

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra ekonomiky



Diplomová práce

**Analýza determinant zahraničního obchodu s vybranými
zemědělskými komoditami**

Bc. Vojtěch Korec

© 2021 ČZU v Praze

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Vojtěch Korec

Ekonomika a management
Provoz a ekonomika

Název práce

Analýza determinant zahraničního obchodu s vybranými zemědělskými komoditami

Název anglicky

Analysis of determinants of foreign trade with chosen agricultural commodities

Cíle práce

Cílem práce je najít a posoudit vliv podstatných ekonomických faktorů působících na zahraniční obchod s vybranými zemědělskými komoditami.

Dílčím cílem je:

1. určit strukturu zahraničního obchodu
2. určit vývojové tendence na základě historických dat
3. prognózovat budoucí vývoj zahraničního obchodu
4. srovnání kvality prognóz odvozených z ekonometrických modelů a predikcí vícevrstevných neuronových sítí

Metodika

V teoretické části budou kompilovány dostupné publikace a vědecké články týkající se agrárního zahraničního obchodu, jeho role, vývoje a struktury. Ve vlastní práci bude využito ekonometrických modelů a mechanismu vícevrstevné neuronové sítě pro modelování závislosti a aplikaci v oblasti prognostických činností.

Doporučený rozsah práce

70 – 80 stran textu.

Klíčová slova

ekonometrický model, vícevrstvá neuronová síť, predikce, prognóza, pšenice, mléko, hovězí maso, agrární zahraniční obchod

Doporučené zdroje informací

HUŠEK, R. – VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE. *Aplikovaná ekonometrie : teorie a praxe*. Praha: Oeconomica, 2009. ISBN 978-80-245-1623-3.

SMUTKA, Luboš et al. *World agricultural production, consumption and trade development – selected problems: (position of the European Union in the global agricultural market)*. 1st print. Prague: Powerprint, 2012. 213 s. ISBN 978-80-87415-45-0.

SMUTKA, L. *Vývoj agrárního zahraničního obchodu ČR v evropském a světovém kontextu*. Praha: Powerprint, 2011. ISBN 978-80-87415-22-1.

SOUKUP, A. *Mezinárodní ekonomie*. Praha: Eurolex Bohemia, 2005. ISBN 80-86861-82-1.

SVATOŠ, Miroslav a kol. *Ekonomika agrárního sektoru: (vybraná témata)*. Vyd. 1. V Praze: Česká zemědělská univerzita, Provozně ekonomická fakulta, 2008. 170 s. ISBN 978-80-213-1846-5.

TUČKOVÁ, Jana. *Úvod do teorie a aplikací umělých neuronových sítí*. Vyd. 1. Praha: Vydavatelství ČVUT, 2003. 103 s. ISBN 80-01-02800-3.

Předběžný termín obhajoby

2020/21 LS – PEF

Vedoucí práce

Ing. Pavlína Hálová, Ph.D.

Garantující pracoviště

Katedra ekonomiky

Elektronicky schváleno dne 10. 3. 2020

prof. Ing. Miroslav Svatoš, CSc.

Vedoucí katedry

Elektronicky schváleno dne 11. 3. 2020

Ing. Martin Pelikán, Ph.D.

Děkan

V Praze dne 31. 03. 2021

Čestné prohlášení

Prohlašuji, že svou diplomovou práci "Analýza determinant zahraničního obchodu s vybranými zemědělskými komoditami" 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. 2021

Poděkování

Rád bych touto cestou poděkoval Ing. Pavlíně Hálové, Ph. D. za vstřícnost, trpělivost a cenné rady při tvorbě této práce.

Analýza determinant zahraničního obchodu s vybranými zemědělskými komoditami

Abstrakt

Diplomová práce se zabývá analýzou determinant vývozu pšenice, hovězího masa a mléka z ČR. V případě vývozu pšenice byly identifikovány determinanty průběh devizových intervencí ČNB, světová cena pšenice a vývoz pšenice v několika předchozích měsících. V případě vývozu hovězího masa se jednalo o vývoz hovězího masa v předchozím měsíci, vývoz živého skotu a průměrnou cenu hovězího masa na trhu EU. V případě vývozu mléka se jednalo o vývoz mléka v předchozím měsíci, produkci mléka a průměrnou cenu syrového mléka na trhu EU. Při volbě vhodné funkční formy modelu bylo rozhodováno mezi formou lineární a mocninnou. Vývoj vývozu pšenice a mléka byl modelován pomocí lineárního modelu a vývoj vývozu hovězího masa pomocí mocninného modelu. Největší vliv na vývoz analyzovaných komodit měl vývoz těchto komodit v předchozích obdobích, což potvrdilo předpoklad silné role setrvačnosti v jejich vývoji, o níž je v práci blíže pojednáno. Na všechny modely byla úspěšně aplikována ekonomická, statistická a ekonometrická verifikace. Jako podkladová data sloužily měsíční nestacionární časové řady a analýzou reziduí byla potvrzena pravá regrese. Pomocí verifikovaných modelů vývozu pšenice a vývozu hovězího masa byla provedena bodová prognóza ex-post na měsíce prvních tří čtvrtletí roku 2020. Průměrná přesnost prognóz vývozu pšenice byla 76,4% a vývozu hovězího 85,63%. Jako alternativní přístup k modelování vztahu mezi proměnnými byla zvolena technika třívrstvé neuronové sítě, jež ve všech třech případech vystihla tento vztah lépe, což je způsobeno výraznou schopností neuronové sítě vystihnout nelineární aspekty vztahů proměnných. Průměrná přesnost predikcí vývozu pšenice a hovězího masa na období prvních tří čtvrtletí roku 2020 byla 81,58% resp. 85,60%. Pomocí techniky třívrstvé neuronové sítě bylo v porovnání s ekonometrickými modely dosaženo lepších či srovnatelných výsledků a lze je tedy považovat za vhodný doplněk ekonometrických modelů.

Klíčová slova: ekonometrický model, vícevrstvá neuronová síť, vývoz pšenice, vývoz hovězího masa, vývoz mléka, zahraniční agrární obchod, predikce, prognóza

Analysis of determinants of foreign trade with chosen agriculture commodities

Abstract

The diploma thesis deals with the analysis of determinants of wheat, beef and milk exports from the Czech Republic. In the case of wheat exports, the determinants identified were the course of the CNB's foreign exchange interventions, the world price of wheat and wheat exports in the previous few months. In the case of beef exports, these were beef exports in the previous month, live cattle exports and the average price of beef on the EU market. In the case of milk exports, these were milk exports in the previous month, milk production and the average price of raw milk on the EU market. When choosing a suitable functional form of the model, a decision was made between the linear and the power form. The development of wheat and milk exports was modeled using a linear model and the development of beef exports using a power model. The greatest influence on the export of the analyzed commodities had the export of these commodities in previous periods, which confirmed the assumption of a strong role of inertia in their development, which is discussed in more detail in the work. Economic, statistical and econometric verification was successfully applied to all models. Monthly non-stationary time series served as background data and true regression was confirmed by residue analysis. Using verified models of wheat exports and beef exports, an ex-post point forecast for the months of the first three quarters of 2020 was performed. The average accuracy of wheat export forecasts was 76.4% and the accuracy of beef export forecasts was 85.63%. As an alternative approach to modeling the relationship between variables, the technique of three-layer neural network was chosen, which in all three cases captured this relationship better, which is due to the strong ability of the neural network to capture nonlinear aspects of variable relationships. The average accuracy of wheat and beef export forecasts for the first three quarters of 2020 was 81.58% and 85.60%, respectively. Using the three-layer neural network technique, better or comparable results were achieved in comparison with econometric models and can therefore be considered a suitable complement to econometric models.

Keywords: econometric model, multilayer neural network, wheat exports, beef exports, milk exports, foreign agrarian trade, prediction, prognosis

Obsah

1. Úvod	11
2. Cíl práce	13
3. Metodika.....	14
3.1 Ekonomický a ekonometrický model	14
3.1.1 Podkladová data – Časové řady	14
3.1.2 Předpoklady a odhad LRM	15
3.1.3 Porovnání kvality modelů lineární a log-lineární regrese	16
3.1.4 Verifikace ekonometrického modelu	17
3.1.5 Aplikace modelu	20
3.1.6 Software Gretl	21
3.2 Vícevrstvá neuronová síť	22
3.2.1 Neuron	22
3.2.2 Plně propojená vrstva	23
3.2.3 Topologie vícevrstvé neuronové sítě.....	24
3.2.4 Učení neuronové sítě	25
3.2.5 Obecný postup použití vícevrstvé neuronové sítě.....	26
3.2.6 Programovací jazyk Python – program neuronové sítě	27
4. Teoretická východiska.....	33
4.1 Definování zahraničního obchodu.....	33
4.2 Důležitost zahraničního obchodu v ekonomice země	34
4.3 Postavení zahraničního obchodu v ekonomice země	35
4.4 Úloha zahraničního obchodu	36
4.4.1 Zahraniční obchod jako činitel vnitřní a vnější rovnováhy.....	36
4.4.2 Zahraniční obchod jako činitel ekonomického růstu	37
4.4.3 Zahraniční obchod jako překážka ekonomického růstu	37
4.5 Činitele ovlivňující vnější ekonomické vztahy	39
4.6 Kvantifikace role zahraničního obchodu	40
4.7 Postavení agrárního sektoru ve světové ekonomice	41
4.8 Vliv globalizace na světový zemědělský obchod	42
4.9 Společná zemědělská politika Evropské unie.....	43
4.10 Zahraniční obchod České republiky	46
4.10.1 Historický vývoj zahraničního obchodu ČR před vstupem do EU.	46
4.10.2 Vývoj zahraničního obchodu ČR po vstupu do EU	47

4.10.3 Historický vývoj agrárního zahraničního obchodu ČR před vstupem do EU	47
4.10.4 Vývoj agrárního zahraničního obchodu ČR po vstupu do EU	48
4.10.5 Teritoriální struktura českého AZO před a po vstupu ČR do EU	49
4.10.6 Komoditní struktura českého AZO před a po vstupu ČR do EU	50
4.10.7 Současný vývoj a struktura agrárního zahraničního obchodu ČR	51
5. Vlastní práce.....	54
5.1 Analýza vybraných determinantů vývozu pšenice z ČR	54
5.1.1 Jednorovnicový ekonometrický model vývozu pšenice z ČR.....	54
5.1.1.1 Ekonomické předpoklady.....	55
5.1.1.2 Testování stacionarity časových řad	56
5.1.1.3 Specifikace a kvantifikace modelu.....	57
5.1.1.4 Verifikace modelu	59
5.1.1.5 Aplikace modelu v podobě strukturální analýzy	63
5.1.1.6. Bodová prognóza ex-post.....	64
5.2 Analýza vybraných determinantů vývozu hovězího masa z ČR	66
5.2.1 Jednorovnicový ekonometrický model vývozu hovězího masa z ČR.....	66
5.2.1.1 Ekonomické předpoklady.....	66
5.2.1.2 Testování stacionarity časových řad	67
5.2.1.3 Specifikace a kvantifikace modelu.....	68
5.2.1.4 Verifikace modelu	72
5.2.1.5 Aplikace modelu v podobě strukturální analýzy	75
5.2.1.6 Bodová prognóza ex-post.....	75
5.3 Analýza vybraných determinantů vývozu mléka z ČR	78
5.3.1 Jednorovnicový ekonometrický model vývozu mléka z ČR.....	78
5.3.1.1 Ekonomické předpoklady.....	78
5.3.1.2 Testování stacionarity časových řad	79
5.3.1.3 Specifikace a kvantifikace modelu.....	80
5.3.1.4 Verifikace modelu	84
5.3.1.5 Aplikace modelu v podobě strukturální analýzy	86
5.4 Neuronová síť jako alternativa pro modelování závislosti proměnných	87
5.4.1 Modelování vztahu vývozu pšenice z ČR a jeho determinantů pomocí NS	89
5.4.1.1 Predikce pomocí neuronové sítě	91
5.4.2 Modelování vztahu vývozu hovězího masa z ČR a jeho determinantů pomocí NS	94
5.4.2.1 Predikce pomocí neuronové sítě	96
5.4.3 Modelování vztahu vývozu mléka z ČR a jeho determinantů pomocí NS	98

5.4.4 Porovnání ekonometrických modelů a třívrstvé neuronové sítě	99
6. Závěr.....	101
Seznam literatury.....	103
Přílohy	107
Příloha č.1 (Data zahraničního obchodu)	107
Příloha č.2 (Podkladová data).....	109
Příloha č.3 (Ekonometrická verifikace modelů – výstupy Gretl).....	109
Příloha č.4 (Neuronová síť – program, serializovaná NS, predikční modul NS).....	112
Seznam obrázků	112
Seznam tabulek	113
Seznam grafů.....	114

1. Úvod

Tématem této práce je identifikace a analýza determinant zahraničního obchodu České republiky s vybranými zemědělskými komoditami, konkrétně vývozu pšenice, mléka a hovězího masa. V případě produkce pšenice a mléka je Česká republika soběstačná, ale zároveň tato produkce nedokáže pokrýt tuzemskou spotřebu z důvodu vývozu její značné části ke zpracování do zahraničí, jež je motivován obchodními a komerčními důvody. Realita je tedy taková, že je vyvážena surovina, jež je poté dovážena zpět ve formě hotových pekárenských a mléčných výrobků. Dochází tedy k jevu, kdy je vyvážena surovina a dovážena práce, tedy přidaná hodnota, což staví Českou republiku v rámci Evropského trhu do role méně rozvinuté země. Růst vývozu hovězího masa má v posledních 20 letech znatelně rostoucí trend. Tato situace je nevýhodná jak z pohledu národního hospodářství, tak z pohledu spotřebitelů, jelikož např. čeští chovatelé dojného a masného skotu si drží vysokou úroveň a o česká masná zvířata a české mléko je ve světě zájem, jak pro jeho vysoké výživové parametry, tak pro jeho zdravotní nezávadnost.

Pro potřeby ekonometrické analýzy byly zvoleny jako podkladová data měsíční časové řady z let 2005-2019. Měsíční periodicitu byla zvolena z důvodu možné detekce krátkodobé setrvačnosti vývoje ukazatelů a možnosti využití techniky vícevrstvé neuronové sítě vyžadující větší počet záznamů, jež bude v práci použita vedle standardních nástrojů ekonometrické analýzy pro modelování závislosti a budoucího vývoje vývozu jednotlivých komodit. Hlavní i dílčí cíl této práce je nadefinován v kapitole Cíl práce.

Metodika obsahuje popis nástrojů ekonometrické analýzy, které byly aplikovány prostřednictvím softwaru Gretl. Dále je zde popsána technika vícevrstvé neuronové sítě a postup jejího použití. Závěr této kapitoly tvoří přehled nástrojů programovacího jazyka Python, které byly použity pro sestavení neuronové sítě.

Teoretická část se zabývá úlohou zahraničního obchodu v ekonomice země, jeho vlivem na ekonomický růst, jeho možnou kvantifikaci a činiteli majícími vliv na vnější ekonomické vztahy. Popisuje postavení agrárního sektoru ve světové ekonomice a vliv globalizace na světový zemědělský obchod. Kapitola se věnuje také principům společné zemědělské politiky EU, jejímu financování a dopadům na členské státy. Závěr kapitoly je věnován vývoji českého agrárního zahraničního obchodu, před a po vstupu do EU a to především s ohledem na jeho komoditní a teritoriální strukturu.

V rámci kapitoly Vlastní práce je provedena ekonometrická analýza vývoje vývozu jednotlivých komodit v závislosti na vybraných determinantech, náležitá ekonomická interpretace výstupů, verifikace získaných modelů a ověření jejich prognostických vlastností. Jako alternativní přístup k modelování závislosti a budoucího vývoje je použita technika vícevrstvé neuronové sítě.

2. Cíl práce

Cílem této diplomové práce je identifikovat determinanty vývozu vybraných komodit zahraničního obchodu, modelovat jejich vztah pomocí nástrojů ekonometrické analýzy, kvantifikovat vliv jednotlivých determinantů a verifikovat výsledné ekonometrické modely. Mezi dílčí cíle patří určení role, vývojových tendencí a struktury zahraničního agrárního obchodu, provedení prognóz vývozu vybraných komodit, srovnání získaných ekonometrických modelů s technikou vícevrstevných neuronových sítí v oblasti modelování závislosti a budoucího vývoje a zhodnocení možnosti použití vícevrstvé neuronové sítě jako alternativy k získaným ekonometrickým modelům.

3. Metodika

3.1 Ekonomický a ekonometrický model

Ekonomický model (3.1) je odvozen z ekonomické teorie a je zjednodušenou abstrakcí reálného světa. Ekonomický model, tzn. vztahy mezi ekonomickými proměnnými, může být vyjádřen slovně, graficky či algebraicky. Definovaný ekonomický model vyjadřuje deterministický vztah mezi vysvětlující a vysvětlovanou proměnnou a slouží k porovnání ekonomické teorie s realitou, resp. se statistickými daty. Při porovnání ekonomického modelu se statistickými daty je tohoto deterministického vztahu málokdy dosaženo, z důvodu pravděpodobností povahy ekonomických dat. Z tohoto důvodu musí být ekonomický model modifikován tak, aby bral v potaz pravděpodobnostní povahu procesu generování ekonomických dat. Ekonometrický model je získán určením funkční formy modelu a přidáním náhodné složky, jež reprezentuje stochastickou povahu modelovaného vztahu (Čechura et al., 2013).

$$y_t = f(x_1, x_2, \dots, x_k) \quad (3.1)$$

3.1.1 Podkladová data – Časové řady

Časovou řadou je posloupnost hodnot ukazatelů, jež jsou měřeny v určitých časových intervalech. Tyto intervaly bývají zpravidla rovnoměrné a lze je tedy zapsat následujícím způsobem:

$$y_1, y_2, \dots, y_n \text{ neboli } y_t, t = 1, \dots, n,$$

kde y zastupuje analyzovaný ukazatel a t reprezentuje časovou proměnnou s celkovým počtem porovnání n .

Podle periodicity, s jakou jsou hodnoty ukazatelů sledovány, rozlišujeme krátkodobé časové řady s periodicitou kratší jak 1 rok (nejčastěji 1 měsíc) a dlouhodobé časové řady s periodicitou jeden rok či delší. Pro zobrazení časových řad slouží spojnicové grafy, jež zaznamenávají na vodorovné ose časovou proměnnou a na svislé ose zobrazují hodnoty ukazatele časové řady y_t (Kozák, Arlt, Hindls, 1994).

Nestacionarita a stacionarita časových řad

Ze statistického hlediska podléhá chování časové řady změnám v průměru či variabilitě (nestacionární časová řada) anebo je stále stejné (stacionární časová řada). U stacionární řady nejsme schopni odlišit, na základě např. průměru či rozptylu, jeden úsek časové řady od druhého. U nestacionární časové řady se např. průměr či rozptyl signifikantně liší v jednotlivých úsecích časové řady a tedy můžeme říci, že časová řada vykazuje změny v chování. Pro testování stacionarity časových řad lze použít např. rozšířený Dickey-Fuller test (ADF test) (Hančlová, 2012).

Hlavním důsledkem nestacionarity časových řad je zdánlivá regrese, jež zvyšuje hodnotu koeficientu determinace a t-statistiky, což má za následek nesprávnou specifikaci modelu. Přestože jsou časové řady nestacionární, může být kombinace těchto řad stacionární. Takováto dlouhodobá rovnováha několika časových řad se nazývá kointegrace. Kointegrované časové řady mohou zbavit ekonometrické modelování problému zdánlivé regrese. Jako test kointegrace časových řad se používá např. rozšířený Dickey-Fuller test (ADF test), jenž se aplikuje na rezidua časové řady a funguje jako metoda pro odlišení mezi pravou a zdánlivou regresí (Arlt, Arltová, 2009)

3.1.2 Předpoklady a odhad LRM

Odhadnuté parametry ekonometrického modelu mají požadované vlastnosti, tj. jsou nejlepší, nestranné a konzistentní, jestliže jsou splněny tyto předpoklady:

- Specifikační požadavky – zahrnují neopomenutí podstatné vysvětlující proměnné, vypuštění irelevantních vysvětlujících proměnných, volba správné funkční formy modelu, stabilita odhadnutých parametrů a časová invariantnost a respektování simultánnosti vztahů mezi proměnnými.
- Nulový průměr náhodné složky u_t
- Homoskedasticita
- Nepřítomnost autokorelace reziduí
- Nezávisle proměnné jsou nenáhodné a fixní v opakujících se souborech
- Neexistence perfektní multikolinearity
- Normální rozdělení náhodné složky

K odhadu parametrů lineárního regresního modelu se nejčastěji využívá běžná metoda nejmenších čtverců (BMNČ), jejíž podstatou je nalezení parametrů, které minimalizují součet

čtverců odchylek teoretických hodnot vysvětlované proměnné od jejich skutečných hodnot. Tato metoda poskytuje nejlepší, nestranné a konzistentní odhady parametrů modelu za předpokladu, že jsou splněny výše uvedené předpoklady a kritérium (3.2). (Čechura et al., 2013).

$$\min \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (3.2)$$

Vztah (3.3) pro odhad parametrů modelu pomocí BMNČ :

$$\gamma = (X^T X)^{-1} X^T y \quad , \quad (3.3)$$

kde

γ vektor ($k \cdot 1$) odhadovaných parametrů

X matice o rozměru $n \cdot k$, která obsahuje napozorované hodnoty „ k “ vysvětlujících proměnných

y vektor ($n \cdot 1$), který obsahuje napozorované hodnoty vysvětlované proměnné

3.1.3 Porovnání kvality modelů lineární a log-lineární regrese

Při rozhodování o kvalitě dvou regresních modelů s odlišnými vysvětlovanými proměnnými jsou rozptyly závisle proměnné zcela odlišné a tedy nesrovnatelné. V tomto případě nelze použít korigovaný koeficient determinace, jenž lze použít pro srovnání kvality regresních modelů se stejnou závislou proměnnou. V případě rozhodování, zda použít lineární či log-lineární regresi, rozhodujeme mezi modely:

$$Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_{ki} X_{ki} + \varepsilon_i,$$

$$\ln(Y_i) = \alpha + \beta_1 \ln(X_{1i}) + \dots + \beta_k \ln(X_{ki}) + \varepsilon_i$$

V první lineární regresi je vysvětlovaná proměnná nelogaritmovaná, v případě log-lineární regrese naopak logaritmována je. Vysvětlované proměnné nejsou přímo srovnatelné. Tento problém, lze vyřešit pomocí použití nové proměnné:

$$Y_i^* = \frac{Y_i}{\hat{Y}}, \quad (3.4)$$

kde \hat{Y} je geometrický průměr nelogaritmované závisle proměnné (tzn. $\hat{Y} = (Y_1 \cdot Y_2 \cdot \dots \cdot Y_N)^{\frac{1}{N}}$).

V případě použití této nové proměnné v lineární a log-lineární regresi, lze tyto dvě vysvětlované

proměnné srovnávat. V případě, že platí $SSR_{LIN} > SSR_{LOG}$, tedy že lineární regrese má větší součet čtverců reziduí, má testovací statistika pro testování nulové hypotézy, že lineární a log-lineární regrese vyrovnávají data stejně, podobu:

$$LL_1 = \frac{1}{2N} \ln \left(\frac{SSR_{LIN}}{SSR_{LOG}} \right) \quad (3.5).$$

V případě, že je hodnota $LL_1 > 3.841$ (Rozdělení Chí-kvadrát: kritická hodnota na hladině významnosti 5% pro případ jednostranného testu), zamítáme nulovou hypotézu, ve prospěch alternativní hypotézy, že log-lineární model vyrovnává data lépe. V případě, že platí $SSR_{LOG} > SSR_{LIN}$, tedy že log-lineární regrese má větší součet čtverců reziduí, má testovací statistika pro testování nulové hypotézy, že lineární a log-lineární regrese vyrovnávají data stejně, podobu:

$$LL_2 = \frac{1}{2N} \ln \left(\frac{SSR_{LOG}}{SSR_{LIN}} \right) \quad (3.6).$$

V případě, že je hodnota $LL_2 > 3.481$, zamítáme nulovou hypotézu, ve prospěch alternativní hypotézy, v tomto případě s propozicí, že lineární regrese vyrovnává data lépe. V obou případech ((3.5) a (3.6)) platí, že pokud je hodnota LL_1 , resp. LL_2 menší jak 3.481, nezamítáme nulovou hypotézu a lze tedy s modely lineární a log-lineární regrese pracovat zcela rovnocenně.

3.1.4 Verifikace ekonometrického modelu

Odhadnutý ekonometrický model je nutné před jeho aplikací verifikovat, což znamená ověřit, zda jsou odhadnuté parametry v souladu s výchozími ekonomickými hypotézami a zda mají požadované statistické charakteristiky. Verifikaci odhadnutého ekonometrického modelu lze rozdělit do tří kroků:

- Ekonomická verifikace
- Statistická verifikace
- Ekonometrická verifikace

Ekonomická verifikace

V rámci ekonomické verifikace je posuzován především směr a intenzita působení vysvětlujících proměnných na vysvětlovanou proměnnou. Je ověřována správnost znamének a velikost číselných hodnot odhadnutých parametrů. Nesoulad odhadnutých parametrů ekonometrického modelu s ekonomickými předpoklady indikuje nesprávnou specifikaci modelu.

Statistická verifikace

Statistická verifikace je používána k posouzení statistické významnosti odhadnutých parametrů i celého modelu. V rámci statistické verifikace se hodnotí:

- Shoda odhadnutého modelu s daty
- Statistická významnost odhadnutých parametrů

Kvalita odhadnuté rovnice se v případě lineární funkce posuzuje pomocí koeficientu vícenásobné determinace R^2 (3.7), jež je založen na rozkladu celkového rozptylu (3.7) vysvětlované proměnné (S_y^2) na rozptyl teoretický ($S_{\hat{y}}^2$) a reziduální (S_u^2).

$$S_y^2 = S_{\hat{y}}^2 + S_u^2 \quad (3.7)$$

$$R^2 = 1 - \frac{S_u^2}{S_y^2} \quad (3.8)$$

Koeficient determinace se obvykle vyjadřuje v % a udává, z kolika % jsou změny závisle proměnné vysvětlené změnami nezávisle proměnných. Jelikož má R^2 tendenci s přidáním dalších vysvětlujících proměnných růst, je často používán korigovaný koeficient vícenásobné determinace (3.9), kde p je počet odhadovaných parametrů v dané rovnici a n je délka časové řady (Čechura et al., 2013).

$$R_{UPR}^2 = 1 - (1 - R^2) \frac{n-1}{n-p} \quad (3.9)$$

Statistickou významnost modelu jako celku lze testovat pomocí F-testu, v jehož rámci se porovnává F poměr s tabulkovou hodnotou F^* . Jestliže je hodnota F poměru větší než tabulková hodnota na zvolené hladině významnosti a při daném počtu stupňů volnosti, je možno zamítnout nulovou hypotézu, jejíž propozice je statistická nevýznamnost R^2 , ve prospěch alternativní hypotézy, tedy že shoda odhadnutého modelu s daty je statisticky významná. V případě nelineární funkce se k měření těsnosti závislosti používá index determinace I^2 , jeho výpočet i interpretace jsou však shodné s R^2 (Čechura et al., 2013).

Statistická významnost jednotlivých strukturálních parametrů je hodnocena pomocí t-testu. Toto hodnocení probíhá pomocí porovnání vypočtené t-hodnoty s tabulkovou hodnotou t-testu při zvolené hladině významnosti a příslušnému počtu stupňů volnosti t_α . V případě, že $t > t_\alpha$, zamítáme nulovou hypotézu, jejíž propozice je statistická nevýznamnost parametru a lze tedy říci, že vysvětlující proměnná je z hlediska svého vlivu na vysvětlovanou proměnnou na hladině významnosti α a při $n-p$ stupních volnosti významnou proměnnou.

Ekonometrická verifikace

V rámci ekonometrické verifikace se ověřují předpoklady ekonometrického modelu nutné k jeho úspěšné aplikaci. Mezi nejdůležitější ekonometrická kritéria patří testování stupně multikolinearity, autokorelace náhodných složek, normality reziduí, heteroskedasticity a vhodnosti funkční formy modelu.

Multikolinearita vyjadřuje závislost mezi dvěma či více vysvětlujícími proměnnými v rovnici. Při výskytu vysoké multikolinearity není možné odlišit vlivy jednotlivých vysvětlujících proměnných na vysvětlovanou proměnnou a není umožněno dosáhnout přesného odhadu parametrů vysvětlujících proměnných, které multikolinearitu zapříčiňují, což je důvod, proč je vysoká multikolinearita nežádoucí. K vysoké multikolinearitě dochází, pokud hodnoty vysvětlujících proměnných disponují nízkou variabilitou. K perfektní multikolinearitě dochází, pokud je závislost mezi dvěma či více vysvětlujícími proměnnými deterministická. K detekci multikolinearity lze použít např. metodu VIF¹ (3.10), která měří nakolik je rozptyl odhadovaných strukturálních parametrů zvětšen oproti situaci, kdy by byly vysvětlující proměnné vzájemně nezávislé.

$$VIF_i = \frac{1}{1-r_i^2} \quad (3.10)$$

Parametr r_i^2 je koeficient mnohonásobné korelace, jenž lze vypočítat jako odmocninu koeficientu determinace regresního modelu pro závislost konkrétní vysvětlující proměnné na ostatních vysvětlujících proměnných. Orientačním pravidlem je, že hodnoty $VIF > 4$ mohou být problematické a hodnoty > 10 mohou závažně ovlivnit výsledky ekonometrického modelování (Fiala, 2008).

Pro detekci autokorelace lze použít Breuch-Godfrey test pro autokorelaci vyšších řádů. Jedná se o případy, kdy pracujeme s vyššími než druhými zpožděními proměnných. Propozice nulové hypotézy je, že data nejsou autokorelací reziduí zasažena. Pokud je p-hodnota testu nižší než zvolená hladina významnosti, nulová hypotéza se zamítá ve prospěch alternativní hypotézy, že data jsou autokorelací reziduí zasažena (Hančlová, 2012).

K testování normality reziduí lze použít Doornik-Hansenův test, který pomocí koeficientů šikmosti a špičatosti testuje nulovou hypotézu o normalitě pravděpodobnostního rozdělení reziduí. V případě že je hodnota p-hodnoty nižší než zvolená hladina významnosti,

¹ Variance inflation factor

nulová hypotéza se zamítá ve prospěch alternativní hypotézy, že rezidua nejsou normálně rozdělena (Hančlová, 2012).

K testování heteroskedasticity, jevu kdy se rozptyl náhodných složek liší v rámci jednotlivých pozorování, lze použít Breusch-Pagan test, jenž testuje nulovou hypotézu, že rozptyl náhodných složek se v rámci jednotlivých pozorování neliší (homoskedasticita). V případě, že je p-hodnota testu nižší než zvolená hladina významnosti, nulová hypotéza se zamítá ve prospěch alternativní hypotézy, tedy heteroskedasticity náhodné složky (Hančlová, 2012).

Pro ověření vhodné specifikace modelu lze použít Ramsey RESET test. Mezi hlavní specifikační chyby patří vynechání důležité vysvětlující proměnné, zahrnutí nepodstatných vysvětlujících proměnných a volba nevhodné funkční formy modelu. RESET test ověřuje nulovou hypotézu, že model byl vhodně specifikován. V případě, že je p-hodnota testu nižší než zvolená hladina významnosti, nulová hypotéza se zamítá ve prospěch alternativní hypotézy, tedy že model nebyl vhodně specifikován (Hančlová, 2012).

3.1.5 Aplikace modelu

Výsledkem ekonomického, statistického a ekonometrického ověření modelu je rozhodnutí o možnosti jeho praktického využití či jeho zamítnutí. Přijatelný ekonometrický model lze využít v oblasti, pro kterou byl odvozen. Aplikaci ekonometrického modelu lze rozdělit do tří skupin: prognostické využití ekonometrického modelu, strukturální analýza a simulace efektů a výsledků různých scénářů (Čechura et al., 2013).

Koeficienty pružnosti

Při aplikaci modelu se často využívají koeficienty pružnosti (elasticity). Oproti strukturálnímu parametru, který vyjadřuje působení vysvětlující proměnné na vysvětlovanou proměnnou v jednotkách, v jakých jsou obě proměnné uváděny, koeficient pružnosti umožňuje vyjádřit toto působení v procentech. Toto relativní vyjádření umožňuje srovnat intenzitu působení jednotlivých vysvětlujících proměnných, bez ohledu na odlišné jednotky proměnných. Koeficient pružnosti lze vypočítat dle výrazu (3.11).

$$E = \frac{\partial y}{\partial x_i} \frac{x_i}{\hat{y}} \quad (3.11)$$

Koeficient pružnosti je podílem procentuální změny vysvětlované proměnné a procentuální změny i-té vysvětlující proměnné (Čechura et al., 2013).

