekt růstu srážek v případě všech skupin. Největší sklon přímky elasticity má v tomto případě skupina č. 2. Zajímavostí v případě tohoto grafu je, že nejvyšší elasticitu na průměru můžeme pozorovat u skupiny č. 1 a zároveň lze u této skupiny pozorovat velice mírný sklon přímky elasticity. Tento sklon je natolik mírný, že to vypadá, jako by růst srážek neměl skoro žádný vliv na elasticitu dané proměnné. To může znamenat velice nízkou nelinearitu této proměnné ve skupině číslo 1.

Graf 17: Elasticita proměnné SM4



Zdroj: vlastní zpracování

Graf 18: Elasticita proměnné SM5




Zdroj: vlastní zpracování

SM4: V případě grafu 17 pro proměnnou SM4 lze pozorovat negativní efekt růstu srážek na elasticitu všech proměnných. Nejvyšší sklon přímky elasticity má v tomto případě skupina č. 1. Nejvyšší elasticitu na průměru souboru lze pozorovat u druhé skupiny s hodnotou $-0,007\%$. Na základě grafu lze pozorovat obdobnou citlivost elasticity na změnu srážek v případě skupiny č. 2 a č. 3.

SM5: V případě grafu 18 pro proměnnou SM5 lze pozorovat negativní efekt růstu srážek na elasticitu. Nejvyšší sklon přímky elasticity v tomto případě má skupina č. 3. Zároveň má tato skupina také nejvyšší hodnotu elasticity na průměru souboru s kladnou hodnotou $0,0028\%$. Z grafu lze také pozorovat, že skupina č. 3 překlopí kladnou elasticitu do elasticity záporné až při podstatně větší změně srážek, než je tomu tak u skupiny č. 1 a 2.


Graf 19: Elasticita proměnné SM6



Zdroj: vlastní zpracování

SM6: V případě grafu 19 pro proměnnou SM6 lze pozorovat negativní efekt růstu srážek na elasticitu v případě skupiny č. 1 a 2. Elasticita na průměru souboru je v případě skupiny č. 1 a 3 téměř stejná. Nejvyšší elasticitu na průměru má v tomto případě skupina č. 2 s hodnotou -0,007 %. Nejvyšší sklon má přímka elasticity skupiny č. 3.


Graf 20: Elasticita proměnné SM7



Zdroj: vlastní zpracování

SM7: V případě grafu 20 pro proměnnou SM7 lze pozorovat pozitivní efekt růstu srážek na elasticitu u všech skupin. Skupina č. 1 má nejvyšší sklon přímky elasticity a zároveň nejvyšší hodnotu elasticity na průměru souboru s hodnotou -0,007 %. Oproti tomu skupina č. 2 má sklon nejmírnější, a proto je změna elasticity nejpomalejší vzhledem ke změně srážek.


Graf 21: Elasticita proměnné SM9



Zdroj: vlastní zpracování

SM9: V případě grafu 21 pro proměnnou SM9 lze pozorovat pozitivní vliv růstu srážek u skupiny č. 1 a 3. Elasticity na průměru souboru v případě devátého měsíce se u skupiny č. 1 prakticky blíží nule. Nejvyšší elasticitu na průměru souboru má skupina č. 2 a skupina číslo 3 má nejvyšší sklon přímky elasticity. Skupina č. 2 má zároveň nejnižší sklon přímky elasticity.


Graf 22: Elasticita proměnné SM10



Zdroj: vlastní zpracování

SM10: V případě grafu 22 pro proměnnou SM10 lze pozorovat negativní vliv růstu srážek od průměru souboru u skupiny č. 1 a 3. Stejně jako v případě SM9 se skupina č. 2 chová opačně. Nejvyšší elasticitu na průměru souboru lze pozorovat u skupiny č. 1 (-0,003 %) a největší sklon přímky elasticity lze pozorovat u skupiny č. 3. Opět lze pozorovat nejmenší sklon u skupiny č. 2.

Graf 23: Elasticita proměnné SM11



Zdroj: vlastní zpracování

SM11: V případě grafu 23 pro proměnnou SM11 lze pozorovat pozitivní vliv růstu srážek na elasticitu v případě skupiny č. 2 a 3. Nejvyšší elasticitu na průměru lze pozorovat u skupiny č. 3 a tato skupina má zároveň největší sklon přímky elasticity. Elasticita skupiny č. 2 má stejně jako v několika předchozích případech nejpomalejší změnu vzhledem ke změně srážek.

4.6.2 Tvorba scénářů modelu

1. scénář

Scénář číslo jedna je vytvořen na základě ClimateChange Post (2024), kdy se očekává nárůst teploty o 1,2 stupně celsia do roku 2030. Zároveň na základě Caloireo et al. (2018) je uvažován nárůst srážek zhruba o 20 mm za desetiletí. Tato změna se odráží v níže uvedeném scénáři v podobě změny nárůstu teploty oproti průměru o 8 % a nárůstu srážek o 4 %. Poslední efekt, který je vhodné zahrnout, je posun v čase. Pro scénář číslo jedna uvažujeme změnu o 10 let. Tento scénář je aplikován na model pro skupinu 1.

- a) Nárůst teploty ve všech měsících o 8 % při nezměněném čase a cenovém indexu pro Jihočeský kraj.

Nárůst teploty o 8 % povede ke snížení výnosu pšenice o 0,02 t/ha od průměru souboru. Jestliže průměrem souboru jsou 4,11 t/ha, tak při simulované změně teploty dojde ke snížení výnosu pšenice na hodnotu 4,08 t/ha.

- b) Nárůst srážek ve všech měsících o 4 % při nezměněném čase a cenovém indexu pro Jihočeský kraj.

Nárůst srážek ve všech měsících o 4 % povede ke zvýšení výnosu pšenice o 0,51 t/ha. Jestliže průměrem souboru jsou 4,11 t/ha, tak při simulované změně srážek dojde ke zvýšení výnosu pšenice na hodnotu 4,62 t/ha. Tato hodnota se může zdát vysoká, nicméně příbytek je dán především hodnotou konstanty v modelu, proti které nedostatečně působí srážky. Srážky samotné výnos snižují o hodnotu 0,02 t/ha (pokud není brána v úvahu konstanta).

- c) Nárůst teploty ve všech měsících o 8 %, nárůst srážek ve všech měsících o 4 % a posun v čase o 10 let dopředu.

Kombinace výše uvedených změn povede ke zvýšení výnosu pšenice o 0,6 t/ha. Jestliže průměrným výnosem souboru jsou 4,11 t/ha, tak při simulované změně dojde ke zvýšení výnosu pšenice na hodnotu 4,71 t/ha.

2. scénář

Scénář číslo dva je vytvořen na základě předpokladu zvýšení teploty o 2 stupně celsia (CNRS, 2021) a zvýšení úhrnu srážek o 50 mm (Caloiero, 2018). Tato změna odpovídá změně nárůstu teploty o 12 % a nárůstu srážek o 8 %. Tento scénář se týká skupiny č. 1.

- a) Nárůst teploty ve všech měsících o 12 % při nezměněném čase a cenovém indexu pro Jihočeský kraj.

Nárůst teploty o 12 % povede ke snížení výnosu pšenice o -0,42 t/ha od průměru souboru. Jestliže průměrem souboru jsou 4,11 t/ha, tak při simulované změně teploty dojde ke snížení výnosu pšenice na hodnotu 3,69 t/ha.

- b) Nárůst srážek ve všech měsících o 4 % při nezměněném čase a cenovém indexu pro Jihočeský kraj.

Nárůst srážek ve všech měsících o 0,08 % povede ke zvýšení výnosu pšenice o 0,43 t/ha. Jestliže průměrem souboru jsou 4,11 t/ha, tak při simulované změně srážek dojde ke zvýšení výnosu pšenice na hodnotu 4,54 t/ha. Lze vidět, že v tomto případě srážky působí proti konstantě modelu již o něco více.

- c) Nárůst teploty ve všech měsících o 12 %, nárůst srážek ve všech měsících o 8 % a posun v čase o 25 let dopředu.

Kombinace výše uvedených změn povede ke zvýšení výnosu pšenice o 1,24 t/ha. Jestliže průměrným výnosem souboru jsou 4,11 t/ha, tak při simulované změně dojde ke zvýšení výnosu pšenice na hodnotu 5,35 t/ha. Lze vidět, že na základě dvou předchozích scénářů působí srážky a teplota proti výnosu pšenice. Pokud by nebyl uvažován čas a byly by uvažovány pouze změny v teplotách a srážkách, tak by se výnos pšenice snižoval 0,5 t/ha.