Bodová prognóza ex-post

Bodová prognóza ex-post má negativní prognostický horizont. Jedná se o prognózu již známých hodnot a slouží k ověření prognostických vlastností modelu. Přesnost prognóz lze měřit pomocí statistiky MSE (střední kvadratická chyba) (3.12) nebo pomocí statistiky RMSE (3.13) jenž je vypočtena jako odmocnina MSE.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.12)$$

$$RMSE = \sqrt{MSE} \quad (3.13)$$

3.1.6 Software Gretl


Pro ekonometrickou analýzu v této práci byl používán software Gretl², jenž se ovládá pomocí grafického rozhraní a jehož instalační balíček je volně dostupný na internetové adrese www.gretl.sourceforge.net.

² Gretl - Gnu Regression, Econometrics and Time-series Library

3.2 Vícevrstvá neuronová síť

3.2.1 Neuron

Na obrázku č. 2 je znázorněn neuron, jenž je základním stavebním kamenem neuronové sítě. Každý neuron má vstupy x_1 až x_n opatřené vahami w_1 až w_n .



zdroj: vlastní

Vnitřní potenciál neuronu reprezentuje vážená suma vstupních hodnot, již lze vyjádřit pomocí vztahu:

$$y_{in} = \text{bias} + \sum_{i=1}^n x_i \cdot w_i, \quad (3.14)$$

kde x_1 až x_n je vektor vstupů neuronu, w_1 až w_n je vektor vah těchto vstupů a bias je konstantním vstupem neuronu. Finálního výstupu neuronu je dosaženo dosazením vnitřního potenciálu neuronu do aktivační (přenosové) funkce. Aktivační funkce vyjadřuje intenzitu odezvy neuronu na daný vstup. Obecně platí, že aktivační funkcí může být jakákoliv matematická funkce, u které platí, že libovolnému x přiřadí právě jednu hodnotu y . V současné době je jednou z nejpoužívanějších aktivačních funkcí funkce ReLU³. (Volná, 1998; Suzuki 2014).

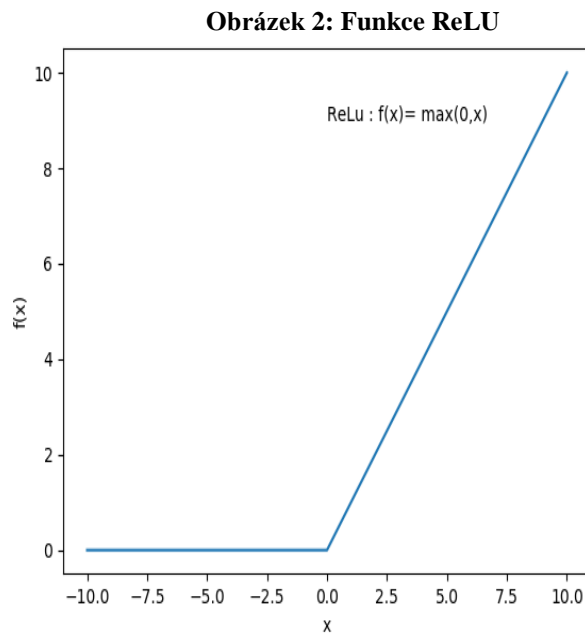
³ Rectified Linear Unit

Aktivační funkce ReLU (Rectified Linear Unit)

Předpis funkce ReLU je:

$$f(x) = \max(0, x). \quad (3.15)$$

Funkce transformuje negativní hodnoty x na hodnotu 0. Mezi její pozitivní vlastnosti patří velmi malá výpočetní náročnost a jednoduchá derivace.



zdroj: vlastní

3.2.2 Plně propojená vrstva

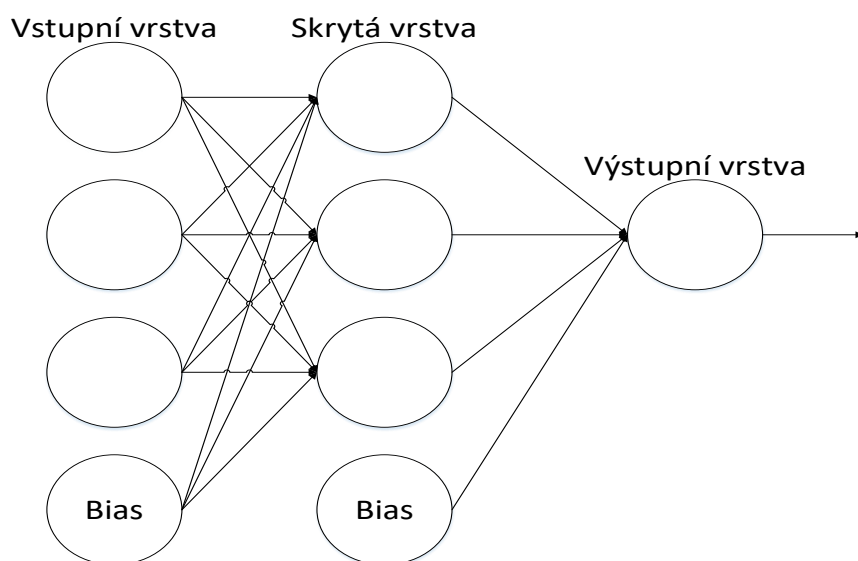
Plně propojená vrstva⁴ se skládá z n neuronů, které jsou plně propojeny s m neurony z předcházející vrstvy. Plně propojenou vrstvu lze definovat vztahem:

$$y_j = \sum_{i=0}^m w_{ij} \cdot x_i, \quad (3.16)$$

kde y_j reprezentuje vnitřní potenciál j -tého neuronu ($1 \leq j \leq n$) v aktuální vrstvě, x_i jsou vstupní hodnoty neuronu z předchozí vrstvy a w_{ij} je váha synapse mezi j -tým neuronem a i -tou hodnotou vstupu. Hodnota bias je ve výše uvedeném výrazu reprezentována jako x_0 a je součástí vektoru vstupních hodnot z předchozí vrstvy. Plně propojené vrstvy znázorňuje obrázek č. 4 (Volná, 1998)

⁴ V zahraniční literatuře se vyskytuje pod názvy fully-connected layer či Dense layer

Obrázek 3: Neuronová síť s plně propojenými vrstvami



zdroj: vlastní

3.2.3 Topologie vícevrstvé neuronové sítě

Vícevrstvou neuronovou sítí nazýváme síť, jež obsahuje jednu nebo více skrytých vrstev neuronů nacházejících se mezi vstupní a výstupní vrstvou. V topologii vícevrstvé neuronové sítě jsou neurony jedné vrstvy spojeny se všemi neurony bezprostředně následující vrstvy. Výstup k -tého neuronu umístěného v n -té skryté vrstvě anebo ve výstupní vrstvě vícevrstvé neuronové sítě lze vyjádřit vztahem:

$$y_k^n = f \left(w_{0,k}^n + \sum_{i=1}^m y_i^{n-1} \cdot w_{i,k}^n \right), \quad (3.17)$$

kde $f(x)$ je aktivační funkce neuronu, $w_{0,k}^n$ je bias neuronu a m je počet vah neuronu, jenž se rovná počtu výstupů nižší vrstvy sítě. Neexistuje pevně daný vztah k určení topologie sítě a je tedy třeba ji určit experimentálně s ohledem na několik obecných pravidel (Vondrák, 2009).

Pro většinu úloh řešených pomocí techniky vícevrstvé neuronové sítě, je dostačující síť s jednou skrytou vrstvou a dostatečným počtem neuronů. Adekvátní počet neuronů ve skryté vrstvě je velmi důležitý. Pokud je zvolený počet neuronů ve skryté vrstvě příliš malý, neuronová síť postrádá prostředky k řešení daného problému a pokud je příliš velký, tak dochází ke značnému prodloužení doby učení sítě a zvětšení rizika přeučení sítě⁵. Přeučením označujeme jev, kdy naučená neuronová síť příliš odpovídá konkrétní sadě dat a klesá její

⁵ V zahraniční literatuře se vyskytuje pod názvem overfitting

schopnost zobecňovat a spolehlivě předpovídat budoucí pozorování. Charakteristickou vlastností přeučené neuronové sítě je, že dosahuje výborných výsledků při aplikování na učící množinu dat, ale při aplikaci na testovací množinu dat jsou výsledky velmi špatné (Fausett, 1994).

Experimentální určení počtu neuronů ve skryté vrstvě probíhá tak, že je určen počáteční stav skryté vrstvy s malým počtem neuronů a je vybrána statistika, pomocí které je měřena chyba sítě, tedy toho jak odpovídají výstupy neuronové sítě empirickým hodnotám výstupní proměnné. Počet neuronů je postupně navyšován s ohledem na vývoj chybové funkce, kdy je znamením pro ukončení navyšování počtu neuronů její pokles pod předem stanovenou mez či zastavení jejího zlepšování (Fausett, 1994).


3.2.4 Učení neuronové sítě

Celkovou chybu neuronové sítě lze měřit pomocí střední kvadratické chyby:

$$E = \frac{1}{n} \sum_{i=0}^q \sum_{k=0}^n (y_{i,k} - t_{i,k})^2, \quad (3.18)$$

kde q je počet hodnot výstupní proměnné, n je počet výstupů neuronové sítě, $y_{i,k}$ je výstup neuronové sítě a $t_{i,k}$ je hodnota vysvětlované proměnné z učící množiny dat. Minimalizace této chyby se děje pomocí iterativních optimalizačních procedur, jichž existuje celá řada a jež jsou nazývány učením či trénováním neuronové sítě. V této práci byl využíván optimalizační algoritmus Adam. Natrénovanou neuronovou sít' lze pak využít k predikci hodnot výstupní proměnné, při zadané kombinaci hodnot vstupních proměnných. Model neuronové sítě je lokální, což znamená, že predikční schopnost sítě prudce klesá mimo rozsah zadaných hodnot nezávisle proměnné, což znázorňuje obrázek č. 5 (Fausett, 1994).

Obrázek 4: Predikční oblasti Neuronové sítě – příklad pro 1-rozměrnou nezávislou proměnnou a 1-rozměrný výstup y



zdroj: (Trilobyte, 2013)


3.2.5 Obecný postup použití vícevrstvé neuronové sítě

Typický postup použití vícevrstvé neuronové sítě je shrnut v následujících bodech:

- Zvolení nezávislých proměnných a závislé proměnné, jejichž počet napozorovaných empirických hodnot je N .
- Zvolení architektury neuronové sítě – počet vrstev a počet neuronů v jednotlivých vrstvách;
- Zvolení aktivační funkce neuronů skrytých a výstupních vrstev;
- Optimalizace parametrů sítě neboli tzv. učení neuronové sítě. V průběhu tohoto procesu se optimalizační algoritmus snaží najít takové nastavení vah, které povede k největší shodě předpovídaných hodnot a empirických hodnot závislé proměnné. Na počátku procesu optimalizace jsou vahám přiřazeny náhodné hodnoty, z čehož vyplývá, že každé řešení nalezené tímto procesem je zcela odlišné od ostatních, přičemž zároveň platí, že i zcela rozdílné nastavení vah v síti může generovat téměř identickou predikci a chybu modelu.
- Informaci o spolehlivosti predikce lze zjistit tak, že je zvolena tzv. učící podmnožina dat o PN řádcích ($0 < P < 1$), která je použita k naučení neuronové sítě a zbytek dat o rozsahu $(1-P)N$, tzv. validační data, použijeme k validaci sítě. Jako alternativní postup v případě nedostatku dat může sloužit pravidlo, dle kterého je výhodné nesnažit se dosáhnout absolutního minima chybové funkce přes celou množinu učících dat, ale zastavit učení neuronové sítě dříve. Tento okamžik lze velmi často identifikovat jako

náhlý pokles hodnoty chybové funkce sítě nad učicí množinou dat, což znázorňuje obrázek č. 6.

Obrázek 5: Syndrom přeučení



zdroj: (Holčík, Komenda; 2015)

- Měření efektivity učicího procesu pomocí zvolené metriky (např. střední kvadratická chyba).
- Použití naučené neuronové sítě k predikování neznámých hodnot závisle proměnné, na základě známých hodnot nezávislých proměnných (Fausett, 1994; Holčík, Komenda, 2015).

3.2.6 Programovací jazyk Python – program neuronové sítě

Program implementující techniky neuronových sítí byl sestaven v programovacím jazyce Python (verze 3.6), při využití distribuce Anaconda⁶. Při tvorbě programu byly využívány tyto knihovny a moduly:

- Keras⁷ - Softwarová knihovna s otevřeným zdrojovým kódem, která poskytuje rozhraní v programovacím jazyce Python pro aplikaci technik neuronových sítí.
- Pandas⁸ - knihovna nástrojů pro analýzu dat reprezentovatelných 2D tabulkou;

⁶ Anaconda je distribuce jazyka Python s mnoha předinstalovanými a tudíž kompatibilními knihovnami. Tato distribuce je ke stažení, pro operační systém Windows, na stránce: <https://docs.anaconda.com/anaconda/install/windows/>

⁷ Dostupné z <https://keras.io/api/>

⁸ Dostupné z <https://pandas.pydata.org/>

- Numpy⁹ - knihovna poskytující infrastrukturu pro práci s vektory, maticemi a obecně vícerozměrnými poli;
- Sklearn¹⁰ – knihovna nástrojů pro strojové učení;
- os¹¹ - modul pro interakci s operačním systémem;
- sys¹² - modul pro interakci s prostředím Python;
- time¹³ - modul pro práci s časovými funkcemi;
- argparse¹⁴ – modul k vytváření rozhraní pro příkazovou řádku.

V následujícím výčtu jsou zmíněny použité funkce a jejich využití parametry, třídy a objekty z výše uvedených knihoven, jež byly použity při sestavování programu vícevrstvé neuronové sítě.

Keras

import keras – import celé knihovny;

from keras.models import Sequential – import třídy Sequential z knihovny Keras;

from keras.layers import Dense – import třídy Dense z knihovny Keras;

from keras.callbacks import ModelCheckpoint – import třídy ModelCheckpoint z knihovny Keras;

*keras.Sequential()*¹⁵ – třída umožňující tvorbu sekvenčních modelů neuronových sítí;

*model.add(layer, input_shape)*¹⁶ – Funkce přidává vrstvu do sekvenčního modelu neuronové sítě. Parametr *layer* reprezentuje vrstvu. Parametr *input_shape* reprezentuje počet vstupů do vrstvy.

⁹ Dostupné z <https://numpy.org/>

¹⁰ Dostupné z <https://scikit-learn.org/stable/>

¹¹ Dostupné z <https://docs.python.org/3/library/os.html>

¹² Dostupné z <https://docs.python.org/3/library/sys.html>

¹³ Dostupné z <https://docs.python.org/3/library/time.html>

¹⁴ Dostupné z <https://docs.python.org/3/library/argparse.html>

¹⁵ Dostupné z https://keras.io/guides/sequential_model/

¹⁶ Dostupné z https://keras.io/guides/sequential_model/

*Dense(units, input_dim, kernel_initializer=' normal ', activation=' relu')*¹⁷ - Třída umožňující konstrukci plně propojené vrstvy neuronové sítě. Parametr *units* reprezentuje počet neuronů ve vrstvě. Parametr *input_dim* reprezentuje počet vstupů do vrstvy. Parametr *kernel_initializer=' normal '* reprezentuje normální rozdělení pravděpodobnosti, dle kterého jsou distribuovány inicializační hodnoty vah synapsí vedoucí do vrstvy. Parametr *activation=' relu '* reprezentuje aktivační funkci ReLU, kterou obsahují neurony dané vrstvy.

*ModelCheckpoint(filepath, monitor='loss', verbose=1, save_best_only=True, mode='min')*¹⁸ - Funkce ukládá topologii neuronové sítě a její váhy dle definovaného pravidla. Parametr *filepath* definuje cestu souboru ve formátu HDF do kterého je ukládána neuronová síť se svými vahami. Parametr *monitor='loss'* definuje chybu neuronové sítě jako metriku, od jejíž hodnoty se bude odvíjet ukládání neuronové sítě. Parametr *verbose=1* definuje s jakou periodicitou je zobrazován vývoj učícího procesu neuronové sítě. Parametr *save_best_only=True* určuje, že bude uložena jen topologie neuronové sítě s takovými vahami, pomocí nichž došlo ke snížení chyby sítě. Parametr *mode='min'* definuje cíl, jímž je minimalizace chyby sítě.

*model.compile(loss='mean_squared_error', optimizer=keras.optimizer.Adam(lr=0.01))*¹⁹ - Funkce umožňuje kompilaci neuronové sítě. Parametr *loss='mean_squared_error'* definuje jako chybu neuronové sítě střední kvadratickou chybu (MSE). Parametr *optimizer=keras.optimizer.Adam(lr=0.01)* určuje, že optimalizačním algoritmem, pomocí něhož bude minimalizována chyba sítě, bude algoritmus Adam s koeficientem učení 0.01.

*model.fit(x, y, epochs, batch_size, callbacks=[ModelCheckpoint()])*²⁰ - Funkce spouští trénování neuronové sítě. Parametry *x* a *y* reprezentují vstupní a výstupní data. Parametr *epochs* reprezentuje počet epoch učení neuronové sítě. Parametr *batch_size* reprezentuje počet vzorků z učící množiny dat, jež procházejí sítí, přičemž platí, že čím větší je velikost dávky, tím více operační paměti je využito. Parametr *callbacks* reprezentuje funkci *ModelCheckpoint()* s jejími definovanými parametry a pravidly, jež je funkcí *model.fit()* aplikována na učící proces neuronové sítě.

*model.summary()*²¹ - Funkce vrací shrnutí informací o použité neuronové síti.

*load.model(filepath)*²² - Funkce načítá serializovanou topologii neuronové sítě a její váhy. Parametr *filepath* reprezentuje cestu souboru ve formátu HDF.

¹⁷ Dostupné z https://keras.io/api/layers/core_layers/dense/

¹⁸ Dostupné z https://keras.io/api/callbacks/model_checkpoint/

¹⁹ Dostupné z https://keras.io/api/models/model_training_apis/

²⁰ Dostupné z https://keras.io/api/models/model_training_apis/

²¹ Dostupné z <https://keras.io/api/models/model/#summary-method>

²² Dostupné z https://keras.io/api/models/model_saving_apis/

*model.predict(x)*²³ – Funkce predikuje hodnoty výstupní proměnné na základě hodnot vstupních proměnných. Parametr *x* reprezentuje vstupní proměnné.

Pandas

import pandas as pd - import celé knihovny;

*pd.read_excel(io, sheet_name)*²⁴ – Funkce načítá soubory vytvořené v tabulkovém procesoru Excel do datového typu DataFrame. Parametr *io* reprezentuje cestu k souboru aplikace Excel. Parametr *sheet_name* reprezentuje název listu, který má být z daného souboru načten.

*pd.DataFrame(data, columns=[])*²⁵ – Funkce přijímá data a vrací je ve formě datového typu DataFrame. Parametr *data* reprezentuje vstupní data. Parametr *columns* reprezentuje názvy sloupců datového typu DataFrame.

*pd.DataFrame.columns*²⁶ – Funkce vrací jména všech sloupců datového typu DataFrame.

*pd.index.to_list()*²⁷ – Funkce vrací seznam indexů datového typu DataFrame.

pd.to_csv(path, index=False) – Funkce ukládá datový typ DataFrame do CSV souboru. Parametr *path* reprezentuje cestu uloženého souboru a parametr *index*, slouží k určení, zda se má ukládat index řádků datového typu DataFrame či nikoliv.

Numpy

import numpy as np – import celé knihovny;

*numpy.mat(data)*²⁸ – Funkce interpretuje vstupní data jako matici. Parametr *data* reprezentuje vstupní data.

Sklearn

from sklearn.preprocessing import MinMaxScaler – import třídy²⁹ MinMaxScaler z knihovny Sklearn;

²³ Dokumentace dostupná z https://keras.io/api/models/model_training_apis/

²⁴ Dokumentace je dostupná z https://pandas.pydata.org/pandas-docs/stable/reference/api/pandas.read_excel.html

²⁵ Dokumentace je dostupná z <https://pandas.pydata.org/pandas-docs/stable/reference/api/pandas.DataFrame.html>

²⁶ Dokumentace je dostupná z <https://pandas.pydata.org/pandasdocs/stable/reference/api/pandas.DataFrame.columns.html>

²⁷ Dokumentace je dostupná z <https://pandas.pydata.org/pandas-docs/stable/reference/api/pandas.Index.tolist.html>

²⁸ Dokumentace je dostupná z <https://numpy.org/doc/stable/reference/generated/numpy.mat.html>

²⁹ Třída v programovacím jazyce Python popisuje, jak se všechny objekty daného typu chovají.

*MinMaxScaler*³⁰ – Třída mapující hodnoty do ní vstupující na určený interval. Přednastavený interval je $\langle 0,1 \rangle$.

MinMaxScaler.fit(X) – Funkce třídy *MinMaxScaler* vypočítává minimum a maximum ze zadaných hodnot. Parametr *X* reprezentuje vstupní hodnoty.

MinMaxScaler.fit_transform(X) – Funkce třídy *MinMaxScaler* mapuje vstupní hodnoty na interval $\langle 0,1 \rangle$ pomocí minimální a maximální hodnoty vstupních hodnot vypočtených pomocí funkce *MinMaxScaler.fit(X)*. Parametr *X* reprezentuje vstupní hodnoty.

OS

import os – import celého modulu;

*os.path.split(path)*³¹ – Funkce modulu *os.path* přijímá cestu k souboru a vrací n-tici, která obsahuje zvlášť cestu a zvlášť jméno souboru. Parametr *path* reprezentuje cestu souboru.

Sys

import sys – import celého modulu;

*sys.stdout*³² – Jedná se o objekt typu stream, který podporuje pouze zápis. Jeho standardní nastavení je takové, že vrací výstup do integrovaného vývojového prostředí nebo do terminálového okna.

Time

import time – import celého modulu;

*time.time()*³³ – Funkce modulu *time* vrací počet sekund které proběhly od 1.1.1970.

Argparse

import argparse – import modulu;

*argparse.ArgumentParser()*³⁴ – instance třídy *ArgumentParser*;

parser.add(name, help=" ", required=True) – Funkce slouží k předání argumentu parseru, který ho bude umět zpracovat. Parametr *name* slouží k pojmenování argumentu. Parametr *help*

³⁰ Dokumentace celé třídy je dostupná z <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>

³¹ Dokumentace je dostupná z <https://docs.python.org/3/library/os.path.html>

³² Dokumentace je dostupná z <https://docs.python.org/3/library/sys.html>

³³ Dokumentace je dostupná z <https://docs.python.org/3/library/time.html>

³⁴ Dokumentace celé třídy je dostupná z <https://docs.python.org/3/library/argparse.html>

slouží k integrování textové informace o daném argumentu a parametr *required* slouží k definování, zda je nutné zadat hodnotu argumentu či nikoliv.

4. Teoretická východiska

4.1 Definování zahraničního obchodu

Zahraníční obchod je nejvýznamnější součástí vnějších ekonomických vztahů, jež zahrnují jak mezinárodní ekonomickou spolupráci, tak mezinárodní dělbu práce. Platí, že čím větší má země stupeň ekonomické vyspělosti, tím je síť ekonomických vztahů, jež země navazuje, pestřejší. Zahraníční obchod zahrnuje tu část sféry oběhu zboží, která představuje směnu se zahraničím, tj. překračuje hranice jednotlivého státu či ekonomického celku. Prostřednictvím zahraničního obchodu jsou spojeny vnitřní struktury hospodářství konkrétní země se světovou ekonomikou. Zahraníční obchod se skládá ze dvou základních komponent, dovozu (importu) a vývozu (exportu) a týká se výlučně jednoho ekonomického celku ve vztahu k ostatním zemím a světu (Fojtíková, 2009).

Hlavním regulátorem a koordinátorem zahraničně obchodních vztahů je stát, který dohlíží na realizaci dovozu a vývozu zboží a služeb. Činnost státu, jako koordinátora vnějších hospodářských vztahů, má dva aspekty, aspekt ochranný (ochrana domácí ekonomiky) a aspekt fiskálního charakteru, jenž je spjat s faktem, že vstup importovaného zboží na tuzemský trh je v mnoha případech spojen s úhradou cel a jiných poplatků, které se stávají jedním z příjmů státního rozpočtu (Fojtíková, 2009).

Hlavním důvodem, který motivuje státy, potažmo firmy, participovat na zahraničním obchodu, je v případě firem zvyšování zisku, tedy pronikání na nové trhy a případné dovážení levnějších vstupních materiálů či polotovarů a v případě státu zajištění ekonomické rovnováhy země. Zahraníční obchod přímo ovlivňuje vnější rovnováhu země, reprezentovanou vyrovnanou platební bilancí (obchodní bilance a bilance služeb) a stabilitou devizového kurzu a nepřímo ovlivňuje vnitřní rovnováhu země, prostřednictvím růstu zaměstnanosti, jež často doprovází růst exportní výkonnosti. Míra, ve které daná země participuje na zahraničním obchodu, závisí na míře její otevřenosti, velikosti a ekonomické vyspělosti. Jako ukazatele míry otevřenosti jsou zpravidla užívány poměry vývozu, dovozu, a obratu zahraničního obchodu (aritmetického průměru vývozu a dovozu) konkrétní země na HDP. V míře otevřenosti můžeme zaznamenat dva tendenční směry. Větší míru otevřenosti můžeme nalézt zpravidla u malých vyspělých ekonomik, přičemž výjimku tvoří země, kde vysoký podíl exportu na HDP může být dán úzkou specializací výroby. Nižší míra otevřenosti je typická pro rozvinuté ekonomiky, jež se vyznačují rozsáhlým vnitřním trhem, nebo rozvojové země, jejichž výrobky jsou na

světovém trhu nekonkurenceschopné. Velikost země je dána jejím celkovým zeměpisným rozměrem zahrnujícím jak pevninu, tak i vodní plochy. Ekonomická vyspělost země se nejčastěji měří pomocí úrovně HDP na obyvatele anebo pomocí komplexnějšího pohledu, prováděného pomocí indexu lidského rozvoje HDI, což je komparativní nástroj, jež bere v potaz i neekonomické veličiny, jako jsou střední délka života, gramotnost, chudoba, vzdělání a další (Neumann et al., 2010).

Ekonomie popisuje užitek z účasti na mezinárodním obchodu pomocí teorie absolutních výhod, formulované Adamem Smithem, a teorie komparativních výhod, formulované Davidem Ricardem. Teorie absolutních výhod říká, že by se země měla specializovat na výrobu těch produktů, které je schopna vyrábět levněji, tedy za použití menšího množství práce, než ostatní země. Výrobky takto vyrobené by pak země měla vyvážet do zemí, v nichž je výroba těchto výrobků nákladnější a zároveň by z nich měla dovážet výrobky, které tyto země dovedou vyrobit levněji. Teorie absolutních výhod však neřeší situaci, kdy země není schopna vyrábět žádný výrobek levněji než ostatní země. Teorie komparativních výhod tvrdí, že zapojení do mezinárodní dělby práce je výhodné, i když daná země nemá ve výrobě žádného výrobku absolutní výhodu. Země má komparativní výhodu v produkci toho zboží, u něhož jsou náklady příležitosti výroby tohoto zboží nižší než u jiných zemí (Neumann et al., 2010).

4.2 Důležitost zahraničního obchodu v ekonomice země

Ke zhodnocení významu zahraničního obchodu v ekonomice konkrétní země se používá hledisko efektivnosti, proporcionality a demonstrativního efektu.

Efektivnost zahraničního obchodu označuje tendenci země soustředit se v exportní politice na ty výrobky, u nichž je možno dosáhnout maximálních úspor společenské práce. Do oblasti generující takto identifikované výrobky, by pak měl být soustředěn výzkum, vývoj, propagační úsilí a další podpůrné činnosti (Svatoš, 2009).

Proporcionalita zahraničního obchodu charakterizuje nekomplexnost ekonomiky, kdy je ekonomický rozvoj země závislý na importovaném zboží ze zahraničí. Nekomplexní ekonomiku má většina zemí světa. Pouze malé procento zemí disponuje dostatečně velkým domácím trhem a průmyslovou základnou, jež jsou nutné k soběstačnému vývoji (Beneš 2004; Svatoš, 2009).

Demonstrativní efekt označuje fenomén, kdy jsou vývozní programy jakousi vizitkou ekonomického rozvoje a úrovně země a naopak dovozní programy podávají informaci o tom,

jak je ta která země schopna vypořádat se s hlediskem proporcionality. Jedná se tedy o určitou demonstraci světového, technického, designového a módního trendu, jenž může mít stimulační účinek na společenský a ekonomický pokrok (Svatoš, 2009).

Zahraniční obchod má také mírotvorné účinky a tedy snižuje riziko konfliktu. Lze sledovat přímou závislost mezi hospodářskou provázaností dvou nebo více zemí a stabilitou celkových vztahů těchto zemí (Kalínská et al., 2010).

4.3 Postavení zahraničního obchodu v ekonomice země

Z národohospodářského hlediska můžeme definovat dva přístupy k zahraničnímu obchodu, přístup pasivní a přístup aktivní.

U pasivního přístupu k zahraničnímu obchodu je kladen důraz na hledisko proporcionality ekonomiky, jenž má zajistit zahraniční obchod za účelem dosáhnutí plynulosti reprodukčního procesu. Jedná se především o zajištění surovin, potravin, strojů a zařízení, které v zemi schází. Tento přístup neobsahuje žádné prvky proexportní politiky. U zastánců tohoto přístupu, se můžeme často setkat s argumentem označujícím vývoz jako negativní fenomén, jenž je nutný pro získání devizových prostředků pro potřeby dovozu. Pro pasivní přístup k zahraničnímu obchodu jsou typické protekcionistické přístupy, jež si kladou za cíl ochranu domácího trhu. Tyto přístupy se vyznačují vysokými vývozními cly či kvótami, což má zajistit dostupnost zboží pro danou zemi (Svatoš, 2009).

Aktivní přístup k zahraničnímu obchodu zdůrazňuje hledisko efektivnosti a užívá zahraniční obchod jako prostředek k zvyšování efektivnosti konkrétní ekonomiky. Za cíl je kladena exportní orientace ekonomiky, tedy ekonomika užívající zahraniční obchod jako významný činitel a stimul, přispívající k rozvoji ekonomického růstu. Aktivní přístup se v rukou státu vyznačuje především koncentrovanou snahou zajistit co nejsnadnější přístup na trhy jednotlivých zemí. Země praktikující aktivní přístup jsou úzce spjaty s ekonomickým liberalismem, což je politika, jež se mimo jiné snaží minimalizovat státní zásahy do obchodních vztahů. Snaží se například minimalizovat či rušit cla a kvóty a tak podporovat ideu volného obchodu (Holman, 2016).

Téměř všechny země světa uplatňují nějaké formy obchodního ochranářství. Nejčastějšími nástroji jsou dovozní cla a dovozní kvóty. V mnoha případech se však uplatňují skrytější a méně průhledné formy ochranářství, jako např. různé ekologické, zdravotní, hygienické, technické, bezpečnostní a jiné požadavky na zboží z dovozu. Tyto opatření jsou

většinou realizována z důvodu ochrany domácích pracovních míst, zabezpečení rovné konkurence či ochrany mladého odvětví (Holman, 2016).

4.4 Úloha zahraničního obchodu

Úloha zahraničního obchodu je výrazná především v malých nebo ekonomicky vyspělých zemích, což se u těchto zemí projevuje vysokým podílem zahraničního obchodu na HDP či na obyvatele, tedy velkou mírou otevřenosti v obchodě. Funkce, jež zahraniční obchod v těchto zemích plní, lze rozdělit do tří skupin (Štěrbová et al., 2013).

4.4.1 Zahraniční obchod jako činitel vnitřní a vnější rovnováhy

Do této skupiny patří funkce transformační, funkce vyrovnaných trhů a funkce harmonizační (Štěrbová et al., 2013).

Transformační funkce přeměňuje strukturu domácí produkce (agregátní nabídka) na žádoucí strukturu z hlediska výrobního a spotřebního užití (agregátní poptávka). Jedná se o historicky prvotní smysl existence ekonomických vztahů se zahraničím, jehož cílem byla kompenzace nerovnoměrné vybavenosti zemí výrobními faktory. Mezi tyto faktory se řadí přírodní podmínky (prostor, suroviny, vodní, půdní a klimatické zdroje), ekonomické podmínky (pracovní síla, kapitál, technologie atd.) a účinnost vynakládání těchto zdrojů. Prostřednictvím působení transformační funkce dochází k růstu efektivity alokace domácích a zahraničních zdrojů a tím zároveň k růstu hospodářské vyspělosti země (Štěrbová et al., 2013).

Funkce vyrovnávání trhů zabezpečuje soulad mezi agregátní nabídkou (AS) a agregátní poptávkou (AD). Tento vztah můžeme vyjádřit prostřednictvím základní makroekonomické identity (Štěrbová et al., 2013):

$$(X - M) = (C + I + G)$$

kde výraz $(X - M)$ vyjadřuje bilanci zahraničního obchodu se zbožím a službami, Y značí domácí agregátní důchod a výraz $(C + I + G)$ značí celkovou domácí poptávku.

Funkce harmonizační zprostředkovává odstranění nerovnováh mezi domácí ekonomikou a zahraničím, prostřednictvím zapojení do světového hospodářství a sblížováním hospodářské úrovně domácí ekonomiky s rozvinutějšími zahraničními ekonomikami (Štěrbová et al., 2013).

4.4.2 Zahraniční obchod jako činitel ekonomického růstu

Působení na fenomén ekonomického růstu probíhá prostřednictvím funkce transmisní a funkce růstové (Štěrbová et al., 2013).

Prostřednictvím transmisní funkce dochází ke zvýšení mezinárodní konkurenceschopnosti ekonomiky, což se děje v důsledku přenosu informací, kritérií a podnětů z vnějšího prostředí do domácí ekonomiky a jež má za následek přizpůsobení se náročnějším požadavkům při exportu na zahraniční trhy a zároveň zvýšení tlaku konkurence na domácí firmy při importu (Štěrbová et al., 2013).

Růstová funkce formuje mezinárodní specializaci. Prostřednictvím zahraničního obchodu stimuluje růst HDP a zároveň utváří optimální specializační profil ekonomik. Specializace dosažená tím, že se ekonomiky podílí na mezinárodní dělbě práce formou zahraničního obchodu, generuje úspory vynakládané práce a ekonomii času, což má za následek zvýšení produktivity a spotřebních možností ekonomiky (Štěrbová et al., 2013).

4.4.3 Zahraniční obchod jako překážka ekonomického růstu

V souvislosti se zahraničním obchodem vyvstávají jak v rozvojových, tak v rozvinutých zemích určité problémy.

Prvním problémem je problém nepříznivé specializace, který nastává v případech, kdy se ekonomika, z hlediska komparativních nákladů a vybavenosti výrobními faktory, specializuje na vývoz zboží a služeb s nižší přidanou hodnotou (např. zemědělská produkce a nerostné bohatství), anebo kdy je specializace výsledkem administrativního rozhodnutí (Štěrbová et al., 2013).

Teorie zblídačujícího růstu, vytvořená indickým ekonomem Jagdishem Bhagwatim a kanadským ekonomem Harrym G. Johnsonem se zabývá situací, kdy při rostoucí nabídce exportních komodit hospodářsky méně vyspělých zemí dochází prostřednictvím poklesu cenové hladiny k poklesu exportních příjmů těchto zemí. Pokud postižené země reagují na pokles ceny dalším zvýšením vývozu, jediné čeho tím dosáhnou je další snížení ceny a tím dochází k zacyklení (Štěrbová et al., 2013).

Teorie závislosti ekonomik zformovaná argentinským ekonomem Raúlím Prebishem a britským ekonomem Harry G. Johnsonem prosazuje tvrzení, že ceny surovin a potravin, které

jsou nejčastěji vyváženým artiklem rozvojových zemí, rostou pomaleji než ceny průmyslových výrobků, jež tyto země povětšinou dovážejí. Tímto mechanismem se zhoršuje postavení rozvojových ekonomik a jsou odsouvány na periferii (Štěrbová et al., 2013).

Paradox „surovinového prokletí“ definován britským ekonomem Richardem Autym popisuje nepříznivé změny v ekonomice, jež postihují surovinově bohaté rozvinuté země a rozvojové země, projevující se nižším tempem růstu HDP, útlumem zpracovatelských odvětví ve prospěch těžebních, růstem mezd převyšujícím růst produktivity práce, apreciací reálného měnového kurzu a zvýšením citlivosti exportu a ekonomiky jako celku na výkyvy světových cen komodit (Štěrbová et al., 2013).

Dalším problémem je problém nedostatečné vyspělosti, jenž se zabývá situací, kdy zahraniční obchod vede k útlumu či zániku řady méně konkurenceschopných odvětví.

Teorie dětských odvětví formulovaná německým ekonomem Friedrichem Listem tvrdí, že země, jež nemá dostatečně rozvinutá průmyslová odvětví, by měla svůj průmysl chránit před zahraniční konkurencí, dokud nedosáhne dostatečné zralosti. Až poté může země otevřít své trhy volnému obchodu (Štěrbová et al., 2013).

Maurice Allais, francouzský ekonom a nositel ceny Nobelovy ceny, ve svých tezích upozorňoval na fakt, že volný obchod mezi ekonomikami, které jsou na odlišném stupni vývoje, může narušovat jejich hospodářskou a sociální stabilitu. Řešením by dle Allaiho bylo omezení zahraničního obchodu až do doby, kdy bude stupeň vývoje zemí srovnatelný (Štěrbová et al., 2013)

Problém zranitelnosti popisuje situaci, kdy zahraniční obchod slouží jako kanál, jímž se do domácí ekonomiky přenesou recese ze zahraničí. Příčinný řetězec vzniku recese v domácí ekonomice má počátek ve snížení zahraniční poptávky, jež se projeví poklesem vývozu, což má za následek zpomalení růstu exportních odvětví (pokles investic, propuštění zaměstnanců) a při vysoké obchodní otevřenosti ekonomiky dojde k rozšíření tohoto zpomalení na celou ekonomiku (růst nezaměstnanosti, pokles domácí poptávky a důchodu), což se podepíše na snížení dovozu a vytvoří v ekonomice recesi. Tento fenomén se významně projevil při ekonomické krizi probíhající od prosince roku 2007 do června roku 2009 (Štěrbová et al., 2013).

4.5 Činitele ovlivňující vnější ekonomické vztahy

Ve vnějších ekonomických vztazích konkrétní země se střetávají nejrůznější vlivy, jež lze rozdělit na objektivní a subjektivní (Svatoš, 2009).

Za objektivní vlivy jsou považovány činitele, jež jsou dány geografickou polohou, faktem zda země má či nemá přístup k moři nebo má-li splavné řeky, geografickým charakterem země, klimatickými faktory jako jsou srážkové poměry a rozložení srážek, rizika záplav či existence periodických klimatických extrémů a zdroji surovin. Výše jmenované fenomény je třeba reflektovat a mít na paměti při zpracování důležitých národohospodářských koncepcí. Mezi objektivní faktory patří i ekonomická vyspělost měst a venkova, struktura vzdělanosti obyvatelstva a demografická struktura obyvatelstva, u nichž sice může dojít ke změnám, ale jedná se o dlouhé časové horizonty (Svatoš, 2009).

Mezi subjektivní faktory patří především vlivy státu, jeho institucí a další vlivy, jež se snaží objektivní faktory modifikovat, usměrňovat, využívat či eliminovat. Růst výrobních sil, který vyvolal rozvoj mezinárodního obchodu, postupně vedl též k uplatňování státních zásahů jak do vnitřních ekonomických vztahů, tak do procesů mezinárodní směny. Rozsah a síla státních zásahů rostla s relativní ekonomickou slabostí země. Z historického pohledu měly státní zásahy především chránit domácí výrobu. Určitá státní ochrana jako např. cla měla mladým státům zajistit dodatečné ekonomické zdroje. Trend zásahů státu ve prospěch vyvážejících podniků, jejichž zástupcem je např. subvencovaný vývoz, se začal prosazovat až ve 20. století (Svatoš, 2009).

Obecně lze říci, že nástrojů na bezprostřední ovlivňování zahraničního obchodu ubývá, což má na svědomí autorita Světové obchodní organizace (WTO). WTO je jediná mezinárodní organizace globálního charakteru, která se zabývá pravidly obchodu mezi státy. Ústřední bod tohoto subjektu tvoří dohody WTO, jež jsou dojednávány a podepisovány všemi členskými zeměmi (mnohostranné dohody) či většinou členských států (vícestranné dohody). Primárním úkolem WTO je zajistit rovnost v rámci otevřeného trhu a poskytnout členským státům nástroj, pomocí něhož mohou země redukovat obchodní bariéry a tak vytvářet stabilní a předvídatelné prostředí pro mezinárodní obchod. (Agriculture and international trade: law, policy, and the WTO, 2003).

4.6 Kvantifikace role zahraničního obchodu

Jeden ze způsobů jak kvantifikovat význam role, kterou zahraniční obchod hraje v ekonomice jednotlivých zemí, je vztah mezi vyrobeným a užitým společenským produktem, jenž je možno vyjádřit následujícími schémata (Svatoš, 2009) :

$$\text{Užitý společenský produkt} = \text{vyrobený společenský produkt} + \text{dovoz} - \text{vývoz}$$

nebo:

$$\text{Vyrobený společenský produkt} = \text{užitý společenský produkt} - \text{dovoz} + \text{vývoz}$$

Pokud má země aktivní obchodní bilanci, tak se užitý společenský produkt zmenšuje a pokud má naopak pasivní obchodní bilanci, pak se společenský produkt zvyšuje. Obměna společenského produktu se v jednotlivých zemích liší, přičemž v některých případech může činit až 70%. U zemí s komplexní ekonomikou činí jen několik málo procent (Svatoš, 2009).

Dalším způsobem kvantifikace je objem zahraničního obchodu. Tato charakteristika vypovídá, v absolutní hodnotě, o postavení země ve světové ekonomice. Mezi přední světové vývozce se z hlediska tohoto ukazatele řadí řada relativně malých zemí a naopak velké země se často nacházejí na středních či nižších pozicích (Svatoš, 2009).

Význam zahraničního obchodu v ekonomice země vyjadřuje též schopnost vývozu pokrýt dovozní potřeby země, což lze vyjádřit jako:

$$\text{vývoz/dovoz} * 100$$

Případy, kde ukazatel dosáhne hodnoty větší než 100, označují země s aktivní obchodní bilancí, jež může být výsledkem jak cílevědomého úsilí v tomto směru, tak i výsledkem shody okolností, kdy například daná země disponuje zásobami, na světových trzích poptávaného, přírodního bohatství (Svatoš, 2009).

Význam zahraničního obchodu či vnějších ekonomických vztahů v ekonomice země, lze vyjádřit také jako vztah dovozu vůči devizovým rezervám, což je označení pro mezinárodní likviditu, jež představuje volné měnové rezervy, disponibilní v národní bance země (Svatoš, 2009).

4.7 Postavení agrárního sektoru ve světové ekonomice

Zemědělství má v současném světě postavení nejdůležitější ekonomicko-sociální aktivity. Globálně a napříč regiony rostlo HDP zemědělství pomaleji než HDP ostatních odvětví, což vedlo ke snížení podílu zemědělství na celkovém HDP. V letech 1970 až 2017 se celosvětový HDP zemědělství reálně zvýšil z 0,9 na 3,0 bilionu USD, i když příspěvek sektoru k reálnému HDP klesl z 5% na 3,9%. Toto odvětví však hraje klíčovou roli v hodnotovém řetězci zemědělského průmyslu využívajícího přírodní zdroje a tedy ovlivňuje kvalitu životního prostředí a kvalitu potravin nad rámec účinků, jež jsou zachyceny jeho příspěvkem k celkovému HDP (Food and Agriculture Organization of the United Nations, 2019).

Vlivy zemědělství na vývoj společnosti lze rozdělit do dvou skupin: vlivy s přímým dopadem a vlivy s dopadem nepřímým. Vlivy s přímým dopadem zahrnují produkci potravin, zdroj příjmů a zaměstnanost. Mezi vlivy s nepřímým dopadem patří schopnost zemědělství zajistit dostatek dostupných pracovních sil pro potřeby dalších odvětví lidské činnosti, odběr produktů z jiných odvětví světového hospodářství (služby, chemie, strojírenství atd.) a poskytování surovinové základny celé řady zpracovatelských odvětví. Zemědělství je také tvůrcem mnoha pozitivních externalit, tedy fenoménů, jež přispívají k rozvoji lidské společnosti. Mezi tyto pozitivní externality se řadí podíl na boji s chudobou, zajištění potravinové bezpečnosti, ochrana životního prostředí či rovnoměrném osídlení povrchu planety. Všeobecně platí, že další rozvoj lidstva je těsně spjat s vývojem a postavením zemědělství ve světě. Síla této závislosti se bude nadále zvětšovat. Demografické prognózy zveřejněné Organizací spojených národů počítají ve své mediánové variantě pro rok 2050 s 9,7 mld. lidí a pro rok 2100 s 11 mld. lidí (Smutka, 2010; United Nations, 2019).

Na agrární produkci je vázán obchod s touto produkcí, což je velmi výrazný fenomén, který silně ovlivňuje současný vývoj světové ekonomiky. Většina států světa není schopná uspokojit svou produkcí vzrůstající poptávku po zemědělských a potravinářských produktech a zároveň také platí, že většina států není schopna pomocí svých zdrojů zabezpečit plný rozsah nabídky produktů jednotlivých klimatických pásem. Agrární obchod, představuje možnost, jak rozšířit nabídku celé řady produktů v jednotlivých státech světa. Představuje také možnost, která umožňuje státům prodávat část své produkce v zahraničí či nakupovat produkci v zahraničí a zásobovat vlastní trh (Smutka, 2010).

Klíčové znaky agrárního sektoru

Mezi klíčové znaky agrárního sektoru patří:

- časové zpoždění, nízká nabídková pružnost a nízká cenová a důchodová poptávková pružnost v případě většiny výrobků;
- stabilita poptávky po potravinách v čase a cykličnost, periodicita a sezónnost nabídky zemědělské produkce;
- omezená a nákladově náročná skladovatelnost většiny zemědělských a potravinářských výrobků;
- modifikace tržních signálů prostřednictvím působení klimatických podmínek;
- pouze částečná odpovědnost zemědělských producentů za výrobu nekontaminovaných potravin, odpovídajících požadavkům standardů zdravé výživy;
- nízká nákladová pružnost zemědělských podniků vyplývající z jejich všeobecně nepříznivé ekonomické situace a závislosti na cenové úrovni, kvalitě a časové dostupnosti průmyslových vstupů;
- otázka potravinové bezpečnosti, mající vysoký stupeň důležitosti pro řadu zemí světa;
- stále výraznější trend mimoprodukční funkce zemědělství, mající mimo jiné velký vliv na obchod s agrárními produkty (Smutka, 2010).

4.8 Vliv globalizace na světový zemědělský obchod

Globalizace je rostoucí integrace ekonomik a společností po celém světě. Jedná se o komplexní proces, který mnoha způsoby ovlivňuje potravinovou a zemědělskou ekonomiku světa. S procesem globalizace je spojen také rostoucí vliv nadnárodních společností. Moderní globalizace přinesla zásadní změny ve světovém zemědělském obchodu: bezprecedentní růst zemědělské tržní hodnoty v reálném vyjádření a dramatickou změnu struktury zemědělského obchodu, kdy podíl nezpracovaných komodit klesá a naopak silně roste podíl částečně zpracovaného a zpracovaného zemědělského zboží s vysokou přidanou hodnotou, určeného k okamžité spotřebě. Účinky globalizace jsou však asymetrické. V případě zemí LDC³⁵ je tato asymetrie silná a cesta k jejímu narovnání vyžaduje selektivní a fázovou integraci se světovými trhy. Bez přílivu zahraničních investic do infrastruktury, institucí, lidského a sociálního kapitálu se země LDC nebudou moci podílet na dividendách globalizace (Donato, 2006).

³⁵ Least Developed Countries

Fenomén globalizace je charakterizován poklesem nákladů na přeshraniční obchod se zemědělskými a jinými produkty. Důvodem těchto revolučních změn byla revoluce v oblasti ICT³⁶, snížení skutečných nákladů na dopravu a v případě zemědělských produktů snížení vládních deformací trhu a tedy postupnou liberalizací obchodu. Fenomén globalizace podpořil hospodářský růst a celosvětově snížil chudobu a zároveň v průběhu tohoto procesu mění globální zemědělskou produkci, spotřebu a obchodní vzorce. Světové ceny potravin závisí na tom, do jaké míry překonává růst produkce růst poptávky. Poptávka je poháněna růstem populace, příjmů, ale také cenami ropy, jež se promítají v poptávce po biopalivech. Hlavními faktory, jež ovlivňují a do budoucna budou ovlivňovat zemědělskou produkci, nejistotu cen a obchod jako takový jsou:

- růst populace, příjmů a produktivity zemědělství;
- vývoj cen a kolísání cen ropy a jejich dopad na poptávku po biopalivech;
- obchodní náklady a revoluce v supermarketovém prodeji;
- vývoj politiky narušujících zemědělské pobídky;
- změny klimatu a národní a globální politické reakce;
- reformy vodohospodářských institucí a politiky;
- investice do výzkumu a vývoje v zemědělství (Anderson 2010).

4.9 Společná zemědělská politika Evropské unie

Společná zemědělská politika (SZP) je sada politik, jež se zaměřuje na zvyšování zemědělských příjmů v EU. Hlavním impulsem pro vytvoření integrovaného zemědělství v Evropě bylo zajištění dostatečného množství potravin pro obyvatele západní Evropy a zaostalost evropského zemědělství za agrární produkci USA a v dalších zemích po druhé světové válce. Integrace měla přinést zvýšení produktivity práce, což mělo posílit konkurenceschopnost evropských zemědělců ve světě. Kladnou stránkou zavedení SZP je zvýšení zemědělské produkce, rozvoj sektoru zemědělství, stabilizace ekonomické situace na venkově a zabezpečení přiměřené životní úrovně obyvatel pracujících v zemědělství. Negativní stránkou této politiky, je výrazné zatížení rozpočtu Evropské unie, jelikož zemědělství tvoří největší část Evropské dotační politiky. Z celkového hlediska zahrnuje SZP v roce 2020 výdaje ve výši 58,124 mld. EUR a představuje tak 34,5 % rozpočtu Unie. Část výdajů na zemědělství se již několik let konstantně snižuje. Zatímco SZP představovala počátkem osmdesátých let 66

³⁶ Informační a komunikační technologie

% rozpočtu Unie, v letech 2014 – 2020 dosahovala pouze 37,8 %. (Vošta, 2010; Financování společné zemědělské politiky, 2020).

Hlavní cíle SZP byly vymezeny Římskou smlouvou z roku 1957 a netýkají se pouze ekonomické roviny, ale také oblasti sociální a politické. Ekonomické cíle zahrnovaly především zvýšení produktivity zemědělství, využití technických inovací a lepší využívání výrobních zdrojů, zejména pracovní síly. Sociální rovina zahrnovala především snahu o zlepšení životní úrovně obyvatelstva pracujícího v zemědělství a žijícího ve venkovských oblastech. Politická rovina zahrnovala především stabilizaci trhů a vytvoření podmínek pro zásobování zemědělskými komoditami. Takto definované cíle SZP měly zajistit ochranu vnitřního trhu před importovaným zbožím, tedy ochranu evropských výrob, jež byly v mnoha případech méně efektivní než konkurence produkující importované zboží (Vošta, 2010).

Základní principy společné zemědělské politiky jsou:

- Princip jednotného trhu, který představuje volný pohyb zemědělských produktů mezi jednotlivými členskými státy.
- Princip preference Společenství, jenž zahrnuje přednost odbytu ze společného trhu.
- Princip finanční solidarity, jenž představuje financování zemědělské politiky členskými státy (Palán 2007).

Princip jednotného trhu umožňuje volný pohyb agrárních komodit v prostoru EU. K ochraně vnitřního trhu se užívá koncept společných cen, jež jsou vytvářeny uměle a nepodléhají tržním mechanismům, cla, kvóty a další regulační mechanismy. Výše regulace je závislá na typu komodity. Mezi nejvíce regulované komodity patří cukr a obilí, zatímco trh s ovocem a zeleninou není regulován téměř vůbec. Základními kameny cenového systému jsou cílová (orientační) cena, mezní (prahová) cena a intervenční (minimální) cena. Cílová cena stanovuje cenu výrobku, kterou musí producent obdržet a odráží průměrné náklady zemědělců a jejich přiměřený zisk. Mezní cena je nejnižší cena, za kterou může být výrobek dovezen ze třetích zemí do oblasti společného trhu a měla by tedy bránit situaci, kdy by se dovážené zboží prodávalo za nižší ceny, než jsou ceny domácích výrobků. K dosažení mezních cen se používá celních mechanismů. Mechanismus intervenční ceny se uplatňuje v případě poklesu poptávky po určité komoditě, kdy hrozí pokles tržní ceny pod požadovanou úroveň a slouží tedy jako garance příjmu pro producenty (Vošta, 2010).

Princip preference Společenství se zaměřuje na posílení pozice domácích výrobků na vnitřním trhu, tedy jeho ochranu před dovozem ze třetích zemí, výkyvy cen na světových trzích

a podporu exportu domácích zemědělských komodit. Za situace kdy cena domácího výrobku přesahuje cenu světovou a je tedy ohrožena konkurenceschopnost domácích producentů, zavádí EU na dovážené výrobky dovozní cla tzv. zemědělské dávky, jenž jsou dány rozdílem světových a mezních (prahových) cen. Princip preference domácí produkce se zaměřuje také na podporu exportu agrárních komodit z produkce EU. Produkce, jejíž vnitřní cena je vyšší než světová cena je činěna konkurenceschopnou pomocí vývozních refundací, které tento rozdíl mezi vnitřní a světovou cenou vyrovnávají (König, Lacina, Přenosil, 2006).

Princip finanční solidarity vyjadřuje fakt, že se všechny členské státy podílejí na financování částí společné zemědělské politiky EU. Jedná se především o oblasti poskytování záruk v podobě garantovaných cen a financování rozvoje, jako například přizpůsobování struktury zemědělské výroby, modernizace, zlepšování životních podmínek či rozvoj venkovských regionů (Vošta, 2010).

Společná zemědělská politika se skládá ze dvou pilířů. První pilíř se týká tržních opatření, která byla definována v počátečních fázích této politiky. Patří sem tradiční nástroje řízení trhu, platby přímé podpory a přechodná a nouzová opatření. Výdaje prvního pilíře činily v letech 2014 až 2020 286,1 mld. €. Druhý pilíř je založen na dokumentu „Agenda 2000“ a zabývá se politikou rozvoje venkova. Tento pilíř zastřešuje podkapitoly týkající se podpory konkurenceschopnosti a inovací, péče o životní prostředí a podpory při řešení problematiky ztráty pracovních míst v zemědělství. Podpora péče o životní prostředí je pro členské státy povinná. Výdaje druhého pilíře činily v letech 2014 až 2020 96,7 mld. €. Dotační podíl je v případě druhého pilíře významně menší, než v případě pilíře prvního a tak je z velké části spolufinancován členskými státy. Aktuální trend ve Společné zemědělské politice je ten, že postupně oslabuje první pilíř a zvyšují se dotace do druhého pilíře, čímž by mělo dojít k jeho posílení (Slováková, 2015; The Common Agricultural Policy in figures 2020).

Společná zemědělská politika je terčem mnohé kritiky. Kritizována je nadprodukce a s tím související tvorba zbytečného odpadu. Často je poukazováno na fakt, že zemědělci představují pouze 5,4 % evropské populace a jejich produkce tvoří 1,6 % HDP EU a zároveň k nim směřuje 40 % z celkového rozpočtu EU. Nekonzistentnost panuje i v oblasti konkurenceschopnosti a inovací v zemědělství, jež tvoří jeden z cílů společné zemědělské politiky. Společný zemědělský trh je chráněn před většinou importu ze třetích zemí a tak si evropské státy konkurují jen v rámci evropského trhu, ale nejsou nuceny přizpůsobovat se tlakům a inovacím přicházejícím ze třetích zemí, především ze Spojených států, Kanady a Číny (Slováková, 2015).

Společná zemědělská politika je financována ze dvou fondů, které náleží do souhrnného rozpočtu EU. Prvním je Evropský zemědělský záruční fond (EZZF), jenž má na starosti podporu udržitelného zemědělství, přímé platby zemědělcům a tržně-regulační mechanismy a spadá pod první pilíř. Druhým je Evropský zemědělský fond pro venkov (EZFRV), jenž spadá pod druhý pilíř a přispívá ke strategii 2020 tím, že podporuje udržitelný rozvoj venkova v EU. V období 2014 až 2020 obdržela ČR v oblasti Společné zemědělské politiky 6,1 mld. EUR na přímých platbách a 2,2 mld. EUR na rozvoj venkova a celkové příjmy v této oblasti tedy dosáhly 8,3 mld. EUR a významně tak převýšily příjmy z období 2007 až 2013, kdy činily 7,4 mld. EUR (Greer, 2013; Ministerstvo financí, 2015).

4.10 Zahraniční obchod České republiky

4.10.1 Historický vývoj zahraničního obchodu ČR před vstupem do EU.

Oblast zahraničního obchodu prošla radikální proměnou v průběhu ekonomické transformace, kterou ČR prodělala na přelomu 80. a 90. let 20. století. Předchozí Československá ekonomika se vyznačovala uzavřeností, nesměnitelnou měnou a monopolizovaným sektorem podniků zahraničního obchodu. Po rozpadu Rady vzájemné hospodářské pomoci (RVHP), přechodu na světové ceny a platby ve volně směnitelných měnách se začal měnit jak směr orientace zahraničního obchodu, tak jeho komoditní struktura (Volejníková, 2009).

V roce 1993 byl objem zahraničního obchodu v absolutním vyjádření 847 685 mil. Kč. Za 10 let, tedy v roce 2003, byl dosažen objem zahraničního obchodu ve výši 2 811 600 mil. Kč. Za tuto dobu došlo ke značnému zvýšení vývozu. Od roku 1997 rostla dynamika českého vývozu rychleji než dynamika dovozu. V roce 2003 dosáhlo krytí dovozu vývozem celkem 95,2%, což byl nejvyšší podíl od roku 1993. V období 1993 – 2003 se vývoz z ČR soustředil na trhy Evropské unie, přičemž role Ruska a rozvojových zemí, jako cílů českého vývozu, výrazně oslabila, což se projevilo poklesem podílu k celkovému českému exportu o třetinu. V důsledku toho se podíl vývozu do zemí s vyspělou tržní ekonomikou zvedl na tři čtvrtiny českého exportu. Na obratu českého zahraničního obchodu se významně podílelo Německo, jež představuje zemi, s níž má ČR, v rámci Evropské unie, nejvyšší obchodní přebytek. V roce 2003 se na vývozu do Evropské unie podílel vývoz do Německa z 53% a na dovozu z Evropské unie se podílel dovoz z Německa z 55%. Mezi další významné obchodní partnery patřila v tomto období Velká Británie, Rakousko, Francie, Itálie (Volejníková, 2009).

Z hlediska komoditní struktury byl bilanční přínos zaznamenán především v těchto třídách SITC³⁷: stroje a dopravní prostředky, tržní výrobky tříděné dle materiálu a průmyslové spotřební zboží. Na vysokém nárůstu vývozu se podílely především silniční vozidla, elektrická zařízení, přístroje a spotřebiče. Nepříznivý vliv na vývoj obchodní bilance měly především zahraničně-obchodní transakce s potravinami a živými zvířaty, chemikáliemi a surovinami (Volejníková, 2009).

4.10.2 Vývoj zahraničního obchodu ČR po vstupu do EU

Zapojení České Republiky do vnitřního trhu Evropské unie mělo na český zahraniční obchod významný vliv. Zahraniční bilance se zbožím dosahovala ve většině let po vstupu kladného salda. V roce 2018 to bylo 123,5 mld. Kč. Obchod s EU se podílel v roce 2018 z 84 % na celkovém vývozu a z 67 % na celkovém dovozu. Bilance přebytků se zeměmi EU 28 dosahovala v roce 2018 692,2 mld. Kč oproti 244,7 mld. Kč v roce 2004. Export směřoval nejčastěji do Německa, v roce 2018 tam směřovala třetina vyváženého zboží, a v komoditách vedl vývoz motorových vozidel. V oblasti dovozu je naším nejvýznamnějším partnerem také Německo. V roce 2018 z něj pocházela čtvrtina českého importu. Se státy mimo EU má ČR dlouhodobě zápornou bilanci, na níž se odráží především dovoz surovin, zejména ropy a zemního plynu. Tento deficit se zvýšil z -270 mld. Kč v roce 2004 na -549,8 mld. Kč v roce 2018. Z komoditního pohledu rostly nejvýrazněji přebytky obchodu s motorovými vozidly, jež vzrostly z 144,5 mld. Kč v roce 2005 na 442,4 mld. Kč v roce 2018. Záporná bilance se nejvíce prohlubovala u skupiny ropa a zemní plyn, u níž vzrostla z -112,9 mld. Kč v roce 2005 na -130,7 mld. Kč v roce 2018. Motorová vozidla tvořila nejvýraznější komoditu dovozu i vývozu (Český statistický úřad, 2019).

4.10.3 Historický vývoj agrárního zahraničního obchodu ČR před vstupem do EU

V porevolučních letech 1993 – 2001 výrazně klesal význam agrárních komodit v rámci celkového zahraničního obchodu ČR a to přesto, že hodnota vývozu i dovozu agrárních produktů vzrůstala, přičemž dynamika nárůstu dovozu byla v porovnání s vývozem vyšší. Hlavním problémem českého agrárního zahraničního obchodu byl především nepříznivý vývoj komoditní struktury českého vývozu. Nejvýznamnější exportní surovinou bylo sušené mléko, jehož vývoz však musel být subvencován a tudíž pozitivní efekt vývozu nebyl velký. Vývoz

³⁷ Standard International Trade Classification

tradičních exportních agrárních komodit, jež těžily z někdejších komparativních výhod a mezi které se řadilo např. pivo, chmel či slad, stagnoval. Mezi hlavní dovozní komodity patřilo ovoce, zelenina, krmiva, což byly stejné komodity, jež se podílely na generování pasivního salda i v předrevolučních letech. Růst dovozu se týkal především nejvyspělejších zemí, zatímco růst exportu směřoval především na trhy méně vyspělých zemí. Nejdůležitějším partnerem ČR byla v oblasti dovozu EU, jež se na celkovém dovozu do ČR podílela z 50 procent. V oblasti vývozu se nejdůležitějším partnerem stala v roce 1998 skupina zemí CEFTA³⁸. V době, kdy ČR vstupovala do Evropské Unie, tvořil podíl EU na našem vývozu 39 procent a podíl skupiny CEFTA 44 procent. Obecně dynamika růstu českého agrárního exportu zaostávala jak za tempem růstu mezinárodního obchodu, tak i za tempem růstu agrárního vývozu srovnatelných ekonomik (Smutka et al., 2011).

V období před vstupem ČR do EU došlo k určité liberalizaci vzájemného obchodu. V roce 1998 vešel v platnost Dodatkový protokol k Evropské dohodě o úpravách obchodních aspektů mezi ČR a ES a v roce 2000 začala platit tzv. „dvou-nulová varianta“, která zavedla bezcelní obchod bez množstevního omezení pro méně citlivé zemědělské výrobky a preferenční kvóty s možností či bez možnosti poskytování exportních subvencí. Liberalizace obchodu vedla k vývoji hodnotových i množstevních ukazatelů agrárního zahraničního obchodu ve prospěch EU, zatímco schodek agrárního zahraničního obchodu ČR se rychle prohluboval, což bylo mimo jiné způsobeno poklesem průměrné kilogramové ceny vývozu, nárůstem dovozních cen a vyšší úrovní užívání preferenčních celních kvót na straně EU (Smutka et al., 2011).

4.10.4 Vývoj agrárního zahraničního obchodu ČR po vstupu do EU

Po vstupu ČR na jednotný trh EU se výrazně zjednodušily podmínky obchodu s členskými zeměmi a zároveň se výrazně zvýšila ochrana domácího trhu vůči třetím zemím. Došlo také k výraznému zostření konkurenčních podmínek jako důsledku odstranění celních překážek, různých cenových úrovní v zemích EU, meziročních pohybů průměrných cen řady významných agrárních komodit a kolísání kurzu Kč vůči Euru. Po vstupu do EU docházelo ke stálému navyšování bilančního schodku a celkový vývoj agrárního zahraničního obchodu nebyl pozitivní (Smutka et al., 2011).