5 Výsledky a diskuse

V rámci této diplomové práce bylo odhadnuto několik typů modelů. Všechny modely vycházely z dat, která byla sesbírána Katedrou ekonomiky na ČZU. Tato data obsahují klimatické proměnné poskytované Českým hydrometeorologickým ústavem. Dále pak data o rozloze, sklizni a výnosech pšenice v České republice, tato data jsou čerpána z ČSÚ. To samé platí i o cenových indexech, které byly v modelu použity. Tato databáze obsahovala data od roku 1961 až do roku 2016. Autorem diplomové práce byla následně databáze rozšířena do roku 2022.

5.1 Výsledky OLS modelů

První skupinou modelů byly OLS modely pro jednotlivé kraje v České republice. Tyto modely obsahovaly neupravená data a zahrnovaly klimatické proměnné od září do července (vyjma prosince a listopadu), poměrovou proměnnou cenových indexů a časový trend. Šest ze čtrnácti modelů mělo obtíže s ekonometrickou verifikací (zvolená hladina významnosti pro verifikaci byla $\alpha=0,05$). Verifikací neprocházely následující kraje: Liberecký, Královehradecký, Pardubický, Vysočina, Olomoucký a Zlínský.

OLS modely vykazovaly dobrou vysvětlovací schopnost. U ekonometricky verifikovatelných modelů vykazoval adjustovaný koeficient determinace 77 % až 88 %. Modely se víceméně shodovaly ve směru závislostí jednotlivých parametrů u teplotních proměnných (ne vždy byly tyto parametry významné). Všeobecně modely vykazují přímou závislost v souvislosti s průměrnými teplotami února a března a výnosem pšenice. Oproti tomu teploty v dubnu až červenci vykazují negativní závislosti (výjimkou byl kraj Karlovarský, Liberecký, Jihomoravský). Tyto směry závislostí byly v souladu s ekonomickým předpokladem.

Mezi parametry pro srážky bylo podstatně horší nalézt obdobné zobecnění jako v případě teplot. V krajích Jižních Čech vykazovaly modely nejvyšší významnost v měsíci březnu (nepřímá závislost – březen nebyl v souladu s ekonomickým předpokladem) a červenci (nepřímá závislost). Oproti tomu kraje Moravy vykazovaly významnost spíše v měsíci červnu (nepřímá závislost).

Časový trend byl všeobecně významný a s kladným znaménkem. Parametr poměrové proměnné cenových indexů vykazoval nepřímou závislost. Tento vztah nebyl v souladu se studií Halová et al. (2021). Ovšem podle Miao et al. (2016) se v některých případech tento

vztah objevuje. Tento vztah vyjadřuje to, že čeští farmáři při nárůstu cenového indexu pšenice (popřípadě poklesu cen vstupů do zemědělství) rozšiřují svá pole i na méně úrodné plochy, a to následně vede k poklesu výnosu pšenice.

5.2 Výsledky modelů fixních efektů

OLS modely byly jednoduché a v zásadě dobře vysvětlovaly závisle proměnné. Nicméně nezachycovaly nelinearitu klimatických proměnných, a tím pádem nemohly vytvořit obraz, který by odrážel skutečnost. Na základě toho byl nejdříve vytvořen plně agregovaný model pro Českou republiku, který zahrnoval kvadratické tvary klimatických proměnných a časového trendu. Aby bylo zároveň možné odhadnout modely s nelineárními proměnnými, bylo nutné odebrat průměry z proměnných prvního řádu. Model byl odhadnut za pomoci fixních efektů. Tento model neprocházel ekonometrickou verifikací. Byl tedy částečně disagregován do tří skupin. První skupina obsahovala kraj Jihočeský, Plzeňský a Karlovarský. Druhá skupina obsahovala kraj Jihomoravský, Zlínský a Moravskoslezský. Třetí skupina obsahovala Prahu, Středočeský a Ústecký kraj. Následně byly při odhadu opět použity fixní efekty s dummy proměnnými.

Zároveň v této fázi byla testována ekonometrická verifikace modelu s logaritmickými proměnnými a modelu bez logaritmických proměnných. Lépe z verifikace vycházel model bez logaritmických proměnných, a proto byl dále využit. Studie se v zásadě neshodují na určitém tvaru proměnných ve výnosových funkcích. Halová et al. (2021) využila logaritmicky transformované proměnné. Oproti tomu studie Miao et al. (2016) a Shayanmehr et al. (2020) využily netransformované proměnné.

Lze se také v mnoha studiích setkat s Just a Popeovou specifikací modelu. Opět jako příklad lze uvést Shayanmehr et al. (2020) a Halová et al. (2021). V této diplomové práci byla tato specifikace také odhadnuta a následně testována. JP modely ovšem oproti klasickému modelu fixních efektů nevykazoval větší rozdíly v adjustovaném koeficientu determinace a ve směrech a velikosti parametrů. Model s fixními efekty byl tedy vyhodnocen jako nejvhodnější a bylo s ním dále pracováno.

Modely podle skupin s fixními efekty byly mezi sebou v zásadě konzistentní vyjma různých hladin významnosti parametrů. Teploty v únoru a březnu vykazovaly přímou závislost a teploty od dubna do července nepřímou závislost. To se shodovalo s výsledky z OLS modelů. Ze zpožděných proměnných byl významný pouze měsíc září s nepřímou závislostí. Jelikož byly parametry prvního řádu zbaveny průměrů, tak lze říci, že z teplotních

proměnných měl největší efekt na výnos pšenice měsíc červen. Procentuální změna této proměnné představovala snížení závislé proměnné až o 0,2 % (v případě skupiny č. 2 za podmínky *ceteris paribus*). Druhým parametrem s největším efektem na průměru souboru byl měsíc květen. Teplota v těchto dvou měsících pravděpodobně determinuje délku času, po který je plněno zrno.

Všechny tři modely vykazovaly pro parametry června a července nepřímou závislost v případě srážek prvního řádu a statistickou významnost. Duben vykazoval statistickou významnost a nepřímou závislost pouze ve skupině č. 2. Na elasticitě lze vidět, že srážky měly všeobecně mnohem menší efekt, než tomu bylo v případě teplot. Největší efekt na výnos sklizně měl měsíc červenec (ve dvou ze tří modelů), tento efekt odpovídal 0,007% až 0,006% změně závislé proměnné při změně nezávisle proměnné o procento (za podmínky *ceteris paribus*).

Parametry pro kvadratické proměnné představují efekt, kdy se s rostoucí hodnotou nad průměr souboru posiluje efekt parametrů prvního řádu. V případě teplot měly statisticky významné parametry druhého řádu tento posilující negativní efekt především v měsíci červnu, červenci a září. V případě srážkových proměnných se s tímto vztahem setkáváme u měsíce února v první a třetí skupině a u měsíce září ve třetí skupině.

Časový trend prvního řádu byl ve všech modelech významný a vykazoval přímou závislost. Procentuální efekty se s každým dalším rokem pohybovaly v rozmezí 0,06 až 0,05 % (za podmínky *ceteris paribus*). S posilujícím pozitivním efektem v případě parametru druhého řádu.

Největší negativní efekt, jakožto parametr prvního řádu, měla poměrová proměnná cenových indexů. Při procentuálním nárůstu této proměnné o jedno procento dochází ke snížení závislé proměnné v rozmezí od 1,32 % až po 1,68 % (v závislosti na skupině) za podmínky *ceteris paribus*.

5.3 Očekávání v budoucích letech

Na základě analýzy průměrů teplotních proměnných lze očekávat rostoucí průměrnou teplotu především v pozdních jarních a letních měsících. Vzhledem k nepřímé závislosti parametrů a elasticit těchto měsíců lze do budoucna očekávat spíše zvětšující se negativní efekt teploty na výnos pšenice (za podmínky *ceteris paribus*). V oblasti srážek je ve sledovaném období velice nepatrný úbytek (hodnoceno na základě rozdílu mezi desetiletými průměry). To nekoresponduje se závěry Caloiero et al. (2018). Nicméně vzhledem ke

komplexnosti a náročnosti tvorby skutečné predikce vývoje srážek bylo přihlíženo při tvorbě scénářů k závěrům z Caloiero et al. (2018) a bylo tedy předpokládáno, že dojde k nárůstu srážek vlivem zkrácení vodního cyklu.