Po vstupu do EU došlo k nárůstu hodnoty dovozu vepřového, hovězího a drůbežího masa, sýrů, vína, destilátů, přípravků k výživě zvířat a limonád. Na růstu hodnoty vývozu se podílel

³⁸ Středoevropská dohoda o volném obchodu

především vývoz živého (jatečního skotu), nezahuštěného mléka, obilovin, řepky a cukru. Došlo také ke zvýšení obchodního obrátu u výrobků a polotovarů, které podléhají striktně obchodním záměrům nadnárodních společností (pekařské zboží, oplatky, sušenky, cukrovinky, čokoláda a ostatní přípravky s kakaem). Dalším jevem byl růst disproporce mezi zbožovou skladbou vývozu a dovozu z hlediska míry přidané hodnoty. V roce 2005 činila průměrná kilogramová cena exportu 7,8 Kč, zatímco v oblasti dovozu činila 22,7 Kč. Na ústupu byl i obchod se třetími zeměmi, jelikož se značná část operací realizovaná na jejich trzích přesunula na liberalizovaný trh EU. Z rozšíření EU v roce 2004 profitovali především vývozci ze států EU 15 a z nových členských států především Polsko. V agrárním dovozu ČR hrálo nejvýznamnější roli Německo, Polsko, Rakousko, Slovensko a Maďarsko. (Smutka et al., 2011).

4.10.5 Teritoriální struktura českého AZO před a po vstupu ČR do EU

Dominantní postavení, co se týká českého agrárního exportu, mají staré členské země EU (EU15) a nové členské země EU (EU12). V období čtyř let před vstupem ČR do EU se podíl zemí EU 15 na českých agregátních exportech meziročně zvyšoval cca o 4 %, zatímco podíl budoucích zemí EU 12 se navyšoval ročně pouze o 0,1%. Po vstupu ČR do EU se tento vývojový trend zcela otočil a podíl zemí EU 15 se meziročně v průměru navyšoval o 0,86%, zatímco podíl EU 12 rostl průměrně o 2,47 % (Smutka et al., 2011).

Zatímco podíl starých i nových členských zemí EU na českém agrárním exportu rostl, podíly ostatních teritorií neustále klesaly. V letech 2000 až 2009 poklesl podíl SNS³⁹ na celkovém agrárním exportu ČR z 8,4 % na 2,7 %, rozvojových zemí z 5,5 % na 2,2% a ostatních vyspělých zemí z 2,6 % na 1,7 %. V roce 2009 dosáhl podíl třetích zemí na celkovém českém exportu historického minima. Výjimku tvořily země ESVO⁴⁰, jejichž podíl se po našem vstupu do EU zvýšil o 100 %, což bylo dáno především tím, že tyto země jsou součástí jednotného trhu EU (Smutka et al., 2011).

V letech 2000 až 2009 byl zaznamenán také neustálý růst podílu zemí EU na českém agrárním dovozu, přičemž jejich podíl vzrostl o 11,5 %. Před vstupem ČR do EU činil podíl zemí EU 15 6,6 % a podíl zemí EU 12 2,6 %. Stejně jako v případě vývozu došlo po vstupu do EU k otočení tohoto trendu. V letech 2005 – 2007 bylo průměrné meziroční tempo růstu podílu zemí EU 15 na celkovém agrárním dovozu ČR 17,3 %, zatímco v případě EU 12 se pohybovalo

³⁹ Společenství nezávislých států

⁴⁰ Evropské sdružení volného obchodu (ESVO, anglicky European Free Trade Association – EFTA)


na úrovni cca 19,2 %. Podíl ostatních teritorií, s výjimkou zemí ESVO, na českém importu soustavně klesal. Nejrapidnější pokles byl zaznamenán u rozvojových zemí a ostatních vyspělých států, jejichž podíl během let 2000 až 2009 klesl o polovinu (Smutka et al., 2011).

4.10.6 Komoditní struktura českého AZO před a po vstupu ČR do EU

Nejdůležitější vývozní agregací byla v letech 2001 až 2003 agregace KN 04 „Mléko, mléčné výrobky, vejce a med, jejíž podíl na českém agrárním vývozu činil před vstupem do EU v letech 2001 až 2003 13,7 % a po vstupu do EU, v letech 2007 až 2009, činil 13,9 %. Druhé nejvýznamnější postavení patřilo vývozní agregaci KN 22 „Nápoje a lihoviny“ s podílem 10 %. Mezi další významné vývozní agregace patřila agregace KN 21 „Různé potravinové přípravky“ s podílem 8,5 % v letech 2007 až 2009, agregace KN 10 „Obiloviny“, jejíž podíl vzrostl z 3,5 % v letech 2001 až 2003 na 7,9 % v letech 2007 až 2009 a agregace KN 01 „Živá zvířata“ a KN 19 „Přípravky z obilí“, jenž si udržely v letech 2007 až 2009 5 % podíl, jímž disponovaly i v letech 2001 až 2003 (Smutka et al., 2011).

Komoditní struktura českého AZO v období 2007 – 2009 se ve srovnání s předvstupním obdobím příliš nezměnila, s výjimkou komoditní agregace KN 02 „Maso a droby, a změny v jejich procentuálním podílu na celkových agrárních dovozech představují difference v řádu desetin procentních bodů. K mimořádně veliké strukturální změně došlo u agregace KN 02 „Maso a droby“. V letech 2001 až 2003 se podílela tato agregace na celkové hodnotě agrárního dovozu 4,2 %. Po vstupu do EU vzrostl její podíl na 9,1 % v letech 2004 až 2007 a na 10,8 % v letech 2007 až 2009. Agregace KN 02, tak zaujala místo největší dovozní agregaci českého agrárního dovozu. V letech 2004 až 2006 byl průměrný roční hodnotový objem dovozů masa a drobů na úrovni 9,3 mld. Kč a v letech 2007 až 2009 činil 14 mld. Kč. Tyto hodnoty velkou mírou přispívaly k záporné bilanci agrárního zahraničního obchodu ČR. Své postavení si po vstupu do EU udržely i agregace KN 08 „Ovoce, ořechy“ s 10,5% podílem v letech 2004 až 2006 a 8,6% v letech 2007 až 2009, KN 21 „Různé potravinové přípravky“ s podílem 8,3 % v letech 2004 až 2006 a 7,9 % v letech 2007 až 2009, KN 07 „Zelenina“ a KN 23 „Zbytky a odpady, krmiva“ s podílem 7 % v letech 2007 až 2009, KN 22 „Nápoje a lihoviny“ s podílem 6,4 %, KN 19 „Přípravky s obilí“ a KN 18 „Kakao a kakaové přípravky s podílem 5 %. V letech 2006 až 2009 došlo k dynamickému nárůstu agregace KN 04 „Mléko a mléčné výrobky“ a dosáhla 8 % podílu na celkových agrárních dovozech. Vývoj obchodních bilancí AZO za konkrétní agregace je znázorněn v grafu č.1 (Smutka et al., 2011).

Obrázek 6: Vývoj bilance českého AZO za vybrané agregace



zdroj: Statistika zahraničního obchodu ČSÚ

4.10.7 Současný vývoj a struktura agrárního zahraničního obchodu ČR

Záporná bilance agrárního zahraničního obchodu (AZO) ČR vzrostla v roce 2019 meziročně o 13,2 %, kdy se v absolutním čísle zvýšil schodek AZO z 41,7 mld. Kč na 47,2 mld. Kč. Zároveň však byla dynamika prohloubení schodku v roce 2019 téměř poloviční oproti roku 2018. Výrazně se v roce 2019 meziročně zvýšila zejména záporná bilance AZO ČR se zeměmi EU, a to z 25,3 mld. Kč na 30,3 mld. Kč. Záporná bilance AZO ČR se třetími zeměmi se snížila v menší míře, pokračovala v trendu několika předchozích let, a klesla z 15,7 mld. Kč na 16,4 mld. Kč (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

V roce 2019 dosáhl vývoz agrárního zboží z ČR hodnoty 197,3 mld. Kč, což bylo o 11 mld. Kč více než v roce 2018. Hodnota dovozu vzrostla meziročně o 7,2 % (16,5 mld. Kč) na 244,5 mld. Kč. Stupeň krytí dovozu vývozem se meziročně snížil o 1 procentní bod na 80,7 %. V případě srovnání AZO ČR v roce 2019 s rokem 2009 roste export ČR do třetích zemí

dynamičtější než export do zemí EU (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

Nejsignifikantnější zlepšení bilance v celkovém AZO ČR vykázaly v roce 2019 cigarety (meziroční nárůst 1418,3 mil. Kč), semena (meziroční nárůst 991,1 mil. Kč), řepka (meziroční nárůst 559,2 mil. Kč), řepkový olej (meziroční nárůst 599,2 mil. Kč) a pivo (meziroční nárůst 564,7 mil. Kč). Nejvýraznější zhoršení nastalo u vepřového masa (meziroční pokles o 2128 mil. Kč), tvarohových náhražek (meziroční pokles o 950 mil. Kč), sýrů a tvarohu (meziroční pokles 787,5 mil. Kč) a brambor (meziroční pokles 745,6 mil. Kč) (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

Celkový AZO ČR zaznamenal v roce 2019 historicky nejvyšší schodek a na jeho utvoření se významně podílelo zvýšení dovozu vepřového masa a tabákových náhražek. Zároveň byl zaznamenán meziroční nárůst agrárního exportu ČR ve většině zemí, kde působí agrární diplomaté ČR. Agrární zboží participovalo v roce 2019 na celkovém zahraničním obchodu ČR na straně vývozu 4,3 % a na straně dovozu 6 % (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

Teritoriální struktura

Nejdůležitějšími destinacemi v rámci EU, do nichž směřovalo agrární zboží z ČR v roce 2019, byly Slovensko (21,8 %), Německo (20,3%), Polsko (9,9 %), Itálie (8,8%), Rakousko (5,5%) a Maďarsko (5,0%). Mezi nejdůležitější cíle českého exportu v rámci trhu třetích zemí patřilo Rusko (1,8 %), Čína (0,8 %), Japonsko (0,6 %), Turecko (0,6 %), USA (0,4 %) a Ukrajina (0,4 %) (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020; Ročenka agrárního zahraničního obchodu ČR za rok 2018, 2019).

Český agrární dovoz pocházel v roce 2019, co se týká EU, především z Německa (22,2 %), Polska (15,7 %), Nizozemska (6,8 %), Slovenska (6,6 %), Španělsko (5,9 %) a Itálie (5,7 %). Mezi hlavní dovozce z třetích zemí patřila Čína (1,4 %), USA (1 %), Turecko (1,0 %), Ukrajina (0,9 %) a Norsko (0,7 %) (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

Z teritoriálního pohledu došlo k nejvýraznějšímu zlepšení bilance AZO ČR v obchodě s Itálií, Slovenskem, Spojeným královstvím a Ruskem. Zhoršení bilance bylo zaznamenáno v obchodu s Německem, Belgií, Rumunskem a Nizozemskem.

Komoditní struktura

Mezi agrární položky, které se v roce 2019 nejvíce vyvážely, patřily cigarety, přípravky používané k výživě zvířat, pekařské zboží, potravinové přípravky, nezahuštěné mléko a smetana, pšenice a pivo. Hlavním dováženým agrárním zbožím do ČR bylo vepřové maso, pekařské zboží, sýry a tvaroh, potravinové přípravky a cigarety (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

Podrobnější čtvrtletní údaje o nejvíce vyvážených a dovážených agrárních položkách v letech 2014 až 2019 se nachází v tabulkách přílohy č. 1 této práce.

Aktuální stav českého zemědělství

Celková produkce českého zemědělství v roce 2019 vzrostla meziročně o 9 mld. Kč a dosáhla výše 151 mld. Kč. Čistý zisk zemědělského sektoru činil 19 mld. Kč, přičemž objem vyplacených dotací jej převyšoval dvojnásobně. Na lepším výsledku se příznivě projevila dobrá sklizeň ozimých obilovin, kukuřice, brambor, chmele, máku, zelí, mrkve, meruněk a třešní. V roce 2019 byly pro zemědělce pozitivní ceny obilovin, chmele a většiny druhů zeleniny. V oblasti živočišné výroby mírně klesly ceny živého skotu, ceny prasat vzrostly a ceny drůbeže stagnovaly. Zemědělcům vzrostly meziročně celkové náklady o 6 mld. a dosáhly výše 175 mld.. Tento nárůst měly na svědomí především rostoucí platy a také vyšší nájmy za půdu a budovy (Výsledky agrárního zahraničního obchodu ČR v roce 2019, 2020).

5. Vlastní práce

Tato část práce se zabývá modelováním závislosti vývoje vývozu pšenice, vývozu hovězího masa a vývozu mléka z České republiky na vybraných determinantech. Pro modelování závislostí byly použity jednorovnicové ekonometrické modely a třívrstvá neuronová síť, jejíž program byl sestaven v programovacím jazyce Python. Tyto dva přístupy a teoretické hodnoty jimi generované budou v závěru práce porovnány. V případě vývozu pšenice a jejich determinantů budou porovnány i bodové prognózy ekonometrického modelu s predikcemi neuronové sítě. Modelování závislosti probíhalo na základě měsíčních dat, jež byla zvolena především z důvodu možnosti srovnání ekonometrických modelů s technikou neuronových sítí, která vyžaduje větší množství záznamů. Podkladová data pochází z databází ČSÚ a Eurostatu a jsou obsahem přílohy č. 2 ve formě souboru formátu XLS⁴¹.

5.1 Analýza vybraných determinantů vývozu pšenice z ČR

5.1.1 Jednorovnicový ekonometrický model vývozu pšenice z ČR

Uvažovanými determinanty vývoje vývozu pšenice z ČR byly: fakt, zda probíhaly devizové intervence ČNB či ne, vývoj světové ceny pšenice a vývoz pšenice v předchozích obdobích. Podkladová data měla charakter měsíčních časových řad za roky 2005-2019. Pro modelování závislosti proměnných byly uvažovány dva ekonometrické modely, lineární a mocninný model.

Ekonomický model

Závisle proměnná:

y_1 Vývoz pšenice z ČR v čase t [t]

Nezávisle proměnné:

x_2 Průběh devizových intervencí

$x_{3,t-p}$ ⁴²..... Světová cena pšenice v předchozích obdobích [USD/t]

$y_{1,t-p}$ Vývoz pšenice z ČR v předchozích obdobích [t]

⁴¹ XLS je přípona souborů vytvořených v aplikaci Microsoft Excel.

⁴² p reprezentuje zpoždění časové řady

Formulace ekonomického modelu:

$$y_1 = f(x_2, x_{3,t-p}, y_{1,t-p})$$

5.1.1.1 Ekonomické předpoklady

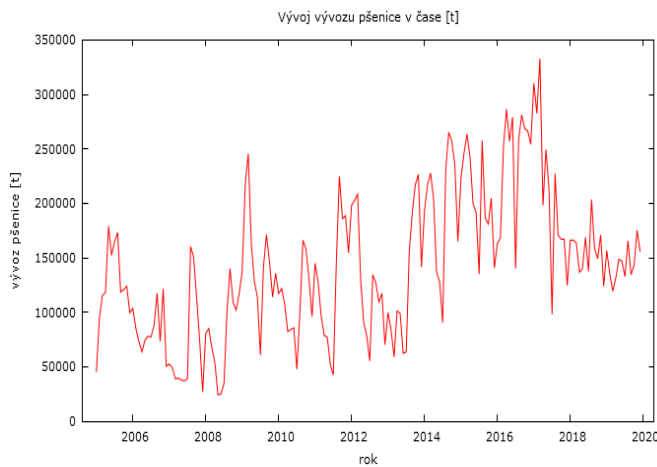
Devizové intervence - Průběh devizových intervencí ČNB, jako nástroje měnové politiky, by měl mít pozitivní vliv na vývoz pšenice z ČR. Bankovní rada ČNB se rozhodla zahájit devizové intervence 7. listopadu 2013 a trvaly do 6. dubna 2017. Cílem ČNB bylo oslabit korunu kvůli hrozící deflaci. Cíl byl naplňován pomocí nákupu cizích měn a prodejem korun. Tímto krokem ČNB pomohla českému exportu, který se tak stal pro zahraničí levnějším a tedy konkurenceschopnějším (Patria.cz, 2018).

Světová cena pšenice - Růst světové ceny pšenice by měl mít pozitivní vliv na vývoz této komodity, kdy je její vývoz motivován vyšší cenou na zahraničních trzích. Pšenice je obchodována spekulanty jako technická komodita a tedy její vyšší cena by měla být spouštěčem realizace prodejů této komodity. Pšenice je také jedním ze zemědělských produktů, jež slouží k výrobě biopaliv, jejichž cena a jejím prostřednictvím i cena pšenice, je ovlivňována cenami energií, především cenami ropy.

Vývoz pšenice – Ačkoli se v České republice pěstuje pšenice na jedné třetině osevních ploch, není dosaženo soběstačnosti, což je zapříčiněno tím, že je velká část vypěstované hrubé suroviny vyvážena za hranice. To má za následek, že % zrna semletého na území ČR klesá, s mírnými výkyvy, od roku 2005. Motivací českých zemědělců prodávat pšenici do zahraničí jsou především obchodní a komerční důvody, kdy zemědělci v zahraničí realizují vyšší cenu za obilí, než je tomu na tuzemském trhu. Část produkce pšenice je nasmlouvaná dopředu zahraničními mlýny a na ně navazujícím pekárenským průmyslem. U vývozu pšenice se vyskytuje vysoká míra setrvačnosti, což je dáno tím, že vývoz závisí na sobě samém v předchozích obdobích. Krátkodobou setrvačnost je možno kvantifikovat pomocí zpožděné proměnné vývoz pšenice v předchozím období, dlouhodobou setrvačnost pak pomocí celkového vlivu všech statisticky významných zpoždění této proměnné.

5.1.1.2 Testování stacionarity časových řad

Graf 1: Časová řada vývozu pšenice z ČR

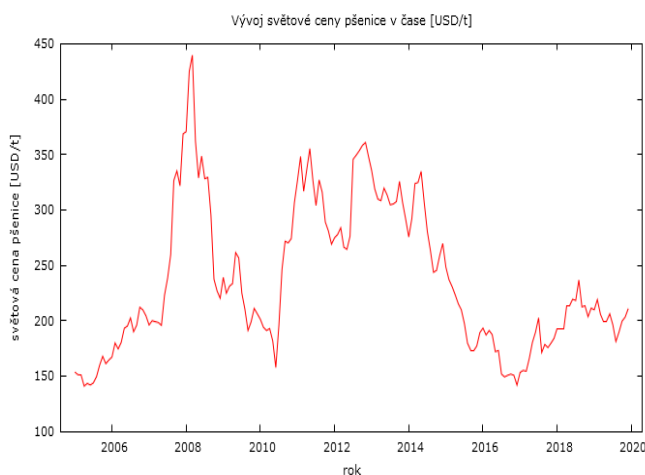


Rozšířený Dickey-Fullerův test pro vyvoz_psenice
testing down from 13 lags, criterion AIC
počet pozorování 167
nulová hypotéza jednotkového koefienu: $a = 1$

s konstantou a trendem
s použitím 12 zpožděných proměnných (1-L)vyvoz_psenice
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,217081
testovací statistika: $\tau_{ct}(1) = -2,72285$
asymptotická p-hodnota 0,2271
autokorelační koeficient 1. řádu pro e: -0,020
zpožděné diference: $F(12, 152) = 7,756 [0,0000]$

zdroj: Gretl, vlastní zpracování

Graf 5: Časová řada světové ceny pšenice



Rozšířený Dickey-Fullerův test pro svcena_psenice
testing down from 13 lags, criterion AIC
počet pozorování 172
nulová hypotéza jednotkového koefienu: $a = 1$

s konstantou a trendem
s použitím 7 zpožděných proměnných (1-L)svcena_psenice
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,0643508
testovací statistika: $\tau_{ct}(1) = -2,79586$
asymptotická p-hodnota 0,1987
autokorelační koeficient 1. řádu pro e: -0,006
zpožděné diference: $F(7, 162) = 3,365 [0,0022]$

zdroj: Gretl, vlastní zpracování

Z výše uvedených grafů vyplývá, že časové řady vývozu pšenice z ČR a světové ceny pšenice jsou nestacionární, což v obou případech dosvědčuje i p-hodnota Dickey-Fullerova testu, která je větší jak hladina významnosti 0,05. V obou případech nedošlo k zamítnutí H_0 na 5% hladině významnosti ve prospěch alternativní hypotézy a lze tedy říci, že časové řady jsou nestacionární.

5.1.1.3 Specifikace a kvantifikace modelu

Obrázek č. 7 níže obsahuje výstup metody BMNČ ze softwaru Gretl pro výchozí lineární model, do nějž byly zahrnuty všechny uvažované nezávisle proměnné. Obrázek č. 8 obsahuje výstup pro finální lineární model, k jehož specifikaci bylo použito metody sestupného výběru regresorů.

Obrázek 7: Výchozí lineární ekonometrický model vývozu pšenice (vlevo)

Obrázek 8: Finální lineární ekonometrický model vývozu pšenice (vpravo)

Model 2: OLS, za použití pozorování 2006:01-2019:12 (T = 168)
Závisle proměnná: vyvoz_psenice

	koeficient	směr. chyba	t-podíl	p-hodnota
const	8826,34	20719,2	0,4260	0,6707
intervence_dummy	31149,4	8421,41	3,699	0,0003 ***
scena_psenice	181,149	147,343	1,229	0,2208
scena_psenice_t_1	-260,085	148,135	-1,756	0,0812 *
scena_psenice_t_12	158,397	48,2579	3,282	0,0013 ***
vyvoz_psenice_t_1	0,562100	0,0774800	7,255	1,96e-011 ***
vyvoz_psenice_t_2	-0,0236082	0,0897808	-0,2630	0,7929
vyvoz_psenice_t_3	0,0504924	0,0893673	0,5650	0,5729
vyvoz_psenice_t_4	-0,245665	0,0875477	-2,806	0,0057 ***
vyvoz_psenice_t_5	0,407411	0,0854828	4,766	4,38e-06 ***
vyvoz_psenice_t_6	-0,144537	0,0910547	-1,597	0,1145
vyvoz_psenice_t_7	0,0775908	0,0908966	0,8536	0,3947
vyvoz_psenice_t_8	-0,309992	0,0853871	-3,630	0,0004 ***
vyvoz_psenice_t_9	0,220905	0,0874907	2,525	0,0126 **
vyvoz_psenice_t_10	-0,150544	0,0894661	-1,683	0,0945 *
vyvoz_psenice_t_11	0,0499363	0,0894652	0,5582	0,5776
vyvoz_psenice_t_12	0,265798	0,0734356	3,619	0,0004 ***
Střední hodnota závisle proměnné	144338,9			
Sm. odchylka závisle proměnné	67995,87			
Součet čtverců reziduí	1,72e+11			
Sm. chyba regrese	33710,24			
Koeficient determinace	0,777762			
Adjustovaný koeficient determinace	0,754213			
F(16, 151)	33,02817			
P-hodnota(F)	3,40e-41			
Logaritmus věrohodnosti	-1980,914			
Akaikovo kritérium	3995,827			
Schwarzovo kritérium	4048,935			
Hannan-Quinnovo kritérium	4017,381			
rho (koeficient autokorelace)	0,085299			
Durbin-Watsonova statistika	1,824637			

zdroj: Gretl, vlastní zpracování

Model 1: OLS, za použití pozorování 2006:01-2019:12 (T = 168)
Závisle proměnná: vyvoz_psenice

	koeficient	směr. chyba	t-podíl	p-hodnota
const	-11394,5	15274,7	-0,7460	0,4568
intervence	30106,1	8323,02	3,617	0,0004 ***
sv_cena_psenice_~	133,698	44,9679	2,973	0,0034 ***
vyvoz_psenice_t_1	0,567287	0,0594499	9,542	2,41e-017 ***
vyvoz_psenice_t_4	-0,200609	0,0734974	-2,729	0,0071 ***
vyvoz_psenice_t_5	0,324539	0,0695876	4,664	6,54e-06 ***
vyvoz_psenice_t_8	-0,300384	0,0697168	-4,309	2,87e-05 ***
vyvoz_psenice_t_9	0,158475	0,0743384	2,132	0,0346 **
vyvoz_psenice_t_12	0,260957	0,0533289	4,893	2,41e-06 ***
Střední hodnota závisle proměnné	144338,9			
Sm. odchylka závisle proměnné	67995,87			
Součet čtverců reziduí	1,82e+11			
Sm. chyba regrese	33822,57			
Koeficient determinace	0,764425			
Adjustovaný koeficient determinace	0,752572			
F(8, 159)	64,49310			
P-hodnota(F)	4,95e-46			
Logaritmus věrohodnosti	-1985,809			
Akaikovo kritérium	3989,618			
Schwarzovo kritérium	4017,734			
Hannan-Quinnovo kritérium	4001,029			
rho (koeficient autokorelace)	0,087979			
Durbin-Watsonova statistika	1,818061			

zdroj: Gretl, vlastní zpracování

Finální podoba modelu obsahuje oproti výchozímu modelu pouze nezávislé proměnné, které jsou statisticky významné. Jedná se o proměnné intervence ČNB v čase t, světová cena pšenice v čase t-12 a vývoz pšenice z ČR v obdobích t-1,t-4,t-5,t-8,t-9 a t-12. Oproti výchozímu modelu došlo ke zmenšení směrodatných chyb odhadů regresních parametrů těchto proměnných a tedy k jejich přesnějším odhadu a k poklesu hodnot informačních kritérií.

Obrázek č. 9 obsahuje výstup metody BMNČ pro mocninný model, při využití regresorů vybraných pro finální lineární model.

Obrázek 9: Mocinný model vývozu pšenice


Model 1: OLS, za použití pozorování 2006:01-2019:12 (T = 168)
Závisle proměnná: ln_vyvoz_psenice

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-0,572081	1,04041	-0,5499	0,5832	
intervence	0,140553	0,0654637	2,147	0,0333	**
ln_vyvoz_pseni~_1	0,552103	0,0575747	9,589	1,81e-017	***
ln_vyvoz_pseni~_4	-0,147052	0,0726826	-2,023	0,0447	**
ln_vyvoz_pseni~_5	0,273355	0,0691453	3,953	0,0001	***
ln_vyvoz_pseni~_8	-0,218653	0,0697309	-3,136	0,0020	***
ln_vyvoz_pseni~_9	0,0936109	0,0730965	1,281	0,2022	
ln_vyvoz_psen~_12	0,331378	0,0534249	6,203	4,61e-09	***
ln_sv_cena_pseni~	0,348956	0,0930181	3,751	0,0002	***
Střední hodnota závisle proměnné		11,74823			
Sm. odchylka závisle proměnné		0,552019			
Součet čtverců reziduí		12,71402			
Sm. chyba regrese		0,282776			
Koeficient determinace		0,750162			
Adjustovaný koeficient determinace		0,737591			
F(8, 159)		59,67647			
P-hodnota(F)		5,01e-44			
Logaritmus věrohodnosti		-21,55595			
Akaikovo kritérium		61,11190			
Schwarzovo kritérium		89,22757			
Hannan-Quinnovo kritérium		72,52261			
rho (koeficient autokorelace)		0,101773			
Durbin-Watsonova statistika		1,780736			


zdroj: Gretl, vlastní zpracování

Graf 12: Grafické znázornění empirických a teoretických hodnot lineárního ekonometrického modelu vývozu pšenice (vlevo)

Graf 13: Grafické znázornění empirických a teoretických hodnot mocinného ekonometrického modelu vývozu pšenice (vpravo)



zdroj: Gretl, vlastní zpracování



zdroj: Gretl, vlastní zpracování

Pro potřeby porovnání lineárního a mocinného modelu byla použita pomocná proměnná y^* , jež je geometrickým průměrem závisle proměnné (vývoz pšenice) a jejíž hodnoty jsou uvedeny v příloze č. 2. V tabulce níže jsou uvedeny součty čtverců reziduí lineárního a mocinného modelu při použití proměnné y^* , resp. $\ln(y^*)$ jako závisle proměnné.

Tabulka 1: Součty čtverců reziduí při použití proměnné y^* - lineární a mocninný model vývozu pšenice

model	Lineární model při použití y^*	Mocninný model při použití $\ln(y^*)$
SSR	11,36120	12,71402

zdroj: Gretl, vlastní zpracování

V tomto případě je $SSR_{LOG} > SSR_{LIN}$ a hodnota testovací statistiky LL_2 je 0,0029762. Platí, že $LL_2 < 3.841$ (kritická hodnota) a nebylo tedy možné na 5% hladině významnosti zamítnout H_0 , jejíž propozice je, že lineární i mocninný model vyrovnávají empirická data stejně. Pro potřeby této práce bude dále, s ohledem na hodnotu statistiky SSR, využíván lineární ekonometrický model.

Tabulka 2: Deklarace proměnných ekonometrického modelu vývozu pšenice z ČR

Označení	Proměnná	Typ proměnné	Jednotky
y_1	Vývoz pšenice v čase t	Endogenní	tuny
x_1	jednotkový vektor	-	-
x_2	Devizové intervence v čase t	Dummy	[0,1]
x_3	Světová cena pšenice v čase $(t-12)$	Predeterminovaná	USD/tuna
$y_{1,(t-1,t-4,t-5,t-8,t-9,t-12)}$	Vývoz pšenice z ČR v čase $(t-1,t-4,t-5,t-8,t-9,t-12)$	Predeterminované	tuny
u_t	náhodná proměnná	Stochastická	tuny

zdroj: vlastní zpracování

Odhadnutá podoba lineárního ekonometrického modelu prostřednictvím BMNČ:

$$y_{1t} = -11394,5 + 30106,1x_2 + 133,698x_3 + 0,567287y_{1,t-1} - 0,200609y_{1,t-4} + 0,324539y_{1,t-5} - 0,300384y_{1,t-8} + 0,158475y_{1,t-9} + 0,260957y_{1,t-12} + u_{1t}$$

5.1.1.4 Verifikace modelu

Ekonomická verifikace

Interpretace $\gamma_2 = 30106,1$: Průběh devizových intervencí ČNB v čase t , zvýší vývoz pšenice z ČR v čase t o 30106,1 tun, za podmínky ceteris paribus.

Interpretace $\gamma_3 = 133,698$: Zvýší-li se světová cena za tunu pšenice v čase $(t-12)$ o 1 USD, pak vzroste vývoz pšenice z ČR v čase t o 133,698 tun, za podmínky ceteris paribus.

Interpretace $\gamma_4 = 0,567287$: Zvýší-li se vývoz pšenice v čase $(t-1)$ o 1 tunu, pak se zvýší vývoz pšenice z ČR v čase t o 0,567287 tun, za podmínky ceteris paribus.

Interpretace $\gamma_5 = -0,200609$: Zvýší-li se vývoz pšenice v čase (t-4) o 1 tunu, pak klesne vývoz pšenice z ČR v čase t o 0,200609 tun, za podmínky ceteris paribus.

Interpretace $\gamma_6 = 0,324639$: Zvýší-li se vývoz pšenice v čase (t-5) o 1 tunu, pak se zvýší vývoz pšenice z ČR v čase t o 0,324639 tun, za podmínky ceteris paribus.

Interpretace $\gamma_7 = -0,300384$: Zvýší-li se vývoz pšenice v čase (t-8) o 1 tunu, pak klesne vývoz pšenice z ČR v čase t o 0,300384 tun, za podmínky ceteris paribus.

Interpretace $\gamma_8 = 0,158475$: Zvýší-li se vývoz pšenice v čase (t-9) o 1 tunu, pak vzroste vývoz pšenice z ČR v čase t o 0,158475 tun, za podmínky ceteris paribus.

Interpretace $\gamma_9 = 0,260957$: Zvýší-li se vývoz pšenice v čase (t-12) o 1 tunu, pak se zvýší vývoz pšenice z ČR v čase t o 0,260957 tun, za podmínky ceteris paribus.

Pozitivní vliv vývozu pšenice v čase (t-1) na hodnotu tohoto ukazatele v čase t, můžeme vysvětlit jako krátkodobou setrvačnost vývoje tohoto ukazatele. Celkový vliv všech zpoždění proměnné vývoz pšenice v modelu je takový, že pokud se zvýší všechny zpožděné proměnné o 1 tunu, za podmínky ceteris paribus, pak vzroste vývoz pšenice v čase t o 0,810265 tun, což můžeme vysvětlit jako dlouhodobou setrvačnost vývoje tohoto ukazatele. Hodnoty strukturálních parametrů jednotlivých zpoždění vývozu pšenice potvrdily ekonomický předpoklad o setrvačnosti vývoje vývozu pšenice a to jak z krátkodobého, tak dlouhodobého hlediska. Různost znamének strukturálních parametrů jednotlivých zpoždění proměnné vývoz pšenice lze interpretovat jako reakci na pravidelné obnovování smluv o odběru produkce pšenice, či jejich uzavírání na určitou dobu. Záporná znaménka u strukturálních parametrů proměnných vývoz pšenice v čase (t-4) a (t-8) naznačují, že se určité % uzavřených smluv obnovovalo po 4 měsících nebo bylo uzavřeno na tuto dobu.