V rámci simulací scénářů lze pozorovat negativní vliv nárůstu teploty a srážek s tím, že škodlivý efekt nárůstu teploty bude akcelarovat s větší vzdáleností teploty od průměru. Do roku 2030 bude mít nárůst teploty společně s nárůstem srážek na svědomí snížení výnosu pšenice zhruba o 0,1 t/ha od průměrné hodnoty (pokud není uvažován čas). Další hrubou projekcí byl scénář roku 2050, kdy nárůst teplot společně se srážkami budou mít na svědomí snížení výnosu pšenice zhruba o 0,5 t/ha (opět bez uvažování času). Technologie, které jsou v časovém trendu zahrnuty, představují jedinou výraznou páku působící proti zhoršujícím se klimatickým podmínkám.

Scénáře jsou také tvořeny pouze na základě dvou zdrojů, které výrazně zjednodušují a také omezují scénáře budoucích vývoje.

I specifikace modelu s sebou nesla i určité nevýhody. V pracích, jako je například Miao et al. (2016), Shayanmehr et al. (2020) a Cabas et al. (2009), bývají často využívány proměnné jako extrémně teplé dny anebo mrazivé dny v určitém období. Tyto proměnné nejsou v modelu použitém v této práci využity. Proto není zachycen případ, kdy dojde k poškození mrazem brzo vzešlé rostliny v jarním období. Dny s extrémní teplotou mohou také terminovat růst rostliny, a s tímto jevem se pravděpodobně budeme v budoucích letech setkávat spíše.

6 Závěr

V praktické části diplomové byla nejdříve práce vytvořena elementární statistická analýza proměnných vstupujících do modelu a následně byly tyto proměnné použity v ekonometrické analýze. Ekonometrická analýza obsahuje běžné lineární modely pro jednotlivé kraje a také modely, které zachycují nelinearitu pomocí kvadratických proměnných. Kvadratické proměnné jsou do modelu přidány z toho důvodu, že není očekáván lineární vliv klimatických proměnných na výnos pšenice. Tento způsob přístupu by měl lépe zachytit budoucí vývoj klimatické změny. Jelikož zahrnutí kvadratických proměnných do modelů zvýšilo množství regresorů, tak bylo přistoupeno k panelové analýze dat za pomoci fixních efektů. V diplomové práci je zároveň zkoumána i Just a Popeova specifikace, která je běžně k vidění v odborné literatuře. Tato specifikace nicméně nevykazovala zásadní rozdíl od modelů běžných fixních efektů.

Vytvořené modely se lišily od ostatní, v práci zmíněné, odborné literatury tím, že v sobě obsáhly prakticky celý životní cyklus zkoumané rostliny. Díky tomu bylo zjištěno, že například únor a zpožděné podzimní měsíce mají v modelech své místo. Na základě elasticit na průměrech souborů lze prohlásit, že průměrné teploty v květnu a červnu představují největší hrozbu pro výnos pšenice. Úhrny srážek, které byly v modelech, sice působí negativně na výnos pšenice, nicméně ne tolik jako teplotní průměry. Technologická změna se projevila jako jediná významně zlepšující proměnná. Kvadratické tvary proměnných poukázaly na to, že se zvyšujícím se odchýlením od průměru souboru se bude zhoršovat výnos pšenice. To znamená, že jestliže nebude klimatická změna zpomalena, tak v budoucích může mít fatální následky letech na výnos pšenice.

Literatura zabývající se zkoumáním a analýzou vlivu klimatické změny zohledňuje různé vlivy. Vlivy, které nejsou v práci zkoumány a zahrnuty, jsou například extrémně teplé dny anebo naopak dny mrazivé. V budoucích letech lze ovšem předpokládat, že největší riziko budou představovat extrémně teplé dny. Zde je tedy určitý prostor k vytvoření modelu, který by toto riziko zohledňoval.

Aktuální predikce, ať je již debata o IPCC anebo RCP, v budoucích letech naznačují spíše prohlubování klimatické změny a v mírných scénářích pouze zpomalení klimatické změny. I když Česká republika zatím nepředstavuje přímo ohrožený stát, tak i pro ni v budoucích letech bude klimatická změna představovat výzvy jak politické, tak i environmentální.

7 Seznam použitých zdrojů

- AKADEMIE VĚD [AV], 2020. *Klimatická změna – fenomén současnosti*. Online. Dostupné z: <https://www.avcr.cz/export/sites/avcr.cz/cs/veda-a-vyzkum/avex/files/2020-04-Klimaticka-zmena.pdf>. [cit. 2024-03-30].
- ANGRIST, Joshua David a PISCHKE, Jorn-Steffen, 2009. *Mostly harmless econometrics: an empiricist's companion*. Princeton, N.J: Princeton University Press. ISBN 978-0-691-12035-5.
- BRČÁK, Josef; SEKERKA, Bohuslav; SEVEROVÁ, Lucie a SVOBODA, Roman, 2020. *Mikroekonomie: teorie a aplikace*. Plzeň: Aleš Čeněk. ISBN 978-80-7380-818-1.
- CABAS, Juan; WEERSINK, Alfons a OLALE, Edward, 2010. Crop yield response to economic, site and climatic variables. Online. *Climatic Change*. Roč. 1, č. 101, s. 599-616. Dostupné z: <https://doi.org/10.1007/s10584-009-9754-4>. [cit. 2024-03-30].
- CALOIERO, Tommaso; CALOIERO, Paola a FRUSTACI, Francesco, 2018. Long-term precipitation trend analysis in Europe and in the Mediterranean basin. Online. *Water and Environment Journal*. Č. 32, s. 433-445. Dostupné z: <https://doi.org/10.1111/wej.12346>. [cit. 2024-03-30].
- CIPRA, Tomáš, 2013. *Finanční ekonometrie*. 2. úpr. vyd. Praha: Ekopress. ISBN 978-80-86929-93-4.
- CLIMATE CHANGE POST, 2024. *Climate change in Czech Republic*. Online. Dostupné z: <https://www.climatechangepost.com/czech-republic/climate-change/>. [cit. 2024-03-30].
- CRS, 2021. *Europe's Climate in 2050*. Online. Dostupné z: <https://www.letstalkabouteu.com/en/in-a-nutshell/europes-climate-in-2050/>. [cit. 2024-03-30].
- ČHMÚ, 2024. *Český hydrometeorologický ústav*. Online. Dostupné z: <https://www.chmi.cz/>. [cit. 2024-03-31].
- ČSÚ, 2022. *Definitivní údaje o sklizni zemědělských plodin*. Online. Český statistický úřad. Dostupné z: <https://www.czso.cz/csu/czso/definitivni-udaje-o-sklizni-zemedelskych-plodin-2022>. [cit. 2024-03-30].

- ČSÚ, 2024. *Český statistický úřad*. Online. Dostupné z: <https://www.czso.cz/csu/czso/domov>. [cit. 2023-08-11].
- DESCHÊNES, Olivier a GREENSTONE, Michael, 2007. The Economic Impacts of Climate Change: Evidence from Agricultural Output and Random Fluctuations in Weather. Online. *The American Economic Review*. Roč. 97, č. 1, s. 354–85. Dostupné z: <http://www.jstor.org/stable/30034398>. [cit. 2024-03-30].
- DOUGHERTY, Christopher, 2009. *Introduction to econometrics*. 4th ed. New York: Oxford University Press. ISBN 978-0-19-956708-9.
- EVROPSKÁ KOMISE, 2023. *Důsledky změny klimatu*. Online. Dostupné z: https://climate.ec.europa.eu/climate-change/consequences-climate-change_cs. [cit. 2023-08-12].
- GUJARATI, Damodar N., 2003. *Basic econometrics*. 4th ed. New York: MacGraw-Hill/Irwin. ISBN 0-07-112342-3.
- HÁLOVÁ, Pavlína; MACH, Jiří; ČECHURA, Lukáš a SLABOCH, Josef, 2021. Climate Change and Sustainability in Czech Wheat Production. Online. *Agris on-line Papers in Economics and Informatics*. Roč. 4, č. 13. Dostupné z: <https://doi.org/10.7160/aol.2021.130402>. [cit. 2024-03-30].
- HANČLOVÁ, Jana, 2012. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Professional Publishing. ISBN 978-80-7431-088-1.
- HINDLS, Richard; HRONOVÁ, Stanislava; SEGER, Jan a FISCHER, Jakub, 2007. *Statistika pro ekonomy*. 8.vyd. Praha: Professional Publishing. ISBN 978-80-86946-43-6.
- HOLMAN, Johnathon D.; SCHLEGEL, Alan J.; THOMPSON, Curtis R. a LINGENFELSER, Jane E., 2011. Influence of Precipitation, Temperature, and 56 Years on Winter Wheat Yields in Western Kansas. Online. *Crop Management*. Roč. 10, č. 1, s. 1-10. Dostupné z: <https://access.onlinelibrary.wiley.com/action/showCitFormats?doi=10.1094%2FCM-2011-1229-01-RS>. [cit. 2024-03-30].
- CHAMBERS, Robert G., 1989. *Applied production analysis (A dual approach)*. Cambridge University Press. ISBN 0-521-31427-5.