Hodnota strukturálního parametru proměnné devizové intervence ČNB odpovídá ekonomickému předpokladu, kdy devizové intervence oslabující korunu mají pozitivní vliv na export pšenice z ČR, jelikož činí český export levnějším na zahraničních trzích a tedy konkurenceschopnějším.

Hodnota strukturálního parametru proměnné světová cena pšenice v čase (t-12) také odpovídá ekonomickým předpokladům, kdy vyšší světová cena pšenice má pozitivní vliv na prodej této komodity, jež je obchodována na komoditních burzách. Vyšší světová cena pšenice motivuje její producenty k prodeji a zároveň motivuje k prodeji spekulanty, kteří pšenici nepěstují ani nezpracovávají, ale snaží se vydělat na kolísavé ceně. Zpoždění této proměnné o

12 měsíců lze vysvětlit faktem, že na komoditních burzách se pšenice obchoduje přes tzv. futures kontrakty⁴³, jež se využívají k zajištění cen komodit proti budoucím výkyvům. Producenti, kteří se obávají budoucího poklesu ceny pšenice, mohou svoji produkci předprodat, odběratelé si mohou sjednat pšenici s několikaměsíčním předstihem, pokud mají obavy, že cena komodity bude růst a spekulanti, kteří tvoří pomyslný most mezi těmito dvěma tábory, kontrakty na pšenici nakupují, počkají, až cena na burze vzroste a poté kontrakt se ziskem prodají.

Statistická verifikace

Jako statisticky významné vyšly na 5 procentní hladině významnosti všechny strukturální parametry.

Hodnota upraveného koeficientu determinace je $R_{upr}^2 = 0,752572$ a tedy můžeme říci, že model vysvětluje variabilitu vysvětlované proměnné z 75,25%.

Kritická hodnota F-testu je 1,997 a hodnota testovací statistiky je 64,49310. Na 5 % hladině významnosti zamítáme nulovou hypotézu ve prospěch alternativní hypotézy a můžeme tedy říci, že model je statisticky významný.

Ekonometrická verifikace (Příloha č. 3)

Použitím metody VIF⁴⁴ nebyla detekována závažná lineární závislost vysvětlujících proměnných. Z níže uvedeného výstupu vyplývá, že v modelu se nevyskytuje nežádoucí multikolinearita.

Obrázek 10: Testování multikolinearity – podkladová data lineárního ekonometrického modelu vývozu pšenice

```
Faktory zvyšující rozptyl (VIF)
Minimální možná hodnota = 1.0
Hodnoty > 10.0 mohou indikovat problém kolinearity
```

intervence	1,877
sv_cena_psenice_tmin12	1,365
vyvoz_psenice_t_1	2,391
vyvoz_psenice_t_4	3,657
vyvoz_psenice_t_5	3,280
vyvoz_psenice_t_8	3,299
vyvoz_psenice_t_9	3,753
vyvoz_psenice_t_12	1,961

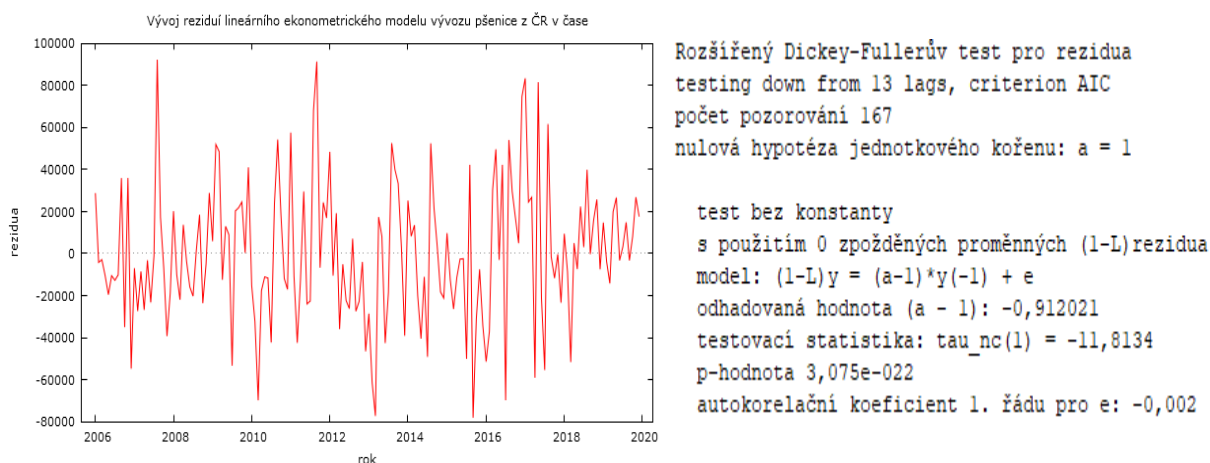
zdroj: Gretl, vlastní zpracování

⁴³ Futures kontrakt – Jedná se o dohodu dvou stran o směně určitého množství podkladového aktiva v předem určené kvalitě, za předem stanovenou cenu a k předem stanovenému datu dodání.

⁴⁴ The variance inflation factor

Z grafu č. 5, zobrazujícím průběh reziduí ekonometrického modelu vývozu pšenice, je patrná stacionarita reziduí, kterou potvrzuje i p-hodnota Dickey-Fullerova testu. Parametry ekonometrického modelu byly odhadovány na základě nestacionárních časových řad a rezidua takto odhadnutého modelu jsou stacionární. Můžeme konstatovat, že se jedná o pravou regresi, nikoliv zdánlivou.

Graf 14: Vývoj reziduí lineárního ekonometrického modelu vývozu pšenice z ČR v čase



zdroj: Gretl, vlastní zpracování

- **Autokorelace**

Testováno pomocí Breusch-Godfrey testu

H_0 : autokorelace se v modelu nevyskytuje

H_1 : autokorelace se v modelu vyskytuje

P-hodnota = 0,106221 > 0,05

Na 5% hladině významnosti nezamítáme H_0 a můžeme tedy říci, že v modelu se nevyskytuje autokorelace

- **Normalita**

Testováno pomocí testu normality reziduí

H_0 : náhodná složka má normální rozdělení

H_1 : náhodná složka nemá normální rozdělení

P-hodnota = 2,51825 > 0,05

Na 5% hladině významnosti nezamítáme H_0 a můžeme tedy říci, že náhodná složka má normální rozdělení.

- **Heteroskedasticita**

Testováno pomocí Breusch-Pagan testu

H_0 : Homoskedasticita

H_1 : Heteroskedasticita

P-hodnota = 0,130394 > 0,05

Na 5% hladině významnosti nezamítáme H_0 ve prospěch alternativní hypotézy a můžeme tedy říci, že rozptyl náhodných složek se neliší v rámci jednotlivých pozorování (Homoskedasticita).

- **Vhodnost funkční formy modelu**

Testováno pomocí Reset testu

H_0 : Model vykazuje správnou specifikaci

H_1 : Model nevykazuje správnou specifikaci

P-hodnota = 0,137857 > 0,05

Na 5% hladině významnosti nezamítáme H_0 ve prospěch alternativní hypotézy a můžeme tedy říci, že model vykazuje správnou specifikaci.

5.1.1.5 Aplikace modelu v podobě strukturální analýzy

Tabulka 3: Koeficienty pružnosti pro lineární ekonometrický model

Proměnná	Elasticita (%)
Světová cena pšenice v čase (t-12) (x_3)	0,22
Vývoz pšenice z ČR v čase (t-1) ($y_{1,t-1}$)	0,57
Vývoz pšenice z ČR v čase (t-4) ($y_{1,t-4}$)	-0,2
Vývoz pšenice z ČR v čase (t-5) ($y_{1,t-5}$)	0,32
Vývoz pšenice z ČR v čase (t-8) ($y_{1,t-8}$)	-0,3
Vývoz pšenice z ČR v čase (t-9) ($y_{1,t-9}$)	0,16
Vývoz pšenice z ČR v čase (t-12) ($y_{1,t-12}$)	0,26

zdroj: Gretl, vlastní zpracování

Dle výše uvedených koeficientů pružnosti lze konstatovat, že reakce endogenní proměnné vývoz pšenice na změny jednotlivých predeterminovaných proměnných je nepružná a tedy se mění méně jak proporcionálně. Na vývoz pšenice v čase t má největší vliv vývoz pšenice v čase (t-1) a nejmenší vliv má vývoz pšenice v čase (t-9). Celkový procentuální vliv všech zpoždění proměnné vývoz pšenice, je takový, že pokud by se hodnoty všech těchto proměnných zvýšily o jedno procento, pak by se vývoz pšenice v čase t zvýšil o 0.81%, za podmínek ceteris paribus a reakce endogenní proměnné by byla i v tomto případě nepružná.

5.1.1.6. Bodová prognóza ex-post

V této podkapitole byla provedena bodová prognóza ex-post proměnné vývoz pšenice z ČR v měsících prvních třech čtvrtletí roku 2020. Pro potřeby bodové prognózy byl použit verifikovaný lineární ekonometrický model odhadnutý v předchozí části na měsíčních datech z let 2005 – 2019. Tato bodová prognóza byla v závěru této práce porovnána s predikcí třívrstvé neuronové sítě.


Bodová prognóza ex-post pro první 3 čtvrtletí roku 2020

Tabulka 4: Bodová prognóza ex post vývozu pšenice z ČR pro první 3 čtvrtletí roku 2020

Proměnná	Období	Výsledek bodové prognózy [t]	Skutečná hodnota [t]	% shoda
Vývoz pšenice z ČR	Leden 2020	148702,117	202218,205	73,54%
	Únor 2020	162367,727	220778,711	73,54%
	Březen 2020	167297,462	251789,766	66,44%
	Duben 2020	189526,553	261248,686	72,54%
	Květen 2020	197942,205	223486,297	88,57%
	Červen 2020	180875,938	174065,525	96,23%
	Červenec 2020	139434,407	102897,583	79,79%
	Srpen 2020	124822,287	183999,852	67,84%
	Září 2020	157304,802	209769,654	74,99%

zdroj: Gretl, vlastní zpracování

Graf 15: Bodová prognóza ex-post pro proměnnou vývoz pšenice z ČR v prvních 3 čtvrtletích roku 2020



zdroj: Gretl, vlastní zpracování

Průměrná přesnost bodových prognóz hodnot proměnné vývoz pšenice z ČR pro první 3 čtvrtletí roku 2020 je 76,4%. Nejvyšší přesnosti dosáhla prognóza pro měsíc červen, kdy byla míra shody s empirickou hodnotou 96,23%. Nejnižší přesnosti bylo dosaženo v měsíci březnu, kdy byla míra shody jen 66,44%.

5.2 Analýza vybraných determinantů vývozu hovězího masa z ČR

5.2.1 Jednorovnicový ekonometrický model vývozu hovězího masa z ČR

Uvažovanými determinanty vývoje vývozu hovězího masa z ČR byly: vývoz hovězího masa v předchozích obdobích, vývoz živého skotu z ČR a průměrná cena hovězího masa na trhu EU. Podkladová data měla charakter měsíčních časových řad za roky 2005-2019. Pro modelování závislosti proměnných byly uvažovány dva ekonometrické modely, lineární a mocninný model.

Ekonomický model

Závisle proměnná:

y_1 Vývoz hovězího masa z ČR [t]

Nezávisle proměnná:

$y_{1,t-p}$ Vývoz hovězího masa z ČR v předchozích obdobích [t]

x_2 Vývoz živého skotu z ČR [kusy]

$x_{3,t-p}$ Průměrná cena hovězího masa na trhu EU v předchozích obdobích [EUR/100 kg]

Formulace ekonomického modelu:

$$y_1 = f(y_{1,t-p}, x_2, x_{3,t-p})$$

5.2.1.1 Ekonomické předpoklady


Vývoz hovězího masa - U vývoje vývozu hovězího masa je předpokládána krátkodobá setrvačnost a to především z důvodu, že se jedná o biologický materiál, jenž je sice možno uchovávat zamrazováním, ale to je nákladné a maso to de facto znehodnocuje.

Vývoz živého skotu - V ČR převládá trend, kdy je živý skot ve velké míře vyvážen na porážku do zahraničí, místo toho, aby byl zpracováván v tuzemsku a to z důvodu vyšších nákupních cen zpracovatelských podniků na zahraničních trzích. V zahraničí zpracované maso je k nám poté dováženo ve formě hotových výrobků za cenu, které čeští výrobci nemohou konkurovat a jelikož je pro tuzemského spotřebitele stále nejdůležitější cena, jsou nuceni maso vyvážet na zahraniční trhy.

Průměrná cena hovězího masa na trhu EU - Růst průměrné ceny hovězího masa na trhu EU by měl mít pozitivní vliv na vývoz hovězího masa, kdy je vývoz této komodity motivován vyšší cenou v zahraničí.

5.2.1.2 Testování stacionarity časových řad

Graf 16: Časová řada vývozu hovězího masa z ČR



Rozšířený Dickey-Fullerův test pro vyvoz_hm
s použitím 13 zpožděných proměnných (1-L)vyvoz_hm
počet pozorování 166
nulová hypotéza jednotkového kořenu: $a = 1$

s konstantou a trendem

model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota (a - 1): -0,345964

testovací statistika: $\tau_{ct}(1) = -2,7146$

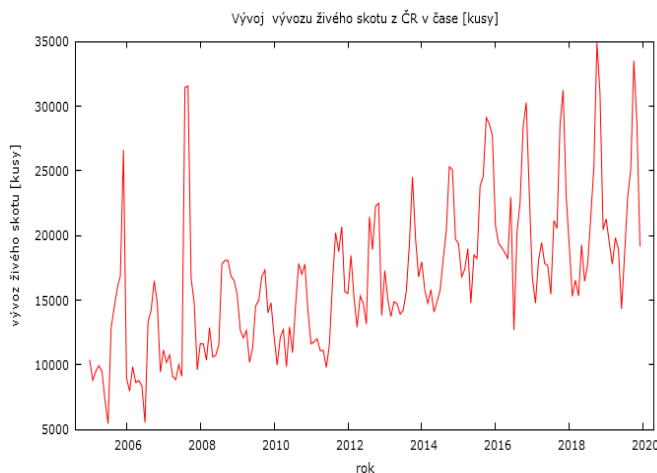
asymptotická p-hodnota 0,2305

autokorelační koeficient 1. řádu pro e: 0,003

zpožděné diference: $F(13, 150) = 0,763 [0,6979]$

zdroj: Gretl, vlastní zpracování

Graf 17: Časová řada vývozu živého skotu z ČR



Rozšířený Dickey-Fullerův test pro vyvoz_zs
testing down from 13 lags, criterion AIC
počet pozorování 167
nulová hypotéza jednotkového kořenu: $a = 1$

s konstantou a trendem

s použitím 12 zpožděných proměnných (1-L)vyvoz_zs
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota (a - 1): -0,504112

testovací statistika: $\tau_{ct}(1) = -2,59739$


asymptotická p-hodnota 0,2815

autokorelační koeficient 1. řádu pro e: 0,007

zpožděné diference: $F(12, 152) = 9,048 [0,0000]$

zdroj: Gretl, vlastní zpracování

Graf 18: Časová řada průměrné ceny hovězího masa na trhu EU



Rozšířený Dickey-Fullerův test pro hm_cena_EU
testing down from 13 lags, criterion AIC
počet pozorování 175
nulová hypotéza jednotkového koefentu: a = 1

s konstantou a trendem
s použitím 4 zpožděných proměnných (1-L)hm_cena_EU
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota (a - 1): -0,0164634
testovací statistika: tau_ct(1) = -1,30301
asymptotická p-hodnota 0,887
autokorelační koeficient 1. řádu pro e: 0,009
zpožděné diference: F(4, 168) = 5,518 [0,0003]

zdroj: Gretl, vlastní zpracování

Z výše uvedených grafů vyplývá, že časové řady vývozu hovězího masa z ČR, vývozu živého skotu z ČR a průměrné ceny hovězího masa na trhu EU jsou nestacionární, což ve všech případech dosvědčuje i p-hodnota Dickey-Fullerova testu, která je větší jak hladina významnosti 0,05. Ve všech případech nedošlo k zamítnutí H_0 na 5% hladině významnosti ve prospěch alternativní hypotézy a lze tedy říci, že časové řady jsou nestacionární.

5.2.1.3 Specifikace a kvantifikace modelu

Obrázek č. 11 níže obsahuje výstup metody BMNČ ze softwaru Gretl pro výchozí lineární model, do nějž byly zahrnuty všechny uvažované nezávisle proměnné. Obrázek č. 12 obsahuje výstup pro finální lineární model, k jehož specifikaci bylo použito metody sestupného výběru regresorů.

Obrázek 11: Výchozí lineární model vývozu hovězího masa (vlevo)**Obrázek 12: Finální lineární model vývozu hovězího masa (vpravo)**

Model 62: OLS, za použití pozorování 2005:01-2019:12 (T = 180)

Závisle proměnná: vyvoz_hm

HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)

Model 63: OLS, za použití pozorování 2005:01-2019:12 (T = 180)

Závisle proměnná: vyvoz_hm

HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-160,127	77,5581	-2,065	0,0404	**
vyvoz_hm_t_1	0,805467	0,0459522	17,53	2,75e-040	***
vyvoz_hm_t_12	0,00884543	0,00557902	1,585	0,1147	
hm_cena_EU	1,03754	1,42252	0,7294	0,4668	
hm_cena_EU_t_1	-0,532644	1,39926	-0,3807	0,7039	
vyvoz_zs	0,00626634	0,00220336	2,844	0,0050	***

Střední hodnota závisle proměnné	639,7389
Sm. odchylka závisle proměnné	288,3857
Součet čtverců reziduí	1866781
Sm. chyba regrese	103,5791
Koeficient determinace	0,874601
Adjustovaný koeficient determinace	0,870998
F(5, 174)	428,3113
P-hodnota(F)	8,86e-96
Logaritmus věrohodnosti	-1087,618
Akaikovo kritérium	2187,236
Schwarzovo kritérium	2206,394
Hannan-Quinnovo kritérium	2195,004
rho (koeficient autokorelace)	-0,152264
Durbin-Watsonova statistika	2,227522

zdroj: Gretl, vlastní zpracování

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-161,654	78,0769	-2,070	0,0399	**
vyvoz_hm_t_1	0,807566	0,0465864	17,33	6,50e-040	***
vyvoz_zs	0,00628332	0,00222008	2,830	0,0052	***
hm_cena_EU	0,520965	0,280680	1,856	0,0651	*

Střední hodnota závisle proměnné	639,7389
Sm. odchylka závisle proměnné	288,3857
Součet čtverců reziduí	1874874
Sm. chyba regrese	103,2119
Koeficient determinace	0,874058
Adjustovaný koeficient determinace	0,871911
F(3, 176)	709,0895
P-hodnota(F)	5,35e-98
Logaritmus věrohodnosti	-1088,008
Akaikovo kritérium	2184,015
Schwarzovo kritérium	2196,787
Hannan-Quinnovo kritérium	2189,193
rho (koeficient autokorelace)	-0,157987
Durbin-Watsonova statistika	2,237248

zdroj: Gretl, vlastní zpracování

Finální podoba modelu obsahuje oproti výchozímu modelu pouze nezávislé proměnné, které jsou statisticky významné. Jedná se o proměnné vývoz hovězího masa v čase t-1, vývoz živého skotu v čase t a průměrnou cenu hovězího masa na trhu EU v čase t. Oproti výchozímu modelu došlo ke zmenšení směrodatných chyb odhadů regresních parametrů proměnných vývoz živého skotu a průměrná cena hovězího masa na trhu EU a tedy k jejich přesnějším odhadu, k mírnému zvýšení hodnoty adjustovaného koeficientu determinace a k poklesu hodnot informačních kritérií.

Obrázek č. 13 obsahuje výstup metody BMNČ pro mocninný model, jenž využívá determinanty vybrané pro finální lineární model.

Obrázek 13: Mocninný model vývozu hovězího masa

Model 4: OLS, za použití pozorování 2005:01-2019:12 (T = 180)
 Závisle proměnná: ln_vyvoz_hm
 HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)


	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-2,88446	0,854620	-3,375	0,0009	***
ln_vyvoz_hm_t_1	0,788192	0,0384465	20,50	1,65e-048	***
ln_vyvoz_zs	0,186011	0,0695202	2,676	0,0082	***
ln_hm_cena_EU	0,415683	0,182803	2,274	0,0242	**
Střední hodnota závisle proměnné		6,330998			
Sm. odchylka závisle proměnné		0,556275			
Součet čtverců rezidui		4,813329			
Sm. chyba regrese		0,165374			
Koeficient determinace		0,913101			
Adjustovaný koeficient determinace		0,911620			
F(3, 176)		637,9912			
P-hodnota(F)		2,76e-94			
Logaritmus věrohodnosti		70,53218			
Akaikovo kritérium		-133,0644			
Schwarzovo kritérium		-120,2925			
Hannan-Quinnovo kritérium		-127,8859			
rho (koeficient autokorelace)		-0,061179			
Durbin-Watsonova statistika		2,074408			

zde je poznámka o zkratkách statistik modelu


zdroj: Gretl, vlastní zpracování

Graf 19: Grafické znázornění empirických a teoretických hodnot lineárního ekonometrického modelu vývozu hovězího masa (vlevo)

Graf 20: Grafické znázornění empirických a teoretických hodnot mocninného ekonometrického modelu vývozu hovězího masa (vpravo)



zdroj: Gretl, vlastní zpracování



zdroj: Gretl, vlastní zpracování

Pro potřeby porovnání lineárního a mocninného modelu byla použita pomocná proměnná y^* , jež je geometrickým průměrem závisle proměnné (vývoz hovězího masa z ČR) a jejíž hodnoty jsou uvedeny v příloze č. 2. V tabulce níže jsou uvedeny součty čtverců reziduí lineárního a mocninného modelu při použití proměnné y^* , resp. $\ln(y^*)$ jako závisle proměnné.

Tabulka 5: Součty čtverců reziduí při použití proměnné y^* - lineární a mocninný model vývozu hovězího masa z ČR

model	Lineární model při použití y^*	Mocninný model při použití $\ln(y^*)$
SSR	5,942060	4,813329

zdroj: Gretl, vlastní zpracování

V tomto případě je $SSR_{LIN} > SSR_{LOG}$ a hodnota testovací statistiky LL_1 je 0,000585. Platí, že $LL_1 < 3.841$ (kritická hodnota) a nebylo tedy možné na 5% hladině významnosti zamítnout H_0 , jejíž propozice je, že lineární i mocninný model vyrovnávají empirická data stejně. Pro potřeby této práce bude, s ohledem na hodnotu statistiky SSR, dále využíván mocninný ekonometrický model.

Ekonometrický model

Tabulka 6: Deklarace proměnných ekonometrického modelu vývozu hovězího masa z ČR

Označení	Proměnná	Typ proměnné	Jednotky
y_1	Vývoz hovězího masa z ČR v čase t	Endogenní	tuny
x_1	jednotkový vektor	-	-
$y_{1,t-1}$	Vývoz hovězího masa z ČR v čase $(t-1)$	Predeterminovaná	tuny
x_2	Vývoz živého skotu z ČR v čase t	Predeterminovaná	kusy
x_3	Průměrná cena hovězího masa na trhu EU v čase t	Predeterminovaná	EUR/100 kg
u_t	náhodná proměnná	Stochastická	tuny

zdroj: vlastní zpracování

Odhadnutá linearizovaná podoba mocninného ekonometrického modelu prostřednictvím BMNČ:

$$\ln y_{1t} = -2,88446 + 0,788192 \ln y_{1,t-1} + 0,186011 \ln x_{2t} + 0,415683 \ln x_{3t} + u_{1t}$$

5.2.1.4 Verifikace modelu

Ekonomická verifikace

Interpretace $\gamma_2 = 0,788192$: Zvýší-li se vývoz hovězího masa v čase t-1 o 1%, pak vývoz hovězího masa v čase t vzroste o 0,788192%, za podmínky ceteris paribus.

Interpretace $\gamma_3 = 0,186011$: Zvýší-li se vývoz živého skotu v čase t o 1%, pak vzroste vývoz hovězího masa v čase t o 0,186011%, za podmínky ceteris paribus.

Interpretace $\gamma_4 = 0,415683$: Zvýší-li se průměrná cena hovězího masa na trhu EU v čase t o 1%, pak vzroste vývoz hovězího masa v čase t o 0,415683%, za podmínky ceteris paribus.

Největší vliv na vývoz hovězího masa z ČR měl vývoz hovězího masa v období (t-1) a byl tedy potvrzen předpoklad krátkodobé setrvačnosti tohoto ukazatele, jenž může být zapříčiněn nákladovou náročností uchovávání masa v zamrazeném stavu i ztrátou kvality, jenž tento typ uchovávání doprovází a zároveň relativně krátkou údržností chlazeného masa, která nutí dodavatele prodat maso v chlazeném stavu co nejrychleji.

Hodnota strukturálního parametru proměnné vývoz živého skotu z ČR odpovídá ekonomickému předpokladu, kdy je živý skot vyvážen na porážku do zahraničí, kvůli vyšším nákupním cenám tamějších zpracovatelských podniků. Hovězí maso pocházející z českého chovu je k nám dováženo ze zahraničí za ceny, kterým nemohou tuzemští zpracovatelé konkurovat a tak jsou nuceni hovězí maso vyvážet.

Hodnota strukturálního parametru proměnné průměrná cena hovězího masa na trhu EU v čase t odpovídá ekonomickým předpokladům, kdy je vývoz hovězího masa z ČR motivován vyššími cenami na zahraničních trzích.

Statistická verifikace

Jako statisticky významné vyšly na 5 procentní hladině významnosti všechny čtyři strukturální parametry.

Hodnota upraveného koeficientu determinace je $R_{upr}^2 = 0,911620$ a tedy můžeme říci, že model vysvětluje variabilitu vysvětlované proměnné z 91,16%.

Kritická hodnota F-testu je 2,655939 a hodnota testovací statistiky je 637,9912. Na 5 % hladině významnosti zamítáme nulovou hypotézu ve prospěch alternativní hypotézy a můžeme tedy říci, že model je statisticky významný.

Ekonometrická verifikace (Příloha č. 3)

Použitím metody VIF nebyla detekována závažná lineární závislost vysvětlujících proměnných. Z níže uvedeného výstupu vyplývá, že v modelu se nevyskytuje nežádoucí multikolinearita.

Obrázek 14: Testování multikolinearity – podkladová data mocninného ekonometrického modelu vývozu hovězího masa


```
Faktory zvyšující rozptyl (VIF)
Minimální možná hodnota = 1.0
Hodnoty > 10.0 mohou indikovat problém kolinearity

ln_vyvoz_hm_t_1    3,356
  ln_vyvoz_zs      1,720
  ln_hm_cena_EU    2,920
```

zdroj: Gretl, vlastní zpracování

Z grafu č. 12, zobrazujícím průběh reziduí ekonometrického modelu vývozu hovězího masa, je patrná stacionarita reziduí, kterou potvrzuje i p-hodnota Dickey-Fullerova testu. Parametry ekonometrického modelu byly odhadovány na základě nestacionárních časových řad a rezidua takto odhadnutého modelu jsou stacionární. Můžeme konstatovat, že se jedná o pravou regresi, nikoliv zdánlivou.

Graf 21: Vývoj reziduí mocninného ekonometrického modelu vývozu hovězího z ČR v čase



```
Rozšířený Dickey-Fullerův test pro rezidua
testing down from 13 lags, criterion AIC
počet pozorování 179
nulová hypotéza jednotkového kořenu: a = 1
```

```
test bez konstanty
s použitím 0 zpožděných proměnných (1-L)rezidua
model: (1-L)y = (a-1)*y(-1) + e
odhadovaná hodnota (a - 1): -1,06118
testovací statistika: tau_nc(1) = -14,2577
p-hodnota 1,36e-027
autokorelační koeficient 1. řádu pro e: -0,003
```

zdroj: Gretl, vlastní zpracování

- **Autokorelace**

Testováno pomocí Breusch-Godfrey testu

H_0 : autokorelace se v modelu nevyskytuje

H_1 : autokorelace se v modelu vyskytuje

P-hodnota = 0,578323 > 0,05

Na 5% hladině významnosti nezamítáme H_0 a můžeme tedy říci, že v modelu se nevyskytuje autokorelace.

- **Normalita**

Testováno pomocí testu normality reziduí

H_0 : náhodná složka má normální rozdělení

H_1 : náhodná složka nemá normální rozdělení

P-hodnota = 4,11326e-005 < 0,05

Na 5% hladině významnosti jsme zamítli H_0 ve prospěch alternativní hypotézy a tedy můžeme říci, že náhodná složka nemá normální rozdělení. Tento fakt ošetřuje centrální limitní věta, z které vyplývá, že pokud rezidua nejsou normálně rozdělena, ale máme dostatečně velký vzorek ($n > 30$), stále můžeme použít normální rozdělení pro BMNČ estimátor (Hebák, Kahounová, 2010).

- **Heteroskedasticita**

Problém s heteroskedasticitou byl ošetřen odhadem ekonometrického modelu běžnou metodou nejmenších čtverců s robustními směrodatnými odchylkami. Využitím robustních odhadů získáme vyšší směrodatné odchylky parametrů, a tedy i širší intervaly spolehlivosti.

- **Vhodnost funkční formy modelu**

Testováno pomocí Reset testu

H_0 : Model vykazuje správnou specifikaci

H_1 : Model nevykazuje správnou specifikaci

P-hodnota = 0,06 > 0,05

Na 5% hladině významnosti nezamítáme H_0 ve prospěch alternativní hypotézy a můžeme tedy říci, že model vykazuje správnou specifikaci.

5.2.1.5 Aplikace modelu v podobě strukturální analýzy

Tabulka 7: Koeficienty pružnosti pro mocninný ekonometrický model

Proměnná	Elasticita (%)
Vývoz hovězího masa v čase (t-1) ($y_{1,t-1}$)	0,78
Vývoz živého skotu v čase t (x_2)	0,19
Průměrná cena hovězího masa na trhu EU (x_3)	0,42

zdroj: Gretl, vlastní zpracování

Dle výše uvedených koeficientů pružnosti lze konstatovat, že reakce endogenní proměnné vývoz hovězího masa z ČR na změny jednotlivých predeterminovaných proměnných je nepružná a tedy se mění méně jak proporcionálně. Na vývoz hovězího masa z ČR v čase t má největší vliv vývoz hovězího masa z ČR v čase (t-1) a nejmenší vliv vývoz živého skotu v čase t.

5.2.1.6 Bodová prognóza ex-post

V této podkapitole byla provedena bodová prognóza ex-post proměnné vývoz hovězího masa z ČR v měsících prvních třech čtvrtletí roku 2020. Pro potřeby bodové prognózy byl použit verifikovaný mocninný ekonometrický model odhadnutý v předchozí části na měsíčních datech z let 2005 – 2019. Tato bodová prognóza byla v závěru této práce porovnána s predikcí neuronové sítě.


Bodová prognóza ex-post pro první 3 čtvrtletí roku 2020

Tabulka 8: Bodová prognóza ex post vývozu hovězího masa z ČR pro první 3 čtvrtletí roku 2020

Proměnná	Období	Výsledek bodové prognózy [t]	Skutečná hodnota [t]	% shoda
Vývoz hovězího masa z ČR	Leden 2020	1220.66	1491	81,89%
	Únor 2020	1242.76	1049	84,41%
	Březen 2020	926.93	852	91,92%
	Duben 2020	781.02	705	90,27%
	Květen 2020	652.50	740	88,18%
	Červen 2020	709.36	1205	58,87%
	Červenec 2020	1044.14	1085	96,23%
	Srpen 2020	987.60	1170	84,41%
	Září 2020	1134.45	1072	94,50%

zdroj: Gretl, vlastní zpracování

Graf 22: Bodová prognóza ex-post pro proměnnou vývoz hovězího masa z ČR v prvních 3 čtvrtletích roku 2020



zdroj: Gretl, vlastní zpracování

Průměrná přesnost bodových prognóz hodnot proměnné vývoz hovězího masa z ČR pro první 3 čtvrtletí roku 2020 je 85,63%. Nejvyšší přesnosti dosáhla prognóza pro měsíc červenec, kdy byla míra shody s empirickou hodnotou 96,23%. Nejnižší přesnosti bylo dosaženo v měsíci červnu, kdy byla míra shody jen 58.87%.

5.3 Analýza vybraných determinantů vývozu mléka z ČR

5.3.1 Jednorovnicový ekonometrický model vývozu mléka z ČR

Uvažovanými determinanty vývoje vývozu mléka z ČR byly: vývoz mléka v předchozích obdobích, produkce mléka v ČR a průměrná cena syrového mléka na trhu EU. Podkladová data měla charakter měsíčních časových řad za roky 2005-2019. Pro modelování závislosti proměnných byly uvažovány dva ekonometrické modely, lineární a mocninný model.