JIMÉNEZ, Oswalt R.; BORNEMANN, Amalia C.; MEDINA, Yelzen E.; ROMERO, Kendipher a BRAVO, Juan R., 2023. Prospects of biological inputs as a measure for reducing crop losses caused by climate change effects. Online. *Journal of Agriculture and Food Research*. Č. 14, s. 100689. ISSN 2666-1543. Dostupné z:

<https://doi.org/https://doi.org/10.1016/j.jafr.2023.100689>. [cit. 2024-03-30].

JUST, Richard E. a POPE, Rulon D., 1979. Production Function Estimation and Related Risk Considerations. Online. *American Journal of Agricultural Economics*. Roč. 61, č. 2. Dostupné z: <https://doi.org/https://doi.org/10.2307/1239732>. [cit. 2023-08-15].

MADDALA, Gangadharrao S. a LAHIRI, Kajal, 2009. *Introduction to econometrics*. 4th ed. John Wiley. ISBN 978-81-265-3415-9.

MIAO, Ruiqing; KHANNA, Madhu a HUANG, Haixiao, 2016. Responsiveness of Crop Yield and Acreage to Prices and Climate. Online. *American Journal of Agricultural Economics*. Roč. 98, č. 1, s. 191–211. Dostupné z: <https://www.jstor.org/stable/24739918>. [cit. 2024-03-30].

Online. Roč. 29, č. 2. [cit. 2024-03-30].

PECK, Roxy; OLSEN, Chris a DEVORE, Jay, 2008. *Introduction to Statistics and Data Analysis*. 3rd ed. Thomas Brooks/Cole. ISBN 978-0-495-11873-2.

PRÁŠIL, Ilja Tom; MUSILOVÁ, Jana; HERMUTH, Jiří; KOSOVIČ, Klára; KLÍMA, Miroslav et al., 2019. *Fenologie pšenice*. Online. Praha: VÚMOP v.v.i. ISBN 978-80-87361-98-6. Dostupné z: <http://www.cbks.cz/SbornikModra2019/Prasil.pdf>. [cit. 2024-03-30].

ROGER, Kirk E., 2008. *Statistics An Introduction*. 5th ed. Belmont: Thomson Wadsworth. ISBN 978-0-534-56478-0.

RUSSELL, Davidson a MACKINNON, James G., 2021. *Econometric Theory and Methods*. 2nd ed. New York: Oxford University Press. ISBN 0-19-512372-7.

SAMUELSON, Paul A. a NORDHAUS, William D., 2010. *Economics*. 19th ed. McGraw-Hill/Irwin. ISBN 978-0-07-351129-0.

SHAYANMEHR, Samira; HENNEBERRY, Shida Rastegari; SABOUNI, Mahmood Sabouhi a FOROUSHANI, Naser Shahnoushi, 2020. Drought, Climate Change, and Dryland Wheat Yield Response: An Econometric Approach. Online. *International Journal*

of Environmental Research and Public Health. Roč. 17, č. 14, s. 5264. Dostupné z: <https://doi.org/https://doi.org/10.3390/ijerph17145264>. [cit. 2024-03-30].

STOCK, James Harold a WATSON, Mark, 2020. *Introduction to econometrics*. 4th ed. Pearson. ISBN 978-1-292-26445-5.

TICHÁ, Markéta a VYZÍNOVÁ, Petra, 2006. *Polní plodiny*. Online. Dostupné z: <https://cit.vfu.cz/vegetabilie/plodiny/index.htm>. [cit. 2024-03-30].

VÁŇOVÁ, Marie; JIRSA, Ondřej a HLEDÍK, Pave, 2021. Výnosová stabilita ozimé pšenice v závislosti na počasí, osevním sledu a zpracování půdy. Online. *Obilnářské listy*. Roč. 29, č. 2, s. 31-28. Dostupné z: https://www.vukrom.cz/userfiles/files/obilnarske_listy/2021/2021_2/31_38.pdf. [cit. 2024-03-30].

WOOLDRIDGE, Jeffrey, 2001. *Econometric analysis of cross section and panel data*. 2nd ed. The MIT Press. ISBN 978-0-262-23219-7.

WOOLDRIDGE, Jeffrey, 2002. *Introduction to econometrics: a modern approach*. 2nd ed. South Wester College Pub. ISBN 978-0-324-11364-8.

YANG, Chenyao; FRAGA, Helder; TRINDADE, Henrique; SANTOS, João A. a VAN IEPEREN, Wim, 2019. Effects of climate change and adaptation options on winter wheat yield under rainfed Mediterranean conditions in southern Portugal. Online. *Climatic Change*. Č. 154, s. 159–178. Dostupné z: <https://doi.org/https://doi.org/10.1007/s10584-019-02419-4>. [cit. 2024-03-30].

YUN, Seong D. a GRAMIG, Benjamin M., 2022. Spatial Panel Models of Crop Yield Response to Weather: Econometric Specification Strategies and Prediction Performance. Online. *Journal of Agricultural and Applied Economics*. Roč. 1, č. 54, s. 53-71. Dostupné z: <https://doi.org/10.1017/aae.2021.29>. [cit. 2024-03-30].

ZIMOLKA, Josef, 2005. *Pšenice: pěstování, hodnocení a užití zrna*. Praha: Profi Press. ISBN 80-86726-09-6.

8 Seznam obrázků, tabulek, grafů a zkratk

8.1 Seznam obrázků

Obrázek 1: Vyobrazení náhodné složky	21
Obrázek 2: Rozhodovací schéma pro panelová data	39

8.2 Seznam tabulek

Tabulka 1: Porovnání desetiletých teplotních měsíčních průměrů na začátku a konci období	50
Tabulka 2: Porovnání desetiletých měsíčních průměrů úhrnu srážek na začátku a na konci sledovaného období.....	52
Tabulka 3: Trendová analýza cenových indexů.....	55
Tabulka 4: Výsledky odhadů jednotlivých OLS modelů pro jednotlivé kraje - 1. část.....	61
Tabulka 5: Výsledky odhadů jednotlivých OLS modelů pro jednotlivé kraje - 2. část.....	62
Tabulka 6: Výsledný odhad modelů FE pro ČR	71
Tabulka 7: Ekonometrická verifikace	72
Tabulka 8: Adjustovaný koeficient determinace pro tři modely ve dvou funkčních specifikacích.....	73
Tabulka 9: Ekonometrická verifikace modelů s logaritmy	74
Tabulka 10: Ekonometrická verifikace modelů bez logaritmů.....	74
Tabulka 11: Odhad modelů fixních efektů bez logaritmické transformace – 1. skupina a 2. skupina	76
Tabulka 12: Odhad modelů fixních efektů bez logaritmické transformace – 3. skupina	77
Tabulka 13: Odhad modelů fixních efektů bez logaritmické transformace – výsledky adjustovaného koeficientu determinace a směrodatné chyby regrese	78
Tabulka 14: Výpočet konstant pro jednotlivé kraje ve skupině.....	81
Tabulka 15: Ekonometrická verifikace Just a Pope	83
Tabulka 16: Odhad modelu Just a Popeovy specifikace s použitím fixních efektů.....	115
Tabulka 17: Odhad Just a Popeovy specifikace s použitím fixních efektů – 3. skupina ...	116
Tabulka 18: Adjustovaný koeficient determinace Just a Popeovy specifikace	117

8.3 Seznam grafů

Graf 1: Rozdíl mezi desetiletými průměry měsíčních teplot	49
Graf 2: Lineární trend průměrné roční teploty v ČR	51
Graf 3: Rozdíl mezi desetiletými průměry měsíčních úhrnů srážek v mm.....	52
Graf 4: Vývoj ročního úhrnu srážek za sledované období na území ČR.....	53
Graf 5: Cenové indexy vstupů a výstupů	55
Graf 6: Elasticita proměnné TM2	84
Graf 7: Elasticita proměnné TM3	84
Graf 8: Elasticita proměnné TM4	85
Graf 9: Elasticita proměnné TM5	85
Graf 10: Elasticita proměnné TM6	85
Graf 11: Elasticita proměnné TM7	85
Graf 12: Elasticita proměnné TM9	86
Graf 13: Elasticita proměnné TM10	86

Graf 14: Elasticita proměnné TM11	87
Graf 15: Elasticita proměnné SM2	87
Graf 16: Elasticita proměnné SM3	87
Graf 17: Elasticita proměnné SM4	88
Graf 18: Elasticita proměnné SM5	88
Graf 19: Elasticita proměnné SM6	89
Graf 20: Elasticita proměnné SM7	89
Graf 21: Elasticita proměnné SM9	89
Graf 22: Elasticita proměnné SM10	89
Graf 23: Elasticita proměnné SM11	90

8.4 Seznam použitých zkratk

FE	fixní efekty
RE	náhodné efekty
ČHMÚ	Český hydrometeorologický ústav
ČSÚ	Český statistický úřad
OLS	anglický ekvivalent metody nejmenších čtverců
JP	Just a Pope
TM2	průměrná měsíční teplota v únoru
TM3	průměrná měsíční teplota v březnu
TM4	průměrná měsíční teplota v dubnu
TM5	průměrná měsíční teplota v květnu
TM6	průměrná měsíční teplota v červnu
TM7	průměrná měsíční teplota v červenci
TM9	průměrná měsíční teplota v září
TM10	průměrná měsíční teplota v říjnu
TM11	průměrná měsíční teplota v listopadu
SM2	úhrn srážek v únoru
SM3	úhrn srážek v březnu
SM4	úhrn srážek v dubnu
SM5	úhrn srážek v květnu
SM6	úhrn srážek v červnu
SM7	úhrn srážek v červenci
SM9	úhrn srážek v září
SM10	úhrn srážek v říjnu
SM11	úhrn srážek v listopadu

9 Přílohy

9.1 Příloha 1

Při odvozování rovnic pro BMNČ je vycházeno z již zapsané jednoduché regrese:

$$u_t = y_t - (\beta_0 + \beta_1 * x_t), \quad (50)$$

(Davidson et MacKinnon, 2021, str. 30–34).

Na základě teorie očekávaných hodnot je předmětem zájmu průměr výše uvedeného vztahu:

$$\frac{1}{n} \sum_{t=1}^n u_t = \frac{1}{n} \sum_{t=1}^n (y_t - \beta_0 - \beta_1 x_t), \quad (51)$$

(Davidson et MacKinnon, 2021, str. 30–34).

V tomto vztahu (21) využíváme nepodmíněnou předpokládanou hodnotu. Pokud zároveň využijeme i předpoklad, že průměrná hodnota $E(u_t) = 0$, lze takto sestavit naši první rovnici a část BMNČ, tedy:

$$\frac{1}{n} \sum_{t=1}^n (y_t - \beta_0 - \beta_1 x_t) = 0, \quad (52)$$

(Davidson et MacKinnon, 2021, str. 30–34).

Je-li stanoveno, že $\beta_1 = 0$, tak by byl výsledek v zásadě jednoduchý, a to $y_t = \hat{\beta}_0$. Bohužel, v této regresi tomu tak není a bude třeba nalézt druhou rovnici. Tento problém opět řeší teorie očekávaných hodnot, ale tentokrát v podmíněné podobě. Pokud je známo, že očekávaná hodnota u_t je závislá na hodnotě x_t , tak je tím získán vztah, který definuje očekávanou podmíněnou hodnotu (Davidson et MacKinnon, 2021, str. 30–34).

$$E(x_t u_t) = E(E(x_t u_t | x_t)) = E(x_t (u_t | x_t)) \quad (53)$$

Na základě vztahu podmíněné očekávané hodnoty je získána druhá rovnice podle Davidsona a MacKinnon (2021, str. 32), kterou lze použít při výpočtu BMNČ:

$$\frac{1}{n} \sum_{t=1}^n [x_t (y_t - \beta_0 - \beta_1 x_t)] = 0. \quad (54)$$

Je známo, že parametry nejsou závislé na hodně „t“, a lze tak vytvořit dvě rovnice BMNČ, které budou mít tuto podobu:

$$\beta_0 + \beta_1 \left[\frac{1}{n} \sum_{t=1}^n (x_t) \right] = \frac{1}{n} \sum_{t=1}^n (y_t),$$

$$\beta_0 \left[\frac{1}{n} \sum_{t=1}^n (x_t) \right] + \beta_1 \left[\frac{1}{n} \sum_{t=1}^n (x_t^2) \right] = \frac{1}{n} \sum_{t=1}^n (x_t y_t),$$
(55)

(Davidson et MacKinnon, 2021, str. 35–36; Stock et Watson, 2020, str. 149).

9.2 Příloha 2

Breusch-Paganův test

Breusch-Paganův test je založen na možnosti vyhodnocení celkových F a LM statistických testů pro model. Proč vlastně lze využít F a LM testy, když je zde uvedeno, že heteroskedasticita narušuje možnost využívat statistické testy? Je to z toho důvodu, že se využívají celkové testy pro upravený model, který odhaduje regresi na základě čtverců reziduí a původní matice X (Wooldridge, 2002, str. 255–257).

Nulovou hypotézou je, že variabilita náhodné složky je konstantou, tedy podle Wooldridge (2002, str. 255–257):

$$H_0: \text{Var}(u|x_1 x_2 \dots x_k) = \sigma^2. \quad (56)$$

V této podobě je nulová hypotéza ekvivalentem tvaru podmíněné očekávané hodnoty (Wooldridge, 2002, str. 255–257):

$$H_0: E(u^2|x_1 x_2 \dots x_k) = E(u^2) = \sigma^2. \quad (57)$$

Díky tomuto vztahu lze následně vytvořit lineární funkci, kde závislou proměnnou budou čtverce reziduí z původní rovnice a nezávislými proměnnými bude matice X (Wooldridge, 2002, str. 255–257).

$$\hat{u}^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k + v \quad (58)$$

Breusch-Paganův test je založen na tom, že z lineární regresní funkce (nad odstavcem) se odhadují nové parametry δ , které jsou následně testovány na statistickou významnost. To je umožněno díky tomu, že u lineární funkce výše je předpokládáno, že náhodná složka „ v “ má nezávislé rozdělení na matici X (Wooldridge, 2002, str. 255–257).

Nulová hypotéza může být tedy přeepsaná do následující podoby:

$$H_0 = \delta_1 = \delta_2 = \dots = \delta_k = 0, \quad (59)$$

a alternativní hypotéza by tedy byla:

$$H_1: \delta_k \neq 0, \text{ pro } k \neq 0. \quad (60)$$

Je třeba mít na paměti, že hypotézy se netýkají konstant. Následně tedy přichází na řadu testování všech parametrů naráz. Pro tento test se využívá f-test anebo LM test (Wooldridge, 2002, str, 257).

Vzorec pro f-test podle Wooldridge (2002, str, 257):

$$F = \frac{R_{\hat{u}^2}^2/k}{(1 - R_{\hat{u}^2}^2)/(n - k - 1)}, \quad (61)$$

kde n = počet pozorování,

k = počet parametrů.

Vzorec pro LM test Wooldridge (2002, str, 257):

$$LM = n * R_{\hat{u}^2}^2. \quad (62)$$

Pokud je testovaná hodnota (kritická hodnota) vyšší než $F_{k,n-k-1}$, tak test říká, že se v modelu nachází heteroskedasticita. V případě LM testu je porovnávána výsledná hodnota s χ_k^2 . Pokud je kritická hodnota LM vyšší než tabulková hodnota, pak se jedná o heteroskedasticitu (Gujarati, 2003, str. 411-412).

Whiteův test

Whiteův test na rozdíl od Breusch-Paganova testu využívá více rozvinutou pomocnou funkci, i když se v zásadě jedná o principiálně stejný test. Rozdíl ve funkci je ten, že při výpočtu regrese nejsou využívány pouze běžné regresory z matice X, ale zároveň jejich čtvercová a součtová podoba (Cipra, 2013, str. 85-86).

Pomocná funkce pro Whiteův test pro tři parametry (Cipra, 2013, str. 86):

$$\hat{u}^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \delta_3 x_1^2 + \delta_4 x_2^2 + \delta_5 x_1 x_2 + v \quad (63)$$

Cipra (2013, str. 86) následně uvádí vzorec pro f-test v případě Whiteova testu v této podobě pro kritickou hodnotu:

$$F = \frac{T - k}{m} * \frac{RRSS - URSS}{URSS}, \quad (64)$$

kde RRSS = suma čtverců reziduí v omezeném pomocném modelu,

URSS = suma čtverců reziduí v neomezeném pomocném modelu,

T = počet pozorování,

m = počet omezení v modelu (Cipra, 2013, str, 86).