Ekonomický model

Závisle proměnná:

y_1 Vývoz mléka z ČR v čase t [t]

Nezávisle proměnné:

$y_{1,t-p}$ Vývoz mléka z ČR v předchozích obdobích [t]

x_2 Produkce mléka v ČR v čase t [t]

$x_{3,t-p}$ Průměrná cena syrového mléka na trhu EU [EUR/100 kg]

Formulace ekonomického modelu:

$$y_1 = f(y_{1,t-p}, x_2, x_{3,t-p})$$

5.3.1.1 Ekonomické předpoklady

Vývoz mléka – U vývoje vývozu mléka lze očekávat jistou míru setrvačnosti, jež vychází z faktu, že producenti mléka chtějí mít jistotu odbytu mléka, jež rychle podléhá znehodnocujícím vlivům a tak uzavírají s mlékárnami (zpracovatelský průmysl) dlouhodobější kontrakty na dodávku mléka, přičemž cena, kterou zpracovatelský průmysl platí producentům mléka, se odvíjí od předem dohodnutého kritéria.


Produkce mléka – Dlouhodobým trendem v ČR je vývoz mléka ke zpracování do zahraničí, především do Německa, Slovenska a Itálie, což způsobují vyšší výkupní ceny na zahraničních trzích. Tento trend přispívá k vysokému podílu mléčných výrobků z dovozu na domácí spotřebě mléčných výrobků. V roce 2019 se vývoz týkal až o 23% tuzemské produkce mléka. Lze tedy

očekávat, že produkce mléka bude mít pozitivní vliv na vývoz této komodity (zemedelec.cz, 2019).

Průměrné ceny syrového mléka na trhu EU - Růst průměrné ceny syrového mléka na trhu EU by měl mít pozitivní vliv na vývoz mléka z ČR, kdy je vývoz této komodity motivován vyššími výkupními cenami v zahraničí.

5.3.1.2 Testování stacionarity časových řad

Graf 23: Časová řada vývozu mléka z ČR




Rozšířený Dickey-Fullerův test pro vyvoz_mleka
testing down from 13 lags, criterion AIC
počet pozorování 167
nulová hypotéza jednotkového koefienu: $a = 1$

s konstantou a trendem
s použitím 12 zpožděných proměnných (1-L)vyvoz_mleka
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,279242
testovací statistika: $\tau_{ct}(1) = -3,35254$
asymptotická p-hodnota 0,05798
autokorelační koeficient 1. řádu pro e: 0,004
zpožděné diference: $F(12, 152) = 4,067 [0,0000]$

zdroj: Gretl, vlastní zpracování

Graf 24: Časová řada produkce mléka v ČR




Rozšířený Dickey-Fullerův test pro produkce_mleka
testing down from 13 lags, criterion AIC
počet pozorování 166
nulová hypotéza jednotkového koefienu: $a = 1$

s konstantou a trendem
s použitím 13 zpožděných proměnných (1-L)produkce_mleka
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,0401788
testovací statistika: $\tau_{ct}(1) = -1,45979$
asymptotická p-hodnota 0,8432
autokorelační koeficient 1. řádu pro e: 0,008
zpožděné diference: $F(13, 150) = 58,643 [0,0000]$

zdroj: Gretl, vlastní zpracování

Graf 25: Časová řada průměrné ceny syrového mléka na trhu EU



Rozšířený Dickey-Fullerův test pro ceny_mleka_EU
testing down from 13 lags, criterion AIC
počet pozorování 167
nulová hypotéza jednotkového koefentu: $a = 1$

s konstantou a trendem
s použitím 12 zpožděných proměnných $(1-L)ceny_mleka_EU$
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,0800005
testovací statistika: $\tau_{ct}(1) = -3,14927$
asymptotická p-hodnota 0,09495
autokorelační koeficient 1. řádu pro e: -0,003
zpožděné diference: $F(12, 152) = 5,660 [0,0000]$

zdroj: Gretl, vlastní zpracování

Z výše uvedených grafů vyplývá, že časové řady vývozu mléka z ČR, produkce mléka v ČR a průměrné ceny syrového mléka na trhu EU jsou nestacionární, což ve všech případech dosvědčuje i p-hodnota Dickey-Fullerova testu, která je větší než hladina významnosti 0,05. Ve všech případech nedošlo k zamítnutí H_0 na 5% hladině významnosti ve prospěch alternativní hypotézy a lze tedy říci, že časové řady jsou nestacionární.

5.3.1.3 Specifikace a kvantifikace modelu

Obrázek č. 14 níže obsahuje výstup metody BMNČ ze softwaru Gretl pro výchozí lineární model, do nějž byly zahrnuty všechny uvažované nezávisle proměnné. Obrázek č. 15 obsahuje výstup pro finální lineární model, k jehož specifikaci bylo použito metody sestupného výběru regresorů.

Obrázek 15: Obrázek 14: Výchozí lineární model vývozu mléka (vlevo)**Obrázek 16: Obrázek 15: Finální lineární model vývozu mléka (vpravo)**

Model 6: OLS, za použití pozorování 2005:01-2019:12 (T = 180)

Závisle proměnná: vyvoz_mleka

HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)

	koeficient	směr. chyba	t-podíl	p-hodnota
const	-16355,1	3057,85	-5,349	2,81e-07 ***
vyvoz_mleka_t_1	0,797615	0,0540747	14,75	2,69e-032 ***
produkce_mleka	0,0896029	0,0181365	4,940	1,84e-06 ***
ceny_mleka_EU	-92,9730	207,007	-0,4491	0,6539
ceny_mleka_EU_t_1	123,112	256,194	0,4805	0,6315
ceny_mleka_EU_t_3	108,369	327,550	0,3308	0,7412
ceny_mleka_EU_t_4	4,75362	471,206	0,01009	0,9920
ceny_mleka_EU_t_5	21,7722	454,813	0,04787	0,9619
ceny_mleka_EU_t_6	136,922	236,249	0,5796	0,5630

Střední hodnota závisle proměnné	58204,29
Sm. odchylka závisle proměnné	12867,12
Součet čtverců reziduí	2,39e+09
Sm. chyba regrese	3735,242
Koeficient determinace	0,919496
Adjustovaný koeficient determinace	0,915730
F(8, 171)	254,3005
P-hodnota(F)	9,93e-91
Logaritmus věrohodnosti	-1731,395
Akaikovo kritérium	3480,789
Schwarzovo kritérium	3509,526
Hannan-Quinnovo kritérium	3492,441
rho (koeficient autokorelace)	-0,190107
Durbin-Watsonova statistika	2,368977

zde je poznámka o zkratkách statistik modelu

zdroj: Gretl, vlastní zpracování

Model 8: OLS, za použití pozorování 2005:01-2019:12 (T = 180)

Závisle proměnná: vyvoz_mleka

HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)

	koeficient	směr. chyba	t-podíl	p-hodnota
const	-15258,1	2757,42	-5,533	1,12e-07 ***
vyvoz_mleka_t_1	0,810604	0,0460084	17,62	1,05e-040 ***
produkce_mleka	0,0913192	0,0166115	5,497	1,34e-07 ***
ceny_mleka_EU_t_1	228,860	59,6713	3,835	0,0002 ***

Střední hodnota závisle proměnné	58204,29
Sm. odchylka závisle proměnné	12867,12
Součet čtverců reziduí	2,46e+09
Sm. chyba regrese	3736,776
Koeficient determinace	0,917074
Adjustovaný koeficient determinace	0,915660
F(3, 176)	545,1096
P-hodnota(F)	8,05e-89
Logaritmus věrohodnosti	-1734,062
Akaikovo kritérium	3476,125
Schwarzovo kritérium	3488,897
Hannan-Quinnovo kritérium	3481,303
rho (koeficient autokorelace)	-0,168620
Durbin-Watsonova statistika	2,329859

zdroj: Gretl, vlastní zpracování

Finální podoba modelu obsahuje oproti výchozímu modelu pouze nezávisle proměnné, které jsou statisticky významné. Jedná se o proměnné vývoz mléka z ČR v čase t-1, produkce mléka v čase t a průměrná cena syrového mléka trhu EU v čase t-1. Oproti výchozímu modelu došlo ke zmenšení směrodatných chyb odhadů regresních parametrů těchto proměnných a tedy k jejich přesnějšímu odhadu, k poklesu informačních kritérií a k mírnému nárůstu adjustovaného koeficientu determinace.

Obrázek č. 17 obsahuje výstup metody BMNČ pro mocninný model, jenž využívá determinanty vybrané pro finální lineární model.

Obrázek 17: Mocninný model vývozu mléka


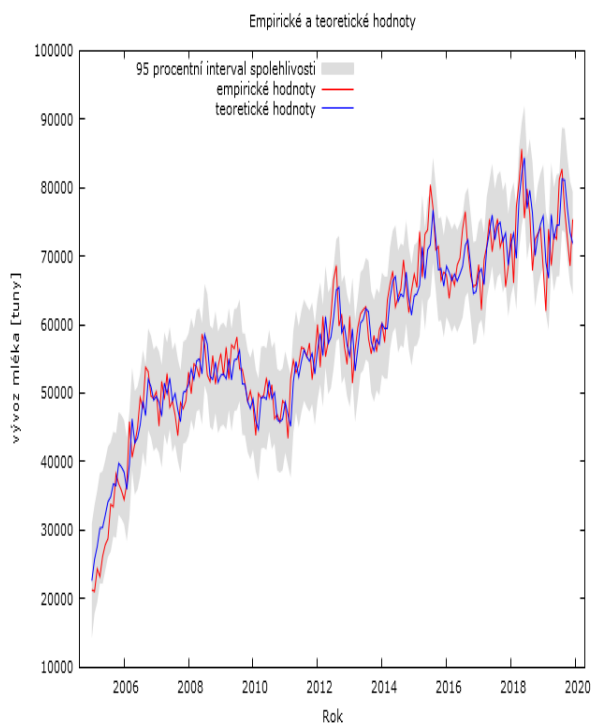
	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-2,33346	0,448195	-5,206	5,33e-07	***
ln_vyvoz_mleka~_1	0,825444	0,0341038	24,20	6,87e-058	***
ln_produkce_mleka	0,315351	0,0501930	6,283	2,53e-09	***
ln_ceny_mleka~_1	0,111986	0,0319714	3,503	0,0006	***
Střední hodnota závisle proměnné		10,94263			
Sm. odchylka závisle proměnné		0,255875			
Součet čtverců reziduí		0,761485			
Sm. chyba regrese		0,065777			
Koeficient determinace		0,935024			
Adjustovaný koeficient determinace		0,933916			
F(3, 176)		645,8998			
P-hodnota(F)		1,02e-94			
Logaritmus věrohodnosti		236,4808			
Akaikovo kritérium		-464,9615			
Schwarzovo kritérium		-452,1897			
Hannan-Quinnovo kritérium		-459,7831			
rho (koeficient autokorelace)		-0,227358			
Durbin-Watsonova statistika		2,430187			

zde je poznámka o zkratkách statistik modelu

zdroj: Gretl, vlastní zpracování

Graf 27: Grafické znázornění empirických a teoretických hodnot lineárního ekonometrického modelu vývozu mléka (vlevo)

Graf 26: Grafické znázornění empirických a teoretických hodnot mocninného ekonometrického modelu vývozu mléka (vpravo)



zdroj: Gretl, vlastní zpracování

Pro potřeby porovnání lineárního a mocninného modelu byla použita pomocná proměnná y^* , jež je geometrickým průměrem závisle proměnné (vývoz mléka) a jejíž hodnoty jsou uvedeny v příloze č. 2. V tabulce níže jsou uvedeny součty čtverců reziduí lineárního a mocninného modelu při použití proměnné y^* , resp. $\ln(y^*)$ jako závisle proměnné.

Tabulka 9: Součty čtverců reziduí při použití proměnné y^* - lineární a mocninný model vývozu mléka z ČR

model	Lineární model při použití y^*	Mocninný model při použití $\ln(y^*)$
SSR	0,768875	0,761485

zdroj: Gretl, vlastní zpracování

V tomto případě je $SSR_{LOG} > SSR_{LIN}$ a hodnota testovací statistiky LL_2 je 0,002804. Platí, že $LL_2 < 3.841$ (kritická hodnota) a nebylo tedy možné na 5% hladině významnosti zamítnout H_0 , jejíž propozice je, že lineární i mocninný model vyrovnávají empirická data stejně. Pro potřeby této práce bude, s ohledem na minimální rozdíl hodnot statistik SSR_{LOG} a SSR_{LIN} jenž je v řádu tisícín, dále využíván lineární ekonometrický model.

Ekonometrický model

Tabulka 10: Deklarace proměnných ekonometrického modelu vývozu mléka

Označení	Proměnná	Typ proměnné	Jednotky
y_1	Vývoz mléka	Endogenní	tuny
x_1	jednotkový vektor	-	-
$y_{1,(t-1)}$	Vývoz mléka v čase (t-1)	Predeterminovaná	tuny
x_2	Produkce mléka v ČR	Predeterminovaná	tuny
x_3	Průměrná cena syrového mléka na trhu EU v čase (t-1)	Predeterminovaná	EUR/100 kg
u_t	náhodná proměnná	Stochastická	-

zdroj: Gretl, vlastní zpracování

Odhadnutá podoba lineárního ekonometrického modelu prostřednictvím BMNČ:

$$y_{1t} = -15258,1x_{1t} + 0,810604y_{1,(t-1)} + 0,0913192x_{2t} + 228,860x_{3t} + u_{1t}$$

5.3.1.4 Verifikace modelu

Ekonomická verifikace

Interpretace $\gamma_2 = 0,810604$: Zvýší-li se vývoz mléka v čase (t-1) o 1 tunu, tak se zvýší vývoz mléka v čase t z ČR o 0,810604 tuny, za podmínky ceteris paribus.

Interpretace $\gamma_3 = 0,0913192$: Zvýší-li se produkce mléka o 1 tunu, tak se zvýší vývoz mléka v čase t z ČR o 0,0913192 tun, za podmínky ceteris paribus.

Interpretace $\gamma_4 = 228,860$: Zvýší-li se průměrná cena za 100kg syrového mléka na trhu EU v čase (t-1) o 1 Euro, pak se zvýší vývoz mléka v čase t z ČR o 228,860 tun, za podmínky ceteris paribus.

Vývoz mléka v období (t-1) má pozitivní vliv na vývoz této komodity v čase t a byl tedy potvrzen ekonomický předpoklad setrvačnosti vývoje tohoto ukazatele, jenž může být ovlivněn skutečností, že kontrakty na dodávky mléka mezi mlékárnami a producenty mléka jsou dlouhodobějšího charakteru, především z toho důvodu, že producenti mléka chtějí mít jistotu odbytu a tudíž prodávají produkci i za pro ně méně výhodnou cenu.

Hodnota strukturálního parametru proměnné produkce mléka odpovídá ekonomickému předpokladu, kdy růst produkce mléka má pozitivní vliv na vývoz této komodity, což je zapříčiněno tím, že Česká republika ve srovnání s evropským průměrem vyváží nadprůměrné množství mléka do zahraničí. V roce 2019 vývoz činil až 23 procent tuzemské produkce.

Hodnota strukturálního parametru proměnné průměrná cena syrového mléka na trhu EU v čase (t-1) odpovídá ekonomickému předpokladu, kdy růst výkupních cen mléka zpracovatelského průmyslu na zahraničních trzích motivuje vývoz této komodity z ČR. Zpoždění této proměnné můžeme vysvětlit tím, že odběratelé si sjednávají dodávky mléka s určitým časovým předstihem.

Statistická verifikace

Jako statisticky významné vycházejí na 5 procentní hladině významnosti všechny čtyři strukturální parametry.

Hodnota upraveného koeficientu determinace je $R_{upr}^2 = 0,915660$ a tedy můžeme říci, že model vysvětluje variabilitu vysvětlované proměnné z 91,16%.

Kritická hodnota F-testu je 2,655939 a hodnota testovací statistiky je 545,1096. Na 5 % hladině významnosti zamítáme nulovou hypotézu ve prospěch alternativní hypotézy a můžeme tedy říci, že model je statisticky významný.

Ekonometrická verifikace (Příloha č. 3)

Použitím metody VIF nebyla detekována závažná lineární závislost vysvětlujících proměnných. Z níže uvedeného výstupu vyplývá, že v modelu se nevyskytuje nežádoucí multikolinearita.

Obrázek 18: Testování multikolinearity – podkladová data lineárního ekonometrického modelu vývozu mléka


```
Faktory zvyšující rozptyl (VIF)
Minimální možná hodnota = 1.0
Hodnoty > 10.0 mohou indikovat problém kolinearity

vyvoz_mleka_t_1    1,739
produkce_mleka     1,457
ceny_mleka_EU_t_1  1,270
```

zdroj: Gretl, vlastní zpracování

Z grafu č. 20, zobrazujícím průběh reziduí ekonometrického modelu vývozu mléka, je patrná stacionarita reziduí, kterou potvrzuje i p-hodnota Dickey-Fullerova testu. Parametry ekonometrického modelu byly odhadovány na základě nestacionárních časových řad a rezidua takto odhadnutého modelu jsou stacionární. Můžeme konstatovat, že se jedná o pravou regresi, nikoliv zdánlivou.

Graf 28: Vývoj reziduí lineárního ekonometrického modelu vývozu mléka z ČR v



Rozšířený Dickey-Fullerův test pro rezidua
testing down from 13 lags, criterion AIC
počet pozorování 167
nulová hypotéza jednotkového koefentu: $a = 1$

test bez konstanty
s použitím 12 zpožděných proměnných $(1-L)$ rezidua
model: $(1-L)y = (a-1)y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,910424
testovací statistika: $\tau_{nc}(1) = -3,58766$
asymptotická p-hodnota 0,0003298
autokorelační koeficient 1. řádu pro e: 0,004
zpožděné diference: $F(12, 154) = 2,046 [0,0237]$

zdroj: Gretl, vlastní zpracování

- **Autokorelace a Heteroskedasticita**

Problém s autokorelací a heteroskedasticitou byl ošetřen odhadem ekonometrického modelu běžnou metodou nejmenších čtverců s robustními směrodatnými odchylkami. Využitím robustních odhadů byly získány vyšší směrodatné odchylky parametrů, a tedy i širší intervaly spolehlivosti.

- **Normalita**

Testováno pomocí testu normality reziduí

H_0 : náhodná složka má normální rozdělení

H_1 : náhodná složka nemá normální rozdělení

P-hodnota = 0,396252 < 0,05

Na 5% hladině významnosti jsme nezamítli H_0 a tedy můžeme říci, že náhodná složka má normální rozdělení.

5.3.1.5 Aplikace modelu v podobě strukturální analýzy

Tabulka 11: Koeficienty pružnosti pro lineární ekonometrický model

Proměnná	Elasticita (%)
vývoz mléka v čase (t-1) ($y_{1,t-1}$)	0,81
Produkce v čase t (x_2)	0,34
Průměrná cena syrového mléka na trhu EU v čase (t-1) (x_3)	0,12

zdroj: Gretl, vlastní zpracování

Dle výše uvedených koeficientů pružnosti lze konstatovat, že reakce endogenní proměnné vývoz mléka z ČR na změny jednotlivých predeterminovaných proměnných je nepružná a tedy se mění méně jak proporcionálně. Na vývoz mléka z ČR v čase t má největší vliv vývoz mléka z ČR v čase (t-1) a nejmenší vliv průměrná cena syrového mléka na trhu EU v čase (t-1).

5.4 Neuronová síť jako alternativa pro modelování závislosti proměnných

Pro potřeby této kapitoly byla sestavena třívrstvá neuronová síť, s jejíž pomocí byl modelován vztah mezi závislými a nezávislými proměnnými ekonometrických modelů vývozu pšenice, hovězího masa a mléka z ČR získaných v předchozích kapitolách. Výsledky dosažené pomocí techniky třívrstvé neuronové sítě byly porovnány s výsledky dosaženými pomocí jednorovnicových ekonometrických modelů. V případě ekonometrických modelů vývozu pšenice a hovězího masa byla porovnána i kvalita prognostických schopností obou přístupů. Obrázky č. 19 a č. 20 obsahuje ukázkou programu neuronové sítě sestaveného v jazyce Python, jenž se nachází v příloze č. 4 v souboru NP.py⁴⁵.

Obrázek 19: Program neuronové sítě (1. část)

```
"""Pandas knihovna slouží pro analýzu dat, které lze reprezentovat 2D tabulkou.
    Tento „tvar“ dat najdeme v SQL databázích, souborech CSV nebo tabulkových procesorech."""
import pandas as pd
# NumPy je knihovna programovacího jazyka Python, která poskytuje infrastrukturu pro práci s vektory, maticemi a obecně vícerozměrnými poli.
import numpy as np
# Time je modul pro práci s časovými funkcemi.
import time
# MinMaxScaler je funkce jež slouží k transformaci hodnot do rozmezí 0 až 1.
from sklearn.preprocessing import MinMaxScaler
# Keras je softwarová knihovna, jež poskytuje rozhraní v jazyce Python pro techniky neuronových sítí.
import keras
# Sequential - sekvenční model
from keras.models import Sequential
# Dense - plně propojená vrstva Neuronové sítě
from keras.layers import Dense
# ModelCheckpoint je funkce sloužící k uložení modelu neuronové sítě či jejich vah v určité fázi učícího procesu za určité podmínky.
from keras.callbacks import ModelCheckpoint
# Argparse je modul sloužící k vytváření rozhraní pro příkazovou řádku.
import argparse
# OS je modul pro interakci s operačním systémem.
import os
# SYS je modul pro interakci s prostředím Python.
import sys

# - definování způsobu, jak předat argument z příkazového řádku do programu
parser = argparse.ArgumentParser()
parser.add_argument("--train_data", help = "absolutní cesta datového souboru s trénovacími daty ", required=True)
args=vars(parser.parse_args())

# - načtení trénovacích dat neuronové sítě ze souboru ve formátu XLS
train_data = pd.read_excel(args["train_data"], sheet_name = "")

# - definování proměnných, vstupních dat(vstupních proměnných) a výstupních dat(výstupní proměnné)
vstupni_data = train_data[train_data.columns[3:]]
vystupni_data = train_data[train_data.columns[2]]

# - vytvoření datových matic vstupních a výstupních proměnných.
matice_vstupnich_dat=np.mat(vstupni_data)
matice_vystupnich_dat=np.mat(vystupni_data)

# - použití funkce MinMaxScaler k namapování hodnot vstupních a výstupních proměnných na interval <0,1>
prepro_x = MinMaxScaler()
prepro_y = MinMaxScaler()
prepro_x.fit(matice_vstupnich_dat)
prepro_y.fit(matice_vystupnich_dat)
min_max_vstupnich_promennych=prepro_x.transform(matice_vstupnich_dat)

# - zapnutí měření doby trvání učení Neuronové sítě
zacatek=time.time()
```

zdroj: vlastní zpracování v jazyce Python

⁴⁵ Soubor s příponou .py je programový soubor nebo skript provedený v programovacím jazyce Python.

Obrázek 20: Program neuronové sítě (2. část)

```
"""Topologie třívrstvé neuronové sítě se skládá ze vstupní vrstvy, jedné skryté vrstvy a jedné výstupní vrstvy.
Vstupní vrstva má počet neuronů roven počtu vstupních proměnných + bias. Skrytá vrstva má 18 neuronů a druhá skrytá vrstva má 1 neuron.
Neurony ve skryté a výstupní vrstvě obsahují aktivační funkci ReLU. Učící proces se skládá z n epoch. Hodnota učícího koeficientu je 0.01.
Chyba sítě je měřena pomocí střední kvadratické chyby."""
epochy=
seed = 7
np.random.seed(seed)
model = Sequential()
model.add(Dense(18, input_dim=min_max_vstupnich_promennych.shape[1], kernel_initializer='normal', activation='relu'))
model.add(Dense(1, kernel_initializer='normal',activation='relu'))

# Definování absolutní cesty souboru ve formátu HDF, do něhož se ukládají naučené váhy neuronové sítě, které vygenerovaly nejmenší chybu sítě.
filepath = "C:\\Users\\korec\\PycharmProjects\\Diplomka\\Neuronova_sit_vystup\\{}_model.h5".format(os.path.split(args["train_data"])[-1][0:-4])
checkpoint = ModelCheckpoint(filepath, monitor='loss', verbose=1, save_best_only=True, mode='min')
callbacks_list = [checkpoint]

"""Sestavení třívrstvé neuronové sítě, jejíž chyba je měřena pomocí střední kvadratické chyby.
K učení sítě je využíván optimalizační algoritmus Adam s koeficientem učení 0.01."""
model.compile(loss='mean_squared_error',optimizer=keras.optimizers.Adam(lr=0.01))

# - učící proces neuronové sítě
history=model.fit(min_max_vstupnich_promennych, matice_vystupnich_dat.reshape(-1,1), epochs=epochy, batch_size=50, callbacks=callbacks_list)

# - uložení výstupů programu Neuronové sítě do souboru ve formátu TXT
file = open('C:\\Users\\korec\\PycharmProjects\\Diplomka\\Neuronova_sit_vystup\\vystup_{}.txt'.format(os.path.split(args["train_data"])[-1][0:-4]),mode="w+")
sys.stdout = file

# - shrnutí informací o sestaveném modelu
print(model.summary())

# - ukončení měření doby trvání učení Neuronové sítě
konec=time.time()
print("Doba učení neuronové sítě je ", konec-zacatek , "sekund")

# - vygenerování vývoje Střední kvadratické chyby v průběhu učícího procesu neuronové sítě
MSE=pd.DataFrame(history.history['loss'])
MSE.columns = ["Stredni kvadraticka chyba"]
MSE["Epocha"] = MSE.index.to_list()
print(MSE)

# - vygenerování nejnížší dosažené střední kvadratické chyby
print("Střední kvadratická chyba = {}".format(MSE["Stredni kvadraticka chyba"].min()))

# - uzavření souboru, do kterého byly zapisovány výstupy Neuronové sítě
file.close()
```

zdroj: vlastní zpracování v jazyce Python

5.4.1 Modelování vztahu vývozu pšenice z ČR a jeho determinantů pomocí NS

Architektura neuronové sítě pro modelování vztahu mezi vývozem pšenice z ČR a jeho determinanty, byla zvolena experimentálně a znázorňuje ji obrázek č. 21.

Obrázek 21: Architektura neuronové sítě pro modelování vztahu vývozu pšenice z ČR a jeho determinantů

Vrstva	Neurony	Váhy
Skrytá vrstva	18	162
Výstupní vrstva	1	19

Celkový počet vah = 181

zdroj: Keras, vlastní zpracování

Jedná se o třívrstvou neuronovou síť, jež má 18 neuronů ve skryté vrstvě a jeden neuron ve výstupní vrstvě. Neuronová síť má 9 vstupů (8 proměnných + bias) a jestliže je každý vstup spojen synapsí s každým z 18 neuronů ve skryté vrstvě, získáváme 162 vah synapsí mezi vstupní a skrytou vrstvou. Mezi skrytou vrstvou a výstupní vrstvou se nachází 19 synapsí a tedy 19 vah.

Trénování třívrstvé neuronové sítě proběhlo v 50000 epochách a trvalo 26 minut a 24 sekund. Chyba neuronové sítě byla měřena pomocí statistiky RMSE⁴⁶. Na obrázku č. 22 je znázorněna finální hodnota statistiky RMSE, které bylo dosaženo v závěrečné epoše učícího procesu neuronové sítě. V tabulce č. 12 jsou uvedeny statistiky RMSE lineárního ekonometrického modelu a neuronové sítě.

Obrázek 22: Výsledná hodnota statistiky RMSE neuronové sítě

```
Epocha 50000/50000  
168/168 [=====] - 0s 167us/step - MSE: 1082312031.2380953 -> RMSE: 32898.511
```

zdroj: Keras, vlastní zpracování

⁴⁶ Root Mean Square Error – statistika je počítána jako odmocnina ze střední kvadratické chyby

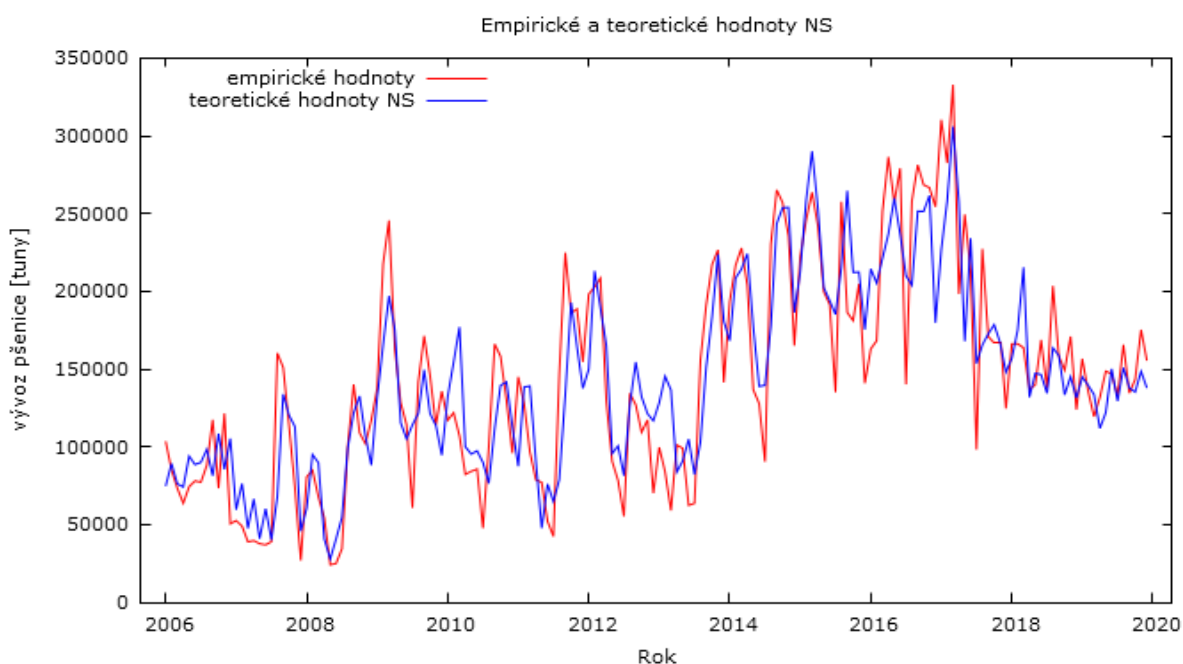
Tabulka 12: Porovnání kvality lineárního ekonometrického modelu vývozu pšenice a naučené neuronové sítě

Statistika	Ekonometrický model	Neuronová síť
RMSE	33822,572 ⁴⁷	32828.511

zdroj: software Gretl (Ekonometrický model), Keras (Neuronová síť), vlastní zpracování

Z výše uvedené tabulky je zřejmé, že neuronová síť dokáže o něco lépe vystihnout vztah mezi vývozem pšenice z ČR a jeho determinanty. Můžeme tedy konstatovat, že odchylka teoretických hodnot⁴⁸ vygenerovaných neuronovou sítí od empirických hodnot⁴⁹ závisle proměnné je menší, než je tomu u odchylek teoretických hodnot vygenerovaných lineárním ekonometrickým modelem. Teoretické hodnoty vygenerované neuronovou sítí obsahuje příloha č. 2. a jejich průběh je znázorněn na obrázku níže. Neuronová síť byla spolu s naučenými váhami synapsí uložena ve formátu HDF⁵⁰ do souboru pšenice_model.h5 a je obsahem přílohy č. 4 této práce.

Graf 29: Grafické znázornění průběhu empirických hodnot vývozu pšenice z ČR a teoretických hodnot této proměnné vygenerovaných neuronovou sítí



zdroj: Gretl, vlastní zpracování

⁴⁷ Viz kapitola 5.1 Analýza vybraných determinantů vývozu pšenice z ČR

⁴⁸ Výrazem teoretické hodnoty jsou v této kapitole nazývány hodnoty, jež byly získány jako výsledek modelování závisle proměnné prostřednictvím ekonometrického modelu a třívrstvé neuronové sítě.

⁴⁹ Výrazem empirické hodnoty jsou v této kapitole nazývány hodnoty skutečně naměřené.

⁵⁰ HDF – Hierarchical Data Format

5.4.1.1 Predikce pomocí neuronové sítě

V této podkapitole byla provedena predikce vývozu pšenice z ČR v měsících prvních třech čtvrtletí roku 2020. Tato predikce byla porovnána s bodovými prognózami lineárního ekonometrického modelu. Predikované hodnoty pomocí neuronové sítě pro první tři čtvrtletí roku 2020 jsou obsahem přílohy č. 9. Na obrázku č. 23 je zobrazen kód predikčního modulu neuronové sítě, jenž načítá z HDF formátu neuronovou síť s natrénovanými vahami synapsí, jež byly získány v učícím procesu neuronové sítě v předchozí kapitole. Tabulka č. 13 pak zobrazuje predikované hodnoty pomocí neuronové sítě pro první tři čtvrtletí roku 2020, pro proměnnou vývoz pšenice z ČR.