Vypočtená kritická hodnota je porovnávána s tabulkovou hodnotou $F_{(1-\alpha)k,n-k}$. RRSS představuje funkci pomocného modelu, která je zredukována pouze na konstantu. I v tomto případě lze využít LM test, který je uveden u Breusch-Paganova testu. Cipra (2013,

str. 87) ovšem uvádí, že χ_m^2 hodnota je ovlivněna počtem omezení „m“ a nikoliv jako v předchozím vzorci počtem parametrů.

Publikace Wooldridge (2002, str. 26) pro zajímavost uvádí speciální případ Whiteova testu, kdy je pomocná funkce tvořena očekávanými (teoretickými) hodnotami \hat{y} a \hat{y}^2 . Díky této pomocné funkci jsou v modelu pouze dvě omezení nehledě na to, kolik obsahuje nezávislých proměnných. Pomocná funkce má následně tuto podobu:

$$\hat{u}^2 = \delta_0 + \delta_1\hat{y} + \delta_2\hat{y}^2 + v. \quad (65)$$

Glejserův test

Dalším testem, který lze použít na model je Glejserův test, který by podle Dougherty (2007, str. 210) mohl být klíčem k nalezení správné funkční formy. Dougherty (2007) uvádí pomocnou funkci, která je pro různé funkční tvary stejná.

Pomocná funkce pro Glejserův test podle Dougherty (2007, str. 210):

$$\sigma_{u_i} = \beta_1 + \beta_2 X_i^Y + v_i. \quad (66)$$

Na základě různé významnosti parametru β_2 pro různé funkční tvary lze určit vhodnější a méně vhodné funkční tvary (Dougherty, 2007, str. 210). Publikace Gujarati (2003, str. 405) uvádí, že Glejserův test není příliš vhodný, a to z toho důvodu, že pomocná funkce nesplňuje několik OLS předpokladů. Mezi ty patří například to, že náhodná složka pomocného modelu nemá nulový průměr, je většinou autokorelována a vykazuje heteroskedasticitu.

9.3 Příloha 3

Robustní chyby v případě heteroskedasticity

Jedná se o metodu, kterou lze aplikovat na heteroskedasticitu bez přihlídnutí k její příčině. Tuto metodu lze podle publikace Wooldridge (2002, str. 251) označit českým ekvivalentem jako Whitova směrodatná chyba.

Hlavním problémem v případě heteroskedasticity je, že nelze využít rozptyl parametrů z matice $(X^T X)^{-1}$ a rozptyl reziduí jako takový. Proto za účelem získání fungujícího odhadu rozptylů, které nejsou ovlivněny heteroskedasticitou, musí být vytvořena právě robustní směrodatná chyba nebo rozptyl.

V literatuře lze dohledat různé podoby vzorců pro výpočet robustní chyby. Základní myšlenka je ovšem pro všechny stejná. Tou myšlenkou je upuštění od směrodatné odchylky původního OLS a tvorba teoretické hodnoty variability parametrů. Toho je dosaženo za

pomocí změny ve výpočtu variability, která je velice dobře prezentována v publikaci Wooldridge (2002, str. 250).

Původní vzorec pro výpočet variability parametru β :

$$Var(\widehat{\beta}_1) = \frac{\sum_{i=1}^n (x_i - \bar{x}) * \sigma_i^2}{SST_x^2}. \quad (67)$$

Upravený vzorec pro výpočet teoretické variability teoretické hodnoty β :

$$\widehat{Var}(\widehat{\beta}_1) = \frac{\sum_{i=1}^n (x_i - \bar{x}) * \hat{u}_i^2}{SST_x^2}. \quad (68)$$

Obecný vzorec pro vícenásobnou regresi je poté následující:

$$\widehat{Var}(\widehat{\beta}_j) = \frac{\sum_{i=1}^n (\hat{r}_{ij}^2) * \hat{u}_i^2}{SST_j^2}, \quad (69)$$

kdy \hat{r}_{ij}^2 představuje hodnotu reziduální složky, která je zjištěna na základě odhadu regrese zvolené proměnné x v závislosti na ostatních nezávislých proměnných (Wooldridge, 2002, str. 250).

Obdobu vzorce č. 69 lze následně nalézt v různých obměnách v ostatní literatuře. Některé publikace používají i tvary s korekcemi, jako například v publikaci Stock et Watson (2020, str. 206):

$$\hat{\sigma}_{\widehat{\beta}_1}^2 = \frac{1}{n} * \frac{\sum_{i=1}^n \hat{H}_i^2 \hat{u}_i^2}{\left(\frac{1}{n} * \sum_{i=1}^n \hat{H}_i^2\right)^2}, \quad (70)$$

kde $\hat{H}_i^2 = 1 - (\bar{X} / \frac{1}{n} \sum_{i=1}^n X_i^2) X_i$.

Pokud je žádoucí využít obecný maticový tvar, tak ten lze dohledat v publikaci Cipra (2013, str. 89):

$$S_{bb}^W = \frac{T}{T-K} (X'X)^{-1} \left(\sum_{i=1}^T \hat{u}_i^2 \hat{x}_i' x_i \right) (X'X)^{-1}. \quad (71)$$

9.4 Příloha 4

Durbin-Watsonův test

Model funguje na základě jednoduchého vzorce, který dle Dougherty (2007, str. 436) vypadá takto:

$$d = \frac{\sum_{t=2}^T (\hat{e}_t - \hat{e}_{t-1})^2}{\sum_{t=1}^T \hat{e}_t^2}, \quad (72)$$

kde výsledkem tohoto testu je kritická hodnota zasazena na přímku, která obsahuje intervaly DW-testu.

Intervalové rozpětí DW-testu:

$< 0; d_L$) – interval poukazující na pozitivní autokorelaci,

$< d_L; d_U >$ – interval poukazující na neprůkaznost testu,

$(d_U; (4 - d_U))$ - Interval, ve kterém rezidua nevykazují autokorelaci,

$< (4 - d_U); (4 - d_L) >$ -interval poukazující na neprůkaznost testu,

$((4 - d_L); 4 >$ -interval, ve kterém test vykazuje negativní autokorelaci (Dougherty, 2007, str. 436-437).

Hodnoty d_L a d_U jsou tabulkové hodnoty, které lze dohledat na internetu, ve statistických tabulkách anebo jejich hodnoty poskytne přímo ekonometrický výpočetní systém.

Breusch-Godfreyův test

Na rozdíl od DW-testu, tento test vychází z autoregresních modelů vyššího řádu (AR(p), kde $p \geq 1$) (Cipra, 2013, str. 97).

Jelikož vychází z autokorelace vyššího řádu, lze zapsat předpokládaný tvar pro „p“ zpoždění reziduální složky následujícím způsobem (Cipra, 2013, str. 98):

$$\varepsilon_t = \varphi_1 \varepsilon_{t-1} + \varphi_2 \varepsilon_{t-2} + \dots + \varphi_p \varepsilon_{t-p} + u_t \quad (73)$$

Jelikož jde v tomto testu o to, zdali je reziduální složka ovlivněna svými předchozími hodnotami, testuje se, zda je parametr φ_p různý od nuly. Testované hypotézy budou vypadat na základě Cipry (2013, str. 98) takto:

$$H_0: \varphi_1 = \varphi_2 = \dots = \varphi_p = 0,$$

$$H_1: \varphi_p \neq 0, \text{ pro } p \geq 1.$$

Následně lze již zkonstruovat pomocný model, který bude mít tvar na základě Cipry (2013, str. 98):

$$\hat{\varepsilon}_t = \gamma_1 + \gamma_2 x_{t2} + \dots + \gamma_k x_{tk} + \varphi_1 \hat{\varepsilon}_{t-1} + \varphi_2 \hat{\varepsilon}_{t-2} + \dots + \varphi_p \hat{\varepsilon}_{t-p} + u_t. \quad (74)$$

Kritická hodnota využívá LM test (*Langrange multiplier*), ve kterém vystupuje R^2 pomocného modelu (74), a jako porovnávací hodnotu bereme χ^2 na hladině významnosti $(\alpha - 1)$ (Cipra, 2013, str. 98):

$$(T - p) * R^2 \geq \chi^2_{1-\alpha}(p). \quad (75)$$

Uživatel, který testuje autokorelaci, by se následně mohl ptát, kolik je třeba testovat zpoždění. Všeobecně platí, že by uživatel měl testovat podle toho, jakou frekvenci jeho data

mají. Pokud se testují měsíční data, tak je využívána hodnota $p = 12$, pokud čtvrtletní tak $p = 4$ a pokud roční tak $p = 1$ (Cipra, 2013, str. 98).

9.5 Příloha 5

První diference

Nejjednodušším způsobem, jakým se lze pokusit zbavit autokorelace, je využití prvních diferencí. Snahou tohoto řešení je vlastně dodatečná dynamizace modelu. Využívá se tedy kombinace dvou modelů, kdy je první model na původní úrovni „ t “ a druhý je model na úrovni „ $t-1$ “. Příklad je uveden na jednoduché regresi podle Maddala et Lahiri (2009, str. 242):

1. rovnice:

$$y_t = \beta_1 + \beta_2 x_t + u_t, \quad (76)$$

2. rovnice:

$$y_{t-1} = \beta_1 + \beta_2 x_{t-1} + u_{t-1}, \quad (77)$$

(Maddala et Lahiri, 2009, str. 242).

Rozdíl obou rovnic bude tedy následně vypadat tímto způsobem:

$$y_t - y_{t-1} = \beta_2 x_t - \beta_2 x_{t-1} + u_t - u_{t-1}, \quad (78)$$

(Maddala et Lahiri, 2009, str. 242).

Je důležité si povšimnout, že tímto způsobem z modelu mizí konstanta, která se v podobě první diference vyrušila. Maddala et Lahiri (2009, str. 242) uvádí, že konstanta v modelu zůstává pouze v případě, kdy je v původním modelu časová proměnná (trend). Pro ukázkou je opět za pomoci tří rovnic vysvětlen daný proces na základě Maddala et Lahiri (2009, str. 242):

1. rovnice:

$$y_t = \beta_1 + \delta t + \beta_2 x_t + u_t, \quad (79)$$

2. rovnice:

$$y_{t-1} = \beta_1 + \delta(t-1) + \beta_2 x_{t-1} + u_{t-1}. \quad (80)$$

Rozdíl:

$$y_t - y_{t-1} = \delta + \beta_2 x_t - \beta_2 x_{t-1} + u_t - u_{t-1}. \quad (81)$$

Publikace Maddala et Lahiri (2009, str. 242) zároveň upozorňuje, že pokud je porovnáván model s prvními diferencemi a model bez nich, tak je třeba mít na paměti, že

využití R^2 by mohlo být problematické. A to z toho důvodu, že diferencovaná rovnice pracuje s upravenými/jinými regresory. Doporučuje se tedy hodnotit funkce na základě sumy čtverců reziduí (SSR) s tou úpravou, že SSR pro původní rovnici by se měla vynásobit tvarem $\left(\frac{n-k-1}{n-k}\right) * d$ (Maddala et Lahiri, 2009, str. 243).

Využití autoregresního modelu (AR)

V případě použití AR modelu prvního řádu (nejjednodušší případ), je využívána regrese reziduální složky u_t na její (v čase) předchozí hodnotě:

$$u_t = \rho u_{t-1} + \varepsilon. \quad (82)$$

Následně se odhadne parametr ρ a použije se původní rovnice s autokorelací. Tato rovnice je zpožděna o jedno období a vynásobena parametrem ρ . Získá se tak rovnice:

$$\rho y_{t-1} = \beta_0 + \rho \beta_1 x_{1t} + \dots + \rho \beta_k x_{kt} + \rho u_{t-1}. \quad (83)$$

Po spojení (rozdílem) původní funkce a funkce se zpožděním s parametrem ρ je získán následující tvar, který by mohl být bez autokorelace v podobě tvaru pro vícenásobnou regresi:

$$y_t - \rho y_{t-1} = \beta_0(1 - \rho) + \beta_1(x_{1t} - \rho x_{1(t-1)}) + \dots + \beta_k(x_{kt} - \rho x_{k(t-1)}) + \varepsilon, \quad (84)$$

(Dougherty, 2002, str. 440-443).

Publikace Wooldridge (2002, str. 388) uvádí, že tímto způsobem dochází k opomenutí prvního pozorování $t = 1$. Z tohoto důvodu lze do modelu vložit právě i první časové období, ale s korekcí $(1 - \rho^2)^{1/2}$, aby se srovnala variabilita reziduální složky se zbytkem odhadu (více v publikaci Wooldridge, 2002, str. 388). Tímto způsobem nebude autokorelace do modelu opět vložena, protože u_t a ε_t nebudou korelovány.

Tvar pro $t=1$ by pro jednoduchou regresi vypadal podle (Wooldridge, 2002, str. 388) následovně:

$$(1 - \rho^2)^{1/2} y_1 = (1 - \rho^2)^{1/2} \beta_0 + (1 - \rho^2)^{1/2} \beta_1 x_1 + (1 - \rho^2)^{1/2} u_1. \quad (85)$$

Ovšem v případě Cochranovy-Orcutovy metody se $t = 1$ opomíjí. Tento výpočet již není typickou OLS metodou, ale GLS metodou, a toto je její speciální případ. Postup této metody by se dal shrnout do tří bodů. 1. Provede se klasická BMNČ, díky které jsou získána rezidua. 2. Provede se odhad parametru ρ , a ten je vložen do funkce se zpožděnými proměnnými. Za 3. se provede odhad funkce se zpožděním a parametrem ρ . V praxi se využívá opakovaný postup těchto tří kroků, dokud není získán ustálený parametr ρ (Wooldridge, 2002, str. 389).

Splňuje nyní model kritéria pro BLUE? Nesplňuje, model postrádá nestrannost, která je vyražena jako cena za použití parametru reziduální složky ρ . Model je však alespoň konzistentní, a to znamená, že lze využít t a F testy v asymptotické podobě (Wooldridge, 2002, str. 389).

Robustní standardní chyba v případě autokorelace

Další možností je využít úpravu směrodatné chyby na robustní chybu, která se dá využít k testování i poté, co v již odhadnutém modelu pomocí OLS nalezneme autokorelaci. Pro potřebu diplomové práce je uveden pouze postup bez odvození. Nejdříve je provedena regrese klasickou OLS metodou, ze které lze získat reziduální složku \hat{u}_t a odhadnuté parametry (například $\hat{\beta}_1$). Následně jsou získána rezidua z regrese daného regresoru na ostatních regresorech \hat{r}_t . Vynásobením těchto dvou reziduí mezi sebou je získána proměnná \hat{a}_t . Následně je třeba zjistit \hat{v} . Pro nalezení použijeme vzorec:

$$\hat{v} = \sum_{t=1}^n \hat{a}_t^2 + 2 \sum_{h=1}^g [1 - h/(g+1)] \left(\sum_{t=h+1}^g \hat{a}_t \hat{a}_{t-h} \right), \quad (86)$$

pro zopakování významu jednotlivých částí vzorce je uveden význam jednotlivých prvků, $\hat{a}_t = \hat{r}_t \hat{u}_t$, $t = 1, 2, \dots, n$, $h = 1, \dots, g$, (Wooldridge, 2002, str. 396-398).

Pro zvolení vhodného g lze použít více postupů. Nejjednodušším způsobem je určit g podle toho, jaká data jsou využívána. Pro roční data stačí g=1 anebo g=2. Pro data, která jsou čtvrtletní, určíme g=4 anebo g=8. Existují i sofistikovanější metody, ale pro potřeby DP je uvedena pouze jednodušší metoda, a tou je, že g lze také určit jako $n^{1/4}$ s podmínkou, že g by mělo být vždy celočíselné (Wooldridge, 2002, str. 396-398).

A na konec je aplikován vzorec, kterým je získána robustní chyba parametru:

$$se(\hat{\beta}_1) = \left[\frac{se(\hat{\beta}_1)}{\hat{\sigma}} \right] \sqrt{\hat{v}}, \quad (87)$$

kde $se(\hat{\beta}_1)$ je původní chyba parametru z OLS (Wooldridge, 2002, str. 396-398).

S takto upravenou směrodatnou chybou již lze testovat t a F statistické testy. Zároveň je tato úprava častokrát vhodná i pro opravu heteroskedasticity. Pokud má tato metoda tolik výhod, proč se nepoužívá automaticky? Wooldridge (2002, str. 396-398) uvádí, že v mnoha případech u průřezových dat postačí použít heteroskedasticitně robustní chybu, která je uvedena výše a je mnohem častěji řešeným problémem. Zároveň je to kvůli parametru g, který není pro ekonometrické softwary lehký určit, i když nyní toto určení začíná být častěji

zařazováno. A nakonec, pokud se v modelu vyskytuje silná autokorelace, tak nám tato úprava může způsobit statistickou nevýznamnost u většiny parametrů (zvláště u dat s malým počtem pozorování) (Wooldridge, 2002, str. 396-398).