Obrázek 23: Kód predikčního modulu neuronové sítě

```
# Keras je softwarová knihovna, jež poskytuje rozhraní v jazyce Python pro techniky neuronových sítí.
import keras
# Load model je funkce sloužící pro načítání uloženého modulu neuronové sítě
from keras.models import load_model
# Pandas slouží pro analýzu dat, které lze reprezentovat 2D tabulkou. Tento „tvar“ dat najdeme v SQL databázích, souborech CSV nebo tabulkových procesorech.
import pandas as pd
# Funkce MinMaxScaler slouží k transformaci hodnot do rozmezí 0 až 1.
from sklearn.preprocessing import MinMaxScaler
# NumPy je knihovna programovacího jazyka Python, která poskytuje infrastrukturu pro práci s vektory, maticemi a obecně vícerozměrnými poli.
import numpy as np
# Argparse je modul sloužící k vytváření rozhraní pro příkazovou řádku.
import argparse
# OS je modul pro interakci s operačním systémem.
import os

# - definování způsobu, jak předat argument z příkazového řádku do programu
parser = argparse.ArgumentParser()
parser.add_argument("--test_data", help = "absolutní cesta datového souboru s testovacími daty ", required=True)
parser.add_argument("--neuronova_sit", help = "absolutní cesta uloženého modulu neuronové sítě ", required=True)
args=vars(parser.parse_args())

# - načtení trénovacích dat neuronové sítě ze souboru ve formátu XLS
test_data = pd.read_excel(args["test_data"],sheet_name="ln(data)")

# - definování vstupních proměnných
vstupni_data = test_data[test_data.columns[3:]]

# - vytvoření datové matice vstupních proměnných
matice_vstupnich_dat=np.mat(vstupni_data)

# - načtení natrénované neuronové sítě ze souboru ve formátu HDF
loaded_model = load_model(args["neuronova_sit"])
loaded_model.compile(loss='mean_squared_error',optimizer=keras.optimizers.adam(lr=0.01))

# - použití funkce MinMaxScaler k namapování hodnot vstupních proměnných na interval <0,1>
prepro_x = MinMaxScaler()
prepro_x.fit(matice_vstupnich_dat)
min_max_vstupnich_promennych=prepro_x.transform(matice_vstupnich_dat)

# - predikce Neuronové sítě hodnot výstupní proměnné na základě hodnot vstupních proměnných a uložení těchto hodnot do souboru v CSV formátu
predictions = loaded_model.predict(min_max_vstupnich_promennych)
predikce=pd.DataFrame(predictions,columns=["predikce_N9"])
predikce.to_csv("C:\\Users\\korec\\PycharmProjects\\Diplomka\\Neuronova_sit_vystup\\{}_predikce.csv".format(os.path.split(args["test_data"])[-1][0:-4]),index=False)
```

zdroj: vlastní zpracování v programovacím jazyce Python

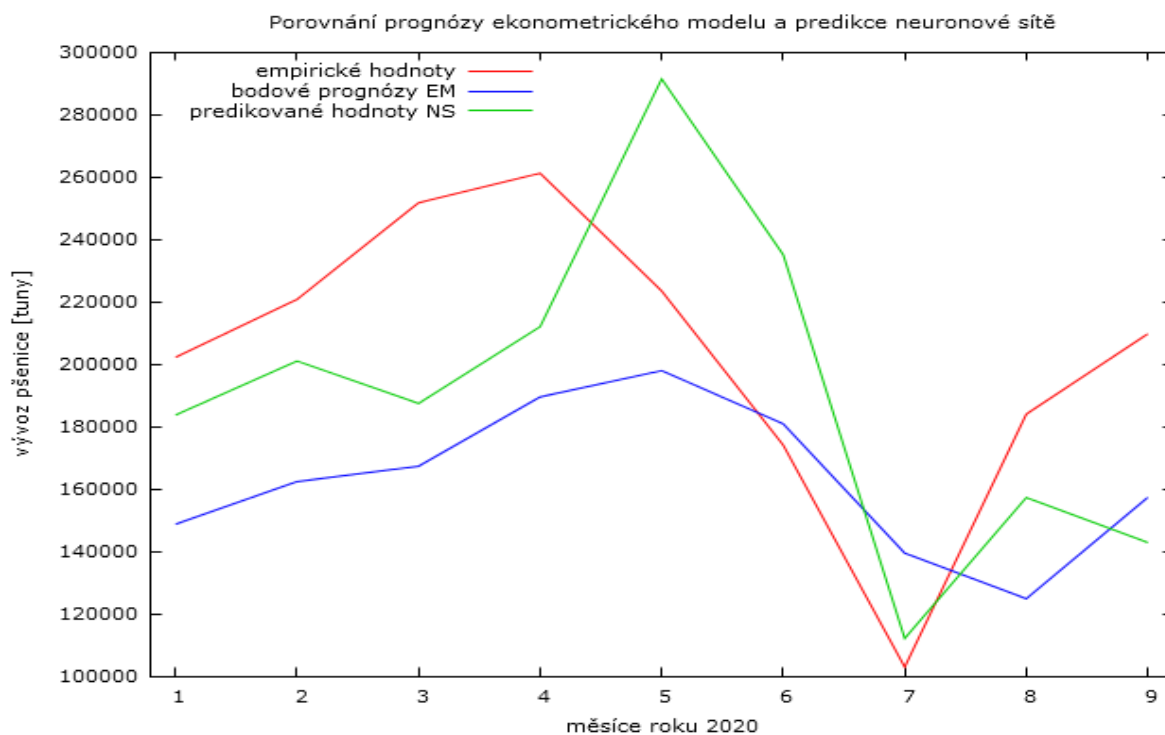
Tabulka 13: Přehled predikovaných hodnot vývozu pšenice z ČR neuronovou sítí a jejich porovnání s empirickými hodnotami této proměnné

Proměnná	Období	Predikce NS [t]	Skutečná hodnota [t]	% Shoda
Vývoz pšenice z ČR	Leden 2020	183724.5	202218.2	90.85%
	Únor 2020	201020.7	220778.7	91.05%
	Březen 2020	187449.1	251789.8	74.45%
	Duben 2020	212025.9	261248.7	81.16%
	Květen 2020	291491	223486.3	76.67%
	Červen 2020	235090.8	174065.5	74.04%
	Červenec 2020	112084.3	102897.6	91.80%
	Srpen 2020	157238.5	183999.9	85.46%
	Září 2020	142826.2	209769.7	68.09%

zdroj: Python, vlastní zpracování

Průměrná přesnost predikce neuronové sítě pro jednotlivé měsíce prvních tří čtvrtletí roku 2020 je 81,58 %. Nejvyšších přesností dosáhla predikce neuronové sítě pro měsíce únor a červenec, kdy dosáhla shoda predikované a empirické hodnoty 91,05% resp. 91,80%. Nejnižší přesnosti predikce bylo dosaženo pro měsíce březen a červen, kdy dosáhla shoda predikované a empirické hodnoty 74,45%, resp. 74,04%. Graf č. 22 vykresluje bodové prognózy lineárního ekonometrického modelu a predikce neuronové sítě v porovnání vůči empirickým hodnotám proměnné vývoz pšenice z ČR.

Graf 30: Grafické znázornění empirických hodnot vývozu pšenice z ČR, bodových prognóz lineárního ekonometrického modelu a predikcí neuronové sítě



zdroj: Gretl, vlastní zpracování

Z výše uvedeného grafu je patrné, že hodnoty predikované neuronovou sítí lépe vystihují skutečnost, což potvrzuje i tabulka č. 14, jež obsahuje hodnoty statistiky RMSE, pomocí nichž můžeme porovnat přesnost prognózy a predikce.

Tabulka 14: Porovnání statistik RMSE prognóz vygenerovaných ekonometrickým lineárním modelem a predikcí vygenerovaných neuronovou sítí pro první tři čtvrtletí roku 2020

statistika	Ekonometrický model	Neuronová síť
RMSE	54617,05	48219,07

zdroj: Gretl (ekonometrický model), Keras (neuronová síť), vlastní zpracování

5.4.2 Modelování vztahu vývozu hovězího masa z ČR a jeho determinantů pomocí NS

Architektura neuronové sítě pro modelování vztahu mezi vývozem hovězího masa z ČR a jeho determinanty, byla zvolena experimentálně a znázorňuje ji obrázek č. 24.

Obrázek 24: Architektura neuronové sítě pro modelování vztahu vývozu hovězího masa z ČR a jeho determinantů

Vrstva	Neurony	Váhy
Skrytá vrstva	18	72
Výstupní vrstva	1	19

Celkový počet vah = 91

zdroj: Keras, vlastní zpracování

Jedná se o třívrstvou neuronovou síť, jež má 18 neuronů ve skryté vrstvě a jeden neuron ve výstupní vrstvě. Neuronová síť má 4 vstupy (3 proměnné + bias) a jestliže je každý vstup spojen synapsí s každým z 18 neuronů ve skryté vrstvě, získáváme 72 vah synapsí mezi vstupní a skrytou vrstvou. Mezi skrytou vrstvou a výstupní vrstvou se nachází 19 synapsí a tedy 19 vah.

Trénování třívrstvé neuronové sítě proběhlo v 10000 epochách a trvalo 5 minut a 36 sekund. Chyba neuronové sítě byla měřena pomocí statistiky RMSE. Na obrázku č. 25 je znázorněna finální hodnota statistiky RMSE, které bylo dosaženo v závěrečné epoše učícího procesu neuronové sítě. V tabulce č. 15 jsou uvedeny statistiky RMSE mocninného ekonometrického modelu vývozu hovězího masa a neuronové sítě.

Obrázek 25: Výsledná hodnota statistiky RMSE neuronové sítě

Epocha 10000/10000
180/180 [=====] - 0s 111us/step - MSE: 0.02183 -> RMSE: 0.148

zdroj: Keras, vlastní zpracování

Tabulka 15: Porovnání kvality mocninného ekonometrického modelu vývozu hovězího masa a neuronové sítě

Statistika	Ekonometrický model	Neuronová síť
RMSE	0,165 ⁵¹	0,148


zdroj: Gretl (Ekonometrický model), Keras (Neuronová síť), vlastní zpracování

Z výše uvedené tabulky je zřejmé, že neuronová síť dokáže lépe vystihnout vztah mezi vývozem hovězího masa z ČR a jeho determinanty. Můžeme tedy konstatovat, že odchylka

⁵¹ Viz kapitola 3.2 Analýza vybraných determinantů vývozu hovězího masa z ČR

teoretických hodnot vygenerovaných neuronovou sítí od empirických hodnot závisle proměnné, je menší, než je tomu u odchylek teoretických hodnot vygenerovaných mocninným ekonometrickým modelem. Teoretické hodnoty vygenerované neuronovou sítí obsahuje příloha č. 2. a jejich průběh je znázorněn společně s teoretickými hodnotami vygenerovanými ekonometrickým modelem v grafu č. 19 níže. Neuronová síť byla spolu s naučenými váhami synapsí uložena ve formátu HDF do souboru hovezi_maso_model.h5 a je obsahem přílohy č. 4 této práce. Graf č. 22 znázorňuje průběh teoretických hodnot závisle proměnné vývoz hovězího masa z ČR vygenerované neuronovou sítí a ekonometrickým modelem v porovnání s empirickými hodnotami této proměnné.

Graf 31: Grafické znázornění průběhu empirických hodnot vývozu hovězího masa a teoretických hodnot této proměnné vygenerovaných mocninným ekonometrickým modelem a neuronovou sítí



zdroj: Gretl, vlastní zpracování

5.4.2.1 Predikce pomocí neuronové sítě

V této podkapitole byla provedena predikce vývozu hovězího masa z ČR v měsících prvních třech čtvrtletí roku 2020. Tato predikce byla porovnána s bodovými prognózami mocninného ekonometrického modelu. Predikované hodnoty pomocí neuronové sítě pro první tři čtvrtletí roku 2020 jsou obsahem přílohy č. 2. Tabulka č. 16 zobrazuje predikované hodnoty pomocí neuronové sítě pro první tři čtvrtletí roku 2020 pro proměnnou vývoz hovězího masa z ČR.

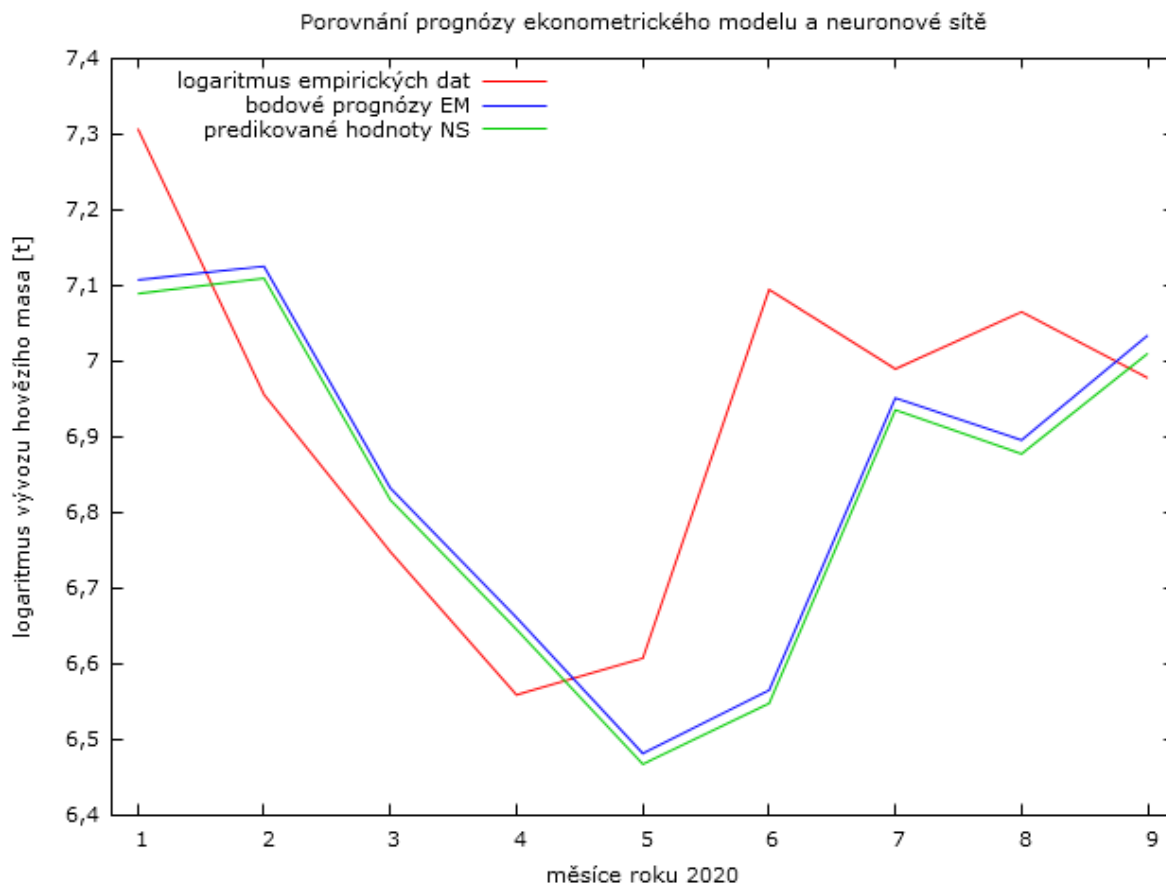
Tabulka 16: Přehled predikovaných hodnot vývozu hovězího masa z ČR neuronovou sítí a jejich porovnání s empirickými hodnotami této proměnné

Proměnná	Období	Predikce NS [t]	Skutečná hodnota [t]	% shoda
Vývoz hovězího masa z ČR	Leden 2020	1198.64	1491	80.39%
	Únor 2020	1223.33	1049	85.75%
	Březen 2020	912.50	852	93.36%
	Duben 2020	768.76	705	91.71%
	Květen 2020	643.33	740	86.94%
	Červen 2020	697.14	1205	57.85%
	Červenec 2020	1027.59	1085	94.71%
	Srpen 2020	969.65	1170	82.88%
	Září 2020	1107.51	1072	96.79%

zdroj: vlastní zpracování v programovacím jazyce Python

Průměrná přesnost predikce neuronové sítě pro jednotlivé měsíce prvních tří čtvrtletí roku 2020 je 85,60 %. Nejvyšších přesností dosáhla predikce neuronové sítě pro měsíce červenec a září, kdy shoda predikovaných a empirických hodnot činila 94.71% resp. 96.79%. Nejnižší přesnosti predikce bylo dosaženo pro měsíce leden a červen, kdy shoda predikovaných a empirických hodnot činila 80.39%, resp. 57.85%. Graf č. 24 vykresluje bodové prognózy mocninného ekonometrického modelu a predikce neuronové sítě v porovnání vůči empirickým hodnotám proměnné vývoz hovězího masa z ČR.

Graf 32: Grafické znázornění empirických hodnot vývozu hovězího masa z ČR, bodových prognóz mocninného ekonometrického modelu a predikcí neuronové sítě



zdroj: Gretl

Z výše uvedeného grafu je patrné, že hodnoty prognózované mocninným ekonometrickým modelem lépe vystihují skutečnost, což potvrzuje i tabulka č. 17, jež obsahuje hodnoty statistiky RMSE, pomocí níž můžeme porovnat přesnost prognózy a predikce.

Tabulka 17: Porovnání statistik RMSE prognóz vygenerovaných ekonometrickým lineárním modelem a predikcí vygenerovaných neuronovou sítí pro první tři čtvrtletí roku 2020

statistika	Ekonometrický model	Neuronová síť
RMSE	0.215080529	0.221572221

zdroj: Gretl (ekonometrický model), Keras (neuronová síť), vlastní zpracování

5.4.3 Modelování vztahu vývozu mléka z ČR a jeho determinantů pomocí NS

Architekturu neuronové sítě zvolenou pro modelování vztahu mezi vývozem mléka z ČR a jeho determinanty znázorňuje obrázek č. 26.

Obrázek 26: Architektura neuronové sítě pro modelování vztahu vývozu mléka z ČR a jeho determinantů

Vrstva	Neurony	Váhy
Skrytá vrstva	18	72
Výstupní vrstva	1	19

Celkový počet vah = 91

zdroj: Keras, vlastní zpracování

Jedná se o třívrstvou neuronovou síť, jež má 18 neuronů ve skryté vrstvě a jeden neuron ve výstupní vrstvě. Neuronová síť má 4 vstupy (3 proměnné + bias) a jestliže je každý vstup spojen synapsí s každým z 18 neuronů ve skryté vrstvě, získáváme 72 vah synapsí mezi vstupní a skrytou vrstvou. Mezi skrytou vrstvou a výstupní vrstvou se nachází 19 synapsí a tedy 19 vah.

Trénování třívrstvé neuronové sítě proběhlo v 10000 epochách a trvalo 9 minut a 18 sekund. Chyba neuronové sítě byla měřena pomocí statistiky RMSE. Na obrázku č. 27 je znázorněna finální hodnota statistiky RMSE, které bylo dosaženo v závěrečné epoše učícího procesu neuronové sítě. V tabulce č. 18 jsou uvedeny statistiky RMSE lineárního ekonometrického modelu vývozu mléka a neuronové sítě.

Obrázek 27: Výsledná hodnota statistiky RMSE neuronové sítě

Epoch 10000/10000
180/180 [=====] - 0s 283us/step - MSE: 13646158.30556 -> RMSE: 3694.1

zdroj: Keras, vlastní zpracování

Tabulka 18: Porovnání kvality lineárního ekonometrického modelu vývozu mléka a neuronové sítě


Statistika	Ekonometrický model	Neuronová síť
RMSE	3736.8 ⁵²	3694.1

zdroj: Gretl (Ekonometrický model), Keras (Neuronová síť), vlastní zpracování

⁵² Viz kapitola 3.2 Analýza vybraných determinantů vývozu mléka a z ČR

Z výše uvedené tabulky je zřejmé, že neuronová síť dokáže lépe vystihnout vztah mezi vývozem mléka z ČR a jeho determinanty. Můžeme tedy konstatovat, že odchylka teoretických hodnot vygenerovaných neuronovou sítí od empirických hodnot závisle proměnné, je menší, než je tomu u odchylek teoretických hodnot vygenerovaných lineárním ekonometrickým modelem. Teoretické hodnoty vygenerované neuronovou sítí obsahuje příloha č. 2. a jejich průběh je znázorněn na obrázku níže. Neuronová síť byla spolu s naučenými váhami synapsí uložena ve formátu HDF do souboru mleko_model.h5 a je obsahem přílohy č. 4 této práce. Graf č. 24 znázorňuje průběh teoretických hodnot závisle proměnné vývoz mléka z ČR vygenerované neuronovou sítí v porovnání s empirickými hodnotami této proměnné.

Graf 33: Grafické znázornění průběhu empirických hodnot vývozu mléka z ČR a teoretických hodnot této proměnné vygenerovaných neuronovou sítí



zdroj: Gretl, vlastní zpracování

5.4.4 Porovnání ekonometrických modelů a třívrstvé neuronové sítě

Ekonometrické modely jsou založeny na ekonomických teoriích, které poskytují vhled do porozumění kauzálním vztahům, které panují mezi proměnnými v nich použitých a činí tyto vztahy srozumitelnými, což má za následek generování logicky konzistentních a spolehlivých prognóz. Ekonometrické modely vytvářejí rámec pro progresivní výzkumnou strategii a generují důvody jejich vlastních selhání při řešení konkrétního problému. Naopak vícevrstvé neuronové sítě jsou obecné, bez předpokladů a lze je přizpůsobit jakékoliv funkci a tedy řešit

silně nelineární úlohy. Největší nevýhodou je nesnadná interpretace výstupů neuronové sítě a procesů, které k nim vedly. Neuronová síť je černá skříňka, jež vyžaduje vstup a generuje výstup, aniž by bylo zcela jasné, jak jsou její parametry přizpůsobeny a jak je lze vysvětlit. S ohledem na výše zmíněné a výsledky, jež byly dosaženy pomocí třívrstvé neuronové sítě, v předchozích kapitolách, lze považovat neuronovou síť za doplněk ekonometrických modelů, ne za jejich alternativu či náhradu.

6. Závěr

Tato práce se zabývala analýzou determinant zahraničního obchodu s vybranými zemědělskými komoditami, konkrétně vývozu pšenice, hovězího masa a mléka z ČR. Prostřednictvím ekonometrické analýzy byly vybrány determinanty vývozu jednotlivých komodit. V případě vývozu pšenice to byly průběh devizových intervencí ČNB, světová cena pšenice a vývoz pšenice v několika předchozích měsících. V případě vývozu hovězího masa se jednalo o vývoz hovězího masa v předchozím měsíci, vývoz živého skotu a průměrnou cenu hovězího masa na trhu EU. V případě vývozu mléka byly identifikovány determinanty vývoz mléka v předchozím měsíci, produkce mléka a průměrná cena syrového mléka na trhu EU v předchozím měsíci. Na základě podkladových údajů, tvořených měsíčními časovými řadami let z 2005 – 2019, byly pro každou komoditu prostřednictvím Běžné metody nejmenších čtverců odhadnuty parametry lineárního a mocninného ekonometrického modelu. Na základě statistické analýzy bylo rozhodnuto o tom, zda se modely významně liší v kvalitě modelování závislosti proměnných a byl vybrán vhodnější model. V případě vývozu pšenice a mléka byl vybrán lineární model a k modelování závislosti vývozu hovězího masa a jeho determinantů byl vybrán mocninný model. Podkladová data ekonometrických modelů byla tvořena nestacionárními časovými řadami a bylo tedy třeba vyloučit jev zdánlivé regrese pomocí analýzy reziduí, která vyšla ve všech případech stacionární a byla tedy potvrzena pravá regrese. Na všechny modely byla úspěšně aplikována ekonomická, statistická a ekonometrická verifikace a byly tedy shledány vhodnými pro aplikaci.

Největší vliv na vývoz analyzovaných komodit měl vývoz těchto komodit v předchozích měsících, což potvrdilo předpoklad silné role setrvačnosti v jejich vývoji. V případě vývozu pšenice byla detekována krátkodobá i dlouhodobá setrvačnost, jež může být způsobena faktem, že část produkce pšenice je nasmlouvána dopředu zahraničními obchodními partnery, kteří nakupují za účelem spekulací či mají návaznost na zpracovatelský a pekárenský průmysl. Různost znamének strukturálních parametrů jednotlivých zpoždění pak může být interpretována jako reakce na pravidelné obnovování smluv o odběru produkce pšenice či jejich uzavírání na určitou dobu, jež by mohla být u určitého procenta smluv, s ohledem na znaménka strukturálních parametrů, 4 měsíce. U vývozu hovězího masa byla detekována krátkodobá setrvačnost, kterou je možno vysvětlit tendencí prodávat chlazené maso co nejrychleji či uzavírat smlouvy o odběru produkce dlouhodobějšího charakteru z důvodu krátké údržnosti chlazeného masa a nákladovou náročností uchovávání masa v zamraženém stavu. U vývozu

mléka lze detekovanou krátkodobou setrvačností vysvětlit též pomocí konstatování, že kontrakty na dodávky mléka jsou dlouhodobějšího charakteru, jelikož producenti chtějí mít jistotu odbytu komodity, jež rychle podléhá znehodnocujícím vlivům.

Verifikované ekonometrické modely vývozu pšenice a hovězího masa byly použity k provedení prognózy ex-post na období prvních 3 čtvrtletí roku 2020 s cílem zhodnotit jejich prognostické schopnosti. Průměrná přesnost prognóz byla v případě vývozu pšenice 76,4% a v případě vývozu hovězího masa 85,63%.

V závěrečné kapitole byla sestavena třívrstvá neuronová síť v programovacím jazyce Python, pomocí které byl modelován vztah vývozu jednotlivých komodit a jejich determinantů. Neuronová síť ve všech třech případech dokázala vystihnout závislost mezi proměnnými lépe než ekonometrické modely, což lze vysvětlit tím, že neuronová síť dokáže lépe vyjádřit nelineární aspekty vztahu mezi závislou a nezávislými proměnnými. V případě vývozu pšenice a vývozu hovězího masa byla neuronová síť použita pro predikci hodnot těchto proměnných na období prvních tří čtvrtletí roku 2020 a její výsledky byly porovnány s výsledky prognóz ekonometrických modelů. U vývozu pšenice, bylo dosaženo pomocí neuronové sítě průměrné přesnosti predikce 81,58%, což byl o 5,18% lepší výsledek než v případě lineárního ekonometrického modelu. U vývozu hovězího masa bylo dosaženo průměrné přesnosti predikce 85,60%, což byl o 0,03% horší výsledek než v případě mocninného ekonometrického modelu. Lepší výsledek mocninného ekonometrického modelu, lze vysvětlit tím, že se jedná oproti zbylým ekonometrickým modelům o nelineární model, jenž dokáže vystihnout i nelineární aspekty vztahu proměnných. Jedním z dalších důvodů, je možnost určité míry přeučení neuronové sítě, kdy se neuronová síť adaptuje na nepodstatné detaily obsažené v učící množině dat. Lze říci, že technika vícevrstvé neuronové sítě dosahovala lepších či srovnatelných výsledků v porovnání s ekonometrickými modely použitými v této práci, zároveň je však tato technika černou skříňkou, jejíž výstupy a procesy k nim vedoucí je složité interpretovat a jejíž sestavování má mnohdy experimentální povahu a to jak v oblasti určení topologie či architektury, tak v oblasti učícího procesu. Z těchto důvodů lze třívrstvou neuronovou síť považovat za doplněk ekonometrických modelů, ne za jejich alternativu či náhradu.

Seznam literatury

Odborné publikace

1. Arlt, Josef a Arltová, Markéta. *Ekonomické časové řady: [vlastnosti, metody modelování, příklady a aplikace]*. 1. vyd. Praha: Grada, 2007. 285 s. ISBN 978-80-247-1319-9.
2. Beneš, Vlastislav a kol. *Zahraniční obchod*. 1. vyd. Praha: Grada Publishing, a. s. 2004. 328 s. ISBN 80-247-0558-3.
3. Čechura, Lukáš et al. *Cvičení z ekonometrie*. Vyd. 3. V Praze: Česká zemědělská univerzita, Provozně ekonomická fakulta, 2013. 90 s. ISBN 978-80-213-2405-3.
4. Fausett, Laurene. *Fundamentals of Neural Networks: Architectures, Algorithms And Applications*. Prentice-Hall, 1994. ISBN 978-0-13-334186-7.
5. Fiala, Petr. *Úvod do ekonometrie*. Vyd. 1. V Praze: České vysoké učení technické, 2008. 173 s. ISBN 978-80-01-04004-1.
6. Fojtíková, Lenka. *Zahraničně obchodní politika ČR: historie a současnost (1945-2008)*. Vyd. 1. Praha: C.H. Beck, 2009. xix, 246 s. Beckova edice ekonomie. ISBN 978-80-7400-128-4.
7. Greer, A. (2013) "The Common Agricultural Policy and the EU budget: stasis or change?", *European Journal of Government and Economics*, 2(2), pp. 119-136.
8. Hančlová, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. ISBN 978-80-7431-088-2
9. Hebák, Petr a Kahounová, Jana. *Počet pravděpodobnosti v příkladech*. 6., nezměn. vyd. Praha: Informatorium, 2010. 311 s. ISBN 978-80-7333-077-2.
10. Holman, Robert. *Ekonomie*. 6. vydání. V Praze: C.H. Beck, 2016. xxii, 696 stran. Beckovy ekonomické učebnice. ISBN 978-80-7400-278-6.
11. Kalínská, Emilie a kol. *Mezinárodní obchod v 21. století*. 1. vyd. Praha: Grada, 2010. 228 s. Expert. ISBN 978-80-247-3396-8.
12. Kozák, Josef, Arlt, Josef a Hindls, Richard. *Úvod do analýzy ekonomických časových řad: určeno pro stud. všech fakult VŠE Praha*. 1. vyd. Praha: Vysoká škola ekonomická, 1994. 208 s. ISBN 80-7079-760-6.
13. König, P. – Lacina, L. – Přenosil, J. (2006): *Učebnice evropské integrace*. Brno: Barrister a Principal. ISBN 978-80-7364-044-6.

14. Kym Anderson ,2010, *Globalization's effects on world agricultural trade, 1960–2050*Phil. Trans. R. Soc. B3653007–3021
15. Neumann, Pavel, Jiráňková, Martina a Žamborský, Pavel. *Mezinárodní ekonomie*. 1. vyd. Praha: Grada, 2010. 159 s. Expert. ISBN 978-80-247-3276-3.
16. Slováková, M. (2015), '*The Common Agricultural Policy in a Czech Context*', World Academy of Science, Engineering and Technology, Open Science Index 101, International Journal of Agricultural and Biosystems Engineering, 9(5), 1586 - 1590.
17. Smutka, Luboš et al. *Vývoj agrárního zahraničního obchodu ČR v evropském a světovém kontextu*. 1. vyd. Praha: Powerprint, 2011. 267 s. ISBN 978-80-87415-22-1.
18. Smutka, Luboš et al. *Vybrané aspekty agrárního sektoru ve světě: (vývoj produkce a obchodu s agrárními komoditami)*. Vyd. 1. V Praze: Česká zemědělská univerzita, Provozně ekonomická fakulta, 2010. 159 s. ISBN 978-80-213-2101-4.
19. Štěrbová, Ludmila a kol. *Mezinárodní obchod ve světové krizi 21. století*. 1. vyd. Praha: Grada, 2013. 364 s. Expert. ISBN 978-80-247-4694-4.
20. Suzuki, Kenji, ed. *Artificial neural networks: architectures and applications*. Rijeka: InTech, 2014. vi, 256 stran. ISBN 978-953-51-0935--8.
21. *Ročenka agrárního zahraničního obchodu ČR za rok 2018*. Praha: Ústav zemědělské ekonomiky a informací, 2019. ISBN 978-80-7271-238-0.
22. Romano, Donato, 2006. "*Agriculture in the Age of Globalization*" 2006 Annual Meeting, August 12-18, 2006, Queensland, Australia 25253, International Association of Agricultural Economists.
23. Volná, Eva. *Neuronové sítě a genetické algoritmy*. Vyd. 1. Ostrava: Ostravská univerzita, Přírodovědecká fakulta, 1998. 141 s. Učební texty Ostravské univerzity. Přírodovědecká fakulta. ISBN 80-7042-762-0.
24. Vondrák, Ivo. *Umělá inteligence a neuronové sítě*. 3. vyd. Ostrava: VŠB - Technická univerzita Ostrava, 2009. 139 s. ISBN 978-80-248-1981-5.