9.6 Příloha 6

Samozřejmě lze zkoumat celkový produkt, ten vyjadřuje množství produkce, kterého na základě výrobních faktorů lze dle Brčáka et al. (2020, str. 130) dosáhnout následovně.

$$TP = Q \quad (88)$$

Dále lze hodnotit průměrnou produkci, která je dána jako poměr mezi celkovou produkcí a daným výrobním faktorem:

$$AP_i = \frac{f(x_1, x_2, \dots, x_i)}{x_i}, \quad (89)$$

průměrná produkce říká, kolik je průměrně získáno celkové produkce za použití výrobního faktoru (Chambers, 1989, str. 18).

V neposlední řadě je také hodnocen mezní produkt („*marginal product*“), který říká, o kolik se změní celková produkce v případě, že se změní výrobní faktor o jednotku, přičemž ostatní výrobní faktory jsou konstantní. Mezní produkt má klesající tendenci. Pokud tedy dojde k určitému počtu použití výrobního faktoru, tak se může stát, že každý další výrobní faktor nám bude snižovat produkci (Chambers, 1989, str. 18; Samuelson et Nordhaus, 2010, str. 108).

Mezní produkt je vypočítán parciální derivací produkční funkce podle zkoumaného produkčního faktoru. Pokud by byl zkoumán například faktor práce, tak by vzorec vypadal následujícím způsobem podle Hořejší et al. (2010, str. 166):

$$MP_L = \frac{\delta Q}{\delta L}. \quad (90)$$

Zároveň se také hodnotí elasticita. Elasticita vyjadřuje hodnocení relativního přírůstku výrobního faktoru oproti relativnímu přírůstku celkového produktu. Lze se setkat se třemi možnými výsledky:

- a) ve chvíli, kdy je elasticita větší než jedna, tak to znamená, že přírůstek výrobního faktoru je poměrově menší, než přírůstek celkového produktu – je získáno více celkového produktu, než kolik přidáváme VF,
- b) pokud se elasticita pohybuje v intervalu (0,1), tak přírůstek výrobního faktoru je větší než přírůstek produkce,

- c) a třetí možností je stav, kdy je elasticita menší než nula – pokud je v tomto případě k produkci přidán výrobní faktor, tak produkce klesá (Brčák et al., 2020, str.140).

9.7 Příloha 7

Tabulka 16: Odhad modelu Just a Popeovy specifikace s použitím fixních efektů

Odhady FEM		1. skupina			2. skupina		
Proměnná	Parametr	P-hodnota		Parametr	P-hodnota		
Teplotní klimatické proměnné	Konstanta	0,5764	0,0452	**	0,2419	0,6004	
	TM2	0,0339	0,066	*	0,1099	<0,0001	***
	TM3	0,0523	0,023	**	0,0086	0,6872	
	TM4	-0,0268	0,3839		0,0347	0,4043	
	TM5	-0,1204	0,0011	***	-0,1976	<0,0001	***
	TM6	-0,1174	0,0006	***	-0,2254	<0,0001	***
	TM7	-0,0527	0,1877		-0,0661	0,1156	
	TM9_1	-0,0571	0,0541	*	-0,0979	0,034	**
	TM10_1	-0,0248	0,5333		0,0330	0,3271	
	TM11_1	-0,0036	0,9224		0,0018	0,9454	
	sq_TM2	0,0018	0,6717		-0,0001	0,9775	
	sq_TM3	-0,0027	0,7161		-0,0109	0,0674	*
	sq_TM4	0,0014	0,9114		-0,0078	0,374	
	sq_TM5	-0,0102	0,4357		-0,0346	0,0031	***
	sq_TM6	-0,0360	0,007	***	-0,0192	0,0343	**
	sq_TM7	-0,0355	0,0031	***	-0,0234	0,0267	**
	sq_TM9_1	-0,0293	0,0228	**	-0,0315	0,0192	**
	sq_TM10_1	-0,0126	0,2764		-0,0346	0,0042	***
sq_TM11_1	-0,0242	0,0716	*	-0,0133	0,1105		
Srážkové klimatické proměnné	SM2	0,0016	0,5463		-0,0027	0,2889	
	SM3	-0,0030	0,1328		-0,0042	0,1113	
	SM4	-0,0035	0,2779		-0,0082	0,0003	***
	SM5	-0,0004	0,8429		-0,0031	0,1838	
	SM6	-0,0044	0,0501	*	-0,0078	<0,0001	***
	SM7	-0,0070	<0,0001	***	-0,0052	0,0016	***
	SM9_1	0,0000	0,9939		0,0023	0,1434	
	SM10_1	-0,0036	0,1282		0,0013	0,5031	
	SM11_1	0,0006	0,7649		0,0005	0,8438	
	sq_SM2	-0,0001	0,0789	*	0,0000	0,5073	
	sq_SM3	0,0000	0,9289		-0,0001	0,403	
	sq_SM4	-0,0001	0,3017		0,0000	0,8956	
	sq_SM5	0,0000	0,4802		0,0000	0,6467	
	sq_SM6	0,0000	0,5285		0,0000	0,219	
	sq_SM7	0,0000	0,1798		0,0000	0,2551	
	sq_SM9_1	0,0001	0,1221		0,0000	0,6452	
	sq_SM10_1	0,0000	0,3499		0,0000	0,429	
	sq_SM11_1	0,0000	0,9656		0,0000	0,6149	
Index cen	P_W_Ratio_1	-1,3458	<0,0001	***	-1,4402	0,0002	***
Trend	t	0,0609	<0,0001	***	0,0473	<0,0001	***
	sq_t	0,0004	0,0452	**	-0,0001	0,6004	
Dummy	DV_1	-0,0026	0,9714		0,0009	0,9937	
	DV_2	-0,6425	<0,0001	***	-0,3716	0,0108	**

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Tabulka 17: Odhad Just a Popeovy specifikace s použitím fixních efektů – 3. skupina

Odhady FEM		3.skupina		
Proměnná		Parametr	P-hodnota	
	Konstanta	0,2465	0,4686	
Teplotní klimatické proměnné	TM2	0,0219	0,331	
	TM3	0,0866	0,0052	***
	TM4	-0,0758	0,0195	**
	TM5	-0,0909	0,0075	***
	TM6	-0,1412	<0,0001	***
	TM7	-0,0522	0,0948	*
	TM9_1	-0,0681	0,0972	*
	TM10_1	0,0068	0,8529	
	TM11_1	-0,0092	0,8404	
	sq_TM2	-0,0012	0,8569	
	sq_TM3	0,0009	0,9124	
	sq_TM4	0,0158	0,2244	
	sq_TM5	-0,0188	0,2871	
	sq_TM6	-0,0197	0,2335	
	sq_TM7	-0,0327	0,0094	***
	sq_TM9_1	-0,0266	0,1615	
	sq_TM10_1	-0,0342	0,018	**
	sq_TM11_1	-0,0250	0,0384	**
Srážkové klimatické proměnné	SM2	0,0016	0,5844	
	SM3	0,0015	0,6414	
	SM4	0,0015	0,6021	
	SM5	0,0043	0,2044	
	SM6	-0,0028	0,3359	
	SM7	-0,0062	<0,0001	***
	SM9_1	0,0006	0,7547	
	SM10_1	-0,0007	0,8312	
	SM11_1	0,0046	0,1587	
	sq_SM2	-0,0002	0,1518	
	sq_SM3	0,0000	0,7035	
	sq_SM4	0,0000	0,9067	
	sq_SM5	0,0000	0,3924	
	sq_SM6	0,0000	0,261	
	sq_SM7	0,0000	0,5225	
	sq_SM9_1	0,0002	0,0012	***
	sq_SM10_1	0,0000	0,8679	
	sq_SM11_1	0,0000	0,697	
Index cen	P_W_Ratio_1	-1,4516	<0,0001	***
Trend	t	0,0566	<0,0001	***
	sq_t	0,0006	0,0059	***
Dummy	DV_1	-0,2255	0,0023	***
	DV_2	-0,7168	<0,0001	***

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl

Tabulka 18: Adjustovaný koeficient determinace Just a Popeovy specifikace

Hodnotící kritérium	1. skupina	2. skupina	3. skupina
Adj. R²	0,9083	0,8803	0,8845
Směrodatná chyba regrese	0,3618	0,4008	0,4004

Zdroj: vlastní zpracování na základě výsledků ze softwaru Gretl