Internetové zdroje

1. *Agriculture and international trade: law, policy, and the WTO* [online]. Wallingford: CABI Publishing, ©2003 [cit. 2020-06-16]. Dostupné z WWW: <http://site.ebrary.com/lib/natl/Doc?id=10173520>

2. Český statistický úřad [online].2019 [cit. 19-06-2020]. Dostupné z WWW: <<https://www.czso.cz/csu/czso/vstup-do-eu-pomohl-ceskemu-zahranicnimu-obchodu>>
3. *Financování společné zemědělské politiky* [online].2020[cit. 13-06-2020]. Dostupné z WWW: <https://www.europarl.europa.eu/ftu/pdf/cs/FTU_3.2.2.pdf>
4. *Food and Agriculture Organization of the United Nations* [online].2019 [cit. 18-06-2020]. Dostupné z WWW: <<http://www.fao.org/economic/ess/ess-economic/gdpagriculture/ro/>>
5. Holčík, Jiří, Komenda, Martin (eds.) a kol. *Matematická biologie: e-learningová učebnice* [online].1. vydání. Brno: Masarykova univerzita, 2015. ISBN 978-80-210-8095-9. Dostupné z WWW: < <https://portal.matematickabiologie.cz/> >
6. Ministerstvo Financí [online].2015 [cit. 15-06-2020]. Dostupné z WWW: <<https://www.mfcr.cz/cs/zahranicni-sektor/hospodareni-eu/prostredky-alokovane-pro-cr/programove-obdobi-2014-2020>>
7. TriloByte [online].2013 [cit. 2021-09-03]. Dostupné z: WWW: <https://www.trilobyte.cz/downloadfree/qcemanual/neural_net.pdf>
8. Palán, J. (2007): *Reforma společné zemědělské politiky*. Praha: Parlamentní institut. Dostupné z WWW: <<http://www.psp.cz/cgi-bin/win/kps/pi/prace/pi-5-273.pdf>>.
9. Patria.cz [online].2018 [cit. 29-01-2021]. Dostupné z WWW: < <https://www.patria.cz/zpravodajstvi/3796920/pred-rokem-skoncily-devizove-intervence-cnb-trvaly-41-mesicu.html>>
10. *The Common Agricultural Policy in figures* [online].2020 [cit. 15-06-2020]. Dostupné z WWW: <https://www.europarl.europa.eu/ftu/pdf/en/FTU_3.2.10.pdf>
11. United Nations [online].2019 [cit. 18-06-2020]. Dostupné z WWW: <<https://population.un.org/wpp/Graphs/Probabilistic/POP/900>>
12. Volejníková, Jolana. *Dynamika zahraničního obchodu České republiky a EU* [online]. 2009 [cit. 2020-05-10]. Dostupné z WWW: <<https://dk.upce.cz/handle/10195/32248>>
13. Vošta, M., *Společná zemědělská politika EU a její aplikace v České republice*. 2010. s. 129 - 130. [on-line]. [cit. 22. 3. 2013]. Dostupné z WWW: <<http://ces.vse.cz/wp-content/vosta.pdf>>
14. *Výsledky agrárního zahraničního obchodu ČR v roce 2019* [online].2020[cit. 06-06-2020]. Dostupné z WWW: <<http://eagri.cz/public/web/mze/ministerstvo-zemedelstvi/zahranicni-vztahy/agrarni-zahranicni-obchod/vysledky-agrarniho-zahranicniho-obchodu-19.html>>

15. Zemedelec.cz [online].2019 [cit. 22-02-2021]. Dostupné z WWW: <
<https://www.zemedelec.cz/ceska-republika-vyvazi-ve-srovnani-s-evropskym-prumerem-prilis-mnoho-mleka/>>

Přílohy

Příloha č.1 (Data zahraničního obchodu)

Vývoj vývozu 10 nejvíce vyvážených agrárních položek z ČR v roce 2014 až 2019

Období	CIGARETY		PŘÍPRAVKY K VÝŽIVĚ ZVÍŘAT		PEKAŘSKÉ ZBOŽÍ		POTRAVIN. PŘÍPRAVKY		MLÉKO A SMETANA		PŠENICE		PIVO		ČOKOLÁDA A KAKAOVÉ PŘÍPRAVKY		ŘEPKOVÝ OLEJ		KÁVA	
	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun
1/2014	2 201	4,6	1 791	77,8	1 675	27,7	1 583	14,5	2 212	181,2	3 301	637,9	1 112	73,0	1 385	13,6	2 362	112,2	825	6,7
2/2014	3 277	7,2	1 829	81,6	1 707	28,3	1 572	15,2	2 222	196,3	2 454	468,7	1 628	112,0	1 236	11,5	1 981	94,4	947	7,0
3/2014	3 284	7,3	1 968	92,4	1 865	29,3	1 572	14,2	2 132	198,7	2 786	585,9	1 496	106,8	1 687	13,7	1 806	89,9	1 296	8,1
4/2014	3 115	6,8	2 030	92,3	1 956	29,3	1 738	15,1	2 021	192,2	2 944	657,7	1 312	90,2	2 170	16,9	2 125	109,6	1 673	10,3
Celkem	11 877	26,0	7 619	344,1	7 203	114,7	6 466	59,0	8 587	768,4	11 484	2 350,3	5 548	382,0	6 478	55,7	8 274	406,0	4 741	32,1
1/2015	3 776	6,4	2 071	99,6	1 889	29,9	1 904	16,6	2 022	206,4	3 484	731,5	1 281	89,4	1 825	14,6	2 104	110,4	1 887	11,3
2/2015	4 118	7,0	1 913	99,7	1 898	30,6	1 795	16,9	1 984	213,9	2 930	633,4	1 780	125,5	1 513	12,6	2 685	142,0	2 149	13,2
3/2015	4 348	7,6	2 000	96,7	2 044	32,8	1 669	13,3	1 956	228,3	2 746	579,2	1 677	120,6	1 936	15,6	2 436	121,8	3 032	16,5
4/2015	4 231	8,8	2 175	104,4	2 177	35,3	1 866	13,8	1 852	205,6	2 470	526,8	1 366	96,7	3 011	20,6	3 064	151,1	4 054	18,7
Celkem	16 473	29,8	8 160	400,4	8 008	128,6	7 234	60,6	7 814	854,2	11 630	2 470,9	6 104	432,2	8 285	63,4	10 290	525,3	11 122	59,7
1/2016	5 453	10,3	2 199	104,0	2 151	37,4	1 787	13,3	1 713	198,2	2 474	582,9	1 323	93,0	2 389	16,7	2 904	142,1	2 967	15,3
2/2016	5 917	10,3	2 121	104,8	2 456	43,7	1 775	13,8	1 562	204,1	3 262	822,4	1 864	133,8	1 811	14,5	3 013	145,4	1 521	9,0
3/2016	4 537	7,6	2 230	107,3	2 483	43,0	1 788	13,6	1 658	221,3	2 656	679,4	1 661	121,6	1 967	14,9	2 520	120,5	1 528	8,5
4/2016	4 062	8,2	2 454	118,4	2 543	43,5	1 939	14,8	1 858	198,5	3 197	789,5	1 398	99,7	2 443	17,6	2 690	117,9	1 042	5,7
Celkem	19 969	36,4	9 003	434,6	9 634	167,5	7 288	55,6	6 791	822,1	11 589	2 874,2	6 246	448,0	8 610	63,6	11 127	525,9	7 058	38,4
1/2017	3 956	8,0	2 646	120,7	2 474	43,9	1 917	16,3	1 940	200,4	3 854	925,6	1 342	98,1	1 824	14,0	1 890	80,6	971	5,2
2/2017	6 219	11,1	2 582	114,2	2 387	43,5	1 928	16,4	2 099	217,5	2 828	660,5	1 795	136,7	1 261	11,1	2 024	91,0	989	5,5
3/2017	5 571	10,4	2 602	126,4	2 253	41,9	1 964	16,5	2 237	220,3	2 110	496,3	1 579	122,7	1 448	13,3	1 630	77,0	943	5,3
4/2017	4 709	9,4	2 707	130,0	2 431	43,7	2 160	16,5	2 211	206,8	1 937	458,3	1 433	107,6	1 905	17,0	1 329	65,2	974	6,0
Celkem	20 454	39,0	10 537	491,2	9 545	173,0	7 969	65,7	8 487	845,0	10 729	2 540,7	6 149	465,0	6 438	55,4	6 872	313,9	3 877	22,0
1/2018	2 678	6,8	2 927	127,5	2 341	43,1	2 059	17,0	2 173	216,5	2 080	496,1	1 341	103,6	1 619	14,0	1 083	57,0	941	6,2
2/2018	4 565	9,0	2 823	126,7	2 449	45,4	2 154	17,3	2 255	241,9	1 896	445,3	2 025	157,4	1 049	10,6	1 264	69,0	814	5,3
3/2018	4 625	9,4	2 817	128,4	2 500	45,4	2 111	16,2	2 116	223,9	2 262	499,4	1 846	145,7	1 488	13,3	1 199	63,2	887	6,2
4/2018	3 988	7,4	3 050	132,9	2 655	45,5	2 263	16,1	2 285	219,8	2 161	444,0	1 516	114,7	1 985	16,7	1 489	76,4	958	6,6
Celkem	15 856	32,7	11 617	515,5	9 945	179,3	8 587	66,6	8 829	902,2	8 399	1 885,0	6 728	521,4	6 141	54,6	5 035	265,7	3 600	24,4
1/2019	3 347	6,4	3 099	133,2	2 726	49,0	2 350	17,5	2 156	204,1	2 096	411,8	1 566	116,5	1 706	14,2	1 240	64,4	1 019	7,5
2/2019	4 310	8,1	3 042	126,7	2 696	48,4	2 399	21,3	2 103	214,5	2 108	427,3	2 159	156,8	1 170	10,6	1 440	75,2	1 017	6,7
3/2019	5 457	9,5	3 085	124,9	2 540	46,5	2 444	18,2	2 225	240,6	2 017	431,9	1 941	141,8	1 645	13,8	1 326	64,8	1 005	6,1
4/2019	4 928	8,8	3 269	129,9	2 737	48,6	2 671	20,5	2 088	216,4	2 069	470,6	1 688	118,0	2 089	17,3	1 538	74,5	741	5,0
Celkem	18 042	32,9	12 495	514,7	10 699	192,5	9 863	77,5	8 573	875,6	8 291	1 741,5	7 354	533,1	6 610	56,0	5 545	278,9	3 782	25,4

Pozn.: Komodity (na základě 4-místného kódu HS) jsou vybrány na základě hodnoty vývozu v mil. Kč za období 2014 až 2019 a řazeny podle roku 2019. Upřesnění názvů: HS 2402 cigarety vč. doutníků a doutniček, HS 1514 řepkový olej vč. hořčičného, HS 1905 pekařské zboží vč. sušenek a oplatek, HS 2106 potravinové přípravky jiné a HS 0401 mléko a smetana pouze nezahuštěné.

zdroj: Databáze zahraničního obchodu ČSÚ

Vývoj dovozu 10 nejvíce dovážených agrárních položek do ČR v roce 2014 až 2019

Období	VEPŘOVÉ MASO		PEKAŘSKÉ ZBOŽÍ		SÝRY A TVAROH		POTRAVIN. PŘÍPRAVKY		CIGARETY		ČOKOLÁDA A KAKAOVÉ PŘÍPRAVKY		PŘÍPRAVKY K VÝŽIVĚ ZVÍŘAT		KÁVA		DRŮBEŽÍ MASO A DROBY		VÍNO	
	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun	mil. Kč	tis. tun
1/2014	3 287	56,4	1 842	35,6	1 980	20,8	1 684	16,5	274	0,7	1 966	20,1	1 480	55,6	1 043	11,3	1 169	23,6	976	36,4
2/2014	3 444	58,9	1 994	35,5	2 051	22,6	1 719	18,7	603	1,6	1 655	17,1	1 416	52,6	1 264	11,8	1 165	21,9	912	32,3
3/2014	3 845	63,0	2 043	35,8	2 058	22,8	1 718	18,3	1 046	2,8	1 968	18,1	1 554	60,2	1 626	13,1	1 325	23,0	959	38,2
4/2014	3 590	64,8	2 165	38,1	1 952	22,3	1 730	18,8	1 096	3,2	2 312	22,8	1 626	61,6	2 053	15,1	1 709	30,9	1 176	34,8
Celkem	14 165	243,1	8 045	144,9	8 041	88,6	6 852	72,4	3 019	8,3	7 901	78,0	6 077	230,1	5 985	51,2	5 367	99,4	4 023	141,6
1/2015	3 360	62,5	1 903	33,6	1 770	21,4	1 733	16,5	1 020	3,0	2 223	20,0	1 590	61,0	2 207	17,1	1 546	28,5	988	38,3
2/2015	3 374	61,8	2 075	38,0	1 792	21,2	1 717	18,4	1 482	4,4	1 845	17,7	1 598	57,6	2 545	18,4	1 593	28,0	1 079	38,2
3/2015	3 329	63,3	2 079	38,7	1 902	23,8	1 719	18,4	1 447	4,1	2 301	20,4	1 537	58,6	3 350	21,3	1 525	27,5	960	36,6
4/2015	3 510	69,5	2 209	39,2	1 928	23,5	1 740	18,6	1 487	4,9	3 193	24,7	1 802	67,1	4 526	25,3	1 576	31,1	1 167	33,8
Celkem	13 573	257,1	8 266	149,4	7 391	90,0	6 909	71,9	5 436	16,5	9 562	82,9	6 526	244,3	12 627	82,0	6 240	115,0	4 193	146,9
1/2016	3 056	62,2	1 985	36,1	1 806	23,7	1 744	16,6	2 019	6,5	2 904	22,3	1 661	61,4	3 225	20,7	1 467	30,0	951	37,8
2/2016	3 304	63,5	2 112	37,9	1 836	24,8	1 815	20,0	2 000	6,4	2 122	18,6	1 657	60,4	1 933	14,9	1 374	29,5	1 009	33,3
3/2016	3 703	63,6	2 178	39,2	1 979	25,4	1 757	18,3	2 103	6,0	2 410	21,5	1 572	57,2	1 927	14,6	1 354	27,8	1 037	37,7
4/2016	4 016	70,6	2 315	44,0	2 126	23,3	1 850	18,4	1 462	4,0	2 807	25,7	1 728	62,1	1 560	11,9	1 540	31,2	1 281	37,1
Celkem	14 081	260,0	8 590	157,2	7 747	97,1	7 167	73,3	7 583	23,0	10 243	88,1	6 617	241,1	8 644	62,1	5 735	118,5	4 278	145,9
1/2017	3 512	63,2	2 160	43,8	2 004	22,7	1 798	19,8	2 050	5,1	2 409	21,4	1 857	62,6	1 366	10,5	1 242	26,2	1 105	38,9
2/2017	4 087	64,3	2 197	42,2	2 139	24,0	1 967	21,2	2 445	7,2	1 698	17,6	1 846	62,1	1 407	10,6	1 345	26,7	1 124	36,1
3/2017	4 026	65,9	2 184	45,0	2 281	25,1	1 991	24,7	2 597	8,1	2 024	19,4	1 795	58,9	1 529	11,5	1 285	25,2	1 199	41,1
4/2017	3 782	70,0	2 333	54,1	2 185	24,0	1 991	24,9	1 676	4,8	2 335	23,5	1 952	69,2	1 643	12,9	1 637	30,9	1 339	37,4
Celkem	15 407	263,4	8 874	185,1	8 609	95,7	7 746	90,7	8 767	25,4	8 466	81,9	7 450	252,8	5 945	45,5	5 509	109,1	4 766	153,4
1/2018	3 384	69,5	2 176	50,1	1 974	23,2	1 903	25,4	1 663	4,2	2 105	20,9	1 904	66,8	1 267	10,8	1 522	29,5	1 150	35,3
2/2018	3 538	66,6	2 191	62,3	2 120	24,2	2 063	25,1	2 130	5,4	1 528	17,5	1 859	63,1	1 281	12,0	1 468	27,2	1 378	38,6
3/2018	3 670	69,1	2 267	53,4	2 224	24,6	2 050	23,7	2 352	6,4	2 091	20,6	2 017	99,4	1 388	12,6	1 509	26,7	1 168	32,5
4/2018	3 755	73,3	2 595	69,5	2 250	24,4	2 118	32,5	2 125	6,0	2 432	23,8	2 180	101,6	1 663	26,4	1 695	31,4	1 505	39,5
Celkem	14 346	278,4	9 229	235,2	8 568	96,5	8 134	106,7	8 270	21,9	8 156	82,7	7 961	330,9	5 599	61,8	6 194	114,8	5 201	145,9
1/2019	3 378	68,2	2 357	45,3	2 235	24,5	2 298	32,8	2 172	5,7	2 291	22,9	2 171	87,5	1 528	14,4	1 341	27,8	1 149	31,5
2/2019	4 246	66,5	2 519	46,3	2 405	26,3	2 278	26,9	2 260	5,9	1 764	18,7	2 088	76,0	1 610	14,0	1 292	25,0	1 366	38,6
3/2019	4 307	67,0	2 647	48,0	2 393	26,5	2 385	36,1	2 408	7,4	2 250	20,9	2 115	60,3	1 417	11,9	1 351	26,1	1 256	35,1
4/2019	4 746	68,1	2 865	56,7	2 460	26,7	2 491	25,5	2 198	6,1	2 483	24,3	2 290	69,9	1 451	12,6	1 594	30,9	1 500	39,1
Celkem	16 677	269,7	10 387	196,3	9 493	104,1	9 451	121,3	9 038	25,1	8 788	86,8	8 664	293,6	6 006	53,0	5 578	109,7	5 272	144,3

Pozn.: Komodity (na základě 4-místného kódu HS) jsou vybrány na základě hodnoty vývozu v mil. Kč za období 2014 až 2019 a řazeny podle roku 2019. Upřesnění názvů: HS 1905 pekařské zboží vč. sušenek a oplatek, HS 2402 cigarety vč. doutníků a doutniček a HS 2106 potravinové přípravy jiné.

zdroj: Databáze zahraničního obchodu ČSÚ

Příloha č.2 (Podkladová data)

Soubor: datová_příloha.xls

zdroj: ČSÚ, Eurostat, vlastní zpracování

Příloha č.3 (Ekonometrická verifikace modelů – výstupy Gretl)

Ekonometrická verifikace ekonometrického modelu vývozu pšenice

Model 4: OLS, za použití pozorování 2006:01-2019:12 (T = 168)

Závisle proměnná: vyvoz_psenice

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-11394,5	15274,7	-0,7460	0,4568	
intervence	30106,1	8323,02	3,617	0,0004	***
sv_cena_psenice_~	133,698	44,9679	2,973	0,0034	***
vyvoz_psenice_t_1	0,567287	0,0594499	9,542	2,41e-017	***
vyvoz_psenice_t_4	-0,200609	0,0734974	-2,729	0,0071	***
vyvoz_psenice_t_5	0,324539	0,0695876	4,664	6,54e-06	***
vyvoz_psenice_t_8	-0,300384	0,0697168	-4,309	2,87e-05	***
vyvoz_psenice_t_9	0,158475	0,0743384	2,132	0,0346	**
vyvoz_psenice~_12	0,260957	0,0533289	4,893	2,41e-06	***

Střední hodnota závisle proměnné 144338,9

Sm. odchylka závisle proměnné 67995,87

Součet čtverců reziduí 1,82e+11

Sm. chyba regrese 33822,57

Koeficient determinace 0,764425

Adjustovaný koeficient determinace 0,752572

F(8, 159) 64,49310

P-hodnota (F) 4,95e-46

Logaritmus věrohodnosti -1985,809

Akaikovo kritérium 3989,618

Schwarzovo kritérium 4017,734

Hannan-Quinnovo kritérium 4001,029

rho (koeficient autokorelace) 0,087979

Durbin-Watsonova statistika 1,818061

zde je poznámka o zkratkách statistik modelu

LM test pro autokorelaci až do řádu 12 -

Nulová hypotéza: žádná autokorelace

Testovací statistika: LMF = 1,57038

s p-hodnotou = $P(F(12, 147) > 1,57038) = 0,106221$

Test normality reziduí -

Nulová hypotéza: chyby jsou normálně rozdělené

Testovací statistika: Chi-kvadrát(2) = 2,51825

s p-hodnotou = 0,283902

Breusch-Paganův test heteroskedasticity -

Nulová hypotéza: není zde heteroskedasticita

Testovací statistika: LM = 12,4964

s p-hodnotou = $P(\text{Chi-kvadrát}(8) > 12,4964) = 0,130394$

Test RESET pro specifikaci -

Nulová hypotéza: specifikace je adekvátní

Testovací statistika: F(2, 157) = 0,0680506

s p-hodnotou = $P(F(2, 157) > 0,0680506) = 0,934241$

zdroj: Gretl, vlastní zpracování

Ekonometrická verifikace ekonometrické modelu vývozu hovězího masa

Model 3: OLS, za použití pozorování 2005:01-2019:12 (T = 180)

Závisle proměnná: ln_vyvoz_hm

HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-2,88446	0,854620	-3,375	0,0009	***
ln_vyvoz_hm_t_1	0,788192	0,0384465	20,50	1,65e-048	***
ln_vyvoz_zs	0,186011	0,0695202	2,676	0,0082	***
ln_hm_cena_EU	0,415683	0,182803	2,274	0,0242	**

Střední hodnota závisle proměnné	6,330998
Sm. odchylka závisle proměnné	0,556275
Součet čtverců reziduí	4,813329
Sm. chyba regrese	0,165374
Koeficient determinace	0,913101
Adjustovaný koeficient determinace	0,911620
F(3, 176)	637,9912
P-hodnota(F)	2,76e-94
Logaritmus věrohodnosti	70,53218
Akaikovo kritérium	-133,0644
Schwarzovo kritérium	-120,2925
Hannan-Quinnovo kritérium	-127,8859
rho (koeficient autokorelace)	-0,061179
Durbin-Watsonova statistika	2,074408

zde je poznámka o zkratkách statistik modelu

LM test pro autokorelaci až do řádu 12 -

Nulová hypotéza: Žádná autokorelace

Testovací statistika: LMF = 0,870312

s p-hodnotou = $P(F(12, 164) > 0,870312) = 0,578323$

Test normality reziduí -

Nulová hypotéza: chyby jsou normálně rozdělené

Testovací statistika: Chi-kvadrát(2) = 20,1974

s p-hodnotou = 4,11326e-005

Breusch-Paganův test heteroskedasticity -

Nulová hypotéza: není zde heteroskedasticita

Testovací statistika: LM = 36,0308

s p-hodnotou = $P(\text{Chi-kvadrát}(3) > 36,0308) = 7,37699e-008$

Test RESET pro specifikaci -

Nulová hypotéza: specifikace je adekvátní

Testovací statistika: F(2, 174) = 2,86112

s p-hodnotou = $P(F(2, 174) > 2,86112) = 0,0599001$

zdroj: Gretl, vlastní zpracování

Ekonometrická verifikace ekonometrického modelu vývozu mléka

Model 4: OLS, za použití pozorování 2005:01-2019:12 (T = 180)

Závisle proměnná: vyvoz_mleka

HAC standardní chyby, šířka okénka 4 (Bartlettovo jádro)

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	-15258,1	2757,42	-5,533	1,12e-07	***
vyvoz_mleka_t_1	0,810604	0,0460084	17,62	1,05e-040	***
produkce_mleka	0,0913192	0,0166115	5,497	1,34e-07	***
ceny_mleka_EU_t_1	228,860	59,6713	3,835	0,0002	***

Střední hodnota závisle proměnné 58204,29

Sm. odchylka závisle proměnné 12867,12

Součet čtverců reziduí 2,46e+09

Sm. chyba regrese 3736,776

Koeficient determinace 0,917074

Adjustovaný koeficient determinace 0,915660

F(3, 176) 545,1096

P-hodnota (F) 8,05e-89

Logaritmus věrohodnosti -1734,062

Akaikovo kritérium 3476,125

Schwarzovo kritérium 3488,897

Hannan-Quinnovo kritérium 3481,303

rho (koeficient autokorelace) -0,168620

Durbin-Watsonova statistika 2,329859

zde je poznámka o zkratkách statistik modelu

LM test pro autokorelaci až do řádu 12 -

Nulová hypotéza: žádná autokorelace

Testovací statistika: LMF = 2,74731

s p-hodnotou = $P(F(12, 164) > 2,74731) = 0,00201473$

Test normality reziduí -

Nulová hypotéza: chyby jsou normálně rozdělené

Testovací statistika: Chi-kvadrát(2) = 1,85141

s p-hodnotou = 0,396252

Whiteův test heteroskedasticity -

Nulová hypotéza: není zde heteroskedasticita

Testovací statistika: LM = 19,7534

s p-hodnotou = $P(\text{Chi-kvadrát}(9) > 19,7534) = 0,0194968$

zdroj: Gretl, vlastní zpracování

Příloha č.4 (Neuronová síť – program, serializovaná NS, predikční modul NS)

soubory: NS.py

predikcni_modul_NS.py

psenice_model.h5

hovezi_maso_model.h5

mleko_model.h5

Seznam obrázků

Obrázek 1: Vývoj bilance českého AZO za vybrané agregace	51
Obrázek 2: Neuron	22
Obrázek 3: Funkce ReLU.....	23
Obrázek 4: Neuronová síť s plně propojenými vrstvami	24
Obrázek 5: Predikční oblasti Neuronové sítě – příklad pro 1-rozměrnou nezávislou proměnnou a 1-rozměrný výstup y.....	26
Obrázek 6: Syndrom přeučení.....	27
Obrázek 7: Výchozí lineární ekonometrický model vývozu pšenice (vlevo)	57
Obrázek 8: Finální lineární ekonometrický model vývozu pšenice (vpravo)	57
Obrázek 9: Mocninný model vývozu pšenice	58
Obrázek 10: Testování multikolinearity – podkladová data lineárního ekonometrického modelu vývozu pšenice	61
Obrázek 11: Výchozí lineární model vývozu hovězího masa (vlevo)	69
Obrázek 12: Finální lineární model vývozu hovězího masa (vpravo)	69
Obrázek 13: Mocninný model vývozu hovězího masa	70
Obrázek 14: Testování multikolinearity – podkladová data mocninného ekonometrického modelu vývozu hovězího masa	73
Obrázek 15: Obrázek 14: Výchozí lineární model vývozu mléka (vlevo).....	81
Obrázek 16: Obrázek 15: Finální lineární model vývozu mléka (vpravo).....	81
Obrázek 17: Mocninný model vývozu mléka	82
Obrázek 18: Testování multikolinearity – podkladová data lineárního ekonometrického modelu vývozu mléka	85
Obrázek 19: Program neuronové sítě (1. část)	87

Obrázek 20: Program neuronové sítě (2. část)	88
Obrázek 21: Architektura neuronové sítě pro modelování vztahu vývozu pšenice z ČR a jeho determinantů.....	89
Obrázek 22: Výsledná hodnota statistiky RMSE neuronové sítě	89
Obrázek 23: Kód predikčního modulu neuronové sítě.....	91
Obrázek 24: Architektura neuronové sítě pro modelování vztahu vývozu hovězího masa z ČR a jeho determinantů	94
Obrázek 25: Výsledná hodnota statistiky RMSE neuronové sítě	94
Obrázek 26: Architektura neuronové sítě pro modelování vztahu vývozu mléka z ČR a jeho determinantů.....	98
Obrázek 27: Výsledná hodnota statistiky RMSE neuronové sítě	98

Seznam tabulek

Tabulka 1: Součty čtverců reziduí při použití proměnné y^* - lineární a mocninný model vývozu pšenice	59
Tabulka 2: Deklarace proměnných ekonometrického modelu vývozu pšenice z ČR.....	59
Tabulka 3: Koeficienty pružnosti pro lineární ekonometrický model	63
Tabulka 4: Bodová prognóza ex post vývozu pšenice z ČR pro první 3 čtvrtletí roku 2020 ..	64
Tabulka 5: Součty čtverců reziduí při použití proměnné y^* - lineární a mocninný model vývozu hovězího masa z ČR	71
Tabulka 6: Deklarace proměnných ekonometrického modelu vývozu hovězího masa z ČR..	71
Tabulka 7: Koeficienty pružnosti pro mocninný ekonometrický model.....	75
Tabulka 8: Bodová prognóza ex post vývozu hovězího masa z ČR pro první 3 čtvrtletí roku 2020.....	76
Tabulka 9: Součty čtverců reziduí při použití proměnné y^* - lineární a mocninný model vývozu mléka z ČR	83
Tabulka 10: Deklarace proměnných ekonometrického modelu vývozu mléka	83
Tabulka 11: Koeficienty pružnosti pro lineární ekonometrický model	86
Tabulka 12: Porovnání kvality lineárního ekonometrického modelu vývozu pšenice a naučené neuronové sítě	90
Tabulka 13: Přehled predikovaných hodnot vývozu pšenice z ČR neuronovou sítí a jejich porovnání s empirickými hodnotami této proměnné.....	92

Tabulka 14: Porovnání statistik RMSE prognóz vygenerovaných ekonometrickým lineárním modelem a predikcí vygenerovaných neuronovou sítí pro první tři čtvrtletí roku 2020.....	93
Tabulka 15: Porovnání kvality mocninného ekonometrického modelu vývozu hovězího masa a neuronové sítě.....	94
Tabulka 16: Přehled predikovaných hodnot vývozu hovězího masa z ČR neuronovou sítí a jejich porovnání s empirickými hodnotami této proměnné.....	96
Tabulka 17: Porovnání statistik RMSE prognóz vygenerovaných ekonometrickým lineárním modelem a predikcí vygenerovaných neuronovou sítí pro první tři čtvrtletí roku 2020.....	97
Tabulka 18: Porovnání kvality lineárního ekonometrického modelu vývozu mléka a neuronové sítě	98

Seznam grafů

Graf 1: Časová řada vývozu pšenice z ČR.....	56
Graf 2: Časová řada světové ceny pšenice	56
Graf 3: Grafické znázornění empirických a teoretických hodnot lineárního ekonometrického modelu vývozu pšenice (vlevo).....	58
Graf 4: Grafické znázornění empirických a teoretických hodnot mocninného ekonometrického modelu vývozu pšenice (vpravo)	58
Graf 5: Vývoj reziduí lineárního ekonometrického modelu vývozu pšenice z ČR v čase.....	62
Graf 6: Bodová prognóza ex-post pro proměnnou vývoz pšenice z ČR v prvních 3 čtvrtletích roku 2020.....	65
Graf 7: Časová řada vývozu hovězího masa z ČR.....	67
Graf 8: Časová řada vývozu živého skotu z ČR.....	67
Graf 9: Časová řada průměrné ceny hovězího masa na trhu EU	68
Graf 10: Grafické znázornění empirických a teoretických hodnot lineárního ekonometrického modelu vývozu hovězího masa (vlevo).....	70
Graf 11: Grafické znázornění empirických a teoretických hodnot mocninného ekonometrického modelu vývozu hovězího masa (vpravo).....	70
Graf 12: Vývoj reziduí mocninného ekonometrického modelu vývozu hovězího z ČR v čase	73
Graf 13: Bodová prognóza ex-post pro proměnnou vývoz hovězího masa z ČR v prvních 3 čtvrtletích roku 2020	76
Graf 14: Časová řada vývozu mléka z ČR.....	79

Graf 15: Časová řada produkce mléka v ČR.....	79
Graf 16: Časová řada průměrné ceny syrového mléka na trhu EU	80
Graf 17: Grafické znázornění empirických a teoretických hodnot lineárního ekonometrického modelu vývozu mléka (vlevo).....	82
Graf 18: Grafické znázornění empirických a teoretických hodnot mocinného ekonometrického modelu vývozu mléka (vpravo).....	82
Graf 19: Vývoj reziduí lineárního ekonometrického modelu vývozu mléka z ČR v čase.....	85
Graf 20: Grafické znázornění průběhu empirických hodnot vývozu pšenice z ČR a teoretických hodnot této proměnné vygenerovaných neuronovou sítí.....	90
Graf 21: Grafické znázornění empirických hodnot vývozu pšenice z ČR, bodových prognóz lineárního ekonometrického modelu a predikcí neuronové sítě.....	93
Graf 22: Grafické znázornění průběhu empirických hodnot vývozu hovězího masa a teoretických hodnot této proměnné vygenerovaných mocinným ekonometrickým modelem a neuronovou sítí.....	95
Graf 23: Grafické znázornění empirických hodnot vývozu hovězího masa z ČR, bodových prognóz mocinného ekonometrického modelu a predikcí neuronové sítě.....	97
Graf 24: Grafické znázornění průběhu empirických hodnot vývozu mléka a teoretických hodnot této proměnné vygenerovaných neuronovou sítí	99